

МОДЕЛИРОВАНИЕ И ИССЛЕДОВАНИЕ НЕЙРОННЫХ СЕТЕЙ ГЛУБОКОГО ДОВЕРИЯ НА ОСНОВЕ ОГРАНИЧЕННОЙ МАШИНЫ БОЛЬЦМАНА

Целью настоящей работы является исследование возможностей Ограниченной Машины Больцмана (Restricted Boltzmann Machine, далее RBM) [1-4] и её применение в моделировании нейронных сетей глубокого доверия (Deep-Belief Neural Networks, далее DBN).

Краткие теоретические сведения

Структура RBM представляет из себя двудольный граф:




Рисунок 1 – Структура RBM

В RBM есть ряд состояний, которые можно наблюдать (видимый слой нейронов, которые предоставляют интерфейс для общения с внешней средой) и ряд состояний, которые скрыты, (скрытый слой нейронов). Можно сделать вероятностный вывод относительно скрытых состояний, опираясь на состояния, которые являются видимыми. Такая обученная модель позволяет делать выводы относительно видимых состояний, зная скрытые. Нейроны могут быть как бинарные, так и небинарные.

Цель обучения RBM звучит следующим образом: необходимо настроить параметры модели так, чтобы восстановленный вектор из исходного состояния был наиболее близок к оригиналу. Под восстановленным понимается вектор, полученный вероятностным выводом из скрытых состояний, которые в свою очередь получены вероятностным выводом из обозреваемых состояний, т.е. из оригинального вектора.

Наиболее популярным алгоритмом для обучения RBM является алгоритм Contrastive Divergence (CD-k). Выглядит он следующим образом:

- 1) состояние видимых нейронов приравнивается к входному образу;
- 2) выводятся вероятности состояний скрытого слоя;
- 3) каждому нейрону скрытого слоя ставится в соответствие состояние «1» с вероятностью, равной его текущему состоянию;
- 4) выводятся вероятности видимого слоя на основании скрытого;
- 5) если текущая итерация меньше k , то возврат к шагу 2;
- 6) выводятся вероятности состояний скрытого слоя.

Исследование двух модификаций алгоритма CD-k

В ходе исследования была написана реализация алгоритма Contrastive Divergence (далее CD-k) в двух модификациях:

1. Предложенная профессором Джеффри Хинтоном в 2002 году [1-4].
2. Предложенная профессором В. А. Головкин в 2014 году [5].

Каждая из модификаций использует батчинг – групповое обучение. Каждая из модификаций была написана с использованием многопоточности для ускорения процесса обучения.

В общем случае формулы для пересчета весовых коэффициентов и пороговых значений выглядят следующим образом:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha \frac{\partial E_s}{\partial w_{ij}(t)}, \quad (1)$$

$$T_j(t+1) = T_j(t) - \alpha \frac{\partial E_s}{\partial T_j(t)}, \quad (2)$$

$$T_i(t+1) = T_i(t) - \alpha \frac{\partial E_s}{\partial T_i(t)}, \quad (3)$$

где – функция энергии:

$$E = \frac{1}{2} \sum_j (y_j(k) - y_j(0))^2 + \frac{1}{2} \sum_i (x_i(k) - x_i(0))^2. \quad (4)$$

Дифференцируя выражения для пересчета настраиваемых параметров по w_{ij} , T_j и T_i соответственно (выражения (1), (2) и (3)), получим окончательные выражения для пересчета весов в алгоритме CD-k:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha ((y_j(k) - y_j(0))F'_j(S_j(k))x_i(k) + (x_i(k) - x_i(0))F'_i(S_i(k))y_j(0)), \quad (5)$$

$$T_j(t+1) = T_j(t) - \alpha ((y_j(k) - y_j(0))F'_j(S_j(k))), \quad (6)$$

$$T_i(t+1) = T_i(t) - \alpha (x_i(k) - x_i(0))F'_i(S_i(k)). \quad (7)$$

Приравняв производные $F'_j(S_j(k))$ и $F'_i(S_i(k))$ к единице, получим модификацию алгоритма Хинтона:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha ((y_j(0)x_i(0)) - (y_j(k)x_i(k))), \quad (8)$$

$$T_j(t+1) = T_j(t) - \alpha (y_j(0) - y_j(k)), \quad (9)$$

$$T_i(t+1) = T_i(t) - \alpha (x_i(k) - x_i(0)). \quad (10)$$

Эксперимент проводился на задаче сжатия-восстановления больших английских рукописных символов. Выборка символов состоит из 260 картинок с разрешением 29x29 пикселей, среди которых 26 оригинальных и 234 зашумленных.




