



Электронное научное издание
«Ученые заметки ТОГУ»
2016, Том 7, № 1, С. 184 – 189

Свидетельство
Эл № ФС 77-39676 от 05.05.2010
[http://pnu.edu.ru/ru/ejournal/about/
ejournal@pnu.edu.ru](http://pnu.edu.ru/ru/ejournal/about/ejournal@pnu.edu.ru)

УДК 684.511

© 2016 г. В. С. Тормозов

(Тихоокеанский государственный университет, Хабаровск)

ИССЛЕДОВАНИЕ НЕЙРОННЫХ СЕТЕЙ ПАМЯТИ

Статья посвящена нейронным сетям памяти (NMN). Проведено исследование возможности этой нейронной сети классифицировать разрозненные образы. Дано сравнение погрешности классификации образов при помощи FNN, NMN и RNN сетей.

Ключевые слова: нейронные сети, искусственный интеллект.

V. S. Tormozov

NEURAL MEMORY NETWORK RESEARCH

Article is devoted to neural networks of memory (NMN). Research of possibility of this neural network to classify separate images is conducted. Comparison of an error of classification of images by means of FNN, NMN and RNN networks is given.

Keywords: neural networks, artificial intelligence.

Введение

В условиях неопределенности, при разработке систем интеллектуальных классификаций немаловажную роль играет контекст. Довольно часто для адекватной работы системы классификации необходимо использовать информацию о прошлых состояниях системы. Для нейронных сетей, контекст выводится в виде информации из входного вектора и обученных весовых коэффициентах [3]. Помимо этого, контекст может также содержаться в специальном буфере памяти для хранения предыдущих значений входного вектора, откуда он может быть извлечен и использован при очередном проходе сигнала через сеть.

Для зашумленных аналоговых сигналов, узлы первого слоя, использующие буфер памяти, с гауссианой как функцией активизации могут быть использованы для предварительной обработки и фильтрации данных.




Рис. 1. Архитектура нейронной сети прямого распространения с буфером памяти

На рисунке 1 изображена схема нейронной сети прямого распространения с использованием буфера памяти.

Эта архитектура может быть использована для предсказания следующей последовательности в зашумленном синусоидальном сигнале. Значения 10 предыдущих входов сохраняются в буфер памяти. Сеть обучается по одной синусоиде (учебная выборка), затем проверяется с суммой трех синусоид переменных частот. Погрешность обучения составила приблизительно 10%, погрешность тестирования - 15%. Графики погрешности при обучении и тестировании изображены на рисунке 2. Графики входного и выходного сигналов показаны на рисунке 3.

