

**ИСПОЛЬЗОВАНИЕ «ГЛУБОКОГО ОБУЧЕНИЯ»
В ЗАДАЧАХ СОКРАЩЕНИЯ РАЗМЕРНОСТИ**

А. Ю. Благодарёв, аспирант,

Запорожский национальный технический университет
alexus85@gmail.com

А. А. Олейник, канд. техн. наук, доцент.,

Запорожский национальный технический университет
olejnika@gmail.com

С. А. Субботин, докт. техн. наук, проф.,

Запорожский национальный технический университет
subbotin@zntu.edu.ua

*Рассмотрено использование технологии «глубокого обучения»
для решения задачи сокращения размерности данных.
Предложен модифицированный метод для сокращения времени
обучения сети глубокого обучения.*

*Blagodaryov A. U., Oliynyk A. A., Subbotin S. A. Using “Deep
learning” in dimensionality reduction tasks. In the article reviewed
The Deep Learning architecture is addressed for the dimensionality
reduction problems. The modified method for decrease the deep
network training time is proposed.*

Ключевые слова: ИСКУССТВЕННАЯ НЕЙРОННАЯ
СЕТЬ, ГЛУБОКОЕ ОБУЧЕНИЕ, СОКРАЩЕНИЕ
РАЗМЕРНОСТИ.

Keywords: ARTIFICIAL NEURAL NETWORK, DEEP
LEARNING, DIMENSIONALITY REDUCTION.

Рост объема и разнообразия данных, а также требований к скорости их обработки увеличиваются с каждым днём. Осмысление этой тенденции привело в 2008 году даже к появлению специального термина «Большие Данные». Основная
Computer Sciences and System Sciences (CS&SS-2016)

сложность в области «Больших Данных» кроется не только в масштабах затрат и усилий на работу с ними, но и в том, чтобы суметь получить от этих затрат достаточно пользы. Для этого разрабатываются и используются технологии по сокращению размерности данных с целью сокращения вычислительных затрат и извлечения полезных свойств из данных [1, 2].

Жизнеспособность метода сокращения размерности зависит не только на его производительности, но также от того, насколько легко он может быть реализован и использован в различных областях. Простым и широко используемым методом является метод главных компонент (principle component analysis – PCA). Но PCA недостаточно, чтобы захватить нелинейные распределения данных [2].

Развитие в последние десятилетия искусственных нейронных сетей привело к появлению новых технологий, которые успешно используются и показывают хорошие результаты в данном направлении.

Одной из таких технологий является "глубокое обучение" – разновидность машинного обучения, которое реализуется с помощью специальных архитектур искусственных нейронных сетей, таких, например, как Deep Belief Network (DBN). DBN – это вероятностная генеративная модель, которая состоит из нескольких слоев стохастических скрытых переменных, каждый слой захватывает корреляции высокого порядка между деятельностью скрытых особенностей в расположенном ниже слое. В данной архитектуре соединения есть между слоями, но не между элементами в пределах одного слоя [1–3]

Основным строительным блоком DBN является двудольная неориентированная графическая модель, называемая Restricted Boltzmann Machine (RBM), т.е. DBN можно рассматривать как композицию простых модулей обучения (RBM), каждый из которых содержит слой видимых элементов (данные) и слой скрытых элементов, которые обучаются представлять особенности данных, захватывая связи более высокого порядка [4, 5].

Недостатком DBN в задачах сокращения размерности являются значительные затраты времени на обучение сети при Computer Sciences and System Sciences (CS&SS-2016)

наличии большого количества скрытых слоёв и элементов в каждом таком слое.

Для сокращения времени обучения сети предлагается в каждом скрытом слое сети использовать группы взаимно независимых областей кластеризации, имеющих k выходных элементов, каждый из которых, в свою очередь, представляет один кластер, выходные элементы всех кластеров конкатенируются во вход более высокого слоя.

Данный подход является простым в реализации и сокращает необходимое количество скрытых элементов в более высоких слоях.

Необходимо отметить, что параметр k должен был максимально большой на нижних слоях и уменьшаться при переходе к более высоким слоям сети.

Дальнейшие исследования целесообразно сосредоточить на разработку и исследование параллельных реализаций предложенного метода.

Литература

1. Deng, L. Deep Learning: Methods and Applications / L. Deng, Y. Dong // Foundations and Trends in Signal Processing vol. 7. – 2014. – № 3–4. – P. 197-387.

2. Yoshua B. Learning Deep Architectures for AI / B. Yoshua // Foundations and Trends in Machine Learning vol. 2. – 2009. – №. 1. – P. 1-127.

3. Salakhutdinov R. Learning deep generative models [Electronic resource] : / Diss. University of Toronto, Dept. of Computer Science. – Thesis, 2009. – Access mode http://www.utstat.toronto.edu/~rsalakhu/papers/Russ_thesis.pdf

4. Salakhutdinov R. Deep Boltzmann machines / R. Salakhutdinov, G. E. Hinton // Proceedings of The Twelfth International Conference on Artificial Intelligence and Statistics (AISTATS'09). – 2009. – Vol. 5. – P. 448–455.

5. Hinton G. E. A fast learning algorithm for deep belief nets / G. E. Hinton, E. Osindero, Y. Teh // Neural Computation. – 2006. – Vol. 18. – P. 1527–1554.