

УДК 004.032.26

Е.В. Бодянский, А.И. Долотов

Харьковский национальный университет радиоэлектроники, Харьков

ГЕТЕРОГЕННАЯ СПАЙК-НЕЙРОННАЯ СЕТЬ С ЛАТЕРАЛЬНЫМИ СВЯЗЯМИ В ЗАДАЧЕ КЛАСТЕРИЗАЦИИ

Рассмотрена модель спайк-нейрона, предложена архитектура гетерогенной спайк-нейронной сети для решения задачи кластеризации. В качестве алгоритма обучения выбрано модифицированное правило Хэбба. Для преобразования входного сигнала в кортежи спайков использованы рецепторные поля. Показана эффективность решения задачи кластеризации на основе сети спайк-нейронов.

спайк, спайк-нейрон, мембранный потенциал, сенсорный нейрон, рецепторное поле, терминал, кластеризация

Введение

Если классифицировать современные искусственные нейронные сети по типу образующих их элементарных вычислительных элементов, можно

выделить три различных поколения. Сети первого поколения основываются на нейронах Маккаллоха-Питтса.

В нейронных сетях второго поколения используются непрерывные функции активации.

Широко известным представителем этого типа являются сети с сигмоидальными функциями активации. Наконец, третье поколение представлено сетями со спайк-нейронами, являющимися одними из наиболее реалистичных моделей биологических нейронов [1].

Искусственный спайк-нейрон представляет входной сигнал в терминах элементарных спайков и описывает, как такой сигнал влияет на генерацию спайк-нейроном результирующих спайков [2 – 5]. Основой такой модели является мембранный потенциал, или внутреннее состояние, спайк-нейрона [6]. Кроме того, по аналогии с биологическим нейроном в модели спайк-нейрона используются два вида синапсов – возбуждающие и тормозящие. Сеть, построенная на основе таких нейронов, по своим вычислительным возможностям во многих случаях превосходит сети второго поколения [2].

Кодирование входного сигнала

Первый вопрос, который следует решить при использовании спайк-нейронных сетей, – это кодирование входного сигнала в последовательность спайков для ее дальнейшей обработки в спайк-нейронах [7]. Проблема такого кодирования до сих пор полностью не решена [8, 9].

Рассмотрим два способа – простейшее кодирование и кодирование на основе рецепторных полей. Нейроны, в которых выполняется кодирование входного сигнала, в общем случае будем называть сенсорными нейронами.

Наиболее простой способ представления входного сигнала в виде кортежа спайков – непосредственное кодирование аналогового сигнала в последовательность конечных временных интервалов [10]. Рассмотрим такое кодирование на примере: на временном интервале в 10 мс требуется закодировать сигнал, принимающий значения из интервала 0-20. Представим значение входного сигнала в виде пропорциональной задержки на временном интервале. Так значение 9,0 будет представлено задержкой 4,5 мс. В этом случае аналоговое значение кодируется в интервалах между спайками. Для фиксирования точки отчета вводится дополнительный спайк-нейрон, генерирующий начальный спайк кортежа. На рис. 1 показано кодирование двух входных переменных тремя сенсорными нейронами. Без задания начального спайка дополнительным нейроном, значения 3,5 и 7 в терминах кортежа спайков были бы, к примеру, эквивалентны значениям 2,5 и 6, так как интервал между спайками одинаковый в обоих случаях.

Если теперь каждый сенсорный нейрон связать с двумя выходными нейронами, мы получим простейшую спайк-нейронную сеть (рис. 2), способную решать задачу кластеризации на плоскости.




Рис. 1. Простейшая схема временного кодирования

В искусственной спайк-нейронной сети, имеющей n сенсорных нейронов и m выходных нейронов, центр РБФ-подобного нейрона J задается вектором $c_j = [c_{1j}, c_{2j}, \dots, c_{nj}]$, где $c_{ij} = \max\{\Delta_{ij}^{ax} | 1 \leq i \leq n\} - \Delta_{ij}^{ax}$. Входной вектор задается как $x = [x_1, x_2, \dots, x_n]$, где $x_i = t_i - \min\{t_i | 1 \leq i \leq n\}$ и t_i – момент активации каждого сенсорного нейрона.

