

CONSTRUÇÃO DE DETECTOR DE ESTÍMULO COM NEURÔNIO PULSANTE VIA EVOLUÇÃO DIFERENCIAL

Gustavo M. Zeferino, Rogério M. Gomes, Henrique E. Borges, Gabriela E. Soares

Centro Federal de Educação Tecnológica de Minas Gerais

{zeferino, rogerio, henrique, gabriela}@lsi.cefetmg.br

Resumo – A neurociência computacional busca compreender as funções e mecanismos do sistema nervoso por meio da construção de modelos matemáticos realistas de redes de neurônios e da realização de simulações computacionais em larga escala. Entretanto, a criação desses mecanismos ainda são uma realidade distante e, dessa forma, as pesquisas atuais tem procurado reproduzir, de uma maneira geral, tarefas mais simples, porém complexas, do sistema nervoso. Para tanto, o modelo de neurônio pulsante de Izhikevich foi escolhido por apresentar excelente desempenho computacional, além de preservar muitas das características biológicas desejáveis. Sendo assim, este artigo propõe a construção de detectores baseados no modelo de neurônio pulsante proposto Izhikevich, que sejam capazes de detectar estímulos externos, isto é, pulsar quando são estimulados por pulsos de correntes provenientes do meio externo. Para isso, foi realizado um conjunto de simulações envolvendo a sintonia dos parâmetros do modelo de neurônio pulsante de Izhikevich, bem como a sintonia da magnitude da corrente de estimulação via o método de otimização evolução diferencial. Como resultado da aplicação do algoritmo de evolução diferencial foi possível encontrar um conjunto de soluções capaz de ajustar automaticamente os parâmetros do neurônio pulsante, de tal forma que ele se comportasse como um detector de estímulos. Além disso, baseado na média amostral da taxa de acerto das soluções obtidas no primeiro conjunto de simulação, 4 entre as melhores soluções foram selecionadas com o propósito de validar e analisar a média das taxas de acerto em função dos valores de probabilidade de ocorrência de estímulos. Espera-se que estes resultados possam contribuir para uma melhor análise do comportamento de neurônios artificiais na construção de sensores com maior plausibilidade biológica.

Palavras-chave – Neurônios pulsantes, Evolução Diferencial, detecção de estímulos.

Abstract – Computational neuroscience seeks to understand the mechanisms and functions of the nervous system through the construction of realistic mathematical models of neural networks and the realization of large-scale computer simulations. However, the creation of these mechanisms are still a distant reality, and thus, current research has sought to reproduce, in general, simple tasks of the nervous system. Therefore, The Izhikevich spiking neuron model was chosen because of their excellent performance computing, while preserving many of the desirable biological features. Thus, this paper proposes the construction of detectors based on Izhikevich spiking neuron model, who are able to detect external stimuli, i.e., to pulse when they are stimulated by current pulses from the external environment. For this, we have performed a set of simulations involving tuning the parameters of the Izhikevich spiking neuron model, as well as tuning the magnitude of current stimulation via the method of differential evolution optimization. As a result, it was possible to find a set of solutions that automatically adjust the parameters of the spiking neuron, so that it behaves as a stimuli detector. Furthermore, based on sample average rate of correct solutions obtained in the first set of simulation, four among the best solutions were selected in order to validate and analyze the average success rates depending on the values of probability of occurrence of stimuli. It is hoped that these results will contribute to a better analysis of the behavior of artificial neurons in the construction of sensors with greater biological plausibility.

Keywords – Spiking neurons, Differential Evolution, stimuli detection.

1 INTRODUÇÃO

A neurociência computacional é um campo de estudo que vem crescendo nos últimos anos e, de uma maneira geral, busca compreender as funções e os mecanismos do sistema nervoso por meio da construção de modelos matemáticos realistas de redes de neurônios. Além disso, diversas abordagens na área de Inteligência Artificial têm surgido na tentativa de se entender os aspectos mais importantes do sistema nervoso por meio de mecanismos de software e hardware que apresentem comportamento inteligente [1]. Entretanto, a criação desses mecanismos ainda são uma realidade distante e, dessa forma, as pesquisas atuais tem procurado, de uma maneira geral, reproduzir tarefas mais simples, porém complexas, do sistema nervoso.

