

МЕТОДИКА АДАПТИВНОГО ОБУЧЕНИЯ СИГМОИДАЛЬНЫХ НЕЙРОНОВ В АРХИТЕКТУРЕ МНОГОСЛОЙНОЙ НЕЙРОННОЙ СЕТИ

А. Ю. Савицкий

Кафедра интеллектуальных информационных технологий, Брестский государственный технический университет

Минск, Республика Беларусь

E-mail: anton.savitsky.1995@gmail.com

В данной работе предлагается методика точного обучения нейронных элементов (НЭ) сигмоидального типа в составе многослойной нейронной сети; приводятся вычислительные эксперименты, демонстрирующие преимущества и особенности предложенных решений.

ВВЕДЕНИЕ

В последнее время в мире активизировались исследования в области глубокого обучения многослойных нейронных сетей. Это связано с определенными успехами в данной области, достигнутыми рядом исследователей [1,2], а также высокой практической значимостью сильно-многослойных нейронных сетей (СМНС). Так, ряд разработчиков интеллектуального программного обеспечения (корпорации Google, Microsoft и др.) с успехом применяют технологии глубоких нейронных сетей в различных своих приложениях. При этом перспективным считается подход к предобучению (pre-training) СМНС не только с помощью ограниченной машины Больцмана (RBM), но и с применением нейросетевых автоэнкодеров (Autoencoder). Каждый такой нейросетевой автоэнкодер представляет собой трехслойный персептрон архитектуры N-M-N, где параметр N соответствует количеству входов текущего предобучаемого слоя, M – количеству нейронов указанного слоя сильно-многослойной нейросетевой архитектуры. Последовательное (начиная с входного слоя СМНС) обучение совокупности таких автоэнкодеров на входной обучающей выборке позволяет получить наборы весовых коэффициентов для финальной настройки синаптических связей всей СМНС (fine-tuning). При этом, для обучения как нейросетевых автоэнкодеров, так и СМНС, как правило, применяется алгоритм обратного распространения ошибки (Back Propagation Error, BPE) [3]. Очевидно, что эффективность алгоритма BPE напрямую определяет эффективность (точность обучения, обобщающие свойства) результирующей модели СМНС в целом.

1. МЕТОДИКА АДАПТИВНОГО ОБУЧЕНИЯ

На рис. 1 и рис. 2 приведены обобщенная архитектура многослойной нейронной сети, структура искусственного НЭ, а также введены обозначения параметров сети.

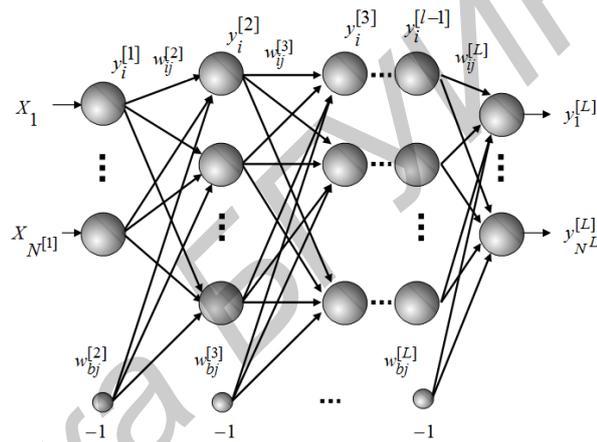


Рис. 1 – Архитектура многослойной нейронной сети

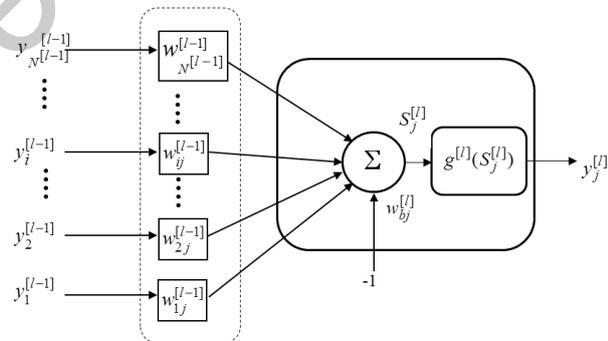


Рис. 2 – Структура искусственного нейроэлемента j в слое l нейронной сети

Нейронный элемент слоя l осуществляет функцию преобразования некоторого вектора входных сигналов $Y^{[l-1]}$ в выходную активность $Y^{[l]}$ по следующему правилу:

$$S_j^{[l]} = \sum_{i=1}^{N^{[l-1]}} y_i^{[l-1]} w_{ij}^{[l]} - w_{bj}^{[l]}, \quad (1)$$

$$y_j^{[l]} = g^{[l]}(S_j^{[l]}), j = 1, \dots, N^{[l]}, \quad (2)$$

где $S_j^{[l]}$ - взвешенная сумма входных активностей НЭ j , находящегося в слое l ; $w_{ij}^{[l]}$ - значение

