

В случае если  $|\nabla^2 E_S(\alpha; \beta)| > 0$  и  $(\nabla^2 E_S \cdot \nabla E_S, \nabla E_S) > 0$ , то функция  $E_S(\alpha; \beta)$  достигает минимального значения при  $\alpha(t)$  и  $\beta(t)$ , определяемыми соотношениями (3).

Таким образом, доказано следующее утверждение.

**Теорема.** Величины квазиоптимальных параметров  $\alpha(t)$  и  $\beta(t)$  шага обучения нейронной сети с использованием метода сопряженных градиентов в момент времени  $t$  определяется соотношениями (3):

Приведем алгоритм обучения нейронной сети с использованием метода сопряженных градиентов, использующий соотношения (3):

1. Задается минимальная квадратичная ошибка сети  $\varepsilon_m$ , которой необходимо достичь в процессе обучения.

2. Записывается число  $t=0$  в счетчик числа итераций алгоритма.

3. Случайным образом инициализируются весовые коэффициенты сети  $w_{ij}(t)$  ( $i = \overline{1, n}$ ,  $j = \overline{1, m}$ ), и пороговые значения нейронных элементов  $T_j(t)$  ( $j = \overline{1, m}$ ).

4. Подаются входные образы  $\overline{x^k} = (x_1^k, \dots, x_n^k)$  ( $k = \overline{1, L}$ ) на нейронную сеть и вычисляются векторы  $\overline{y^k}(t) = (y_1^k(t), \dots, y_m^k(t))$  ( $k = \overline{1, L}$ ) выходной активности сети, определяемые соотношениями (1).

5. Если  $t \neq 0$ , то величины квазиоптимальных параметров  $\alpha(t)$ ,  $\beta(t)$  шага обучения с использованием метода сопряженных градиентов вычисляются в соответствии с соотношениями (3), в противном случае параметр  $\alpha(t)$  определяется выражением

$\alpha(t) = \frac{(\nabla E_S(t), \nabla E_S(t))}{(\nabla^2 E_S(t) \cdot \nabla E_S(t), \nabla E_S(t))}$  [2], а  $\beta(t)$  полагается равным нулю.

6. Производится изменение весовых коэффициентов  $w_{ij}(t+1)$  ( $i = \overline{1, n}$ ,  $j = \overline{1, m}$ ) и порогов нейронной сети  $T_j(t+1)$  ( $j = \overline{1, m}$ ) согласно выражению (2).

7. Полагается  $t=t+1$ .

8. Алгоритм завершает свою работу, если суммарная квадратичная ошибка сети  $E_S(t) = \frac{1}{2} \sum_{j=1}^m \sum_{k=1}^L (y_j^k(t) - t_j^k)^2$  или норма вектора  $\overline{\Delta W}(t) = \overline{W}(t) - \overline{W}(t-1)$  не превосходят заданной величины  $\varepsilon_m$ , т. е.  $E_S(t) \leq \varepsilon_m$  или  $\|\overline{\Delta W}(t)\| < \varepsilon_m$ , в противном случае выполняется п. 4.

### Литература

1. Головкин В.А. Нейронные сети: обучение, организация и применение. Кн. 4: Учебное пособие для вузов / Общая ред. А.И. Галушкина. – М.: ИПРЖР, 2001. – 256 с.: ил. (Нейрокомпьютеры и их применение).

2. Гладкий И.И., Головкин В.А., Махнист Л.П. Обучение нейронных сетей с использованием метода наискорейшего спуска // Вестник Брестского государственного технического университета. – Брест: БГТУ, 2001. – № 5: Физика, математика, химия. – С. 47-55.

## ПРИМЕНЕНИЕ НЕЙРОПОДОБНЫХ СЕТЕЙ В РЕШЕНИИ ЗАДАЧ РЕКУРСИВНОГО ФОРМООБРАЗОВАНИЯ

Полозков Ю. В., ВГТУ, Витебск

Искусственные нейронные сети позволяют эффективно решать широкий круг аналитических информационных задач. В компьютерной технологии изготовления пространственно сложных (нерегулярных) объектов [1] - рекурсивном формообразовании – к таким задачам относятся обработка изображений; организация баз данных, содержащих

цифровые модели поверхностей; оценка эффективности создания геометрических моделей по сравнению с использованием трансформационного преобразования имеющихся цифровых моделей поверхностей.