Рисунок 2 – Оригинальная и зашумленная картинки

Для проведения эксперимента была выбрана RBM с 841 видимыми и 100 скрытыми нейронами. В лучшем из запусков обучения оба алгоритма показали среднюю ошибку в некорректном восстановлении 0.5 пиксела из 841.

Моделирование и исследование DBN

Основная сфера применения RBM – это предобучение многослойных персептронов.

Предобучение производится следующим образом:

Берется последовательно каждая пара слоёв, начиная от входного. Первая пара обучается как RBM на множестве входных данных. После обучения RBM выходы скрытого слоя запоминаются и автоматически становятся обучающей выборкой для следующей пары слоёв. Такое обучение продолжается последовательно для всех пар слоёв (рис. 3). Такие нейронные сети и называются нейронными сетями глубокого доверия

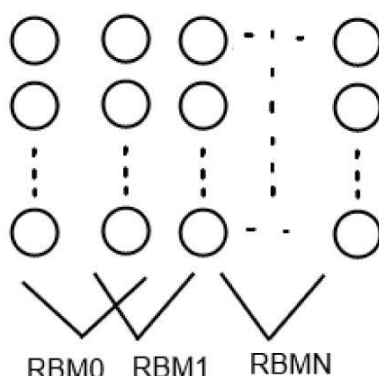


Рисунок 3 – Общая схема предобучения нейронной сети

Исследование проводилось на множестве рукописных символов MNIST. Взято множество из 1000 рукописных цифр от 0 до 9. Каждая картинка имеет разрешение 28x28.

Пример некоторых цифр из множества MNIST приведен на рисунке 4.



Рисунок 4 – Часть выборки из множества рукописных символов MNIST

Была выбрана нейронная сеть с 5 слоями размерностью 784-500-500-2000-10. Входной слой имеет линейную функцию активации, скрытые слои – сигмоидную, выходной – softmax функцию активации. Предобучение каждого из слоёв ограничено 200 эпохами. После этого сеть обучается алгоритмом обратного распространения ошибки (backpropagation) и проверяется на множестве из 10000 картинок.

Было проведено сравнение скорости обучения с предобучением и без него, а также обобщающая способность. Результаты обучения приведены в таблице 1 (было проведено несколько прогонов):

Таблица 1 – Результаты сравнения обучения DBN и обычной многослойной нейросети

Back Propagation с предобучением		Back Propagation без предобучения	
Количество эпох	Обобщающая способность, %	Количество эпох	Обобщающая способность, %
46	91.2	853	90.85
50	91.8	1235	89,30
48	91.5	1196	89,75

Как видно из результатов, предобучение дало значительный выигрыш.

Список цитированных источников

1. Hinton, G.E., Osindero, S., Teh, Y. A fast learning algorithm for deep belief nets. *Neural Computation*, 18, 1527-1554 (2006)
2. Hinton, G. Training products of experts by minimizing contrastive divergence. *Neural Computation*, 14, 1771-1800 (2002).
3. Hinton, G., Salakhutdinov, R. Reducing the dimensionality of data with neural networks. *Science*, 313 (5786), 504-507 (2006).
4. Hinton, G.E. A practical guide to training restricted Boltzmann machines. (Tech. Rep. 2010-000). Toronto: Machine Learning Group, University of Toronto (2010)
5. Golovko V., Kroshchanka F., Rubanau U., Jankowski S. A Learning Technique for Deep Belief Neural Networks. *Lecture Notes in Computer Science*, Springer, 2014 (in press).

УДК 004.514.62

Власенко С.С., Желудок В.А.

Научный руководитель: к.т.н., доцент Костюк Д.А.

ИСПОЛЬЗОВАНИЕ ВЛОЖЕННОЙ ВИРТУАЛИЗАЦИИ В ЭЛЕКТРОННОЙ ВЫСТАВКЕ ИСТОРИИ ГРАФИЧЕСКОГО ИНТЕРФЕЙСА

Быстро растущие потребности в средствах автоматизации интеллектуального труда привели к стремительному развитию компьютерной техники и программного обеспечения, к превращению вычислительных машин в главный инструмент во многих областях человеческой деятельности. На их основе создаются сети обмена информацией, что в свою очередь, дает новые импульсы для развития научно-технического прогресса.

Хотя сейчас для того чтобы работать с новыми информационными технологиями и не обязательно знать историю их возникновения и развития, однако, как говорил великий немецкий философ Гегель, без истории предмета нет теории предмета. Создание теоретических постулатов и воплощающих их практических решений всегда начинается с изучения предыдущих достижений, их эволюции. Специалист, который формулирует либо применяет современную теорию, не зная ее истории, рискует лично повторять ошибки предшественников одну за другой.