O estudo do cérebro, de uma forma geral, pode ser feita por meio de duas abordagens [2]: (i) de cima para baixo, através da observação de funcionalidades que são sintetizadas através de módulos. Nessa abordagem, a modelagem de funcionalidades do cérebro como por exemplo, o sistema de recompensa [3] ou o sistema emocional [4] são sintetizadas em módulos cerebrais artificiais de forma a serem relacionadas as características observadas nos seres vivos; (ii) de baixo para cima, com a criação de estruturas cerebrais artificiais a partir de observações empíricas em que sua dinâmica é estudada através de simulações que buscam padrões que podem ser interpretados em termos de processamento de sinais.

Considerando a segunda abordagem, o principal elemento de uma estrutura cerebral é o neurônio. Os neurônios biológicos são estruturas que recebem estímulos de outros através de ligações chamadas sinapses. Os estímulos de entrada produzem correntes elétricas transmembrânicas que mudam o potencial da membrana do neurônio. Correntes sinápticas produzem mudanças chamadas potenciais pós-sinápticos (PSP do inglês *postsynaptic potentials*). Correntes pequenas produzem pequenas PSPs; correntes grandes produzem significantes PSPs que podem ser amplificadas por canais sensíveis a voltagem incorporados na membrana e que leva a geração de um potencial de ação ou pulso - uma mudança abrupta e transiente da tensão de membrana que se propaga a outros neurônios através do axônio [5]. Como todos os pulsos de um dado neurônio são parecidos, a forma do potencial de ação não carrega informação. O que importa é o quantidade e o tempo em que os pulsos ocorrem. O potencial de ação é a unidade elementar da transmissão de sinal [6].

McCulloch e Pitts propuseram o primeiro modelo matemático de um neurônio em 1943 [7]. Hoje, passados mais de 60 anos, sabe-se que esse modelo está longe de retratar o comportamento e as funcionalidades de um neurônio biológico. No entanto, depois de algumas décadas a área das redes neurais artificiais se destacou no controle eficiente de processos industriais e reconhecimento de padrões sem se preocupar necessariamente com o propósito inicial que era o de auxiliar na compreensão do sistema nervoso. Nesse ínterim a neurociência avançou sobremaneira e surgiram outros modelos matemáticos que descrevem de modo mais adequado a complexa dinâmica de funcionamento dos neurônios reais. Um desses modelos que apresentam grande plausibilidade biológica é o modelo de Hodgkin e Huxley [8]. Esse modelo, embora um dos mais completos biologicamente, é composto por 4 equações diferenciais não-lineares e, portanto, possui um custo computacional muito elevado quando simulações em larga escala são consideradas. Em 1993, Izhikevich apresentou um modelo derivado do de Hodgkin e Huxley em que, utilizando-se da teoria de bifurcações e de redução e ordem, conseguiu obter um modelo que consiste de duas equações diferenciais [9]. Em comparação com outros modelos, o de Izhikevich é o que apresenta atualmente a melhor relação entre custo computacional e plausibilidade biológica [10].

Como resultado, este artigo tem por objetivo a construção de tarefas simples presentes no sistema nervoso central de seres vivos por meio de neurônios que apresentem maior plausibilidade biológica. Sendo assim, foram construídos neurônios baseados no modelo de Izhikevich que são capazes de detectar estímulos externos, isto é, pulsar quando são submetidos a pulsos de correntes do meio externo. Neurônios com a propriedade descrita acima poderiam ser usados como porta de entrada de estímulos externos recebidos repassando esta informação a outros neurônios de uma rede neuronal, mimetizando, de certa forma, o comportamento que acontece em seres vivos, onde neurônios recebem estímulos provenientes de células diferentes. Apesar do apelo biológico, poderíamos por meio dessa simples coordenação construir dispositivos de engenharia embarcados em robôs que poderiam locomover de forma autônoma através do recebimento de estímulos provenientes dos sensores de entrada.

De uma forma geral, esse artigo está organizado da seguinte forma: a seção 2 apresenta o modelo de neurônio utilizado na construção dos detectores de estímulos. A subseção 3.1 ilustra o método de otimização Evolução Diferencial utilizado no processo de otimização dos parâmetros do modelo de neurônio escolhido. A subseção 3.2 apresenta a função de aptidão utilizada no processo de otimização. A validação do modelo proposto foi realizada utilizando-se o processo de validação estocástica e é apresentado na subseção 3.3. A seção 4 ilustra as análises realizadas através de uma sequência de experimentos mostrando a capacidade de detecção de estímulos externos dos neurônios pulsantes de Izhikevich. Finalmente, a seção 5 conclui o artigo e apresenta as perspectivas de trabalhos futuros.

