

Альтернативная схема вывода правил обучения ограниченной машины Больцмана

Крощенко Александр Александрович

УО «Брестский государственный университет имени А.С. Пушкина»

Рассматривая ограниченную машину Больцмана (RBM) как автоэнкодер и выполняя минимизацию ошибок восстановления образов на видимом и скрытом слое (с использованием итераций сэмплирования Гиббса), можно получить классические правила обучения более простым путем, не прибегая к рассмотрению понятия энергии RBM.

Рассмотрим ограниченную машину Больцмана, которую будем представлять в виде трех слоев нейронных элементов [1]: видимый, скрытый и видимый (рисунок 1).




Рисунок 1 – Развернутое представление RBM

Представим сэмплирование Гиббса, используя развернутое представление RBM (рисунок 2)




Рисунок 2 – Сэмплирование Гиббса

Сэмплирование Гиббса заключается в следующей процедуре. Пусть $x(0)$ – входной вектор, который поступает на видимый слой в момент времени 0. Тогда выходные значения нейронов скрытого слоя:

$$y_j(0) = F(S_j(0)), \quad (1)$$

$$S_j(0) = \sum_i \omega_{ij} x_i(0) + T_j. \quad (2)$$

Инверсный (последний) слой реконструирует входной вектор на основе данных со скрытого слоя. В результате получается восстановленный вектор $x(1)$ в момент времени 1:

$$x_i(1) = F(S_i(1)), \quad (3)$$

$$S_i(1) = \sum_j \omega_{ij} y_j(0) + T_i. \quad (4)$$

Затем вектор $x(1)$ поступает на видимый слой, и вычисляются выходные значения нейронов скрытого слоя:

$$y_j(1) = F(S_j(1)), \quad (5)$$

$$S_j(1) = \sum_i \omega_{ij} x_i(1) + T_j. \quad (6)$$

Продолжая данный процесс, можно получить на шаге k

$$x_i(k) = F(S_i(k)),$$

$$S_i(k) = \sum_j \omega_{ij} y_j(k-1) + T_i.$$

$$y_j(k) = F(S_j(k)),$$

$$S_j(k) = \sum_i \omega_{ij} x_i(k) + T_j.$$

Дж. Хинтоном была предложена энергетическая модель, базирующаяся на идее максимизации функции правдоподобия распределения входных данных $P(x)$ [2]. Нами было предложено использование двух разных критериев для обучения RBM [1]. Первый критерий основывается на минимизации среднеквадратичной ошибки (MSE). Второй – на минимизации кросс-энтропийной функции ошибки.

В случае CD-к кросс-энтропийная функция ошибки для видимого слоя определяется следующим образом:

$$CE_v(k) = - \sum_{l=1}^L \left[\sum_{p=1}^k \sum_{i=1}^n (x_i^l(p-1) \log(x_i^l(p)) + (1-x_i^l(p-1)) \log(1-x_i^l(p))) \right]. \quad (7)$$

где L – размер обучающей выборки.

Аналогично для скрытого слоя:

$$CE_h(k) = - \sum_{l=1}^L \left[\sum_{p=1}^k \sum_{j=1}^m (y_j^l(p-1) \log(y_j^l(p)) + (1-y_j^l(p-1)) \log(1-y_j^l(p))) \right]. \quad (8)$$

Общая функция определяется как сумма кросс-энтропийных функций ошибки видимого и скрытого слоев:

$$CE_s(k) = CE_h(k) + CE_v(k). \quad (9)$$

Докажем следующую теорему.

Максимизация логарифма функции распределения входных данных $P(x)$ в пространстве синаптических весов ограниченной машины Больцмана эквивалентно минимизации кросс-энтропийной целевой функции $CE_s(1)$.

Доказательство. В случае CD-1 кросс-энтропийная функция для одного обучающего примера будет иметь следующий вид:

$$CE(1) = -\sum_{i=1}^n (x_i(0) \log(x_i(1)) + (1 - x_i(0)) \log(1 - x_i(1))) - \sum_{j=1}^m (y_j(0) \log(y_j(1)) + (1 - y_j(0)) \log(1 - y_j(1)))$$

Найдем частные производные кросс-энтропийной функции по весовым элементам. Получим

$$\frac{\partial CE(1)}{\partial \omega_{ij}} = \frac{\partial CE_v(1)}{\partial \omega_{ij}} + \frac{\partial CE_h(1)}{\partial \omega_{ij}}$$

Тогда

$$\begin{aligned} \frac{\partial CE_v(1)}{\partial \omega_{ij}} &= -\frac{x_i(0)}{x_i(1)} x_i(1)(1 - x_i(1))y_j(0) + \frac{1 - x_i(0)}{1 - x_i(1)} x_i(1)(1 - x_i(1))y_j(0) = -x_i(0)(1 - x_i(1))y_j(0) + \\ &+ (1 - x_i(0))x_i(1)y_j(0) = -x_i(0)y_j(0) + x_i(0)x_i(1)y_j(0) + x_i(1)y_j(0) - x_i(0)x_i(1)y_j(0) = -x_i(0)y_j(0) + \\ &x_i(1)y_j(0) \end{aligned}$$

и

$$\begin{aligned} \frac{\partial CE_h(1)}{\partial \omega_{ij}} &= -y_j(0)(1 - y_j(1))x_i(1) + (1 - y_j(0))y_j(1)x_i(1) = -y_j(0)x_i(1) + y_j(0)y_j(1)x_i(1) + y_j(1)x_i(1) - \\ &y_j(0)y_j(1)x_i(1) = -y_j(0)x_i(1) + y_j(1)x_i(1). \end{aligned}$$

Окончательно получим

$$\frac{\partial CE(1)}{\partial \omega_{ij}} = \frac{\partial CE_v(1)}{\partial \omega_{ij}} + \frac{\partial CE_h(1)}{\partial \omega_{ij}} = -x_i(0)y_j(0) + x_i(1)y_j(0) - y_j(0)x_i(1) + y_j(1)x_i(1) = x_i(1)y_j(1) - x_i(0)y_j(0).$$

Рассуждая аналогичным образом, можно получить для пороговых элементов:

$$\frac{\partial CE(1)}{\partial T_i} = x_i(1) - x_i(0),$$

$$\frac{\partial CE(1)}{\partial T_j} = y_j(1) - y_j(0).$$

Теорема доказана.

Данная теорема может быть обобщена на случай CD-k ([1]).

Как следует из теоремы, классические правила обучения RBM сети могут быть получены более простым путем по сравнению с конвенциональным методом, основанным на энергии. Таким образом, используя минимизацию функции кросс-энтропии и сэмплирование Гиббса, можно получить классические выражения для обучения RBM.

Использованные источники

1. Golovko, V. The Nature of Unsupervised Learning in Deep Neural Networks: A New Understanding and Novel Approach / Vladimir Golovko, Aliaksandr Kroshchanka, Douglas Treadwell // Optical Memory And Neural Networks (Springer Link). – 2016. – Vol. 25, № 3. – P. 127–141.
2. Hinton, G. A fast learning algorithm for deep belief nets / G. Hinton, S. Osindero, Y. Teh // Neural Computation. – 2006. – Vol. 18. – P. 1527–1554.