

**В.А. КРИСИЛОВ, А.В. КОНДРАТЮК**  
Одесский национальный политехнический университет  
Институт компьютерных систем  
victork@ol405.paco.net, alkond@ukr.net

## **ПРЕОБРАЗОВАНИЕ ВХОДНЫХ ДАННЫХ НЕЙРОСЕТИ С ЦЕЛЬЮ УЛУЧШЕНИЯ ИХ РАЗЛИЧИМОСТИ**

### **Аннотация**

В работе рассматривается вопрос повышения различимости входных данных нейронной сети, за счет применения преобразования исходных данных.

**V.A. KRISILOV, A.V. KONDRATYUK**  
Odessa national polytechnical university  
Institute of computer systems  
victork@ol405.paco.net, alkond@ukr.net

## **THE TRANSFORMATION OF INPUT DATA OF THE NEURAL NETWORK FOR THEIR RECOGNITION IMPROVEMENT**

### **Abstract**

The question of increasing of recognition input data for neural network is discussed in this work. Proposed method based on transformation the initial data.

### **Введение**

Одним из популярных подходов к решению задачи прогнозирования является представление поведения некоторого процесса в виде временного ряда (ВР). Задача прогнозирования решается как задача экстраполяции ВР на основе нейронной модели, построенной в результате его анализа [1, 2].

Важным этапом в решении задачи нейросетевого прогнозирования является формирование обучающей выборки (ОВ). От состава, полноты, качества ОВ в значительной мере зависят время обучения нейронной сети (НС) и достоверность получаемых моделей.

Для большинства НС характерно наличие интервала допустимых значений входных сигналов, в пределах которого сигналы различимы [3].

<http://neuroschool.narod.ru>

Функция активации устанавливает допустимые границы значений исходных данных.

Отображение в этот диапазон в основном осуществляется с помощью простейшего преобразования [3] – нормализации, однако, при этом не учитываются характеристики закона распределения. Как следствие – при сильной неравномерности закона распределения допустимый диапазон используется не полностью.

В нем присутствуют, как слабо заполненные участки, так и участки скученности значений исходной величины. Слабо заполненные участки приводят к тому, что в процессе обучения НС плохо «запоминает» эти значения. А участки скученности, где на относительно небольших отрезках располагается значительное количество значений исходной величины, оказываются слабо различимыми. Точки, как бы, сливаются на этих участках, что также приводит к снижению качества обучения.

Решение этой проблемы может идти в двух направлениях:

- 1) повышение чувствительности НС за счет изменения параметров функции активации;
- 2) повышение равномерности распределения исходной величины.

Целесообразность второго подхода обуславливается тем, что такое преобразование исходных данных фактически является перекодировкой, повышающей их информативность. В то время, как первый повлечет за собой необходимость вмешательства в синтез НС, что нежелательно и сложнее.

Целью настоящей работы является повышение качества и сокращение времени обучения НС за счет предварительного преобразования ОВ, увеличивающего равномерность исходных данных.

## **1. Порядок решения задачи**

Рассмотрим задачу прогнозирования в общем виде с использованием НС типа многослойный перцептрон (МП). Начальные этапы данного процесса можно представить в виде схемы алгоритма (рис. 1).

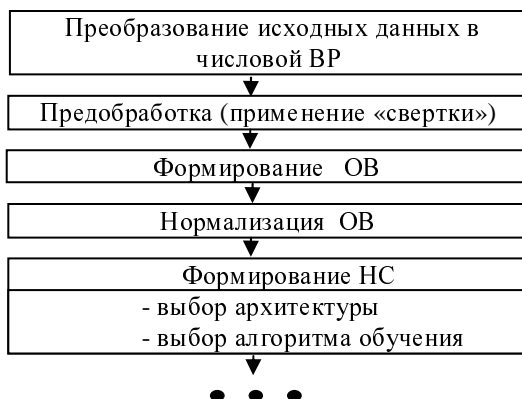


Рис. 1. Начальные этапы процесса решения задачи прогнозирования

### 1.1. Нормализация значений ОБ

Процесс отображения всего множества значений исходной величины в заранее заданный интервал будем называть нормализацией. Данный интервал и называется интервалом допустимых значений и определяется функцией активации нейрона. Для различных функций активации эти интервалы различны. Нормализация необходима для эффективного использования интервала максимальной чувствительности функции активации.

