

Результаты анализа спектральных характеристик рассмотренных дискретных моделей представлены на рисунке.




Рисунок. – Зависимости погрешностей передаточных функций модели цифровой фильтрации (3) – (а) и разностной схемы (2) – (б) от параметра p и шага по времени τ соответственно. Пунктирной линией отмечены характеристики схемы повышенного порядка точности

Как видно из рисунка а), посредством выбора оптимального значения параметра p погрешность передаточной функции схемы (3) может быть многократно уменьшена (приблизительно в четыре раза) по сравнению со схемой четвертого порядка точности (2). Более того, значение шага по времени, которое определено выражением (4), является оптимальным для схемы (2).

Полученные результаты определяют оптимальное соотношение шагов сетки и условия наилучшего спектрального разрешения для разностной схемы (2) в заданном частотном диапазоне.

СПИСОК ЛИТЕРАТУРЫ

1. Самарский, А. А. Теория разностных схем / А. А. Самарский. – М. : Наука, 1989. – 616 с.
2. Волков, В. М. Метод дробных шагов с использованием рекурсивных цифровых фильтров для решения нелинейных уравнений Шредингера / В. М. Волков, Ф. С. Циунчик // Докл. НАН Беларуси. – 2009. – Т. 53, № 5. – С. 22–26.
3. Lele, S. K. Compact finite difference schemes with spectral-like resolution / S. K. Lele // Journal of Computational Physics. – 1992. – Vol. 103, no. 1. – P. 16–42.

В.А. ГОЛОВКО

БрГТУ (г. Брест, Беларусь)

ГЛУБОКОЕ ОБУЧЕНИЕ НЕЙРОННЫХ СЕТЕЙ: ТЕОРИЯ И ПРИМЕНЕНИЕ

Введение. Долгое время в научной среде была приоритетной парадигма, что многослойный перцептрон с одним или двумя скрытыми слоями является более эффективным для нелинейного преобразования входного пространства образов в выходное, чем перцептрон с большим количеством скрытых слоев.

В 2006 году Хинтон (Hinton) предложил «жадный» алгоритм послойного обучения (greedy layer-wise algorithm) [1], который стал эффективным средством обучения нейронных сетей глубокого доверия (DBNN) [1–3]. Было показано, что нейронная сеть глубокого доверия имеет большую эффективность нелинейного преобразования и представления данных по сравнению с традиционным перцептроном. В данной статье предлагается новый метод обучения DBNN. По сравнению с традиционным подходом, который базируется на линейном представлении нейронных элементов, предложенный метод REVA [4; 5] позволяет учитывать нелинейную природу нейронных элементов. Данный метод основывается на минимизации средне-квадратичной ошибки реконструкции в скрытом и видимом слоях ограниченной машины Больцмана (RBM). Приводится теорема, доказывающая, что классическое правило для обучения ограниченной машины является частным случаем предложенного метода.

Глубокое обучение и ограниченная машина Больцмана. Процесс обучения DBNN в общем случае состоит из двух этапов: 1. Предобучение нейронной сети методом послойного обучения начиная с первого слоя (pre-training). Данное обучение осуществляется без учителя на основе RBM [3]. В результате такого обучения можно получить подходящую начальную инициализацию параметров сети. 2. Настройка синаптических связей всей сети (fine-tuning) при помощи алгоритма обратного распространения ошибки или алгоритма «бодрствования и сна» (wake-sleep algorithm).

Рассмотрим ограниченную машину Больцмана, которая состоит из двух слоев – видимого и скрытого (рисунок 1).




Рисунок 1. – Ограниченная машина Больцмана

Дж. Хинтон [1; 2] предложил использовать метод контрастной дивергенции (contrastive divergence, CD) для обучения RBM. Он базируется на сэмплеваннии Гиббса. В случае CD-k правила обучения определяются следующим образом:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(x_i(0)y_j(0) - x_i(k)y_j(k)),$$

$$T_i(t+1) = T_i(t) + \alpha(x_i(0) - x_i(k)), \quad T_j(t+1) = T_j(t) + \alpha(y_j(0) - y_j(k)).$$

где w_{ij}, T_i, T_j – весовые коэффициенты, пороговые элементы визуального и скрытого слоя RBM соответственно.

