

УДК 007.001.362; 681.327.12.001.362

М.Е. Ваткин, А.А. Дудкин

МНОГОСЛОЙНАЯ НЕЧЕТКАЯ НЕЙРОННАЯ СЕТЬ ДЛЯ КЛАССИФИКАЦИИ ОБЪЕКТОВ НА ПОЛУТОНОВЫХ ИЗОБРАЖЕНИЯХ

Рассматриваются особенности построения нейронной сети «неокогнитрон» и проводится анализ применения неокогнитрона к решению задачи распознавания изображений. Предлагается новая структура многослойной нейронной сети, основывающаяся на нечеткой логике и ориентированная на классификацию объектов на полутоновых изображениях с искажениями типа смещения. Она позволяет значительно повысить точность распознавания при решении задачи классификации и распознавания изображений.

Введение

Классификация является одним из основных этапов при обработке и распознавании образов. Задача распознавания формулируется следующим образом. Необходимо построить такое отображение, чтобы на каждый возможный входной образ X формировался класс Y , к которому он принадлежит. Отображение задается конечным набором пар (входной образ, известный класс). Число таких пар (обучающих примеров) существенно меньше общего числа возможных пар (вход, выход). Совокупность обучающих примеров носит название обучающей выборки.

Если образы сильно искажены, то становится слишком трудоемким выделение информативных признаков для эффективной классификации. В общем случае искажения могут быть двух типов: изменены характеристики пикселей либо изменено положение пикселя. Назовем такого рода искажения смещением, т. е. будем считать, что произошло смещение в пространстве цветовых координат или в пространстве расположения. Предварительная обработка изображения, например фильтрация, сглаживание, скелетизация, позволяет уменьшить влияние искажений на процесс распознавания [1, 2]. Тем не менее при обработке визуальной информации в различных предметных областях, таких, как обработка медицинских изображений, идентификация личности, распознавание рукописных символов, имеет место задача распознавания в условиях неполной и нечеткой информации. Наиболее подходят для ее решения нейросетевые технологии. Нейронная сеть при этом реализует названное выше отображение, т. е. выступает в роли классификатора. Применение нейронных сетей в задачах обработки визуальной информации обосновывается еще тем фактом, что нейронные сети обладают свойством обучаемости или адаптивности к новым условиям постановки задачи, при этом сохраняются архитектура сети и алгоритм ее функционирования. Это, в свою очередь, позволяет использовать одну и ту же модель в различных задачах.

Образ представляет собой некоторое структурированное описание объекта. При этом для эффективной классификации необходимо учитывать иерархию информационных признаков объектов. Существует ряд нейронных сетей для классификации, позволяющих решать задачу распознавания образов с определенной степенью точности [3]: многослойный персептрон, сеть радиальной базисной функции, сети ART, сети Хопфилда, самоорганизующееся отображение Кохонена. Наиболее подходящим для этой цели является неокогнитрон [4–7], который имеет иерархическую структуру слоев, ориентированную на моделирование зрительной системы человека [8, 9]. Входной образ подается на первый слой и передается к соответствующим последующим слоям, пока не достигнет выходного слоя, в котором идентифицируется распознаваемый образ.

Известен ряд модификаций неокогнитрона, ориентированных на решение задач распознавания образов на изображениях. Обобщая сущность структурных и алгоритмических решений, применяемых в нейронной сети «неокогнитрон», можно отметить следующее.

1. Во всех идентифицируемых изображениях выделяют два типа признаков: простые признаки, которые присущи всем изображениям, такие, как линии, точки пересечения линий; и

комплексные признаки, которые присущи только определенному классу изображений, такие, как определенная пространственно-геометрическая комбинация простых признаков.

2. В соответствии с критерием сложности все признаки образуют иерархию, где каждый уровень иерархии объединяет группу признаков одной сложности. Первый уровень составляют простые признаки. Каждый следующий уровень является более сложным, и его признаки образуются путем пространственно-геометрической комбинации признаков предыдущего уровня.

3. Строится многослойная сеть, где количество слоев совпадает с количеством уровней сложности. Каждый слой делится на подслои в соответствии с количеством признаков в данной группе. Функция отдельного подслоя заключается в обнаружении (выделении) соответствующего признака на всем изображении, т. е. отдельный подслой строит своего рода карту распределения данного признака на изображении. Для обеспечения инвариантности сети к небольшим сдвигам признаков (искажениям типа смещение) в слои вводятся подслои, которые дублируют карты распределения признаков соответствующих им подслоев, при этом каждый обнаруженный признак «размазывается» в некоторой его окрестности.