2 MODELO DE NEURÔNIO DE IZHIKEVICH

Izhikevich [9], através de metodologias de bifurcação para simplificar o modelo de Hodgkin-Huxley, obteve um modelo bidimensional, que apresenta características biofisiológicas acuradas e pode ser visto como um sistema dinâmico descrito pelo sistema de equações diferenciais a seguir:

$$\frac{dv}{dt} = 0,04v^2 + 5v + 140 - u + I, \quad (1)$$

$$\frac{du}{dt} = a(bv - u), \quad (2)$$

e pela condição auxiliar:

$$\text{se } v \geq 30mV, \text{ então } \begin{cases} v \leftarrow c \\ u \leftarrow u + d, \end{cases} \quad (3)$$

onde:

- I - representa a variável de corrente de estimulação do neurônio medida em pA e é o meio pelo qual o neurônio recebe estímulos externos, de outros neurônios ou de estruturas;
- v - representa o potencial de membrana do neurônio;
- u - representa uma variável de recuperação do potencial de membrana;
- a - descreve a escala de tempo da variável de recuperação u (determina a taxa de decaimento da variável u em função de t);

- b - representa a sensibilidade da variável de recuperação u antes de ocorrer o *reset* do potencial de membrana (expressa a sensibilidade da variável de recuperação u em relação ao potencial de membrana v);
- c - valor de *reset* do potencial de membrana v após o disparo (valor atribuído a v);
- d - valor de *reset* da variável de recuperação após o pulso (valor adicionado a u).

Considera-se a ocorrência de um potencial de ação quando o valor de v , que representa o potencial da membrana, atinge um valor superior a 30mV [9]. Os parâmetros a , b , e d e a variável u , por sua vez, são adimensionais, enquanto c e v têm escala em mV e t representa o tempo em ms .

Os parâmetros fundamentais α , β e γ , todos positivos, são pré-definidos no modelo de Izhikevich com os valores: $\alpha=0.04$, $\beta=5$, $\gamma=140$ e foram obtidos para ajustar o pulso com a dinâmica de um neurônio cortical, de forma que o potencial de membrana v tenha escala mV e o tempo t tenha escala ms . Além disso, os valores escolhidos são os que melhor se aplicam à simulação de neurônios pulsantes em larga escala.

3 MÉTODOS

3.1 Evolução Diferencial

Para ajustar os parâmetros, foi utilizado o método de otimização Evolução Diferencial [11], que é um algoritmo evolucionário populacional e estocástico desenvolvido para otimização de funções contínuas que só dispõem de uma forma de avaliação, como é o caso tratado neste artigo.

Os indivíduos da população podem ser vistos como vetores nos quais as coordenadas representam os parâmetros que se deseja ajustar. Nesse caso, o vetor possui dimensão igual a 5, sendo que a primeira coordenada representa o valor da corrente e as outras 4, os parâmetros a , b , c e d do modelo de Izhikevich.

$$[I, a, b, c, d]$$

Os limites dos parâmetros dos neurônios foram definidos de acordo com os valores apresentados em [9]. O limite superior do valor da corrente, por sua vez, foi definido após alguns testes preliminares.

Limites	I	a	b	c	d
inferior	1	0,02	0,2	-65	0,05
superior	200	0,10	0,25	-50	8

A primeira população P da primeira geração g criada pelo processo de otimização consistiu em vetores gerados de forma aleatória com distribuição uniforme entre os limites de cada dimensão. Estes vetores são avaliados segundo uma função de aptidão que será descrita na subseção 3.2. Para construir a próxima geração ($g+1$) define-se, primeiramente, uma outra população M de vetores que são criados através da combinação vetorial dos elementos da população P . Os vetores de M são conhecidos como vetores “mutantes” e são obtidos pela relação:

$$m_i^{g+1} = x_{r_0}^g + F \times (x_{r_1}^g - x_{r_2}^g),$$

em que $m_i \in M$, $x_{r_0}, x_{r_1}, x_{r_2} \in P$, g é o índice da geração, i é o índice do indivíduo de M , F é um parâmetro do método com domínio em $[0, 1]$ e r_0, r_1, r_2 são os índices dos indivíduos de P escolhidos aleatoriamente sem que haja repetições: $i \neq r_0 \neq r_1 \neq r_2$.

