

## ПЛЕНАРНЫЕ ДОКЛАДЫ

С.В. Безобразов, В.А. Головки  
Беларусь, Брест, БрГТУ

**ПРИМЕНЕНИЕ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА  
В СОВРЕМЕННЫХ НАУЧНЫХ И ИНЖЕНЕРНЫХ ЗАДАЧАХ**

Искусственные нейронные сети (ИНС) являются мощным инструментом и с успехом применяются для решения многих современных сложных инженерных и научных задач. В последнее время ИНС приобретают доминирующие позиции в области искусственного интеллекта. Это подтверждается значительными успехами в задачах обработки видео, изображений, распознавания голоса, обработки больших массивов данных, визуализации, робототехники и т.д. Эти достижения в основе своей ассоциируются с появлением новой парадигмы в области машинного обучения, известной как нейронные сети глубокого доверия. В данной статье речь пойдет об одной архитектуре нейронных сетей глубокого доверия – сверточной нейронной сети.

Сверточная нейронная сеть (известная как Convolutional Neural Network, CNN) – это специальная архитектура искусственных нейронных сетей, предложенная Лекуном (Yann LeCun) [1], являющаяся дальнейшим развитием многослойного перцептрона и неокогнитрона (Neocognitron), предложенного, в свою очередь, Кунишикой Фукусимой (K. Fukushima) [2]. Основная область применения сверточных нейронных сетей – обработка изображений. Основной идеей сверточных нейронных сетей является чередование сверточных слоев (convolution allayers) и субдискретизирующих слоев (subsampling layers или pooling layers – слои подвыборки), которые обеспечивают нелинейную иерархическую трансформацию пространства входных данных. Последним блоком сверточной нейронной сети может быть как многослойный перцептрон, так и другой классификатор. Типовая структура сверточной нейронной сети изображена на рисунке.




Рисунок – Типовая структура сверточной нейронной сети

Сверточный слой является основным блоком сверточной нейронной сети и суммирует результаты матричного произведения для каждого фрагмента обрабатываемого изображения [3]. За сверточным слоем обычно следует блок линейной ректификации (rectified linear unit, ReLU), который представляет собой функцию активации после сверточного слоя. Для активации выбирается ненасыщаемая функция вида

$$f(x) = \max(0, x),$$

которая отвечает за отсеивание ненужных деталей на изображении [4].

Слой пулинга (или подвыборки, субдискретизации) выполняет нелинейное уплотнение карты признаков, как правило используя для этого функцию максимума и позволяя существенно уменьшить пространственный объем изображения [5].

После последней операции свертки данные подаются на классификатор – обычную полносвязную нейронную сеть, в качестве которой, как вариант, может использоваться многослойный перцептрон.

#### СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Gradient-based learning applied to document recognition / Y. LeCun [et al.] // Proceedings of the IEEE. – 1998. – Vol. 86, № 11. – P. 2278–2324.
2. Fukushima, K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position / K. Fukushima // Biological Cybernetics. – 1980. – Vol. 36, № 4. – P. 193–202.
3. Golovko, V. Deep neural networks: a theory, application and new trends / V. Golovko // Proceedings of the 13th International Conference on Pattern Recognition and Information Processing (PRIP2016). – Minsk : BSU, 2016. – P. 33–37.
4. Golovko, V. Theoretical notes on unsupervised learning in deep neural networks / V. Golovko, A. Kroschanka // Proceedings of the 8-th International Joint Conference on Computational Intelligence (NCTA2016), Porto (Portugal), 9–11 November 2016. – Porto, 2016. – P. 91–96.
5. Golovko, V. The nature of unsupervised learning in deep neural networks: a new understanding and novel approach / V. Golovko, A. Kroschanka // Optical memory and neural networks. – 2016. – Vol. 25, № 3. – P. 127–141.

**В.М. Волков, Е.В. Прокопчина**  
Беларусь, Минск, БГУ

#### РАЗНОСТНЫЕ СХЕМЫ И ИТЕРАЦИОННЫЕ МЕТОДЫ ДЛЯ МНОГОМЕРНЫХ ЭЛЛИПТИЧЕСКИХ УРАВНЕНИЙ СО СМЕШАННЫМИ ПРОИЗВОДНЫМИ

Проведен сравнительный анализ двух разностных схем для двумерных эллиптических уравнений со смешанными производными – консервативной монотонной разностной схемы [1; 2] и разностной схемы, предложенной в работе [3] (будем обозначать их как схемы I и II соответственно). Как было показано ранее [3], в случае гладких коэффициентов данные схемы имеют приблизительно одинаковые вычислительные качества, однако при решении задач с разрывными, сильно неоднородными коэффициентами схема II демонстрирует заметные преимущества при реализации, обеспечивая более высокую скорость сходимости итераций.

Рассмотрена модельная задача:

$$\frac{\partial}{\partial x} \left( \sigma_{xx} \frac{\partial u}{\partial x} + \sigma_{xy} \frac{\partial u}{\partial y} \right) + \frac{\partial}{\partial y} \left( \sigma_{yx} \frac{\partial u}{\partial x} + \sigma_{yy} \frac{\partial u}{\partial y} \right) = f(x, y), \quad |x| < 1, \quad |y| < 1, \quad u(x, y)|_{\Gamma} = 0. \quad (1)$$

Внутри квадратной области с изотропной однородной средой  $\sigma_{xx} = \sigma_{yy} = 1$ ,  $\sigma_{xy} = \sigma_{yx} = 0$  задана кольцевая подобласть  $\Theta$ , в которой тензор диффузии определяется следующим образом: