

## СИНТЕТИЧЕСКИЙ АЛГОРИТМ ОПТИМИЗАЦИИ И НАСТРОЙКИ НЕЙРОННЫХ СЕТЕЙ

*И.Ф.ЯСИНСКИЙ*

(Ивановская государственная текстильная академия)

В современных наукоемких технологиях, включая текстильные, все более широкое распространение находят нейросетевые технологии. Быстрота обучения и реагирования таких систем при этом имеют определяющее значение.

Задача настройки нейронной сети является задачей многоэкстремального поиска. При этом одним из самых распространенных методов настройки является метод обратного распространения ошибки, полученный в результате применения метода градиента для минимизации целевой функции ошибки распознавания. При использовании этого метода часто возникают ситуации, когда процесс обучения, достигнув некоторого уровня, останавливается. Происходит это из-за того, что поисковая точка попадает в один из локальных минимумов целевой функции, из которого выйти уже не может.

Для решения этой проблемы нами разработан синтетический алгоритм, включающий следующие составляющие его алгоритмы: усовершенствованный случай-

ный поиск, случайный поиск с памятью, метод инерционной минимизации и две разновидности генетического поиска.

Численные эксперименты позволили убедиться в существенном увеличении быстродействия синтетического алгоритма по сравнению с традиционным подходом при поиске глобального минимума на множестве локальных, что принципиально важно для решения задачи обучения нейронной сети.

Рассмотрим подробнее предложенные нами модификации составляющих алгоритмов поиска, включенных в синтетический.

*Усовершенствованный случайный поиск.* Множество весов нейронной сети можно рассматривать как вектор  $\vec{W}$  в  $N$ -мерном пространстве. Очевидно, целевая функция  $Q$  ошибки распознавания зависит от значений весов  $\vec{W}$ . Пусть  $\vec{W}^0 = (W_1^0, \dots, W_N^0)$  – исходная точка в пространстве поиска. Последовательность  $(W_1^k, \dots, W_N^k)$ ;  $k = 0, 1, \dots, M$  назовем после-

довательностью удачных точек, если в каждой следующей точке целевая функция  $Q(\vec{W})$  меньше, чем в предыдущей.

Последовательность удачных точек получается так. Около очередной удачной точки строится окрестность в виде  $N$ -мерного прямоугольного "ящика" с полуразмерами  $DW_m^k$ . Из этой окрестности выбирается пробная случайная точка  $\vec{W}$  с координатами

$$W_m = W_m^k + \zeta DW_m^k; m = 1, 2, \dots, N, \quad (1)$$

где  $\zeta$  – случайные числа, равномерно распределенные в интервале  $(-1, +1)$ .

В этой точке вычисляется значение целевой функции  $Q(\vec{W})$ , которое сравнивается с ее значением в последней удачной точке  $Q(\vec{W}^k)$ .

Если  $Q(\vec{W}) < Q(\vec{W}^k)$ , то такая точка объявляется новой удачной

$$Q^{k+1} = Q(\vec{W}), W_m^{k+1} = W_m; m=1, 2, \dots, N, \quad (2)$$

и она становится центром новой окрестности с полуразмерами  $DW_m^{k+1}$ .

Следующая пробная точка будет взята из этой новой окрестности. Последовательность удачных точек  $\vec{W}^k$ , очевидно, сходится к точке минимума целевой функции  $Q(\vec{W})$ .

Случайный поиск эффективен, если удачно выбраны размеры окрестности  $DW_m^k$ , из которой берутся случайные пробы, и они оптимально изменяются по мере приближения этой окрестности к точке минимума.

Мы использовали следующий способ выбора начальных размеров окрестности поиска:

$$DW_m^0 = 0,28h_m / \sqrt{\varepsilon^2 + |Q_m^+ - 2Q^0 + Q_m^-|} / N, \quad (3)$$

где  $Q^0 = Q(W_1^0, \dots, W_N^0)$ ;  $Q_m^+ = Q(W_1^0, \dots, W_m + h_m, \dots, W_N^0)$ ;  $Q_m^- = Q(W_1^0, \dots, W_m - h_m, \dots, W_N^0)$ ;  $h_m$  – малые пробные приращения аргумен-

тов  $W_m^0$ ;  $\varepsilon$  – малое положительное число (защита от нуля в знаменателе).