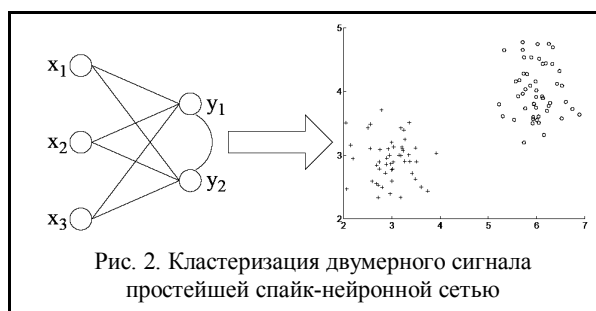


Рис. 2. Кластеризация двумерного сигнала простейшей спайк-нейронной сетью

Непосредственное кодирование входного сигнала применимо лишь в случаях, когда количество кластеров не превышает размерности сигнала. В случае же, если количество нейронов больше размерности входного сигнала, эффективность такого метода кодирования ухудшается [10 – 13].




Рис. 3. Пример кодирования входного сигнала на основе пересекающихся рецепторных полей

Для улучшения эффективности обработки входного сигнала при его кодировании в случае, если число кластеров превышает размерность сигнала, применяют рецепторные поля [14]. При таком методе кодирования сигнал распределяется среди множества нейронов, что повышает его размерность. Каждый сенсорный нейрон включает некоторое множество пересекающихся рецепторных полей, моделируемых функциями Гаусса. Интервал значе-

ний функции Гаусса проецируется на интервал кодирования. Чем ближе значение входного сигнала к центру рецепторного поля, тем раньше оно генерирует спайк. Рассмотрим пример (рис. 3). Значение α входного сигнала активирует рецепторные поля 3, 4, 5 и 6 (рецепторные поля 2 и 7 находятся вне зоны чувствительности). Первый спайк будет сгенерирован рецепторным полем 5, так как значение входного сигнала ближе всего к центру именно этого поля. Среди активных рецепторных полей значение входного сигнала наиболее удалено от центра рецепторного поля 3, поэтому оно сгенерирует спайк позже всех.

Следует отметить, что кодирование на основе рецепторных полей имеет прямые аналогии с биологическими способами представления входного сигнала.

Для улучшения эффективности кодирования входного сигнала применяют два вида рецепторных полей – узкие и широкие [15 – 17]. Параметры соответствующих функций Гаусса следующие (σ_t и c_t – для узких рецепторных полей, σ_b и c_b – для широких):

$$\sigma_t = \frac{X_{\max} - X_{\min}}{\gamma_t(n_t - 2)} ; \quad (1)$$

$$c_t = X_{\min} + \frac{(2i - 3)(X_{\max} - X_{\min})}{2(n_t - 2)} , 1 \leq i \leq n_t ; \quad (2)$$

$$\sigma_b = \frac{X_{\max} - X_{\min}}{\gamma_b(n_b + 1)} ; \quad (3)$$

$$c_b = X_{\min} + \frac{i(X_{\max} - X_{\min})}{n_b + 1} , 1 \leq i \leq n_b , \quad (4)$$

где X_{\max} и X_{\min} – максимальное и минимальное значение входного сигнала, n_t и n_b – количество узких и широких рецепторных полей для каждого входа (не менее трех), $\gamma_t = 1,5$ – параметр формы узкого рецепторного поля, $\gamma_b = 0,5$ – параметр формы широкого рецепторного поля.

Обучение

Обучение без учителя спайк-нейронной сети является модифицированным вариантом правила Хэбба [18 – 21]. В выходном слое сети также используется механизм «победитель получает все». Практическая реализация такого подхода показала обнадеживающие результаты, однако, с точки зрения теории, алгоритм еще не достаточно формализован. В задаче кластеризации процесс обучения в основном сводится к подстройке временных задержек таким образом, чтобы выходной нейрон реализовывал центр некоторой радиально-базисной функции. Это достигается посредством использования функции обучения, использующей в качестве параметра интервал между двумя моментами акти-

вации t_i и t_j . Обозначим его Δt_{ij} . Функция контролирует процесс обучения, изменяя весовые коэффициенты на основе разницы между моментами активации нейрона:

$$\Delta w_{ij} = \eta L(\Delta t_{ij}) . \quad (5)$$

Используемая здесь функция обучения (рис. 4) представляет собой функцию Гаусса и задается следующим образом:

$$L(\Delta t) = (1 + \beta) \exp\left(\frac{(\Delta t - \alpha)^2}{2(k - 1)}\right) - \beta , \quad (6)$$

где

$$k = 1 - \frac{v^2}{2 \ln \frac{\beta}{1 + \beta}} . \quad (7)$$




Рис. 4. Функция обучения

Функция обучения определяется тремя параметрами – v , β и α . Рассмотрим вкратце каждый параметр.