Após a construção dos vetores da população M , estes passaram por uma etapa de recombinação onde serão inseridos, de acordo com uma probabilidade definida *a priori*, componentes dos vetores da população P na população M , sendo que o i -ésimo vetor de M recebe componentes do i -ésimo vetor de P .

Para cada coordenada $j = 1, 2, \dots, d$, é feita a verificação abaixo:

$$m_{i,j}^{g+1} = \begin{cases} m_{i,j}^{g+1} & \text{se } u_j \leq CR \text{ ou } j = u_i \\ x_{i,j}^g & \text{c.c.,} \end{cases}$$

em que CR é a probabilidade de recombinação e u_j e u_i são variáveis aleatórias, sendo u_j com distribuição uniforme no intervalo $[0, 1]$ e u_i com distribuição uniforme e discreta no intervalo dos índices da população. A variável u_j é gerada para cada coordenada e u_i , apenas uma vez para cada vetor.

Após todo esse processo, os indivíduos de M são avaliados da mesma forma que foram avaliados os indivíduos de P , sendo feita uma seleção que consiste em substituir os indivíduos de P pelos respectivos indivíduos da população M , caso estes apresentem melhor valor de aptidão.

A condição de parada do algoritmo foi definida como sendo a estabilidade de uma melhor solução por um período de 1000 gerações. Os parâmetros utilizados na configuração foram:

Tamanho da população	F	CR
50	0,90	0,80

3.2 Função de aptidão

Para avaliar um indivíduo, uma simulação com duração de 100ms foi realizada onde o neurônio, definido pelos parâmetros a, b, c e d do indivíduo é estimulado por uma corrente com valor igual a I em instantes de tempo aleatórios, ou seja, um estímulo ocorre em um instante de tempo t com probabilidade p . Desta forma, cada simulação apresenta um padrão de estímulos diferente e para avaliar o resultado foram definidos dois vetores θ e $\hat{\theta}$:

$$\theta_i = \begin{cases} 1 & \text{ocorreu estímulo no tempo } i \\ 0 & \text{c.c.} \end{cases} \quad \hat{\theta}_i = \begin{cases} 1 & \text{ocorreu pulso no tempo } i + 1 \\ 0 & \text{c.c.,} \end{cases}$$

onde θ é o vetor de estímulos aplicados na entrada do neurônio e $\hat{\theta}$ é o vetor de pulsos de resposta na saída do neurônio. O deslocamento no vetor $\hat{\theta}$ foi necessário pois foram comparadas a distância entre os dois vetores sendo, portanto, impossível que o neurônio pulse no mesmo instante de tempo em que recebe o estímulo na sua entrada, já que o tempo da simulação é discretizado. O estímulo no último milissegundo da simulação foi desconsiderado com o objetivo de não prejudicar a avaliação realizada, uma vez que não é possível verificar se este neurônio pulsou.

A avaliação da qualidade da simulação foi realizada através da comparação entre os vetores definidos acima. Para isto, foi utilizada a distância de *Hamming* [12], que informa o número de coordenadas diferentes existentes entre os dois vetores de mesma dimensão. Além de minimizar a distância, faz-se necessária a minimização do valor da corrente. Sendo assim, a função de avaliação proposta pode ser expressa da seguinte forma:

$$f(\hat{\theta}, \theta, i) = 1000 \times d(\hat{\theta}, \theta) + I, \quad (4)$$

onde d é a distância de *Hamming* e I é o valor da corrente. O peso associado à distância foi definido de forma empírica e tem como objetivo aumentar a prioridade da otimização dos parâmetros do neurônio.

Para melhorar a estimativa do desempenho do indivíduo, foram realizadas 50 simulações sendo que, para cada simulação, o valor da probabilidade de ocorrência de estímulo p foi definido de forma aleatória com distribuição uniforme no intervalo $[0, 1]$. Desta maneira, temos um conjunto de 50 amostras do qual a média, estimada pelo método de reamostragem *Jackknife* [13], representa o valor de aptidão do indivíduo. O cálculo do valor de aptidão pode ser visto no Algoritmo 3.1.

