

Алгоритм обучения сети в задачах классификации всегда является обучением с учителям. Переданным по каналам связи сообщениям задаются ожидаемые результаты в соответствии от системы кодирования выходных значений.

Оптимизация нейронного декодера весьма затруднительна в условиях однозначного количества факторов, влияющих на решение сети. Уменьшить топологию сети за счет уменьшения входных данных невозможно, однако при использовании сети Ворда или двух параллельных нейронных сетей и рассмотрения отдельно информационных и контрольных бит переданного сообщения можно добиться уменьшения количества связей в нейронной сети, что означает меньшее количество операций или большую скорость декодирования сетью.

Нейронный декодер является малоизученным методом, который только начинает свое развитие, что открывает широкие возможности для его дальнейшего изучения. Одним из важнейших его преимуществ перед другими типами декодеров является универсальность использования его с любыми линейными блочными кодами. Для работы с другим кодом необходимо только подстроить количество нейронов под переданное сообщение и выходные данные, а также провести новое обучение сети. Также нельзя не отметить, что нейронная сеть может работать параллельно, что во много раз увеличивает скорость ее работы. Суммируя вышесказанное, можно сказать, что нейронный декодер при детальном изучении и развитии может стать одним из наиболее востребованных декодеров в современном помехоустойчивом кодировании.

УДК 004.032.26

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ГЛУБОКОГО ДОВЕРИЯ В ИНТЕЛЛЕКТУАЛЬНОМ АНАЛИЗЕ ДАННЫХ

Крощенко А.А.

Брестский государственный технический университет, г. Брест
Научный руководитель: Головки В.А., д.т.н., профессор

Введение

Наиболее известным и широко используемым на текущий момент подходом в обучении нейронных сетей глубокого доверия является метод, предложенный Дж. Хинтоном в 2006 году [1]. Ключевой идеей этого метода является использование «жадного» алгоритма послойного обучения (greedy layer-wise algorithm).

Нами был предложен и исследован альтернативный метод послойного предобучения нейронных сетей глубокого доверия, базирующийся на минимизации суммарной квадратичной ошибки восстановления образов на каждом слое [2]. Функция ошибки определяется согласно формуле (1):

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

где L – количество входных образов, m – количество нейронов в скрытом слое, n – количество нейронов в видимом слое, k – стадийность метода.

В случае PD-1 суммарная квадратичная ошибка примет вид:

$$E_s = \frac{1}{2} \frac{L}{e} \frac{m}{e} \left(y_j^l(1) - y_j^l(0) \right)^2 + \frac{1}{2} \frac{L}{e} \frac{n}{e} \left(x_i^l(1) - x_i^l(0) \right)^2. \quad (2)$$

Правило модификации весов нейронной сети глубокого доверия имеет вид:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha \sum_{p=1}^K e^{-\lambda |w_{ij}(t)|} (y_j(p) - y_j(p-1)) x_i(p) F'(S_j(p)) + (x_i(p) - x_i(p-1)) y_j(p-1) F'(S_i(p))$$

В процессе исследования метода была проведена сравнительная оценка классического и предложенного метода на трех задачах: сжатия данных, распознавания выборки MNIST и распознавания выборки PIFAR-10.

Сжатие данных

Рассмотрим систему, генерирующую зашумленные данные [3], вида

$$\begin{cases} x_1 = \sin(\pi t) + \mu \\ x_2 = \cos(\pi t) + \mu \\ x_3 = t + \mu \end{cases}$$

где t – равномерно распределенная случайная величина из интервала $[-1, 1]$, а μ – гауссовый шум с математическим ожиданием 0 и среднеквадратическим отклонением, равным 0,05.

В качестве обучающей и тестирующей выборок нами использовались данные, генерируемые представленной системой (по 1000 образов на каждый тип выборки).

Для экспериментальной проверки предложенного подхода обучался семислойный автоэнкодер (рисунок 1).

Мы использовали сигмоидную функцию активации на всех слоях. Результаты, полученные при тестировании подходов, представлены в таблице 1. MSE определяет ошибку обучения, MS – ошибку обобщения.