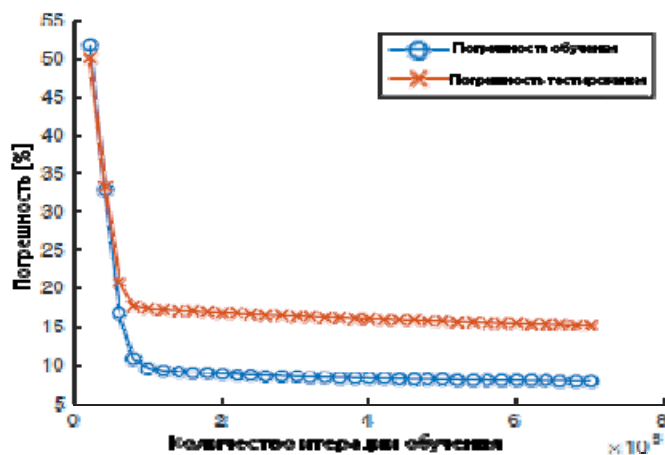


Рис. 2. График погрешности

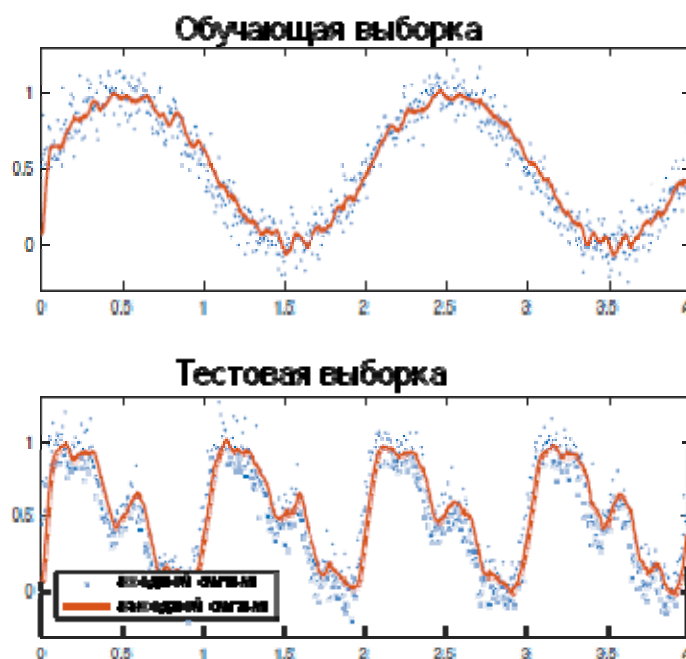


Рис. 3. Сигналы

Сетевые архитектуры с задержкой входов и/или дополнительных входов, взятых из буфера памяти, могут быть полезными инструментами, однако они ограничены по функциональности, так как архитектура буфера памяти predetermined и тривиальна. Более мощная архитектура памяти может хранить память во внутренних слоях сети, что позволяет сети настраиваться посредством использования буферов памяти с командами чтения и записи.

Связанные исследования

Нейронные сети впервые были введены более 60 лет назад в качестве одного из первых алгоритмов машинного обучения. Рекуррентные нейронные сети (RNN) были изобретены в 1980-х, чтобы улучшить процесс последовательных входов, поддерживая внутреннее состояние между входами. Нейронные сети LSTM улучшили RNN в конце 1990-х годов, добавив логические выходы для чтения, записи и стирания внутреннего состояния памяти. Недавно Graves [4] опубликовали работу, в которой они реализовали алгоритм, называемый NTM. NTM алгоритм имеет структуры памяти, которым доступны команды чтения, записи, и стирания данных. Они запустили несколько тестов на своих NTM, один из которых учил сеть последовательности чисел. Они обучили свою сеть последовательностью двадцати 8-битных чисел и проверили последовательностью 120 тестов с хорошими результатами. При таком подходе увеличение памяти может быть достигнуто не только путем изменения весовых коэффициентов, но и сохранением обучаемой информации и в структурах памяти. Примерно в то же время, Weston [1] определил рамки для нейронных сетей для взаимодействия с внешней памятью, для чтения и записи из долговременной памяти. В этой статье Уэстон реализует RNN с памятью для текстовой обработки истории, в которой несколько действующих лиц перемещаются между комнатами, неся и передвигая объекты. С использованием буферов памяти их сеть выигрывала у подобных RNN и LSTM сетей без доступа памяти при запросе о отдаленных прошлых данных.

Постановка задачи

Архитектура нейронной сети памяти состоит из нейронной сети прямого распространения со специальным внутренним банком памяти, связанным с каждым стандартным нейроном в каждом из скрытых слоев. Слои входа и выхода составлены только из стандартных узлов, в то время как скрытые слои составлены из стандартных узлов с их соответствующими банками памяти. Выход каждого узла задается сигмовидной функцией комбинации его входов. Выход узла используется в качестве линейного переключателя, чтобы активировать память, ассоциированную данному узлу. Такая нейронная сеть может учиться извлекать воспоминания из банков памяти по мере необходимости. На рисунке 4 показана общая схема сети для простой памяти нейронной сети.




Рис. 2. Общая схема сети для простой памяти нейронной сети

Нейронная сеть памяти имеет входные и выходные слои, состоящие из стандартных узлов и скрытых слоев, которые в свою очередь состоят из стандартных узлов и узлов памяти. Узлы скрытых слоев имеют сигмоидальную функцию активизации. Каждый узел в скрытом слое связан с банком памяти, и каждый банк памяти составлен из множества буферов памяти. Выходы узлов используются в качестве переключателей, чтобы активировать память при необходимости.