Параметр соседства v определяет ширину положительной части функции обучения и определяет интервал из Δt_{ij} , на котором веса возрастают. Веса вне этой зоны уменьшаются.

Параметр β устанавливает значение, на которое веса будут уменьшаться. Он соответствует кривой, находящейся вне зоны, задаваемой параметром соседства.

Если нейрон i активируется одновременно с нейроном j , он не влияет на нейрон j . Поэтому необходимо немного сдвигать центр функции обучения от нулевого значения. Сдвиг центра функции обучения задается параметром α .

Веса модифицируются только у того нейрона, который первым генерирует спайк на предъявленный сети образец. Это достигается с помощью механизма «победитель получает все» [22 – 24].

Таким образом, обобщая вышесказанное, сформулируем принцип настройки весовых коэффициентов: если возникновение постсинаптического потенциала в синапсе ненамного предшествует моменту активации выходного нейрона, веса такого синапса увеличиваются, так как он должен оказыва-

ет значительное влияние на рост значения мембранного потенциала. Веса тех синапсов, в которых возникновение постсинаптических потенциалов произошло намного позже или намного раньше, уменьшаются, что отражает их незначительное влияние на генерацию выходного спайка. Для того чтобы предотвратить бесконечный рост абсолютных значений весов, вводятся предельные значения изменения весовых коэффициентов – от 0 до w_{max} .

После обучения момент активации выходного нейрона отражает расстояние входного образца до центра нейрона [3].


Архитектура спайк-нейронной сети

Рассматриваемая здесь архитектура сети в значительной мере сходна с общеизвестными архитектурами ИНС. Простейшая спайк-нейронная сеть включает два слоя – слой сенсорных нейронов и слой спайк-нейронов. Каждый нейрон предыдущего слоя связан со всеми нейронами последующего слоя. В слое сенсорных нейронов выполняется преобразование входного сигнала в кортежи спайков (либо методом непосредственного кодирования, либо на основе рецепторных полей). В слое спайк-нейронов выполняется непосредственная обработка информации.

Первая отличительная особенность простейшей спайк-нейронной сети состоит в том, что в случае использования рецепторных полей в качестве сенсорных нейронов, размерность входного сигнала увеличивается.

Вторая особенность – нейроны выходного соединены латеральными тормозящими связями, реализуя механизм «победитель получает все».

Более значимое отличие состоит в структуре синапса (рис. 5). Каждая синаптическая связь в спайк-нейронных сетях состоит из набора терминалов. Каждый терминал характеризуется некоторой задержкой и весовым коэффициентом.



Использование терминальной структуры синапса имеет аналогии с биологическими нейронами: во многих случаях пресинаптический аксон имеет несколько соединений с постсинаптическим нейроном [9, 15, 25, 26].

Хотя для каждого синапса всегда формируется лишь один постсинаптический потенциал, использование терминальной структуры синапса оправдано в том смысле, что такая структура позволяет адекватно выбирать требуемые задержки.

Для каждого сложного синапса между нейронами i и j с терминалами, результирующий постсинаптический потенциал определяется следующим равенством:

$$u_j = \sum_{k=1}^s w_{ij}^k \varepsilon(t - t_i - d^k), \quad (8)$$

где d_k – задержка k -го терминала.


Она выполняет ту же роль, что и аксональная задержка распространения сигнала в биологическом нейроне.