Algoritmo 3.1: Cálculo do valor de aptidão de um indivíduo

```

início
  Entrada:  $x$ ; /* vetor que representa o indivíduo */
  Saída: aptidao; /* valor final da aptidão */
   $i \leftarrow x_1$ ; /* valor da corrente */
   $a \leftarrow x_2$ ;  $b \leftarrow x_3$ ;  $c \leftarrow x_4$ ;  $d \leftarrow x_5$ ; /* parâmetros do neurônio */
   $n \leftarrow 50$ ; /* número de amostras */
   $m \leftarrow 100$ ; /* tempo da simulação em ms */
   $X \leftarrow 0$ ; /* vetor para armazenar as amostras geradas */
  para  $k \leftarrow 1$  até  $n$  faça
     $p \leftarrow U[0, 1]$ ; /* probabilidade de ocorrência de um estímulo */
     $\theta \leftarrow 0$ ; /* vetor que armazena o tempo dos estímulos */
     $\hat{\theta} \leftarrow 0$ ; /* vetor que armazena o tempo dos pulsos */
     $v \leftarrow -65$ ;  $u \leftarrow b \times v$ ;
    para  $t \leftarrow 1$  até  $m$  faça
       $I \leftarrow 0$ ; /* Armazena o valor da corrente durante a simulação */
       $r \leftarrow U[0, 1]$ ;
      se  $r < p$  então
         $I \leftarrow i$ ; /* Estímulo ocorre com probabilidade  $p$  */
         $\theta_t \leftarrow 1$ ;
      fim se
      se  $v \geq 30$  então
         $v \leftarrow c$ ;  $u \leftarrow u + d$ ; /* Quando  $v$  ultrapassa 30, é considerado */
         $\hat{\theta}_{t-1} \leftarrow 1$ ; /* que o neurônio pulsou */
      fim se
       $v \leftarrow v + 0,5 \times ((0,04 \times v + 5) \times v + 140 - u + I)$ ; /* resolução da EDO com passo 0,5ms */
       $v \leftarrow v + 0,5 \times ((0,04 \times v + 5) \times v + 140 - u + I)$ ; /* para estabilidade numérica */
       $u \leftarrow u + a \times (b \times v - u)$ ;
    fim para
     $X_k \leftarrow 1000 \times d(\theta, \hat{\theta}) + i$ ; /* avaliação da simulação.  $d(\cdot, \cdot)$  é a distância de Hamming */
  fim para
   $aptidao \leftarrow \frac{1}{n(n-1)} \sum_{i=1}^n \sum_{j=1, j \neq i}^n X_j$ ; /* Estimativa da média através do método Jackknife */
fim

```

3.3 Validação estocástica

A solução otimizada pelo método de Evolução Diferencial descrito na subseção 3.1 foi validada estocasticamente por um processo semelhante ao realizado para o cálculo da aptidão. A diferença passa a ser a função que avalia a simulação que agora

representa uma taxa de acerto do neurônio e pode ser calculada pela expressão:

$$r(\theta, \hat{\theta}) = 1 - \frac{d(\theta, \hat{\theta})}{n}, \quad (5)$$

onde n é a dimensão dos vetores θ e $\hat{\theta}$.

Durante a validação, a solução foi submetida a 1000 cenários de estímulos diferentes. O resultado final da validação é a média da taxa de acerto calculada pela equação 5 em cada cenário.

4 RESULTADOS

Testes preliminares mostraram que algumas soluções apresentaram uma média de taxa de acerto bem dispersa. Com isso, um conjunto com 100 soluções foi gerado com o propósito de se avaliar a qualidade das soluções encontradas.

O conjunto de soluções passou pelo processo de validação estocástica descrito na subseção 3.3 no qual o valor de p foi definido de forma aleatória para cada cenário. A média das taxas de acerto para cada solução, bem como o seu histograma, foram calculados e podem ser vistos na Figura 1.

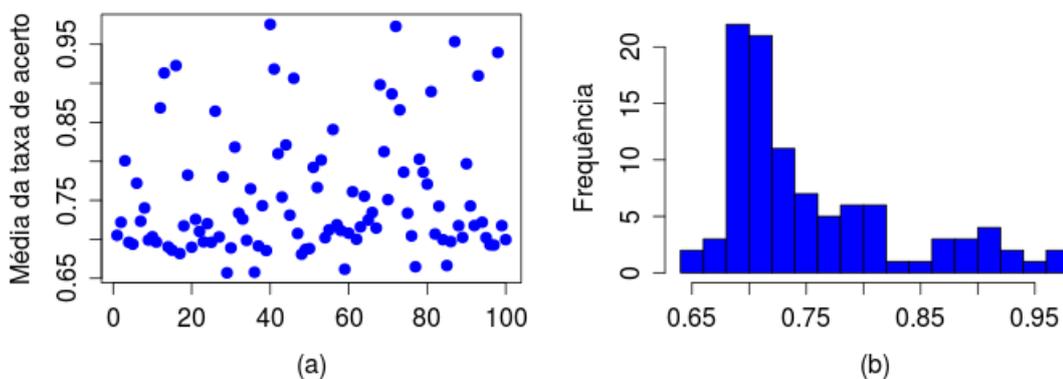


Figura 1: (a) Médias das taxas de acerto para cada uma das 100 soluções (b) Histograma da distribuição das médias.

