

# **Самоорганизующиеся нейронные сети с добавочными узлами скрытых слоёв как возможность для оптимизации нейронных вычислений и управления автономными устройствами**

**Букреев Евгений Геннадьевич**

*Национальный исследовательский Томский политехнический университет*

*Научный руководитель: Торгаев Станислав Николаевич, кандидат физико-математических наук*

*E-mail: evgenybukreev.rab@gmail.com*

Развитие технологий управления электронными приборами закономерно пришло к потребности создавать нелинейные алгоритмы, реализующие принятие решений не на основе заранее определённых методик, а на основе некоторого набора опытных данных и механизма их анализа. Бурно развивающейся технологией в этом направлении являются искусственные нейронные сети (ИНС, НС или нейросети). В работах [1-7] показаны примеры использования нейронных сетей для управления различными объектами.

В работе [8] раскрываются общие проблемы построения нейросетей. К таковым относятся, например, дилемма смещения и дисперсии; и дилемма выбора между объемом памяти и размером обучающего множества.

Первая проблема решается с помощью априорной информации (которая может быть установлена в процессе предварительного обучения посредством ограниченного выбора разнообразия обучающих примеров), что приводит к специализации нейросети на ограниченном выборе классификационных функций. Данный подход демонстрируется в работах [9-12].

Вторая проблема описывается параметром измерения Вапника-Червоненкиса (VC-измерение) [8,9], который иллюстрирует отношение между количеством различных объектов (или классов) в классификации и суммарным размером обучающей выборки и объёма используемой памяти. Эту проблему можно описать как дилемму выбора между количеством скрытых нейронов – объёмом используемой памяти – и количеством обучающих примеров, которые требуются для достижения требуемого уровня достоверности.

Так как каждый скрытый нейрон хранит в себе информацию о некотором параметре (или совокупности параметров) входного сигнала, для обучающей выборки размера  $N$  существует один оптимум, при котором достигается максимально точное обучение нейросети. В случае, если количество скрытых нейронов окажется меньше этого оптимума, возникает проблема недоопределённости, при которой изъятые из обучающей выборки свойства входного сигнала являются слишком размытыми для принятия точных решений. В противоположной ситуации возникает проблема переопределённости – когда изъятые параметры оказываются слабо связанными с реальными свойствами объекта управления.

На текущий момент не существует методик для точного вычисления размерности нейронной сети. Существуют методики для количественной оценки общих параметров, но, как и любая оценка, они служат отправной точкой для проектирования сети и конечное решение о количестве узлов и их распределении по скрытым слоям ложится на проектировщика сети, опирающегося на свой опыт и тенденции в проектировании.

Обучение и организация ИНС преимущественно состоит из определения набора входных данных; общего количества скрытых нейронов; типа нейронной сети; организации соединений и связей между нейронами; набора обучающих примеров и уровня достоверности выходных данных. Примером служат работы [1-4, 8-15].

При этом к обучающим примерам предъявляется определённый набор требований: примеры должны охватывать весь диапазон возможных состояний системы; примеры должны иметь равномерное распределение по области входных и/или выходных сигналов (то есть, нельзя использовать 100-200 примеров одного рабочего состояния и 5-10 примеров другого рабочего состояния), в противном случае аппроксимирующая функция нейронной сети получит смещение, которого в реальной управляющей функции быть не должно; примеры должны быть валидны и релевантны – например, не стоит включать в обучающую выборку примеры исключительных состояний, которые никогда не встретятся в работе устройства.

Таким образом, составление обучающей выборки является сложным и многогранным этапом проектирования нейросети. В условиях ограниченного количества обучающих примеров, что характерно для управления многокомпонентными уникально настроенными комплексами, размер обучающей выборки является более жёстко ограничивающим условием, чем размер используемой памяти. В связи с

этим, актуальной становится задача определения оптимальной конфигурации нейронной сети, которую нельзя решить оценочными методами на этапе проектирования.

Возможным решением задачи оптимизации структуры является метод организации нейронной сети, при котором она проектируется недоопределённой и в дальнейшем самостоятельно подбирает свой размер, добавляя или убирая нейронные узлы своих скрытых слоёв в процессе настройки на множестве примеров на протяжении ограниченного количества эпох обучения. После получения пакета из нескольких изменений конфигурации, нейросеть определяет градиент изменений ошибки и объёма памяти и вырабатывает следующее направление для изменений своей структуры. Так, используя механизм обратного распространения ошибки, сеть вырабатывает маршрут конфигурации и самоорганизуется, пока градиент изменений не меняет своего направления или градиент ошибки не становится слишком мал относительно градиента памяти.