Особенность технологии рекурсивного формообразования состоит в сокращении степени человеческого участия на этапе проектирования изделий за счет автоматизированного геометрического описания (оцифровки) поверхностей физических объектов-аналогов, имеющих пространственно-сложную (нерегулярную) форму и последующего избирательно редактирования полученных данных. Для оцифровки нерегулярных объектов был разработан программно-технический комплекс цифровой фотограмметрии. С его помощью реализуется специальный фотограмметрический метод, основанный на съемке наклонно установленной регистрирующей камерой объекта, поверхность которого освещается структурированным светом посредством горизонтально установленного проектора [2]. На снимках, получаемых в процессе оцифровки, отображаются проекции точек поверхности, освещенных с помощью слайда (рис. 1). Изменение кривизны последовательно расположенных проекций (световых линий) изображения обуславливается изменением формы поверхности. Вследствие имеющих на объекте углублений, отверстий и других “неприятных” особенностей формы при обработке изображений в процессе сегментации могут изменяться количество и последовательность расположения сегментированных компонент (рис.1), что существенно снижает точность математической трансформации координат.

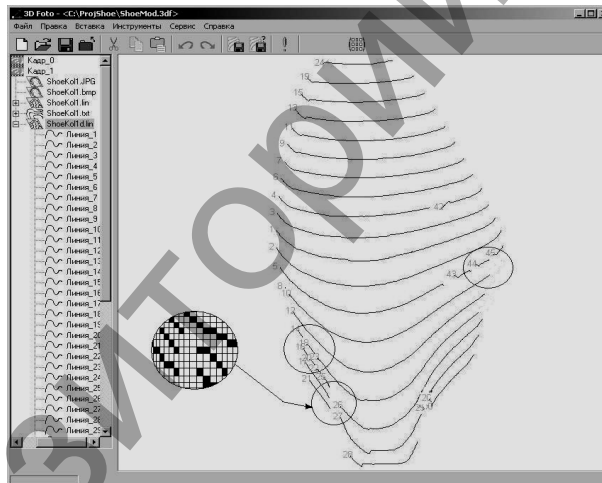


Рис. 1. Характерные неопределенности связности компонент изображения

Возникает задача структуризации и связности сегментированных компонент растрового изображения, решение которой может быть получено посредством нейросетевого анализа, позволяющего восстановить истинный их порядок. Для проведения анализа и интерпретации скелетизированного изображения были определены и формализованы следующие терминальные элементы (ТЕ): элементарная компонента (ЭК), непрерывная компонента (НК), базовая компонента (БК), фрагмент компоненты (Ф). Тип ТЕ определяется по расположению особых точек, в качестве которых выступают начальные, конечные точки ТЕ, а также их текущие точки, с координатами (по оси X или Y), равными координатам начальных и конечных точек смежных ТЕ. Комбинации указанных ТЕ описывают искомые синтезированные компоненты (СК).

На этапе предобработки данных осуществляется кластеризация ТЕ. По координатам особых точек выполняется проверка логических условий сравнения, определяющих пространственные отношения между всеми парами ТЕ. Это позволяет сформировать матрицы булевых функций. В данных матрицах, описывающих шесть возможных вариантов

отношений, индексы строк и столбцов соответствуют номерам ТЕ. Затем в результате выполнения семантических правил, описывающих сочетания пространственных отношений с элементами матриц, осуществляется построение новых (производных) матриц ТЕ, параметры (метрические, аналитические и пр.) которых будут анализироваться в дальнейшем для образования СК. Двоичные значения элементов матриц, полученных на этапе предобработки, задают внешнее возбуждение нейрона, синаптические входы которого соответствуют конкурирующим ТЕ. Отклик активированного нейрона устанавливает принадлежность ТЕ текущей цепочке или воспринимается следующими нейронами, проверяющими пространственно-логические отношения между анализируемыми ТЕ.

Сложность анализа рассматриваемых в данном случае скелетизированных изображений состоит в невозможности создания шаблонов ввиду непредсказуемости характера развития компонент изображения. Кроме того, непрерывная компонента и части дискретной компоненты могут иметь одинаковое признаковое описание. Поэтому для выработки решения о связности компонент построен трехслойный когнитрон, позволяющий реализовать конкурентный метод обучения без учителя (рис. 2) [3]. Эта самоорганизующаяся сеть включает три слоя нейронов. Нулевой слой сети является рецепторным. Количество нейронов в слое зависит от количества конкурирующих ТЕ изображения.