Baseado na média amostral da taxa de acerto das soluções, 4 entre as melhores soluções foram selecionadas e um gráfico *Boxplot* foi construído como pode ser visto na Figura 2. Os parâmetros das 4 melhores soluções selecionadas estão dispostos na Tabela 1.

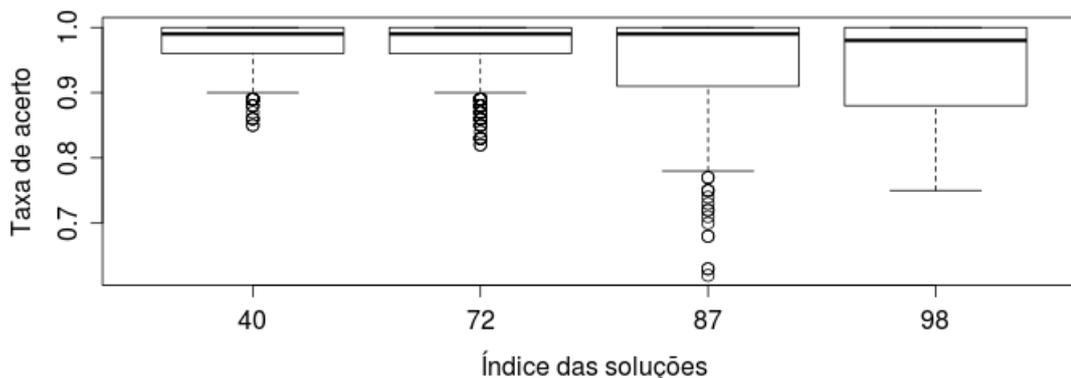


Figura 2: *Boxplot* das 4 melhores soluções com relação ao valor da média amostral da taxa de acerto. Pelo gráfico, é possível perceber a semelhança entre a solução 40 e 72.

É importante observar que até agora as soluções foram analisadas considerando que os estímulos gerados tinham uma probabilidade p diferente à cada simulação. Entretanto, se compararmos as soluções considerando um valor de probabilidade p de ocorrência de estímulos fixo para cada uma das 4 melhores soluções selecionadas, é possível observar um comportamento interessante da taxa de acerto quando o valor de p está em torno de 50%. Através da observação do gráfico da Figura 3 é possível notar, para valores de $p > 50%$, uma acentuada queda seguida de um crescimento quase linear da média da taxa de acerto. A solução 98, que apresentou o pior desempenho, tem sua queda iniciada para $p = 35%$. As soluções 40, 72 e 87 mostraram desempenho semelhante, mas se considerarmos a área sob a curva do gráfico como uma medida de comparação, a solução 40 é a que apresenta o melhor resultado, isto é, uma melhor taxa de acerto.

Solução	i	a	b	c	d
40	111,6875	0,02677	0,23991	-50,11023	0,09708
72	111,2639	0,03819	0,22529	-51,51247	0,17308
87	111,6380	0,08585	0,21039	-50,05393	0,37312
98	111,7545	0,02533	0,21969	-50,73931	0,70116

Tabela 1: Parâmetros das soluções selecionadas.

É possível ainda observar, por meio de uma observação mais criteriosa da Figura 3, que as taxas de acerto mais altas ocorreram, principalmente, quando há um número menor de estímulos. Era de se esperar que houvesse uma diminuição com o aumento dos estímulos, mas o fato interessante é o crescimento da taxa de acertos após a queda brusca. Para analisar melhor este comportamento em cenários opostos, foram realizadas simulações com diferentes intervalos entre os estímulos. Através da observação da Figura 4, nota-se que quando o neurônio é estimulado com um intervalo de tempo fixo e superior a um valor próximo de $10ms$, há uma queda na média da taxa de acerto seguido por um período ruidoso.

Todas as soluções obtiveram taxa de acerto de 100% quando o intervalo de tempo entre os estímulos foi fixo e igual a $1ms$. Isto representa ocorrência de estímulos em 50% do tempo. Entretanto, se considerarmos a mesma frequência de estímulos com um intervalo aleatório a taxa de acerto é menor.