4. Идентификация образа производится путем последовательной активации слоёв: от слоя, выделяющего простые признаки, до слоя, выделяющего признаки всего образа в целом.

Таким образом, при создании неокогнитрона необходимо решить следующие задачи:

- определить способ выделения признака и реализующий его нейрон (сформулировать правило его обучения и активации);
- сформулировать критерий эффективности набора признаков, входящих в одну группу, который позволяет оптимизировать количество подслоев вручную или автоматически;
- разработать иерархию признаков, т. е. метод, определяющий, как должны сочетаться признаки при формировании признака более сложного уровня.

В работах [10–13] рассмотрена модификация неокогнитрона, которая позволяет выполнять классификацию объектов, имеющих искажения формы. В настоящей статье предлагается новая обобщенная структура, ориентированная на обработку объектов на полутоновых изображениях с искажениями типа смещения, которые включают в себя как искажения формы, так и искажения цвета. Далее рассматривается более детально каждая из названных выше задач. Поскольку неокогнитрон требует существенных вычислительных ресурсов, приводятся оценки вычислительной сложности предлагаемых решений. В заключение дано описание экспериментального тестирования неокогнитрона.

1. Анализ структуры нейронов сети «неокогнитрон»

Выделение локального признака осуществляется парой нейронов: тормозящим и собственно выделяющим (рис. 1).

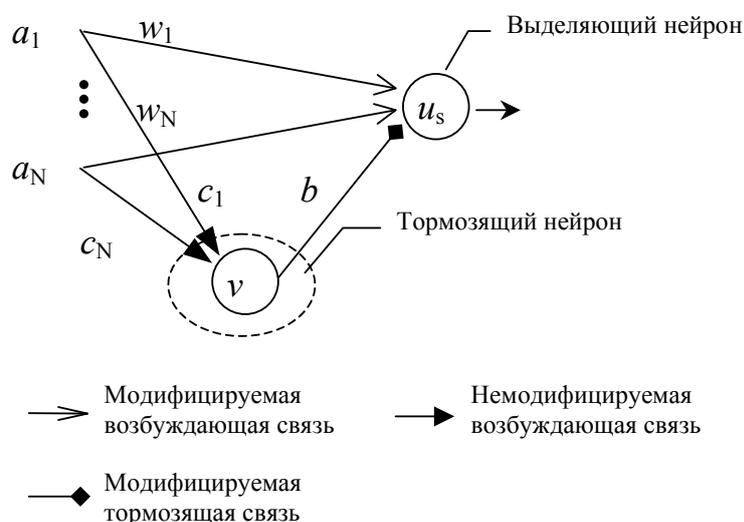


Рис. 1. Структура связей нейронов для выделения признаков

На рис. 1 используются следующие обозначения:

N – количество входящих связей нейрона;

a_i – входящие активности нейронов с предыдущего слоя;

w_i – модифицируемые весовые коэффициенты возбуждающих связей;

c_i – немодифицируемые весовые коэффициенты возбуждающих связей;

b – модифицируемый весовой коэффициент тормозящей связи;

v – активность тормозящего нейрона, $v = \sqrt{\sum_{i=1}^N c_i \cdot (a_i)^2}$;

u_s – активность выделяющего нейрона, $u_s = \varphi \left(\frac{1 + \sum_{n=1}^N w_n \cdot a_n}{1 + h} - 1 \right)$, $h = b \cdot v$; $\varphi(x) = \begin{cases} x, & x \geq 0; \\ 0, & x < 0. \end{cases}$

Множество пар таких нейронов составляет выделяющий слой неокогнитрона.

Для обеспечения инвариантности к искажению образа вводится дополнительный нейрон (обобщающий). Входами для него являются активности выделяющих нейронов с предыдущего слоя (рис. 2).