На первом и втором слоях сети происходит построение цепочки из БК и Ф, принадлежащих различным (последовательно расположенным) группам смежных ТЕ, ограниченных НК. При активации второго слоя на возбуждающие нейроны первого слоя, помимо латерального торможения, воздействуют тормозящие нейроны, имеющие синаптические соединения с набором выходов нейронов второго слоя. Третий слой сети построен аналогично предыдущим. Он обеспечивает выполнение принципа целостности восприятия, позволяя выбирать наиболее подходящие варианты синтеза компонент в обоих направлениях плоскости всего изображения. На этом слое по определенным критериям принимаются или отбрасываются решения, полученные на предыдущих слоях. Таким образом, реализуется способность сети к обучению, что позволяет решать вопрос неопределенности связности дискретных компонент, которая носит случайный характер и обеспечивать корректность и целостность машинной интерпретации изображения при цифровой фотограмметрии.




Рис. 2. Организация нейросетевой структуры первого и второго слоя

## Литература

1. Полозков Ю. В., Свирский Д. Н. Компьютерная технология рекурсивного формообразования нерегулярных поверхностей // Моделирование интеллектуальных процессов проектирования, производства и управления / ИТК НАН Беларуси. - Минск, 2002. - С. 44 - 45.
2. Свирский Д. Н., Полозков Ю. В. Создание трехмерных цифровых моделей нерегулярных объектов по их видеоизображениям // Цифровая обработка изображений. - Мн.: ИТК НАН Беларуси, 2001. - Вып. 5. - С. 33 – 38.
3. Уоссермен Ф. Нейрокомпьютерная техника: Теория и практика.– 1992.–184 с.

## USING ARTIFICIAL NEURAL NETWORK AND STATISTICAL APPROACH FOR TIME SERIES FORECASTING (BY USING CLUSTERING AND CLASSIFICATION ALGORITHMS)

*I. Rubanau*

### 1. INTRODUCTION

The main aim of this paper is to create a mathematical model to forecast electricity load and to find correlation between electricity load and parameters (temperature, brightness and so on), by using clustering and classification algorithms.

From the expert knowledge are known that demand of the electricity load is highly correlated to the set of parameters, like day of the week, seasons, outside temperature, brightness and so on. Also are known that this correlation are non linear, that produce additional difficulties (obstacle) to make reasonable forecasting model.

### 2. THE MODEL

Let us split up the forecasting model (see figure 1) in to three major steps:

- 1) Clustering
- 2) Classification
- 3) Creating correlation function (mathematical model) between input and output

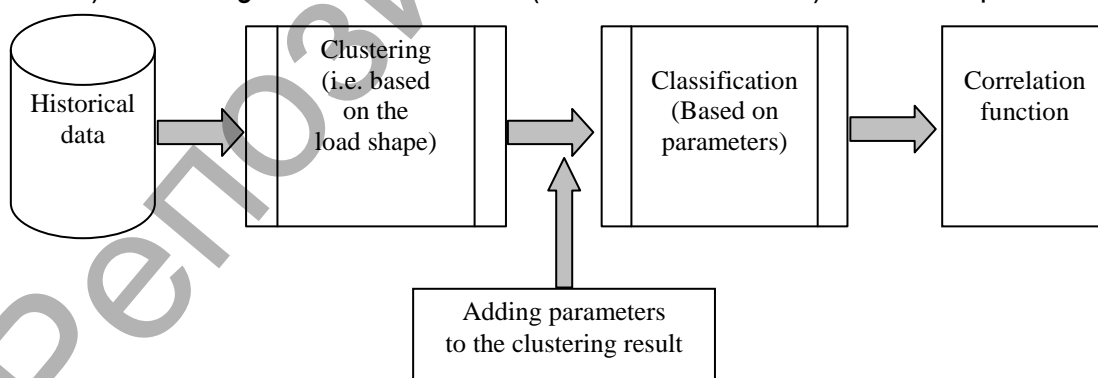


Figure 1. Mathematical model to forecast electricity load

At the first step we do clustering of the historical load data by using one of the clustering algorithm (k-means, hierarchical tree, SOM) [1,2,3], as result we have N clusters with different electricity load shapes, example of the clustering result is present in figure 2.