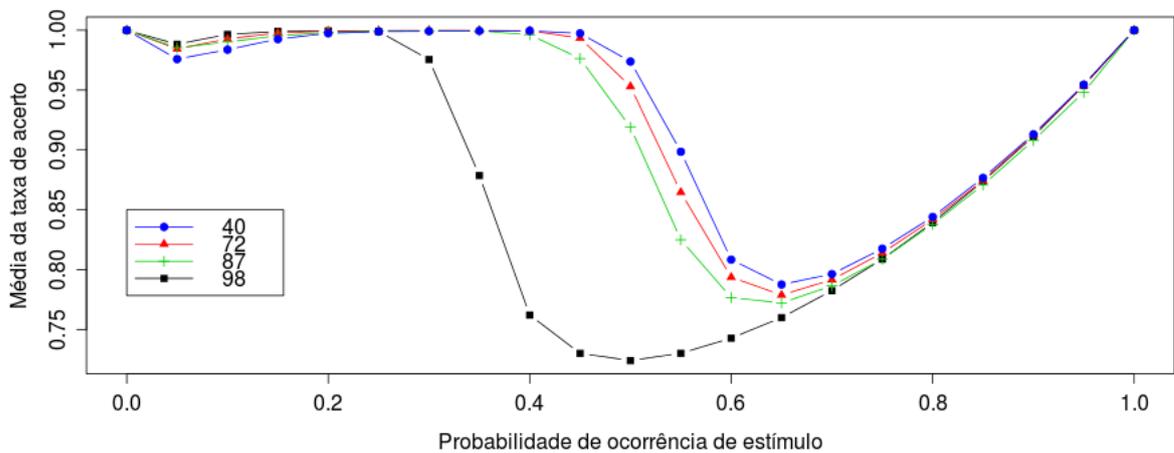


Figura 3: Média das taxas de acerto em função dos valores de probabilidade p de ocorrência de estímulos para cada uma das 4 melhores soluções selecionadas, considerando 1000 simulações.

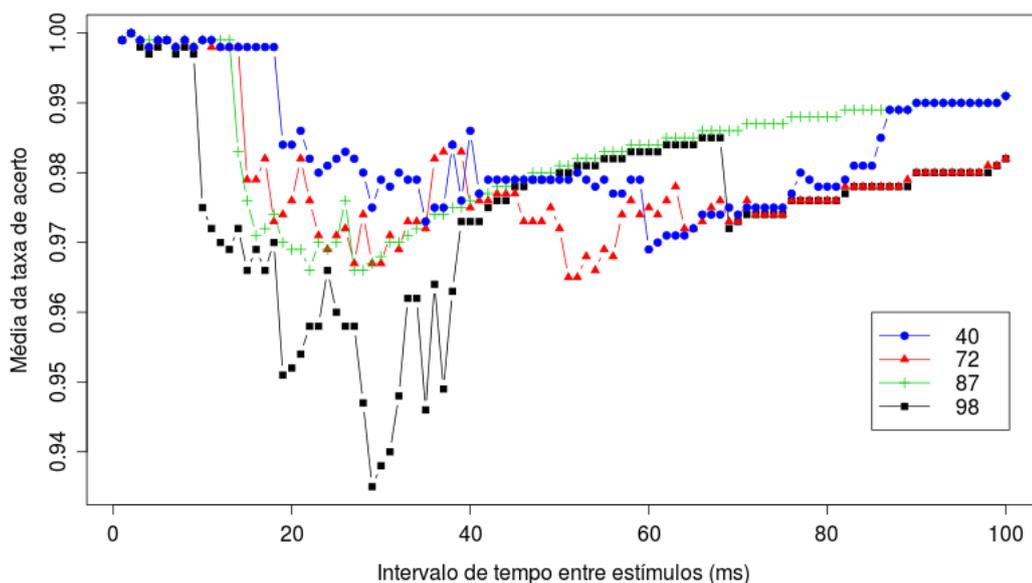


Figura 4: Desempenho dos neurônios quando recebem estímulos com um intervalo de tempo fixo.

5 CONCLUSÃO

Este artigo apresenta uma nova metodologia de parametrização do neurônio pulsante de Izhikevich por meio de Evolução Diferencial com o propósito de se criar um detector de estímulos.