Общее влияние всех пресинаптических нейронов задается уравнением:

$$u_j(t) = \sum_{i \in I_j} \sum_{k=1}^s w_{ij}^k \varepsilon(t - t_i - d^k). \quad (9)$$

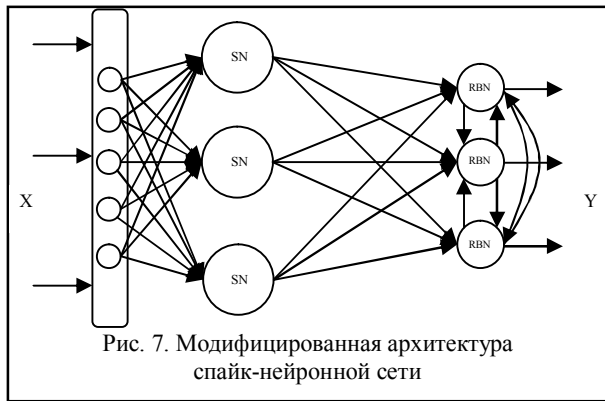
Терминальные задержки d^k не изменяются и для каждого синапса имеют значение от 0 через 1 мс до некоторого максимального значения. Как правило, это 12 мс или 15 мс. Для постсинаптического потенциала пиковое значение τ часто задают на уровне 3 мс. В качестве спайк-нейрона выходного слоя можно использовать любую модель порогово-активационного класса.

В рассматриваемой модели результирующий постсинаптический потенциал представляет собой временную сумму постсинаптических потенциалов каждого терминала (рис. 6).




Модификация архитектуры сети и ее практическое применение

Для того, чтобы повысить эффективность кластеризации, введем третий слой, состоящий из радиально-базисных нейронов (рис. 7). Латеральные связи также перенесем из слоя спайк-нейронов в выходной (третий) слой. Такое усложнение архитектуры обосновывается тем, что, кроме первого активированного спайк-нейрона, информацию о входном образе также могут содержать моменты активации других спайк-нейронов.



Проверим эффективность предложенной архитектуры двумя практическими тестами.

Для первого теста сформируем 5 двумерных кластеров (рис. 8): всего 50 точек. В качестве обучающей выборки будем использовать 25 случайно выбранных точек. Оставшиеся 25 точек будут использованы как тестовая выборка.



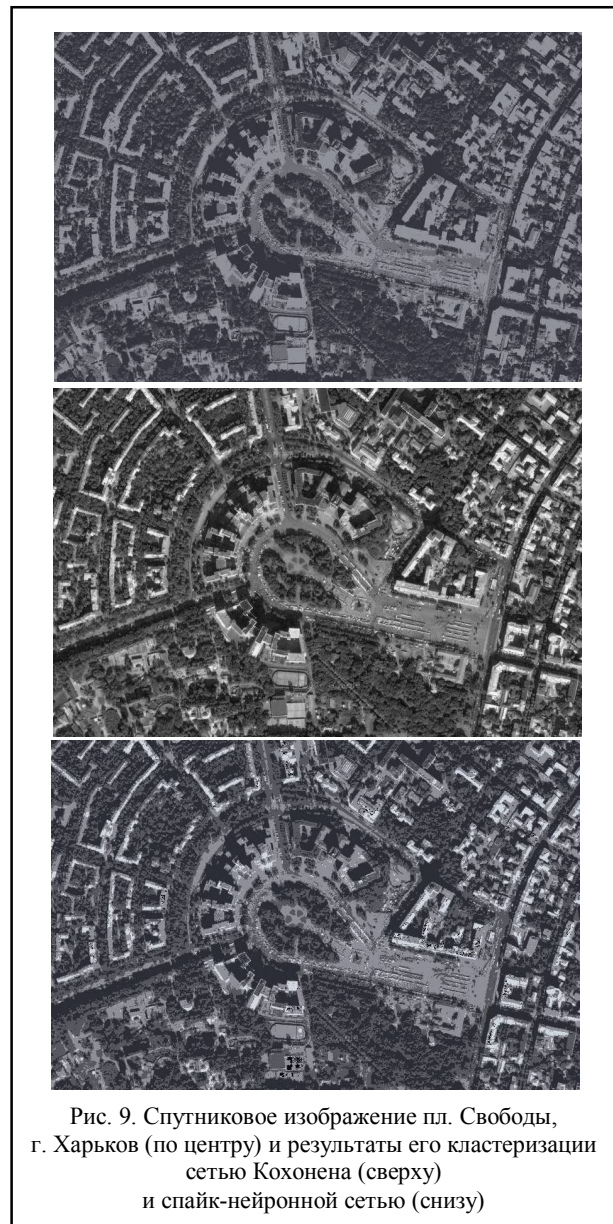
В качестве сенсорных нейронов будем использовать по четыре широких рецепторных поля для каждого из входов. Интервал кодирования входного сигнала зададим равным 10 мс. Во второй и третий слои поместим по 5 нейронов. Диапазон изменения весовых коэффициентов установим от 0 до 1. Это позволит не допустить переход спайк-нейронной сети в неустойчивое состояние.