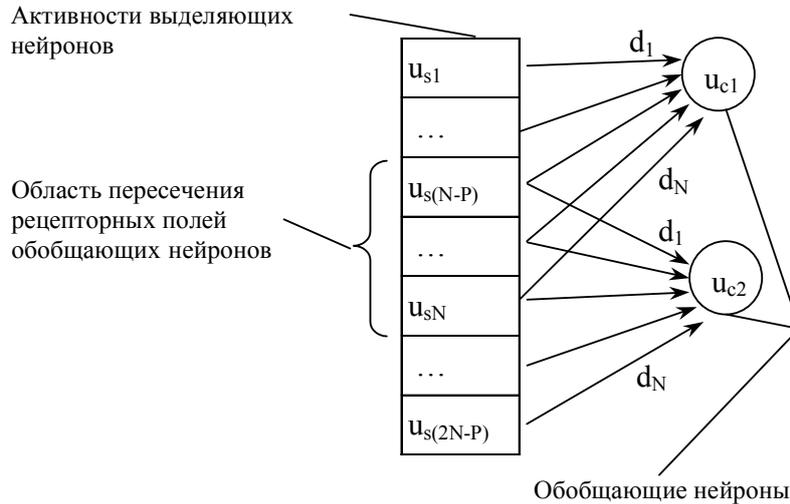


Рис. 2. Структура связей обобщающего слоя

На рис. 2 используются следующие обозначения:

N – количество входящих связей нейрона или размер рецепторного поля нейрона;

P – количество нейронов из предыдущего слоя в области перекрытия соседних нейронов;

d_i – немодифицируемые весовые коэффициенты возбуждающих связей, определенные таким образом, чтобы монотонно уменьшаться к краю рецепторной области.

Активность выделяющего нейрона u_{ci} задается следующими формулами:

$$u_c = \psi \left(\sum_{n=1}^N d_n \cdot u_{sn} \right);$$

$$\psi(x) = \begin{cases} \frac{x}{\alpha_l + x}, & x \geq 0; \\ 0, & x < 0, \end{cases}$$

где α_l – некоторый положительный коэффициент, выбираемый экспертом.

Общий смысл правила активации для обобщающих нейронов таков: если выделенный признак попадает в область пересечения рецепторных полей нейронов, то будут активизироваться оба нейрона. Таким образом, активность одного нейрона из предыдущего слоя переходит в активность нескольких нейронов последующего слоя, что приводит к «размазыванию» признака в данном слое.

Для программной реализации механизма идентификации одного признака из нейронной сети «неокогнитрон» необходимы:

- $N + 2$ ячеек памяти для хранения весовых коэффициентов и результата активации выделяющего нейрона;
- $N + 1$ ячеек памяти для хранения весовых коэффициентов и результата активации тормозящего нейрона;
- $N' + 1$ ячеек памяти для хранения весовых коэффициентов и результата активации обобщающего нейрона;
- $2N+2$ операций умножения для вычисления активности тормозящего нейрона;
- $N+3$ операций умножения для вычисления активности выделяющего нейрона;
- $N' + 2$ операций умножения для вычисления активности обобщающего нейрона.

Операции деления и извлечения квадратного корня считаются эквивалентными операциями умножения, а N операций сложения – эквивалентными одной операции умножения. Итого необходимо $2N+N'+3$ ячеек памяти и $(3N + 5)(N' + 1)$ операций умножения, где $N \approx N'$.

2. Модификация структуры нейрона

Описанное выше правило выделения локального признака, инвариантное к смещениям, близко к его биологическому аналогу, но с точки зрения программной реализации (т. е. экономии объема требуемой памяти и машинного времени) возникает ряд спорных моментов:

- необходимость столь сложного правила для выделения локального признака;
- эффективность применения «размазывания» в качестве правила, обеспечивающего инвариантность;
- необходимость использования дополнительного слоя нейронов для обеспечения инвариантности.

В качестве альтернативы рассмотренному подходу предлагается использовать новую функцию активации нейрона (т. е. новый метод выделения локального признака), основанную на функции нечеткого различия для двух матриц, а в качестве правила обучения (правила модификации коэффициентов) – функцию нечеткого динамического среднего.