В процессе поиска размеры окрестности  $DW_m^k$  мы изменяли следующим образом. Выполнена серия из  $M_s$  проб. Из них  $\nu$  проб оказались удачными. Вычисляем эмпирически полученный множитель:

$$\mu = 1 + 2,8(\nu / M_s - 1/4). \quad (4)$$

По окончании указанной серии проб все размеры окрестности  $DW_m^k$  умножаем на множитель  $\mu$ . Согласно такому алгоритму пробная окрестность по мере приближения к точке минимума сжимается. Поиск прекращается, когда для всех весов начинает выполняться условие  $DW_m^k < E$ , где  $E$  – допустимая погрешность в определении координат минимума.




Рис. 1

На рис.1 представлены процессы обучения нейронной сети распознаванию образов по методу обратного распространения ошибки (кривая 1) и при помощи усовершенствованного случайного поиска (кривая 2). На вертикальной оси отложено отношение текущего значения суммы модулей невязок к ее начальному значению в зависимости от длины обучающей последовательности.

Преимущество усовершенствованного метода случайного поиска очевидно.

Случайный поиск с памятью содержит блок, вычисляющий значения "стохастиче-

ского градиента" от целевой функции при случайных пробах (удачных и неудачных). Окрестность, из которой берется следующая случайная проба, смещается в направлении стохастического антиградиента:

$$\vec{G} = - \sum_{i=1}^n \frac{Q(\vec{W}_i) - Q(\vec{W}^k)}{|\delta \vec{W}_i|^2} \delta \vec{W}_i, \quad (5)$$

где  $\delta \vec{W}_i = \vec{W}_i - \vec{W}^k$  – случайный сдвиг пробной точки относительно  $k$ -й удачной.

В численном эксперименте нами найдены значения коэффициентов  $\alpha_i$ , которые учитывают успешность предыдущих шагов. Эти коэффициенты используются для предварительного сдвига окрестности поиска, из которой берутся случайные пробы:

$$\vec{W}_{\text{new}}^k = \vec{W}^k + \tau(\alpha_1 \vec{G}^k + \alpha_2 \vec{G}^{k-1} + \alpha_3 \vec{G}^{k-2}), \quad (6)$$

$$\alpha_1 + \alpha_2 + \alpha_3 = 1, \quad (7)$$

где  $\vec{W}_{\text{new}}^k$  – новые координаты центра окрестности, из которой берутся случайные пробы;  $\tau$  – шаг по времени

*Алгоритм инерционной минимизации.* Численные эксперименты показали, что эффективной является также следующая методика настройки весовых коэффициентов нейронной сети. Подчиним движение поисковой точки в пространстве весовых коэффициентов следующим дифференциальным уравнениям:

$$\left. \begin{aligned} \frac{dV_s}{dt} &= G_s - \mu V_s, \\ \frac{dW_s}{dt} &= V_s; \quad S = 1, 2, \dots, N, \end{aligned} \right\}, \quad (8)$$

где  $V_s$  – составляющие скорости поисковой точки;  $\mu V_s$  – составляющие силы трения, которая будет гасить колебания поисковой точки;  $\mu$  – "вязкость среды".

Согласно (8) поисковая точка обладает инерцией, которая позволит ей выходить из локальных минимумов и находить гло-

бальный минимум. Если через  $F(x)$  обозначить передаточную функцию нейрона и взять ее в виде  $F(x) = 1 / (1 + \exp(-x))$ , то, воспользовавшись неявной разностной схемой, можно получить следующие итерационные выражения:

$$V_{ij}^{n+1} = (V_{ij}^n - \tau E_j Y_j Y_i (1 - Y_i)) / (1 + \tau \mu), \quad (9)$$

$$W_{ij}^{n+1} = W_{ij}^n + \tau V_{ij}^{n+1}, \quad (10)$$

где  $E_i = Y_i - Y_i^*$ ,  $Y_i$ ,  $Y_i^*$  – действительная и требуемая реакция нейронной сети;  $W_{ij}$  – весовые коэффициенты;  $\tau$  – шаг по времени.