В этом случае первые слагаемые в правилах обучения характеризуют распределение данных в момент времени $t=0$, а вторые слагаемые

характеризуют реконструированные или генерируемые моделью состояния в момент времени $t = k$. Здесь α – скорость обучения. Из последних выражений видно, что правило обучения ограниченной машины Больцмана минимизирует разницу между оригинальными данными и данными, генерируемыми моделью.

Глубокое обучение: новый подход. Рассмотрим ограниченную машину Больцмана, которую будем представлять в виде трех слоев нейронных элементов [4; 5]: видимый, скрытый и видимый (рисунок 2).




Рисунок 2. – Представление RBM в виде рециркуляционной нейронной сети

Целью обучения ограниченной машины Больцмана является минимизация суммарной квадратичной ошибки реконструкции данных на скрытом и восстанавливающем слое, которая в случае CD-k определяется следующим образом:

$$E_s = \frac{1}{2} \sum_{l=1}^L \sum_{j=1}^m \sum_{p=1}^k (y_j^l(p) - y_j^l(p-1))^2 + \frac{1}{2} \sum_{l=1}^L \sum_{i=1}^n \sum_{p=1}^k (x_i^l(p) - x_i^l(p-1))^2,$$

где L – количество входных образов. Можно доказать следующую теорему [5].

Теорема 1. Максимизация функции правдоподобия распределения данных $P(x)$ в пространстве синаптических связей ограниченной машины Больцмана эквивалентна минимизации суммарной квадратичной ошибки сети в том же пространстве при использовании линейных нейронов.

Следствие. Для нелинейной ограниченной машины Больцмана правило модификации синаптических связей в случае CD-k будет следующим:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha \left(\sum_{p=1}^k (y_j(p) - y_j(p-1)) k_i(p) F'(s_j(p)) + (x_i(p) - x_i(p-1)) y_j(p-1) F'(s_i(p)) \right)$$

Эксперименты. Для того чтобы проиллюстрировать эффективность предложенного подхода, рассмотрим задачу визуализации рукописных цифр на основе выборки MNIST. Выборка MNIST содержит 60 000 образов рукописных цифр для обучения и 10 000 образов для тестирования. Каждый образ представляет собой изображение 28X28 пикселей в градациях серого. Для отображения 784-мерных образов в двумерное пространство признаков использовался глубокий автоэнкодер с топологией 784-1000-500-250-2. Визуализация выборки MNIST, выполненная на основе глубокого автоэнкодера, представлена на рисунке 3.




Рисунок 3. – Визуализация рукописных цифр

СПИСОК ЛИТЕРАТУРЫ

1. Hinton, G. Reducing the dimensionality of data with neural networks / G. Hinton, R. Salakhutdinov // *Science*. – 2006. – no. 313 (5786). – P. 504–507.
2. Hinton, G. A fast learning algorithm for deep belief nets / G. Hinton, S. Osindero, Y. Teh // *Neural Computation*. – 2006. – no. 18. – P. 1527–1554.
3. Bengio, Y. Learning deep architectures for AI / Y. Bengio // *Foundations and Trends in Machine Learning*. – 2009. – no. 2 (1). – P. 1–127.
4. A Learning Technique for Deep Belief Neural Networks / V. Golovko [et al.] // *Neural Networks and Artificial Intelligence*. – Springer, 2014. – Vol. 440 : Communication in Computer and Information Science. – P. 136–146.
5. Головки, В. А. От многослойных перцептронов к нейронным сетям глубокого доверия: парадигмы обучения и применение / В. А. Головки // XVII Всероссийская научно-техническая конференция «Нейро-информатика–2015» : лекции по нейро-информатике. – М. : НИЯУ МИФИ, 2015. – С. 47–84.

А.В. ЛИФЕНЕЦ

ИООО «ЭРИКПОЛЬ БРЕСТ» (г. Брест, Беларусь)

ПОДХОДЫ К РАЗРАБОТКЕ ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ

Разработка программного обеспечения (ПО) является одной из самых передовых промышленных сфер. Аппаратная часть современных устройств давно стала вторичной по отношению к наиболее важной составляющей – программным возможностям.

Создание программ – это крупный рынок, вмещающий в себя многих игроков. Как и в любой другой сфере, чтобы быть наиболее привлекательным на рынке, компании стараются искать самые эффективные подходы к созданию ПО.

Объем и сложность программ требуют создания команд разработчиков. Члены таких команд могут отвечать за различные части продукта, распределять между собой роли и обязанности относительно своих компетенций (команда те-