Рассмотрим две матрицы

$$W = \begin{pmatrix} w_{1,1} & \cdots & w_{1,Y} \\ \vdots & \ddots & \\ w_{X,1} & & w_{X,Y} \end{pmatrix}; \quad A = \begin{pmatrix} a_{1,1} & \cdots & a_{1,Y1} \\ \vdots & \ddots & \\ a_{X1,1} & & a_{X1,Y1} \end{pmatrix},$$

где W – матрица пикселей эталонного изображения; A – образ матрицы W , который содержит искажения типа смещения. Поскольку в матрице A предполагается смещение (изменение) как значений соответствующих пикселей, так и его геометрических координат, то матрица A имеет больший размер, определяемый максимальными величинами смещения по горизонтали и вертикали.

Для определения функции $fd(A, W)$ нечеткого различия двух матриц A и W введем два параметра B и R , которые задают диапазоны нечеткости различия. Параметр B – это диаметр яркостных искажений изображения, определяющий максимально допустимое расстояние между двумя пикселями изображения, которые считаются эквивалентными. Параметр R – радиус геометрических искажений, который определяет максимально допустимое смещение пикселей эталона на изображении-образе.

Отметим, что для любых двух соседних пикселей $a_{x1, y1}$, $a_{x2, y2}$ и их смещений $\vec{v}_{x1, y1}$, $\vec{v}_{x2, y2}$ справедливо $|\vec{v}_{x1, y1} - \vec{v}_{x2, y2}| \leq \theta$, где $\theta \leq \max(|\vec{v}_{x1, y1}|, |\vec{v}_{x2, y2}|)$. Данное свойство указывает на од-

нородность геометрических искажений, т. е. на то, что соседние пиксели будут смещены почти одинаково.

Построим матрицу

$$D = \begin{pmatrix} d_{1,1} & \cdots & d_{1,Y} \\ \vdots & \ddots & \\ d_{X,1} & & d_{X,Y} \end{pmatrix};$$

$$d_{x,y} = \begin{cases} 0, & \text{если } \min_{i,j=0..2R} (a_{x+i,y+j}) \leq w_{x,y} \leq \max_{i,j=0..2R} (a_{x+i,y+j}); \\ 0, & \text{если } |w_{x,y} - a_{x+R,y+R}| < B; \\ 1 & \text{в остальных случаях.} \end{cases} \quad (1)$$

Теперь функция нечеткого различия матриц A и W определяется следующим образом:

$$fd(A,W) = \frac{100}{X \cdot Y} \cdot \sum_{x,y} d_{x,y}. \quad (2)$$

Допустим, что на каждой итерации обучения t поступает обучающий образ A^t , тогда в результате обучения на каждой итерации получим последовательность модификаций матрицы пикселей эталонного изображения $\{W^t \mid t = 0, \dots, T\}$, где T – общее число итераций.

Определим функцию нечеткого динамического среднего:

$$w_{x,y}(t+1) = \begin{cases} w_{x,y}(t), & \text{если } \min_{i,j=0..2R} (a_{x+i,y+j}(t)) \leq w_{x,y}(t) \leq \max_{i,j=0..2R} (a_{x+i,y+j}(t)); \\ w_{x,y}(t), & \text{если } |w_{x,y}(t) - a_{x+R,y+R}(t)| < B; \\ \frac{w_{x,y}(t) \cdot t + a'_{x,y}}{t+1} & \text{в остальных случаях,} \end{cases} \quad (3)$$

где t – порядковый номер итерации усреднения, а $a'_{x,y} \in \{a_{x+i,y+j}(t) \mid i, j = 0, \dots, 2R\}$ такое, что $|w_{x,y}(t) - a'_{x,y}(t)| = \min_{i,j}$.

Для программной реализации правила активации нечеткого нейрона (рис. 3) необходимо:

- $2N$ ячеек памяти для хранения значений пар $[\min_k, \max_k]$;
- N ячеек памяти для хранения значений коэффициентов w_i ;
- одна ячейка памяти для хранения значения результата активации нейрона;
- $2N(2R-1)$ операций сравнения для нахождения значений $[\min_k, \max_k]$;
- $3N$ операций сравнения и N операций сложения для вычисления значения d_i ;
- N операция сложения, три операции умножения и одна операция деления для вычисления значения fd .

Полагая, что затраты машинного времени для вычисления операции сравнения эквивалентны затратам для вычисления операции сложения, а N операций сложения – одной операции умножения или деления, получим следующие обобщенные затраты на программную реализацию нейрона:

- $3N+1$ ячеек памяти;
- $4R+7$ операции умножения.