*Генетический алгоритм* брался в следующих двух видах: традиционном и модифицированном. При традиционном подходе было сформировано множество наборов хромосом, представляющих веса нейронной сети. Текущий массив весов  $W_m$  и случайно выбранный набор весов  $W_m'$  составляют "родительскую" пару.

В массив весов-"потомков" входит первая половина весовых коэффициентов текущего массива и вторая половина от выбранного набора. Далее, после предъявления сети обучающего образа и получения на выходе ответа, производится сравнение: если целевая функция ошибки после генетических операций уменьшилась  $Q'(\vec{W}) < Q(\vec{W})$ , то тестируемый массив весов становится текущим (действующим). В противном случае, то есть при  $Q'(\vec{W}) > Q(\vec{W})$ , тестируемый массив стирается.

Был использован также следующий модифицированный вариант генетического алгоритма. В пространстве  $\vec{W}$  выбирается некоторое количество исходных точек  $W_i^f$  ( $f = 1, 2, \dots$ ). Они были получены с помощью усовершенствованного случайного поиска, повторением поиска из различных начальных позиций. Это "родители", образующие пары.

Пары строились следующим образом. Целевые функции для "родителей" должны быть близки, а расстояние между ними максимально:

$$\left. \begin{aligned} |Q^f - Q^l| < \varepsilon_Q \rightarrow \min, \\ \sum_{r=1}^R (W_r^f - W_r^l)^2 = R^2 \rightarrow \max. \end{aligned} \right\} \quad (11)$$

Пара дает "потомство". Для этого координаты точек "родителей" соединяются прямой согласно выражению:

$$W_i = W_i^f + \eta(W_i^l - W_i^f), \quad (12)$$

где  $\eta$  – одномерная координата, по которой затем осуществляется глобальный поиск. Для этого применялись методы интерполяции и Р.Г. Стронгина. Таким образом, многомерный поиск заменяется одномерным, что ускоряет вычисления.




Рис. 2

Рис.2 поясняет идею такого поиска.  $\otimes$  – "родительские" точки;  $*$  – точки "потомки";  $Q = \text{const}$  – линии равного значения целевой функции;  $Q_{\min}$  – значение целевой функции в минимуме;  $W_r^f, W_r^l, Q^f, Q^l$  – координаты "родительских" точек и значение в них целевой функции.

Точки-"потомки" находятся ближе к искомому минимуму, чем "родительские" точки. "Потомков" должно быть не меньше, чем "родителей" с тем, чтобы этот процесс можно было продолжить неограниченно.

В проведенных нами численных экспериментах последовательно чередовалось обучение нейронной сети по методу случайного поиска и минимизация ошибки по генетическому алгоритму. Данный вариант показал большую эффективность по сравнению со случайным поиском и генетическим алгоритмом в отдельности.

Следует обратить внимание, что как случайный поиск, так и генетический алгоритм легко поддаются распараллеливанию и поэтому удобны для реализации на многопроцессорных вычислительных машинах.

Сравнение комбинированного алгоритма генетического и усовершенствованного случайного поиска со случайным алгоритмом на основе распознавания образов нейронной сетью представлено на графике рис.3 – обучение нейронной сети распознаванию 8 образов.




Рис. 3

Нами выполнялись численные эксперименты по определению наилучшей последовательности указанных выше составляющих алгоритмов в *синтетическом алгоритме*. Для оценки эффективности синтетического алгоритма, помимо настройки нейронных сетей, изучалась также минимизация эталонных целевых функций (функция Розенброка и специальные тестовые функции с множеством локальных минимумов).

Пусть С – усовершенствованный случайный поиск; П – случайный поиск с памятью; И – инерционный поиск; Г – генетический алгоритм. В ходе экспериментов было отмечено, что последовательность, позволяющая найти глобальный минимум с наименьшими затратами машинного времени, чаще всего имеет следующий вид:

ПГСИ ПГСИ ПГСИ .....

## ВЫВОДЫ

1. Предложен синтетический алгоритм оптимизации и настройки нейронных сетей, включающий модифицированные варианты усовершенствованного случайного поиска, случайного поиска с памятью, инерционного и генетического поисков.

2. Данный алгоритм позволяет находить глобальный минимум среди множества локальных, ускоряет обучение нейронных сетей и улучшает качество распознавания образов.

Рекомендована кафедрой прикладной математики и информационных технологий. Поступила 11.12.06.

---