

ТРАНСЛЯЦИЯ НЕЙРОННОЙ СЕТИ В СЕТЬ ПЕТРИ*

А.А. ВОЕВОДА¹, Д.О. РОМАННИКОВ²

¹ 630073, РФ, г. Новосибирск, пр. Карла Маркса, 20, Новосибирский государственный технический университет, доктор технических наук, профессор кафедры автоматики. E-mail: ucit@ucit.ru

² 630073, РФ, г. Новосибирск, пр. Карла Маркса, 20, Новосибирский государственный технический университет, кандидат технических наук, доцент кафедры автоматики. E-mail: dmitry.romannikov@gmail.com

В статье приводится пример реализации нейронной сети при помощи сети Петри, что позволяет добавить асинхронности в нейронную сеть – это больше соответствует работе человеческого мозга и, следовательно, может иметь перспективу применения для решения задач искусственного интеллекта. Математический аппарат сетей Петри, с одной стороны, позволяет моделировать поведение асинхронных систем, а с другой – по своей структуре в достаточной степени похож на структуру нейронов, чем и обосновывается выбор сетей Петри. Приведен пример реализации нейронной сети для решения задачи XOR как стандартной задачи в области машинного обучения. В рамках решения этой задачи функции суммирования в нейронной сети представлены в виде переходов, в которых при передаче метки в место происходит суммирование значений входных меток. Функции активации также представлены в виде переходов, в которых для выходных дуг выполняется вызов функций активации (сигмоидальной функции в данном случае). Стоит отметить, что при моделировании реализованная нейронная сеть является асинхронной лишь частично (в частности, для срабатывания переходов требуется наличие меток во всех входящих в нее местах). Данный вариант нейронной сети при помощи сетей Петри является не единственным. В частности, можно также использовать отдельные места и метки для моделирования весовых коэффициентов, что позволит выполнять обучение нейронной сети без модификации ее структуры. Дальнейшим направлением исследования является реализация процедуры обучения нейронной сети с асинхронностью.

Ключевые слова: нейронные сети, сети Петри, искусственный интеллект, преобразования, функция активации, keras, регуляризация, обучение

* Статья получена 13 декабря 2017 г.

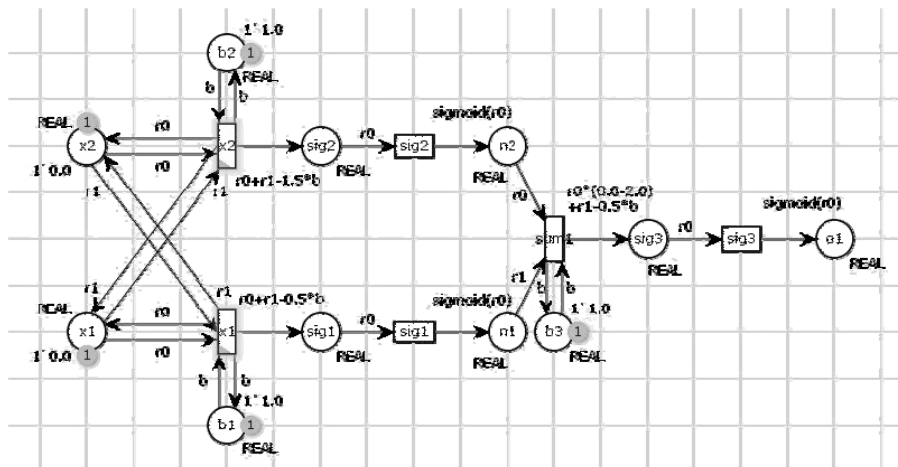
ВВЕДЕНИЕ

На сегодняшний момент все используемые на практике модели нейронных сетей, к которым относятся модели распознавания изображений [1], речи [2], генерации названий изображений [3] и другие [4–17], реализованы на логике их синхронной работы. При этом работа некоторых частей человеческого мозга является асинхронной, что является мотиватором для реализации модели нейронной сети, в которой присутствуют асинхронные операции между нейронами. В статье предлагается модель нейронной сети для решения классической задачи машинного обучения – задачи исключающего или (*XOR*) реализованной при помощи сети Петри.

РЕАЛИЗАЦИЯ НЕЙРОННОЙ СЕТИ

Для примера реализации была выбрана классическая задача машинного обучения – реализация модели для решения задачи исключающего или (*XOR*), которая неоднократно решалась в работе [4].

Один из возможных вариантов решения данной задачи приведен в исследованиях [4, 5]. В нем предлагается нейронная сеть, состоящая из двух входов и трех нейронов (один нейрон в скрытом слое), а также предлагаются пред-рассчитанные значения обучаемых параметров. На основании приведенной нейронной сети можно построить сеть Петри (см. рисунок).



Нейронная сеть для решения задачи *XOR*, реализованная при помощи сетей Петри

Данная сеть содержит два входа – x_1 и x_2 . Первый нейрон состоит из x_1 и x_2 входов, b_1 – смещения, $sig1$ – буферного места для суммирования и n_1 – выходного значения нейрона. Второй входной нейрон и нейрон в выходном слое устроены таким же образом. В нейронах применяется сигмоидальная функция активации.