синаптического веса i -го входа НЭ; $w_{ij}^{[l]}$ - значение порога активационной функции $g^{[l]}(S_j^{[l]})$ НЭ; $N^{[l-1]}, N^{[l]}$ - соответственно количество входов НЭ слоя l и количество НЭ данного слоя.

Теорема. *Правила модификации синаптических связей НЭ j , находящегося в слое L , с сигмоидной функцией активации $g^{[L]}$, минимизирующие среднеквадратичную ошибку $E_j^p(t) = 1/2(y_j^{[L],p}(t) - D_j^p)^2$ данного НЭ для эталона p на итерации обучения t , определяются следующим образом:*

$$\Delta w_{ij}^{[L]}(t+1) = \frac{S_j^{[L],p}(t) - \ln\left(\frac{D_j^p}{1-D_j^p}\right)}{1 + \sum_{k=1}^{N^{[L-1]}} (y_k^{[L-1],p})^2} y_i^{[L-1],p}(t), \quad (3)$$

$$\Delta w_{bj}^{[L]}(t+1) = \frac{S_j^{[L],p}(t) - \ln\left(\frac{D_j^p}{1-D_j^p}\right)}{1 + \sum_{k=1}^{N^{[L-1]}} (y_k^{[L-1],p})^2}, \quad (4)$$

где D_j^p - эталонное выходное значение j -го НЭ.

Доказательство теоремы сводится к нахождению в алгоритме ВРЕ шага обучения $\alpha_j^{[L],p}(t+1)$, приводящего к минимизации функции ошибки $E_j^p(t+1)$ на следующей итерации обучения $t+1$. Это предполагает решение уравнения $dE_j^p(t+1)/\alpha_j^{[L],p}(t+1) = 0$. Подставляя полученное выражение для $\alpha_j^{[L],p}(t+1)$ в стандартные правила модификации синаптических связей алгоритма ВРЕ [3], получаем искомые выражения (3), (4).

Автором также получены аналогичные правила модификации синаптических связей для НЭ функциями активации биполярная сигмоидная и гиперболический тангенс. Следует также отметить, что результаты теоремы (с учетом алгоритма ВРЕ) можно обобщить на НЭ последующих слоев многослойной нейронной сети.

II. ЭКСПЕРИМЕНТАЛЬНЫЕ РЕЗУЛЬТАТЫ

Ряд вычислительных экспериментов был проведен при обучении нейросетевых энкодеров архитектуры 900-30-900. С этой целью для обучения были сгенерированы битовые образы печатных символов размером 30x30 и количеством 100 экземпляров. При выполнении 100 итераций обучения среднеквадратичная ошибка обучения (в расчете на один эталон) достигла значения 0.000945, чего не удавалось достичь методом эмпирического подбора шага. В качестве особенности предложенного решения следует отметить тот факт, что из-за высокой точности правил (3), (4) текущая модификация синаптических связей (особенно для нейронов выходного слоя) приводила к некоторой потере эффекта обучения нейронных элементов для других эталонов обучающей выборки. Для снижения этого эффекта в правила (3), (4) был введен неотрицательный уменьшающий коэффициент $k < 1$.

Помимо вышеуказанного, следует также отметить сравнительно малую вычислительную сложность правила обучения, что является существенным преимуществом перед другими методами обучения многослойных нейронных сетей, а также перед иными существующими методиками вычисления адаптивного шага обучения.

Таким образом, полученные правила (3), (4) можно применять как на этапе предобучения в нейросетевых энкодерах, так на этапе финальной настройки целостной архитектуры СМНС.

1. G. E. Hinton, S. Osindero, and Y.-W. Teh, A fast learning algorithm for deep belief networks // Neural Computation. - 2006. - vol. 18, no. 7. - pp. 1527-1554.
2. Y. Bengio, Learning deep architectures for AI // Foundations and Trends in Machine Learning, vol. 2, no. 1. - 2009. - pp. 1-127.
3. D. E. Rumelhart, G. E. Hinton, and R. J. Williams, Learning representations by back-propagating errors // Nature, vol. 323. - 1986. - pp. 533-536.