Числовые значения сигналов рекомендуется масштабировать и сдвигать так, чтобы весь диапазон значений попадал в интервал допустимых входных сигналов [3]. Это преобразование задается формулой (1):

$$x' = \frac{(x - x_{\min})(b - a)}{(x_{\max} - x_{\min})} + a, \quad (1)$$

где  $[a, b]$  – интервал допустимых значений входных сигналов,  $[x_{\min}, x_{\max}]$  – интервал значений признака  $x$ ,  $x'$  – предобработанный сигнал, который будет подан на вход НС. Предобработку входного сигнала по формуле (1) называют простейшей предобработкой [3]. При этом на практике часто встречается ситуация, когда большая часть поступающих на вход НС сигналов занимает лишь малую часть диапазона различных входных сигналов.

На практике производится, как правило, только преобразование, связанное с нормализацией, и не уделяется должного внимания другим

важным аспектам, например, таким как распределение величин по интервалу значений.

## 1.2. Повышение различимости ОБ

В данной работе рассматриваются сети с сигмоидальными нелинейными преобразователями, график функции которых имеет вид:




Рис.2. Сигмоидальная функция

Данная функция (рис.2) является одной из наиболее распространенных. Она представляет собой нелинейную функцию с насыщением, так называемую логистическую или сигмоидальную функцию [4]:

$$f(x) = \frac{1}{1 + e^{-\alpha x}} \quad (2)$$

Из выражения для сигмоидальной функции очевидно, что выходное значение нейрона лежит в интервале  $[0,1]$ .

Интервал допустимых значений входных сигналов  $[a,b]$  должен соответствовать интервалу зоны чувствительности функции активации нейрона, которая определяется эмпирически как  $[a',b']$ , т.е. перед повышением равномерности исходных значений обязательно необходимо провести нормализацию.

После нормализации интервала значений исходных данных предлагается повысить различимость ОБ. Для этого значения ОБ необходимо наиболее равномерно перераспределить по интервалу значений исходных данных: в областях скученности данных – «растянуть», в «пустых» местах – «сжать». Таким образом, вводится искусственная равномерность распределения данных по интервалу.

Предлагается подход, повышающий различимость ОБ и состоящий из следующих этапов:

1. Преобразование значения исходной величины с целью вычисления ее нового значения с повышенной различимостью.
2. Обучение и работа НС на преобразованных данных.

3. Обратное преобразование полученных на выходе НС величин с целью восстановления исходных (истинных) значений данных, подвергшихся преобразованию.

### 3. Применение предложенного подхода

Преобразование значений исходной величины  $x_i$  выполняется в соответствии с плотностью их распределения  $p(x)$  по диапазону (рис.3).




Рис.3. Применение предложенного подхода

Значение преобразованной величины  $x'_i$  (для подачи на вход НС) вычисляется на основании значения исходной величины  $x_i$  по формуле(3):

$$x'_i = S(x_i), \quad (3)$$

Физически величине  $x'_i$  соответствует площадь  $S(x_i)$  фигуры, ограниченная значением  $x_1=0$  и  $x_2=x_i$ , т.е. с учетом всех предыдущих значений  $x$ .

$$S(x_i) = P(X < x_i), \quad (4)$$

где  $P$  – интегральная вероятность значений исходной величины  $x$ .

Для восстановления исходной неравномерности распределения по диапазону над выходными величинами НС производится обратная обработка. Вычисляется значение  $x_i$ , которому соответствует значение  $P_i$ .

Для случая, когда известен закон распределения исходной величины, не возникает проблем с точностью обработки, т.к. число интервалов  $N$  стремиться к бесконечности, а ширина каждого из них – к нулю.

Если же закон распределения формируется по выборке ограниченного размера, то максимальное количество интервалов  $N$  ограничивается размером выборки. Это обстоятельство может вносить дополнительную ошибку, обуславливаемую дискретизацией.