Foram realizadas duas simulações diferentes com o objetivo de investigar, com uma maior profundidade, o comportamento das melhores soluções. Na primeira simulação, as soluções foram avaliadas para diversas probabilidades de ocorrência de estímulos. Como pode ser visto na Figura 3, houve uma queda brusca para valores de probabilidade de ocorrência de estímulos p próximos de 50%. Uma possível explicação se deve ao fato de que, para estes valores de p , o neurônio passa da fase de repouso para a de excitação um número maior de vezes e em intervalos de tempo bem menores. Outra observação importante é que neste período há uma mudança de tipo de cenários, indo do cenário com poucos para cenários com muitos estímulos. Na segunda simulação, foi investigado o comportamento quando o neurônio é excitado por estímulos espaçados entre intervalos de tempo iguais e determinados, onde foi observado que a média da taxa de acerto sofre uma pequena queda para valores de intervalo de estimulação entre 20 e 40 milissegundos. Isto ocorre pois o neurônio, quando é estimulado uma vez, geralmente pulsa uma ou duas vezes a mais. O impacto disso é maior para intervalos pequenos pois, por exemplo, para um intervalo de estimulação de 20ms em que há ocorrência de dois pulsos extras, temos 2 unidades de tempo com erro dentre as 20, o que indica uma taxa de acerto de 90%. Quando é considerado um intervalo maior, como 100ms, a taxa de acerto vai para 98%, ou seja, para intervalos de estimulação maiores o erro é menor. Para valores de intervalo menores que 10ms a taxa de acerto é alta, e para explicar este fato, é necessário estudar o tempo médio em que ocorre um pulso extra. Se este for maior que 10ms, o próximo estímulo sobrepõe-se ao pulso extra.

Como trabalho futuro pretende-se criar um circuito detector baseado em uma rede de neurônios capaz de detectar a coincidência de pulsos proveniente de estímulos externos. Assim, poderíamos por meio de diversas redes ou módulos simples construir dispositivos de engenharia embarcados em robôs que poderiam locomover de forma autônoma através do recebimento de estímulos provenientes dos sensores de entrada.

REFERÊNCIAS

- [1] R. Florian. “Why it is important to build robots capable of doing science”. In *University Cognitive Studies*. Citeseer, 2002.
- [2] H. Jaeger, W. Maass and J. Principe. “Editorial: Special issue on echo state networks and liquid state machines”. *Neural Networks*, vol. 20, no. 3, pp. 287–289, 2007.
- [3] S. Cole and J. Cole. “Scientific output and recognition: A study in the operation of the reward system in science”. *American Sociological Review*, vol. 32, no. 3, pp. 377–390, 1967.
- [4] L. M. de Assis Campos and H. E. Borges. “Dinâmica do Processo Cognitivo-Emocional numa Perspectiva Neuropsicológica: modelagem e aplicação a seres artificiais”. *Revista médica de Minas Gerais*, vol. 20, pp. 79–79, 2010.
- [5] E. Izhikevich. *Dynamical Systems in Neuroscience: The Geometry of Excitability and Bursting (Computational Neuroscience)*. The MIT Press, 2006.
- [6] W. Gerstner and W. Kistler. *Spiking neuron models: Single neurons, populations, plasticity*. Cambridge Univ Pr, 2002.
- [7] W. McCulloch and W. Pitts. “A logical calculus of the ideas immanent in nervous activity”. *Bulletin of Mathematical Biology*, vol. 5, no. 4, pp. 115–133, 1943.
- [8] A. Hodgkin and A. Huxley. “A quantitative description of membrane current and its application to conduction and excitation in nerve”. *The Journal of physiology*, vol. 117, no. 4, pp. 500, 1952.
- [9] E. Izhikevich. “Simple model of spiking neurons”. *Neural Networks, IEEE Transactions on*, vol. 14, no. 6, pp. 1569–1572, 2003.
- [10] E. Izhikevich. “Which model to use for cortical spiking neurons?” *Neural Networks, IEEE Transactions on*, vol. 15, no. 5, pp. 1063–1070, 2004.
- [11] K. Price, R. Storn and J. Lampinen. *Differential evolution: a practical approach to global optimization*. Natural computing series. Springer, 2005.
- [12] R. Hamming. “Error detecting and error correcting codes”. *Bell System Technical Journal*, vol. 29, no. 2, pp. 147–160, 1950.
- [13] R. Duda, P. Hart and D. Stork. *Pattern classification*, volume 2. Wiley, New York, 2001.