Таким образом, получаем экономию машинного времени в $k_t = (3N + 5)(N' + 1)/(4R+7)$ раз при примерно одинаковых затратах памяти: $k_m = (2N+N'+3)/(3N+1) \approx 1$. Так, при $R \leq 0,2N$ значение $k_t = (3N + 5)(N' + 1)/(4R+7) = (3N^2+8N+3)/(0,8N+7) \approx 3,75N - 32,8125$.

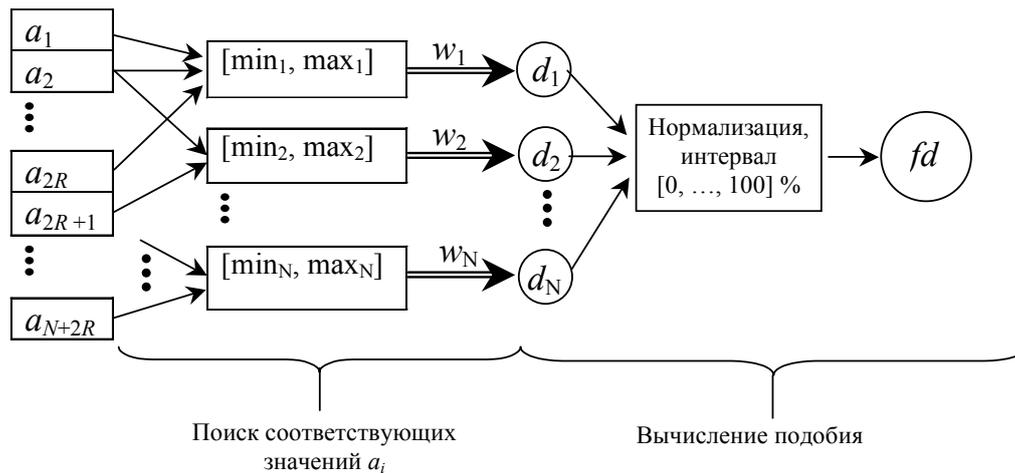


Рис. 3. Общая структура нечеткого нейрона: $[\min_k, \max_k], k = 0, \dots, N$, определяются так же, как в формуле (1),
 $\min_k = \min_i(a_{k+i}), i = 0, \dots, 2 \cdot R$; $\max_k = \max_i(a_{k+i}), i = 0, \dots, 2 \cdot R$

3. Общая структура связей в нейронной сети

Общая структура связей предлагаемой нейронной сети близка по своей сути и функциям структуре связей в сети «неокогнитрон» с тем лишь отличием, что из-за упрощения структуры нейрона в ней отсутствуют обобщающие слои (рис. 4). На рис. 4 рецепторный слой R является входным слоем сети, на который подается обрабатываемый образ. Внутренние слои S_1, \dots, S_{n-1} производят последовательную обработку поступающей информации, а выходной слой сети O генерирует ответ на вопрос, к какому классу относится входное изображение, в виде максимальной активности одного из своих нейронов, т. е. выходной нейрон взаимно однозначно соответствует одному из заданных классов.