Частично данную проблему можно решить использованием одного из известных способов аппроксимации плотности вероятности по имеющимся точкам.

Кроме того, в ряде практических задач не требуется высокая точность задания исходных величин, и допустимый диапазон достаточно разбить на некоторое количество интервалов  $N$ , меньшее количества значений исходной величины (сам же параметр  $N$  выбирается эмпирически).

В соответствии с плотностью распределения значений исходной величины по исходному диапазону, формируется новый диапазон с интервалами прямопропорциональными соответствующим плотностям распределения. Иллюстрация описанного примера приведена на рис.3.

Исходный диапазон  $[0,1]$  выбран для простоты изложения, на практике он может быть любым.

#### 4. Практические результаты

Эксперименты предполагали исследование эффективности предложенного подхода на предмет улучшения различимости ОВ путем применения предложенного преобразования, что должно отразиться на качестве и скорости обучения НС.

Исходными данными служил ряд, состоящий из 30 значений, и описываемый следующим математическим выражением:  $y=0,7*\sin(x_1)+0,3*\sin(x_2)$ . Значения распределены неравномерно по интервалу (рис.4).

Далее производилось предложенное преобразование, в результате которого, данные стали более различимы в местах скученности, и наоборот, более плотно размещены в местах разрежений (рис.5). Это обстоятельство иллюстрируют графики плотности функций распределения исходного и преобразованного рядов соответственно (рис. 6 и 7).




Рис.4. Исходные данные




Рис.5. Преобразованные данные




Рис.6. Плотность распределения исходного ряда




Рис.7. Плотность распределения преобразованного ряда

Плотности распределения исходного и преобразованного рядов свидетельствуют о повышении равномерности распределения данных по диапазону, что должно благоприятно отразиться на различимости этих данных.

Далее проведена попытка воспользоваться полученным преимуществом для повышения скорости обучения НС.

Параметры системы выбирались следующие:

**выборки:** было сформировано две выборки: из исходных данных и из преобразованных, каждая из которых содержала 30 наборов, 74% из них (22 набора) составляли ОБ, 26% (8 наборов) – контрольную выборку (КВ);

**структура НС:** трехслойный персептрон 2-4-1 с сигмоидальной функцией активации;

**алгоритм обучения:** классический алгоритм обратного распространения ошибки с моментом 0.1 и параметром скорости обучения 0.1, обучение останавливалось по прошествии 2500 эпох обучения, с промежуточным фиксированием результата на каждых 500 эпохах.

Обучение проводилось как для исходной ОБ, так и для преобразованной ОБ. Полученные результаты приведены на рис.8.




Рис.8. Зависимость ошибки обучения от числа эпох  
 ИР – на исходных данных  
 ПР – на преобразованных данных

Из рисунка видно, что сравнивая результат работы обученной НС в обоих случаях, результат на ОВ с преобразованием свидетельствует о более быстром падении процента ошибки обучения на ОВ. Из этого следует повышение скорости обучения НС на 41%.

### Выводы

В данной работе для повышения эффективности работы НС было предложено формализовать процесс предобработки данных, состоящий в совмещении нормализации исходных данных с повышением их равномерности распределения по нормализованному интервалу.

Предложенный алгоритм преобразования позволяет повысить равномерность распределения, что приводит к улучшению различимости ОВ.

Предварительные эксперименты показали повышение скорости обучения НС на 41%.

#### Список литературы

1. В.А. Крисилов, Д.Н. Олешко, А.В. Трутнев. Применение нейронных сетей в задачах интеллектуального анализа информации.// Труды Одесского политехнического университета, Вып.2 (8). 1999, с. 134.
2. Роберт Хехт-Нильсен. Нейрокомпьютинг: история, состояние, перспективы. // Открытые системы, N4, 1998.
3. Нейронформатика: Учеб. пособие для студентов / Е.М. Миркес. Красноярск: ИПЦ КГТУ, 2002, 347 с.. / <http://softcraft.ru/neuro/ni/p07.shtml>
4. Ф.Уоссермен, Нейрокомпьютерная техника. Теория и практика, М., Мир, 1992, с.17.