



И.В. Лёзина, А.Е. Краснов

ИДЕНТИФИКАЦИЯ ПЛОТНОСТИ РАСПРЕДЕЛЕНИЯ ВЕРОЯТНОСТИ НЕЧЕТКИМ МНОГОСЛОЙНЫМ ПЕРСЕПТРОНОМ

(ФГБОУ ВПО «Самарский государственный аэрокосмический университет им. академика С.П. Королева (национальный исследовательский университет)»)

Решение задачи идентификации является одним из важнейших применений нейронных сетей. Задача идентификации при распознавании плотности распределения вероятности формулируется следующим образом: имеется числовой набор точек X , которые являются координатами вершин столбцов в гистограмме. Необходимо по данному числовому набору X определить, к какой плотности распределения вероятности относится данная гистограмма.

В качестве идентификатора была выбрана сеть модели нечеткий многослойный персептрон. Данная сеть была выбрана из-за того, что при идентификации возникает пересечение классов. С учётом ярко выраженной двухкомпонентной структуры гибридной сети для её обучения применяется алгоритм, состоящий из двух этапов. На первом этапе обучения будем использовать алгоритм нечеткой самоорганизации C -means.

Рассмотрим основные математические формулы, применяемые в этом алгоритме [1]. Подаваемый на вход сети вектор x будет принадлежать к различным группам, представляемым центрами c_i , в степени u_{it} , причем $0 \leq u_{it} \leq 1$, а суммарная степень принадлежности ко всем группам, очевидно, равна единице.

Поэтому:

$$\sum_{i=1}^M u_{it} = 1 \quad (1)$$

Первичная инициализация центров функции Гаусса:

$$c_i = \frac{\sum_{t=1}^P \mu_{it}^m x_t}{\sum_{t=1}^P \mu_{it}^m} \quad (2)$$

Функцию погрешности можно определить как сумму частных погрешностей принадлежности к центрам c_i с учетом степени принадлежности u_{it} . Следовательно:

$$E = \sum_{i=1}^M \sum_{t=1}^P \mu_{it}^m \|c_i - x_t\|^2 \quad (3)$$

Новые значения степеней принадлежности:



$$u_{it} = \frac{1}{\sum_{k=1}^M \left(\frac{d_{it}^2}{d_{kt}^2} \right)^{\frac{1}{m-1}}} \quad (4)$$

Алгоритм C-means можно разбить на следующие итерации:

1. Выполнить случайную инициализацию коэффициентов u_{it} , выбирая их значения из интервала $[0,1]$ таким образом, чтобы соблюдалось условие (1).
2. Определить M центров в соответствии с (2).
3. Рассчитать значение функции погрешности в соответствии с (3). Если её значение ниже установленного порога, либо если уменьшение этой погрешности относительно предыдущей итерации пренебрежимо мало, то закончить вычисления. Иначе, перейти к п.4.
4. Рассчитать новые значения по формуле (4) и перейти к п.2.

Многочисленное повторение итерационной процедуры ведёт к достижению минимума функции E , который необязательно будет глобальным.

На втором этапе обучения будем использовать алгоритм обратного распространения ошибки. Данный алгоритм сводится к корректировке синоптических связей по формулам:

$$w_{\langle i,j \rangle}^{l+1} = w_{\langle i,j \rangle}^l + \Delta w_{\langle i,j \rangle}^l, \quad (5)$$

$$\text{где } \Delta w_{\langle i,j \rangle}^l = \eta p_{\langle i,j \rangle}^l \quad (6)$$

Обучение многослойной сети с применением градиентных методов требует определения вектора градиента относительно весов всех слоев сети, что необходимо для правильного выбора направления $p(w)$. Эта задача имеет очевидное решение только для весов выходного слоя. Для других слоев используется алгоритм обратного распространения ошибки, который определяется следующим образом [2]:

1. Подать на вход сети вектор x и рассчитать значения выходных сигналов нейронов скрытых слоев и выходного слоя, а также соответствующие производные функций активации каждого слоя (m – количество слоев).
2. Создать сеть обратного распространения ошибок путем изменения направления передачи сигналов, замены функций активации их производными и подачи на бывший выход сети в качестве входного сигнала разности между фактическими и ожидаемыми значениями.
3. Уточнить веса по формулам (5) и (6) на основе результатов, полученных в п.1 и п.2 для исходной сети и для сети обратного распространения ошибки.
4. Пункты 1, 2, 3 повторить для всех обучающих выборок, вплоть до выполнения условия остановки: норма градиента станет меньше заданного значения ϵ , характеризующего точность обучения.

В начале работы системы необходимо выбрать несколько законов распределения вероятности. Форма выбора законов распределения вероятности представлена на рисунке 1.

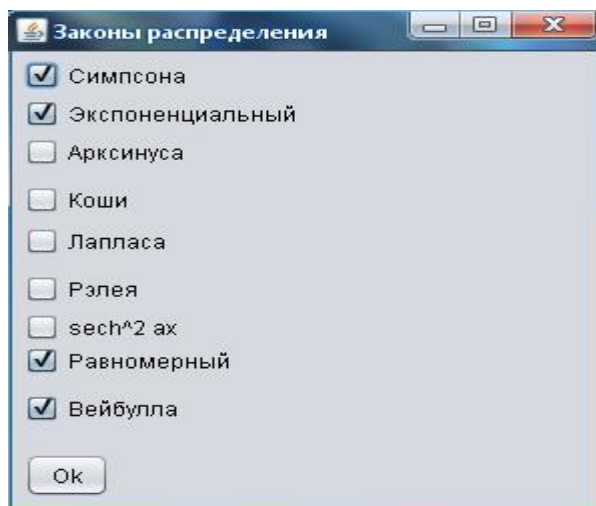


Рис. 1. Выбор законов распределения вероятности

После завершения обучения нейронной сети будет показана форма с результатами тестирования сети и статистикой по обучению. Данная форма представлена на рисунке 2.

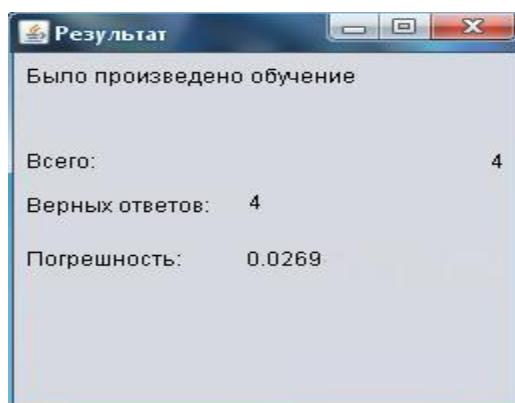


Рис. 2. Графическое отображение результатов тестирования и статистики по обучению

Зависимость качества идентификации от числа нейронов в нечетком слое представлено в таблице 1. Идентификация проводилась с разным количеством выбранных законов распределения при числе обучающих выборок равных 10 и при числе дифференциальных коридоров на гистограмме равном 20.

Таблица 1 – Зависимость качества идентификации от числа нейронов в нечетком слое

Количество нейронов в нечетком слое	Количество выбранных законов распределения вероятности	Программа идентифицировала в %
4	4	75
5	4	50
6	5	60
7	5	40
8	6	68
9	7	71

Из таблицы видно, что наилучшее качество идентификации достигается при количестве нейронов в нечётком слое равном 4.



Литература

1. Осовский С. Нейронные сети для обработки информации / пер. с польского И.Д. Рудинского. – М.: Издательский дом «Финансы и статистика», 2002. – 344 с.
2. Уоссерман Ф. Нейрокомпьютерная техника: теория и практика / пер. с англ. Ю.А. Зуев. – М.: Издательский дом «Мир», 1992. – 184 с.