При таком подходе отсутствует необходимость дескрипции информации узлов скрытых слоёв нейронной сети, задача которой на текущий момент остаётся нерешённой, и процесс конфигурации сети осуществляется стохастическими алгоритмами самой системы.

Список публикаций:

- [1] Bhim Singh, Gaurav Kumar Kasal. *Neural network-based voltage regulator for an isolated asynchronous generator supplying three-phase four-wire loads* // *Electric Power Systems Research*. 2008. Vol. 78, Issue 6. Pp. 985-994.
- [2] Lei Li, Zhizhong Mao. *A direct adaptive controller for EAF electrode regulator system using neural networks* // *Neurocomputing*. 2012. Vol. 82. Pp. 91-98.
- [3] Alberto Pliego Marugan, Fausto Pedro Garcia Marquez, Jesus Maria Pinar Perez, Diego Ruiz-Hernandez. *A survey of artificial neural network in wind energy systems* // *Applied Energy*. 2018. Vol. 228. Pp. 1822-1836
- [4] Moulay Rachid Douiri, Ahmed Essadki, Mohamed Cherkaoui. *Neural Networks for Stable Control of Nonlinear DFIG in Wind Power Systems* // *Procedia Computer Science*. 2018. Vol. 127. Pp. 454-463.
- [5] Asiye Nikseresht, Alireza Nazemi. *A novel neural network for solving semidefinite programming problems with some applications* // *Journal of Computational and Applied Mathematics*. 2019. Vol. 350. Pp. 309-323.
- [6] Daniel A. White, William J. Arrighi, Jun Kudo Seth, E. Watts. *Multiscale topology optimization using neural network surrogate models* // *Computer Methods in Applied Mechanics and Engineering*. 2019. Vol. 346. Pp. 1118-1135.
- [7] Long Jina Shuai, Lic Bin Hu, Mei Liu. *A survey on projection neural networks and their applications*
- [8] Haykin S. *Neural Networks and Learning Machines. Third Edition* // Pearson Education. 2009. P. 937.
- [9] Franco Scarsellia, Ah Chung Tsoib, Markus Hagenbuchnerb. *The Vapnik–Chervonenkis dimension of graph and recursive neural networks* // *Neural Networks*. 2018. Vol. 108. Pp. 248-259
- [10] Conduit B. D., Illston T., Baker S., Vadegadde Duggappa D., Harding S., Stone H. J., Conduit G. J. *Probabilistic neural network identification of an alloy for direct laser deposition* // *Materials & Design*. 2019. Vol. 168.
- [11] Shuo Feng, Huiyu Zhou, Hongbiao Dong. *Using deep neural network with small dataset to predict material defects* // *Materials & Design*. 2019. Vol. 162. Pp. 300-310
- [12] Vahora S. A., Chauhan N. C. *Deep neural network model for group activity recognition using contextual relationship* // *Engineering Science and Technology, an International Journal*. 2019. Vol. 22. Issue 1. Pp. 47-54
- [13] David GT Barrett, Ari S Morcos, Jakob H Macke. *Analyzing biological and artificial neural networks: challenges with opportunities for synergy?* // *Current Opinion in Neurobiology*. 2019. Vol. 55. Pp. 55-64.
- [14] Bärtschi P., Galloni C., Lange C., Kilminster B. *Reconstruction of lepton pair invariant mass using an artificial neural network* // *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*. 2019. Vol. 929. Pp. 29-33
- [15] Ahmed Tealab. *Time series forecasting using artificial neural networks methodologies: A systematic review* // *Future Computing and Informatics Journal*. 2018. Vol. 3. Issue 2. Pp. 334-340

## **Устройство стабилизации температуры контейнеров с рабочим веществом для высокочастотных активных сред на парах металлов**

**Букреев Евгений Геннадьевич<sup>1</sup>**

*Мусоров Илья Сергеевич*<sup>1</sup>

*Торгаев Станислав Николаевич*<sup>1,2</sup>

<sup>1</sup>Национальный исследовательский Томский политехнический университет

<sup>2</sup>Национальный исследовательский Томский государственный университет

Научный руководитель: Евтушенко Геннадий Сергеевич, д.т.н.

E-mail: evgenybukreev.rab@gmail.com

Высокочастотные активные среды на парах металлов используются в науке и технике, например, в качестве скоростных усилителей яркости для визуализации объектов и быстропротекающих процессов в условиях мощной фоновой засветки [1-5]. Системы автоматического управления используются в