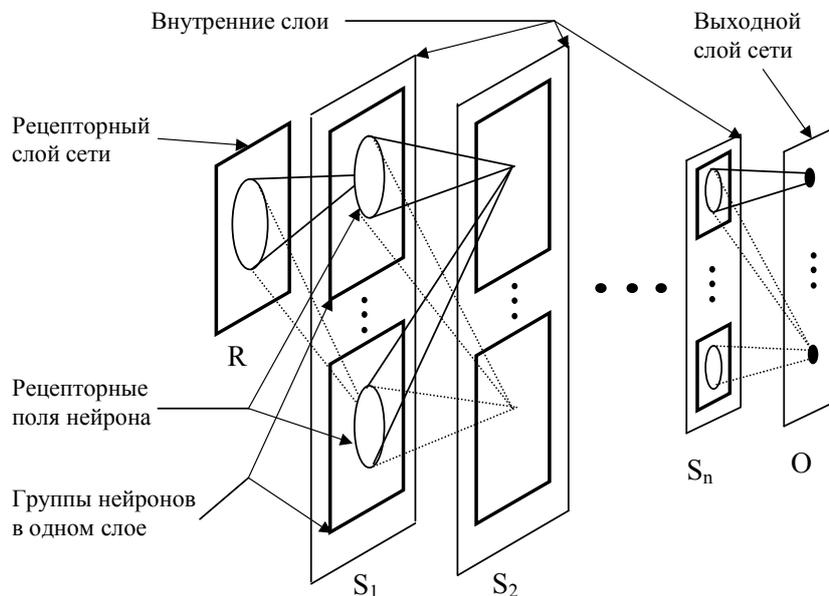


Рис. 4. Структура нейронной сети

Рецепторный слой преобразует яркости пикселей изображения в значения активностей нейронов. Нейроны, выделяющие одинаковый признак на изображении, объединяются в одну группу. Исходными данными для активации каждого нейрона из отдельной группы является локальная часть данных из предыдущего слоя с соответствующим этому нейрону смещением.

Смещение определяется в соответствии с положением нейрона внутри группы. На рис. 5 приведен пример структуры связей нейронов из одной группы в случае одномерных входных данных. Необходимо обратить внимание, что каждый нейрон имеет часть рецепторного поля в каждой из групп предыдущего слоя.

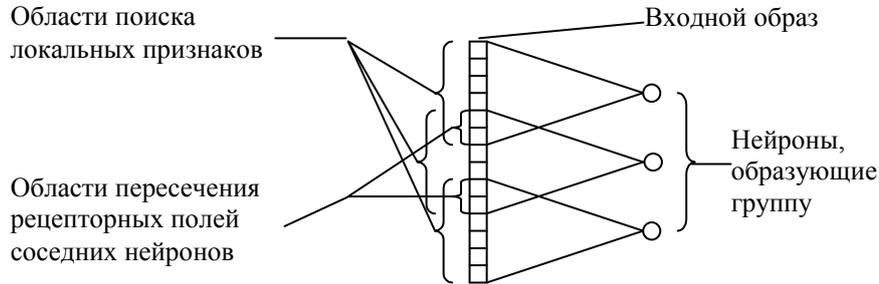


Рис. 5. Схема объединения нейронов в группу

Размер выделяемого признака изображения обычно больше размера областей перекрытия соседних нейронов и меньше либо равен размеру области поиска локального признака. Для случая, когда входные данные представляют собой двумерный массив, нейроны тоже организуются в двумерную структуру. Таким образом, активность нейронов из одной группы формирует карту распределения выделяемого признака на входном изображении.

Учитывая тот факт, что правила обучения и активации нейрона используют методы нечеткой логики, назовем предлагаемую нейронную сеть многослойной нечеткой нейронной сетью (МННС).

В описанной выше структуре нейроны являются классификаторами признаков определенного уровня иерархии. Входные данные для них поступают с предыдущего слоя и объединяют совокупность признаков предыдущего уровня иерархии. Активность нейрона определяет степень принадлежности рассматриваемой совокупности признаков к следующему уровню иерархии. Тогда структуру сети можно представить, как показано на рис. 6, введя в нее локальный классификатор $ЛК_{ij}$ вместо нейрона, где $i = 1, \dots, n$ – номер слоя, $j = 1, \dots, N_i$ – число признаков i -го уровня. Заметим, что в качестве локальных классификаторов могут выступать и более сложные элементы. Тогда данная структура представляет собой группу классификаторов с многослойной организацией структуры процесса классификации.