Обучение и тестирование алгоритма состоит из трех основных этапов:

1. Прямое распространение входных данных через каждый слой сети.
2. Обучение сети с помощью алгоритма обратного распространения ошибки.
3. Хранение памяти в каждом слое соседнего выхода нейрона, как ортогональный набор в многомерном пространстве.

Прямое распространение

Вектор состояния вывода для стандартных узлов каждого слоя увеличивается с выходом узлов памяти слоя. Выход каждого узла памяти это содержание того места памяти и выхода узла, к которому он соотнесен. При таком подходе узел выступает в роли линейного переключателя, чтобы включать и отключать память в зависимости от значения выходы данного узла. Узлы скрытого слоя получают входной сигнал от узлов предыдущего слоя, в то время, как узлы памяти воспринимают входной сигнал только от узла с которым они соотнесены [6].

Обратное распространение ошибки

Обучение с использованием алгоритма обратного распространения ошибки для нейронной сети памяти аналогично обучению сети прямого распространения с использованием одноименного алгоритма [2].

Архитектура памяти

Каждый узел в скрытых слоях содержит статический банк памяти. Каждое уникальное воспоминание в узле является ортогональным ко всем другим воспоминаниям в этом узле. Набор из воспоминаний представлен в виде одного вектора в многомерном пространстве и называется составной памятью. Направление вектора указывает, какие воспоминания присутствуют, а величина вектора при проекции на оси каждого воспоминания определяет порядок, в котором они произошли [5]. Новая память создается ортогональным отображением выходного узла и соседом. Ближайшие соседи могут быть определены в пространственном смысле, то есть быть узлами в том же самом слое с близкими индексами, или они могут также быть определены так, чтобы включать узлы в предыдущие и будущие слои.

Результаты

Набор данных состоит из выборки от 8 случайно сгенерированных многомерных гауссовских распределений, с целью классифицировать от какого распределения была взята конкретная точка. Также были протестированы: нейронная сеть прямого распространения и рекуррентная нейронная сеть RNN аналогичной архитектуры: с тем же количеством узлов на каждом слое, с одной задержкой по обратной связи. Классификационная погрешность RNN сети составила 1.9%. Результаты сходимости показаны на рисунке 5.




Рис. 3. Сравнение погрешностей сходимости между FNN, NMN и RNN сетями для задачи классификации демонстрирует способность NMN сетей использовать временные закономерности в исходных данных

Заключение

Мною был разработан и продемонстрирован алгоритм нейронной сети прямого распространения, которая хранит память, связанную со скрытыми слоями нейронов. Данный тип нейронной сети показывает хорошие результаты классификации и распознавания образов по сравнению с сетями прямого распространения (FNN) и рекуррентными нейронными сетями (RNN). Преимущество NMN сети в том, что она использует блоки памяти, ассоциированные с каждым узлом внутреннего слоя, что позволяет сохранять контекст при вычислении шаблонов распознавания.

Список литературы

- [1] Weston, Jason, Antoine Bordes, Sumit Chopra. Memory networks. // arXiv conference - 2014.
- [2] Esteban M. D. Perceptrons: An Associative Learning Network //Virginia Tech. - 1997.
- [3] Hopfield J. J. Neural networks and physical systems with emergent collective computational abilities // Proceedings of National Academy of Sciences. — April 1982.
- [4] Graves, Alex, Ivo Danihelka, Greg Wayne. Neural Turing Machines. // arXiv conference — 2014.
- [5] Schmidhuber J., Wierstra D., Gagliolo M., Gomez F. Training Recurrent Networks by Evolino. // Neural Computation, 19(3): - 2007. - P.757–779.
- [6] Hochreiter S., Bengio Y., Frasconi P., and Schmidhuber J. Gradient flow in recurrent nets: the difficulty of learning long-term dependencies. // A Field Guide to Dynamical Recurrent Neural Networks. IEEE Press. - 2001.

E-mail:

Тормозов В. С. - knight_vova@mail.ru