



3. Гонсалес Р., Вудс Р. Цифровая обработка изображений / Перев. с англ. — М.: Техносфера, 2006. — 1070 с.
4. Гонсалес, Р. «Цифровая обработка изображений» [Текст] / Р. Гонсалес, Р. Вудс - М.: «Техносфера», 2005. - 1073 с.
5. Гонсалес, Р. Цифровая обработка изображений / Р. Гонсалес, Р. Вудс: пер. с англ. под ред. П. А. Чочиа. — М.: Техносфера, 2006. - 1072 с. — ISBN 5-94836-028-8.

Д.В. Безруков, И.М. Куликовских

## МОДЕЛЬ ДОЛГОВРЕМЕННОЙ ПАМЯТИ НЕОКОГНИТРОНА

(Самарский национальный исследовательский университет  
им. академика С.П. Королева)

В 1980 году Кунихико Фукусима представил неокогнитрон, нейронную сеть прямого распространения, способную распознавать рукописные цифры, а в 1988 году опубликовал документ, описывающий реализованный и функциональный экземпляр Неокогнитрона. Сеть основана на результатах Хьюбеля и Вайзеля, согласно которым существует 2 типа клеток в первичной зрительной коре: S-типа и C-типа (простые и сложные соответственно). Клетки S-типа используются для выявления локальных признаков, а клетки C-типа используются для компенсации искажений. Локальные признаки обобщаются поэтапно от более простых к более сложным.

Существуют различные модификации неокогнитрона – включение в сеть дополнительных слоев, модификация позволяющая проводить обучение с учителем [1,2], модификация двойного порогового значения и многие другие. В данной статье будет предложен вариант добавления в модель неокогнитрона модуля памяти. Такая модификация неокогнитрона позволит применять его для данных, в которых важны такие возможности модели как:

- Устойчивое распознавание образов
- Обработка последовательных данных

Примером таких данных являются:

- Распознавание образов на видео [3]
- Временные ряды (финансовые данные) [4, 5]
- Распознавание рукописного текста в режиме online

### Задача

Построить математическую модель для классификации, соединяющую в себе искусственную нейронную сеть сверточного типа неокогнитрон для распознавания локальных признаков, а также модуль долгосрочной памяти.



## Архитектура

На рис. 1 изображена архитектура неокогнитрона, она состоит из слоя входных данных  $U_0$  и последовательных пар слоев S-типа и C-типа. Слой S-типа состоит из плоскостей S-типа, каждая из которых отвечает за распознавание определенного локального признака. Слой C-типа состоит из плоскостей C-типа, каждая из которых обеспечивают инвариантность относительно позиции шаблона внутри его чувствительной области. C-плоскости последнего слоя реализуют функцию распознавания итогового образа. Например, в случае распознавания цифр, каждая из 10 C-плоскостей будет отвечать за конкретную цифру.




Рисунок 1 – Архитектура неокогнитрона

## Модели памяти

В качестве модели памяти в принято использовать различные варианты рекуррентных нейронных сетей. Благодаря наличию обратных связей данный вид сетей подходит для обработки серии событий во времени.

Примеры рекуррентных нейронных сетей:

- сеть Элмана
- сеть Хопфилда
- сеть Хемминга
- LSTM
- GRU
- NARX

Наибольшее распространение на практике получили сети LSTM и GRU [6].

## Итоговая архитектура сети

Как описано выше, итоговое распознавание в традиционном неокогнитроне происходит в последней паре состоящей из S- и C-слоя нейросети. Этот слой будет заменен на модуль памяти. Итоговая архитектура сети изображена на рисунке 2.

Из-за того, что блок памяти встраивается после основной части неокогнитрона, и традиционный неокогнитрон может быть обучен для распознавания



образов при помощи самоорганизации, то обучение этих двух частей может происходить независимо. Таким образом задача разбивается на 2 части:

1. Обучить традиционный неокогнитрон для распознавания образов
2. Обучить модуль памяти используя полученные образы и маркировку исходных данных

Такой подход имеет как преимущества, так и недостатки – к преимуществам можно отнести изолированность модуля памяти, что позволит использовать различные варианты не переобучая основную сеть, что может быть критично при обучении на большой выборке данных, к недостаткам же можно отнести то, что при обучении неокогнитрона не учитываются особенности выбранного модуля памяти, что может приводить к потенциальной потере точности.




Рисунок 2 – Архитектура неокогнитрона с долгосрочной памятью

## Результаты

В качестве данных используются исторические данные о торгах пары Bitcoin/JPY за период с 04.07.2017 по 08.01.2018 с интервалом в минуту. На базе этих данных при помощи модифицированного неокогнитрона будет проводиться UP/DOWN классификацию. Для каждого момента времени данные содержат кортеж данных:

- *Open* – цена на момент открытия
- *High* – наибольшая цена во время торгов
- *Low* – наименьшая цена во время торгов
- *Close* – цена на момент закрытия
- *Volume (BTC)* – объем продаж в BTC
- *Volume (JPY)* – объем продаж в валюте (JPY)
- *Weighted price* – средневзвешенная цена во время торгов

В качестве меток для данных будем использовать синтетические параметры up – если цена на следующем временном интервале будет выше текущей, или down – если наоборот ниже. Наборы данных генерируются при помощи метода скользящего окна.



В таблице 1 указаны результаты тестирования классического и модифицированного неокогнитрона, а также подобную вариацию для сверточной нейронной сети [7].

Исходя из полученных результатов можно наблюдать, что добавление модуля памяти, привело к увеличению точности классификации. Также из результатов наблюдается больший рост при добавлении LSTM к CNN. Причиной этому может быть как и описано выше, что сеть CNN+LSTM обучается как единое целое, так и то, что CNN для обучения использует метод обратного распространения ошибки.

Таблица 1 – Результаты обучения

Модель	Результат (Accuracy)
Neocognitron	52.13%
Neocognitron + LSTM	54.32%
CNN	54.37%
CNN + LSTM	57.21%

### Благодарности

Работа выполнена при поддержке гранта Президента РФ № МК-6218.2018.9.

### Литература

- [1] Kunihiro Fukushima *Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition* Biological Cybernetics 1980
- [2] Kunihiro Fukushima *Neocognitron capable of incremental learning* Elsevier 2003
- [3] Jeff Donahue, Lisa Anne Hendricks, Marcus Rohrbach, Subhashini Venugopalan, Sergio Guadarrama, Kate Saenko, Trevor Darrell *Long-term Recurrent Convolutional Networks for Visual Recognition and Description*, 2016
- [4] Nima Hatami, Yann Gavet and Johan Debayle *Classification of Time-Series Images Using Deep Convolutional Neural Networks* 2017
- [5] Yi Zheng, Qi Liu, Enhong Chen, Yong Ge, and J. Leon Zhao, *Time Series Classification Using Multi-Channels Deep Convolutional Neural Networks* Springer International Publishing Switzerland 2014
- [6] Understanding LSTM Networks (2015)  
URL: <http://colah.github.io/posts/2015-08-Understanding-LSTMs> (Дата обращения 19 марта 2018)
- [7] Tara N. Sainath, Oriol Vinyals, Andrew Senior, Hasim Sak, *Convolutional, long short-term memory fully connected deep neural networks* IEEE International Conference on Acoustics, Speech and Signal Processing 2015