Задав скорость обучения $\eta = 0,35$, адекватное решение задачи может быть получено уже на третьей эпохе. Следует отметить, что все точки тестовой выборки были корректно сопоставлены с кластерами.

В случае, если количество спайк-нейронов превышает количество кластеров в обучающих данных, некоторые спайк-нейроны не принимают участия в обучении. Однако, если к обучающей выборке добавить данные с новым кластером, неактивные нейроны начинают обучаться, передвигая свои центры в сторону новых кластеров.

Для тестирования эффективности работы сети на более реалистичных данных используем цветное спутниковое изображение с размером 256×256 пикселей (рис. 9). Для обучающей выборки возьмем половину точек. На вход сети будем подавать RGB-компоненты каждой точки. Для каждого входа будем использовать 3 широких рецепторных поля. Поместим в слои спайк-нейронов и радиально-базисных нейронов по 5 нейронов.

Результаты обработки изображения представим в оттенках серого. Каждому оттенку сопоставим один кластер. Для сравнения эффективности работы алгоритма решим также поставленную задачу с помощью карты Кохонена.



Для спайк-нейронной сети приемлемые результаты были получены на 4 эпохе обучения. Карте Кохонена для получения подобных результатов потребовалось 50 эпох. Стоит отметить, что обучение спайк-нейронной сети более требовательно к аппа-

ратным ресурсам по сравнению с обучением карты Кохонена.

Заключение

В работе предложена архитектура гетерогенной трехслойной спайк-нейронной сети для решения задачи кластеризации с латеральными связями в выходном слое и с терминальной структурой синапсов. В качестве алгоритма обучения выбрано модифицированное правило Хэбба. Сеть показала высокую эффективность при решении поставленных задач. Кроме того, были выявлены адаптивные свойства сети, выражающиеся во включении в процесс обучения неактивных нейронов при добавлении новых кластеров в обучающую выборку. Искусственная спайк-нейронная сеть выполнила задачу кластеризации на порядок быстрее карты Кохонена в смысле количества потребованных на обучение эпох. Однако время выполнения двух алгоритмов примерно одинаково. Это вызвано тем, что в силу сложной структуры синапсов между рецепторным слоем и слоем спайк-нейронов используемые в программной реализации матрицы весовых коэффициентов принимают значительный размер. Выходом из сложившейся ситуации может быть усовершенствование программной реализации алгоритма обучения.

Список литературы

1. Maass W. *Networks of spiking neurons: the third generation of neural network models* // *Neural Networks*. – 1997. – 10. – P. 1659-1671.
2. Maass W. *On the computational complexity of networks of spiking neurons*. / Eds. by G. Tesauero, D.S. Touretzky, T.K. Leen "Advances in Neural Information Processing Systems 7". – Cambridge, MA: The MIT Press, 1995. – P. 183-190.
3. Hopfield J.J. *Pattern recognition computation using action potential timing for stimulus representation* // *Nature*. – 1995. – 376. – P. 33-36.
4. Natschläger T., Ruf B. *Spatial and temporal pattern analysis via spiking neurons* // *Network: Computations in Neural Systems*. – 1998. – 9. – P. 319-332.
5. Goren Y. *Clustering with spiking neurons*. – 2001. – http://www.cs.technion.ac.il/Labs/IsI/Project/Projects_done/SpikingNeurons/.
6. Долотов А.И. *Обучение без учителя на основе сети спайк-нейронов* // *Системный анализ и информационные технологии: Материалы IX Международной научно-технической конференции (15-19 мая 2007 г., Киев)*. – К.: НТУУ "КПИ", 2007. – С. 104.
7. Wilson H.R. *Spikes Decisions and Actions – Dynamical Foundations of Neuroscience*. – Oxford: The Oxford University Press, 1999. – 307 p.
8. Gerstner W., Kistler W.M. *Spiking Neurons Models*. – Cambridge: The Cambridge University Press, 2002. – 400 p.
9. Bohte S.M., Kok J.S., La Poutre H. *Unsupervised clustering with spiking neurons by sparse temporal coding and multi-layer RBF networks* // *IEEE Transactions on Neural Networks*. – 2002. – 13. – P. 426-435.