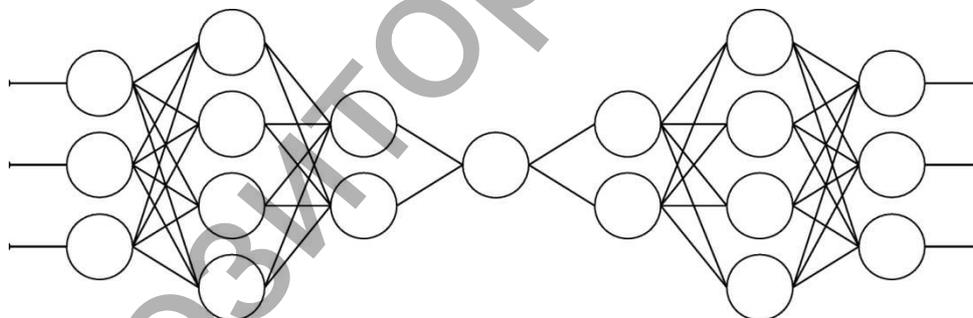


Рисунок 1 — Семислойный автоэнкодер

Таблица 1 — Результаты тестирования методов

Процедура обучения	k для CD-k	MSE	MS
RBM	1	0,699	0,886
	5	0,710	0,932
	10	0,689	0,916
	15	0,688	0,873
REBA	1	0,673	0,851
	5	0,719	0,966
	10	0,677	0,907
	15	0,700	0,895

Выборка MNIST

Элементы этой выборки представляют собой изображения рукописных цифр. MNIST является стандартом при тестировании систем распознавания образов, а также широко используется для обучения и тестирования алгоритмов машинного обучения.

Выборка MNIST состоит из 60000 образов для обучения и 10000 образов для тестирования.

Основной моделью, используемой нами для построения системы распознавания образов, является многослойный перцептрон архитектуры 784-500-500-250-100-10. Количество входов НС определялось размерами образов из базы MNIST (28X28), количество слоев и нейронов в каждом слое выявлялось экспериментальным путем.

Результаты экспериментов на выборке MNIST представлены в таблице 2. MSE_{tr} определяет ошибку обучения, MSE_{test} – ошибку обобщения, Эффективность, % – процент правильно распознанных изображений.

Таблица 2 — Результаты тестирования методов (MNIST)

Процедура обучения	MSE_{tr}	MSE_{test}	Эффективность, %
RBM	0,024	0,028	97,5/96.68
REBA	0,022	0,026	97,62/96.75

Выборка CIFAR-10

Выборка CIFAR-10 состоит из 60000 цветных изображений размером 32X32 пикселя. Каждое изображение относится к определенному классу (самолет, автомобиль, птица, собака и т.д.). Общее количество классов – 10, таким образом, в выборке содержится по 6000 изображений каждого класса. Вся выборка делится на обучающую часть (50000 образов) и тестовую (10000 образов). Нами была использована часть обучающей выборки CIFAR-10 (30000 образов).

Для выполнения сравнительного анализа методов предобучения использовалась нейронная сеть глубокого доверия с архитектурой 3072-1024-500-250-100-10. Результаты, полученные при проведении тестов, представлены в таблице 3.

Таблица 3 — Результаты тестирования методов (CIFAR-10)

Процедура обучения	MSE_{tr}	MSE_{test}
RBM	0,2370	0,4012
REBA	0,2422	0,3917

Список цитированных источников

1. Hinton, G.E. A fast learning algorithm for deep belief nets / G.E. Hinton, S. Osindero, Y. Teh // Neural Computation, 18. – 2006. – P. 1527–1554.
2. Golovko, V.A. Learning Technique for Deep Belief Neural Networks / V. Golovko, A. Kroshchanka, U. Rubanau, S. Jankowski // in book Neural Networks and Artificial Intelligence. – Springer, 2014. – Vol. 440. Communication in Computer and Information Science. – P. 136–146.
3. Scholz, M. Nonlinear principal component analysis: neural network models and applications / M. Scholz, M. Fraunholz, J. Selbig // Principal Manifolds for Data Visualization and Dimension Reduction. – Springer, 2008. – P. 44–67.