При моделировании данная нейронная сеть является асинхронной лишь частично. В частности, для срабатывания перехода $sum1$ требуется наличие меток в местах n_1 и n_2 .

ЗАКЛЮЧЕНИЕ

В статье предлагается реализация нейронной сети для решения задачи XOR при помощи сетей Петри. Использование сетей Петри для реализации нейронной сети придает им асинхронность срабатывания переходов, что больше соответствует работе человеческого мозга. Стоит отметить, что данный вариант нейронной сети при помощи сетей Петри является не единственным. В частности, можно также использовать отдельные места и метки для моделирования весовых коэффициентов, что позволит выполнять обучение нейронной сети без модификации ее структуры.

СПИСОК ЛИТЕРАТУРЫ

1. *Krizhevsky A., Sutskever I., Hinton G.E.* ImageNet classification with deep convolutional neural networks // *Advances in Neural Information Processing Systems 25 (NIPS 2012)*. – Lake Tahoe, Nevada, 2012. – P. 1090–1098.
2. *Graves A., Mohamed A., Hinton G.* Speech recognition with deep recurrent neural networks // *Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP 2013*. – Vancouver, Canada, 2013. – P. 6645–6649.
3. *Karpathy A., Fei-Fei L.* Deep visual-semantic alignments for generating image descriptions // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 2016. – Vol. 39. – P. 664–676.
4. *Haykin S.* *Neural networks and learning machines*. – 3rd ed. – New York: Prentice Hall/Pearson, 2009. – 938 p.
5. *Goodfellow I., Bengio Y., Courville A.* *Deep learning*. – Cambridge: MIT Press, 2016. – 800 p.
6. *Воевода А.А., Романников Д.О.* Синтез нейронной сети для решения логико-арифметических задач // *Труды СПИИРАН*. – 2017. – Вып. 54. – С. 205–223.

7. *Haykin S., Deng C.* Classification of radar clutter using neural networks // IEEE Transactions on Neural Networks. – 1991. – Vol. 2. – P. 589–600.
8. *Hastie T., Tibshirani R., Friedman J.* The elements of statistical learning: data mining, inference, and prediction. – New York: Springer, 2001.
9. *Hagan M., Demuth H., Jesús O.* A neural network predictive control system for paper mill wastewater treatment // Engineering Applications of Artificial Intelligence. – 2003. – Vol. 16 (2). – P. 121–129.
10. *Touretzky D.S., Pomerleau D.A.* What is hidden in the hidden layers? // Byte. – 1989. – Vol. 14. – P. 227–233.
11. *LeCun Y., Bengio Y., Hinton G.* Deep learning // Nature. – 2015. – Vol. 521, N 7553. – P. 436–444.
12. Dropout: a simple way to prevent neural networks from overfitting / N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, R. Salakhutdinov // Journal of Machine Learning Research. – 2014. – Vol. 15. – P. 1929–1958.
13. Early stopping without a validation set / M. Mahsereci, L. Balles, C. Lassner, P. Hennig // ArXiv.org. – 2017. – arXiv:1703.09580.
14. *Prechelt L.* Early Stopping – but when? // Neural networks: tricks of the trade. – 2nd ed. – Berlin; Heidelberg: Springer, 2012. – P. 53–67.
15. *Воевода А.А., Романников Д.О.* Асинхронный алгоритм сортировки массива чисел с использованием ингибиторных сетей Петри // Труды СПИИРАН. – 2016. – Вып. 48. – С. 198–213.
16. *Воевода А.А., Полубинский В.Л., Романников Д.О.* Сортировка массива целых чисел с использованием нейронной сети // Научный Вестник НГТУ. – 2016. – № 2 (63). – С. 151–157.
17. *Voevoda A.A., Romannikov D.O.* A binary array asynchronous sorting algorithm with using Petri nets // Journal of Physics: Conference Series. – 2017. – Vol. 803, N 1. – P. 012178.

Воевода Александр Александрович, доктор технических наук, профессор кафедры автоматки Новосибирского государственного технического университета. Основное направление научных исследований – управление многоканальными объектами. Имеет более 200 публикаций. E-mail: ucit@ucit.ru

Романников Дмитрий Олегович, кандидат технических наук, доцент кафедры автоматки Новосибирского государственного технического университета. Основное направление научных исследований – нейронные сети, сети Петри. Имеет более 50 публикаций. E-mail: dmitry.romannikov@gmail.com

DOI: 10.17212/2307-6879-2018-2-101-107

Translation of the neural network in the Petri network*

A.A. Voevoda¹, D.O. Romannikov²

¹ Novosibirsk State Technical University, 20 Karl Marks Avenue, Novosibirsk, 630073, Russian Federation, doctor of Technical Sciences, professor of the automation department. E-mail: ucit@ucit.ru

² Novosibirsk State Technical University, 20 Karl Marks Avenue, Novosibirsk, 630073, Russian Federation, candidate of Technical Sciences, associate professor of the automation department. E-mail: dmitry.romannikov@gmail.com