10. Maass W., Bishop C.M. *Pulsed Neural Networks*. – Cambridge, MA: The MIT Press, 1998. – 408 p.
11. Hindmarsh J. L., Rose R.M. *A model of neuronal bursting using three coupled first order differential equations* // *Proc. the Royal Society of London*. – 1984. – 221. – P.87-102.
12. Бардаченко В.Ф., Колесницький О.К., Василецький С.А. *Таймерні нейронні елементи та структури*. Монографія. – Вінниця: УНІВЕРСУМ-Вінниця, 2004. – 126 с.
13. Haykin S. *Neural Networks. A Comprehensive Foundation*. – Upper Saddle River, N.J.: Prentice Hall, Inc., 1999. – 842 p.
14. Долотов А.И., Викторов Е.А. *Применение рецепторных полей в спайк-нейронных сетях при решении задачи кластеризации* // 11-й международный молодежный форум "Радиоэлектроника и молодежь в XXI веке": Сб. материалов форума. – Х.: ХНУРЭ. – 2007. – Ч. 1. – С. 351.
15. Gerstner W. *What's different with spiking neurons?* / Eds. by H. Mastebrock, H. Vos "Plausible Neural Networks for Biological Modelling". – Boston, Mass: Kluwer Academic Publ., 2001. – P. 23-48.
16. Natschläger T. *Networks of spiking neurons: a new generation of neural networks models*. – 1998 [Электрон. ресурс]. – Режим доступа: http://www.igi.tugraz.at/tnatschl/online/3rd_gen_eng/3rd_gen_eng.html.
17. Bohte S.M., Kok J.S., La Poutre H. *Error back-propagation in temporally encoded networks of spiking neurons* // *Neurocomputing*. – 2002. – 48. – P. 17-37.
18. Bohte S.M. *The evidence of information processing with precise spike-times: A survey* // *Natural Computing*. – 2004. – 3. – P. 195-206.
19. Nagumo J., Arimoto S., Arimoto S., Yoshizawa S. *An active pulse transmission line simulating nerve axon* // *Proc. IRE*. – 1962. – 50. – P. 2061-2070.
20. Izhikevich E.M. *Resonate-and-fire neurons* // *Neural Networks*. – 2001. – 14. – P. 883-894.
21. Steuber V., Willshaw D.J. *Adaptive leaky integrator models of cerebellar Purkinje cells can learn the clustering of temporal patterns* // *Neurocomputing*. – 1999. – 26. – P. 271-276.
22. Jin D.Z. *Spiking neural networks for recognizing spatiotemporal sequences of spikes* // *Physical Review E*. – 2004. – 69:021905 – P. 1-13 [Электрон. ресурс]. – Режим доступа: <http://hebb.mit.edu/people/djin/pre-2004-sequence.pdf>.
23. Kamo S., Iwai R., Kinjo H., Yamamoto T. *Pulse pattern training of spiking neural networks using improved genetic algorithm* // *Proc. 2003 IEEE Int. Symp. on Computational Intelligence in Robotics and Automation*. – 2003. – V.2. – P. 977-981.
24. Izhikevich E.M. *Simple model of spiking neurons* // *IEEE Trans. on Neural Networks*. – 2003. – 14. – P. 1569-1572.
25. Abbott L.F., Kepler T. *Model neurons: from Hodgkin-Huxley to Hopfield* / Ed. by Garrido L. "Statistical Mechanics of Neural Networks". – Berlin: Springer-Verlag, 1990. – P. 5-18.
26. Hasegawa H. *Responses of a Hodgkin-Huxley neuron to various types of spike-train inputs* // *Physical Review E*. – 2000. – 61. – P. 718-726.

Поступила в редколлегию 25.07.2007

Рецензент: д-р техн. наук, проф. С.Г. Удовенко, Харьковский национальный университет радиоэлектроники, Харьков.