The article gives an example of the implementation of a neural network with the help of a Petri net, which allows adding asynchrony to the neural network, which is more in line with the work of the human brain and, therefore, can have a perspective for using to solve problems of artificial intelligence. The mathematical apparatus of Petri networks, on the one hand, allows one to simulate the behavior of asynchronous systems, and with another in its structure is quite similar to the structure of neurons, which justifies the choice of Petri nets. An example of the implementation of a neural network for solving the XOR problem is given as a standard problem in the field of machine learning. In the framework of solving this problem, summation functions in the neural network are represented in the transitions where the value of the input labels occurs when the label is transferred to the place. Activation functions are also represented in the form of transitions in which the output arcs call the activation functions (the sigmoid function in this case). It is worth noting that in the simulation, the implemented neural network is only partially asynchronous, in particular, the presence of labels in all the places entering it is required to trigger transitions. This variant of the neural network with the help of Petri nets is not the only one, and in particular, it is also possible to use separate places and marks for modeling the weight coefficients, which will make it possible to train the neural network without modifying its structure. The further direction of the research is the implementation of the procedure for training a neural network with asynchrony.

Keywords: neural networks, Petri nets, artificial intelligence, transformation, activation function, keras, regularization, training

REFERENCES

1. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems 25 (NIPS 2012)*, Lake Tahoe, Nevada, 2012, pp. 1097–1105.
2. Graves A., Mohamed A., Hinton G. Speech recognition with deep recurrent neural networks. *Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP 2013*, Vancouver, Canada, 2013, pp. 6645–6649.

* Received 13 December 2017.

3. Karpathy A., Fei-Fei L. Deep visual-semantic alignments for generating image descriptions. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, vol. 39, pp. 664–676.
4. Haykin S. *Neural networks and learning machines*. 3rd ed. New York, Prentice Hall/Pearson, 2009. 938 p.
5. Goodfellow I., Bengio Y., Courville A. *Deep learning*. Cambridge, MIT Press, 2016. 800 p.
6. Voevoda A.A., Romannikov D.O. Sintez neironnoi seti dlya resheniya logiko-arifmeticheskikh zadach [Synthesis of neural network for solving logical-arithmetic problems]. *Trudy SPIIRAN – SPIIRAS proceedings*, 2017, vol. 54, no. 5, pp. 205–223.
7. Haykin S., Deng C. Classification of radar clutter using neural networks. *IEEE Transactions on Neural Networks*, 1991, vol. 2, pp. 589–600.
8. Hastie T., Tibshirani R., Friedman J. *The elements of statistical learning: data mining, inference, and prediction*. New York, Springer, 2001.
9. Hagan M., Demuth H., Jesús O. A neural network predictive control system for paper mill wastewater treatment. *Engineering Applications of Artificial Intelligence*, 2003, vol. 16 (2), pp. 121–129.
10. Touretzky D.S., Pomerleau D.A. What is hidden in the hidden layers?. *Byte*, 1989, vol. 14, pp. 227–233.
11. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*, 2015, vol. 521, no. 7553, pp. 436–444.
12. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: a simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 2014, vol. 15, pp. 1929–1958.
13. Mahsereci M., Balles L., Lassner C., Hennig P. Early stopping without a validation set. *ArXiv.org*, 2017, arXiv:1703.09580.
14. Prechelt L. Early Stopping – but when? *Neural networks: tricks of the trade*. 2nd ed. Berlin, Heidelberg, Springer, 2012, pp. 53–67.
15. Voevoda A.A., Romannikov D.O. Asinkhronnyi algoritm sortirovki massiva chisel s ispol'zovaniem ingibitornykh setei Petri [Asynchronous sorting algorithm for array of numbers with the use of inhibitory Petri nets]. *Trudy SPIIRAN – SPIIRAS Proceedings*, 2014, iss. 3 (34), pp. 218–232.
16. Voevoda A.A., Polubinsky V.L., Romannikov D.O. Sortirovka massiva tselnykh chisel s ispol'zovaniem neironnoi seti [Sorting the array of integers using a neural network]. *Nauchnyi vestnik Novosibirskogo gosudarstvennogo tekhnicheskogo universiteta – Science bulletin of the Novosibirsk state technical university*, 2016, no. 2 (63), pp. 151–157.

17. Voevoda A.A., Romannikov D.O. A binary array asynchronous sorting algorithm with using Petri nets. *Journal of Physics: Conference Series*, 2017, vol. 803, no. 1, p. 012178.

Для цитирования:

Воевода А.А., Романников Д.О. Трансляция нейронной сети в сеть Петри // Сборник научных трудов НГТУ. – 2018. – № 2 (92). – С. 101–107. – doi: 10.17212/2307-6879-2018-2-101-107.

For citation:

Voevoda A.A. Romannikov D.O. Translyatsiya neironnoi seti v set' Petri [Translation of the neural network in the Petry network]. *Sbornik nauchnykh trudov Novosibirskogo gosudarstvennogo tekhnicheskogo universiteta – Transaction of scientific papers of the Novosibirsk state technical university*, 2018, no. 2 (92), pp. 101–107. doi: 10.17212/2307-6879-2018-2-101-107.