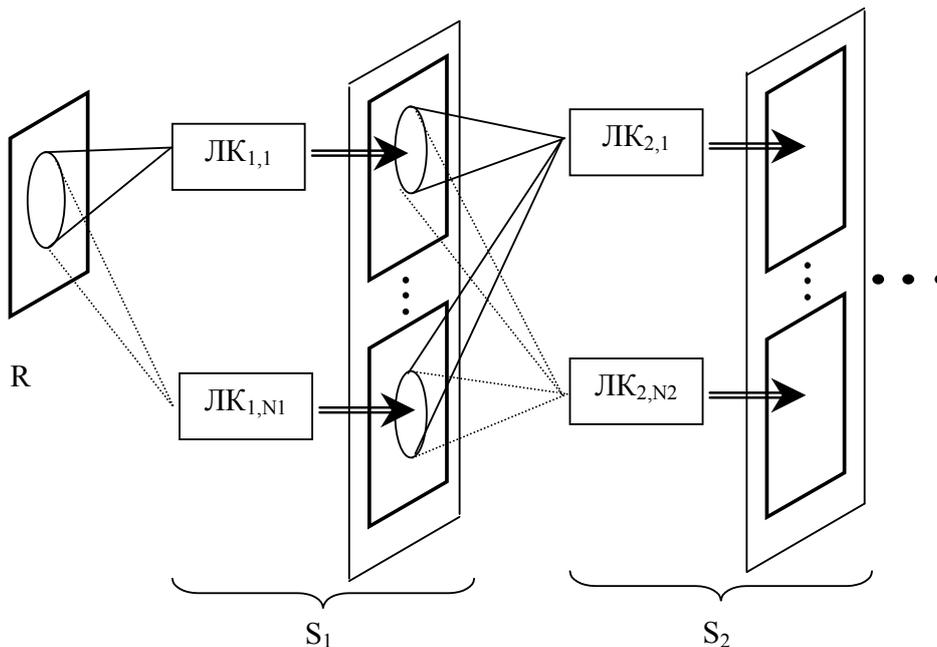


Рис. 6. Структура многослойного классификатора

4. Подбор параметров нечеткого нейрона

Функционирование нечеткого нейрона определяется формулами (1)–(3), в которых переменные R и B являются параметрами. Поскольку параметры R и B взаимно зависимы, то авторами, как правило, рассматривается один из крайних подходов: присутствуют только яркостные искажения (параметр B); присутствуют только геометрические искажения (параметр R). С другой стороны, правильнее считать, что в любом изображении присутствуют оба вида искажений и они некоторым образом связаны друг с другом. Конечно, данные параметры для конкретного изображения могут быть получены экспериментально, но это неоптимально с точки зрения построения автоматизированной системы распознавания образов, где заранее неизвестны количественные параметры искажений, к которым система должна быть инвариантна. Определим значения параметров R и B следующим образом.

Пусть дано L обучающих изображений размера X на Y . Диаметр яркостных искажений изображений B зададим формулой

$$B = \frac{1}{Y \cdot X} \cdot \sum_{x,y} \left[\frac{1}{L} \cdot \sum_l a_{x,y} - \frac{1}{L} \cdot \sum_l a_{x,y} \right]. \quad (4)$$

Обозначим через F среднюю частоту смены уровня яркости изображения, для которой соседние точки изображения считаются принадлежащими одному уровню при условии, что абсолютная разница их яркости меньше B . Теперь радиус геометрических искажений R зададим как

$$R = [0,3 * 1/F], \quad (5)$$

где $[x]$ – операция взятия ближайшего целого.

Формула (5) подчеркивает тот факт, что если радиус искажения превышает средний диаметр атомарных признаков на 30 %, то в результате такого искажения изображение перемещается настолько, что нельзя узнать атомарные признаки, следовательно, невозможно построить отличительный признак и, соответственно, невозможно идентифицировать искаженное изображение как относящееся к классу шаблонного изображения. Здесь под атомарным признаком понимается признак изображения, который нельзя разделить на более мелкие признаки. Отметим, что граница области изображения, образующая атомарный признак, является почти выпуклой фигурой. Свойство «почти выпуклая фигура» означает, что для такой фигуры любая секущая, проведенная через ее центроид, пересекает границу лишь дважды. Диаметр атомарного признака определяется как средняя длина секущей, проведенной через центроид фигуры, которая образована атомарным признаком.

Таким образом, формулы (4), (5) позволяют по обучающему набору вычислить параметры R и B , определяющие поведение нейрона.

5. Формирование обучающего множества для слоя МНС

В оригинальной сети «неокогнитрон» обучающие образы для каждого слоя сети формируются разработчиком нейронной сети исходя из специфики конкретной задачи распознавания. Это, в свою очередь, является препятствием для автоматической адаптации системы распознавания под разные исходные данные.

В рассматриваемой постановке задачи распознавания предполагается, что существует набор шаблонов изображений. Следовательно, имея такой набор образцов, необходимо разработать метод автоматической генерации обучающего множества для каждого слоя сети. Для каждого слоя сети можно определить размеры проекции рецепторного поля нейрона на входной слой сети. На рис. 7 изображена проекция рецепторного поля нейрона из второго слоя на входной слой сети для случая одномерных входных данных.

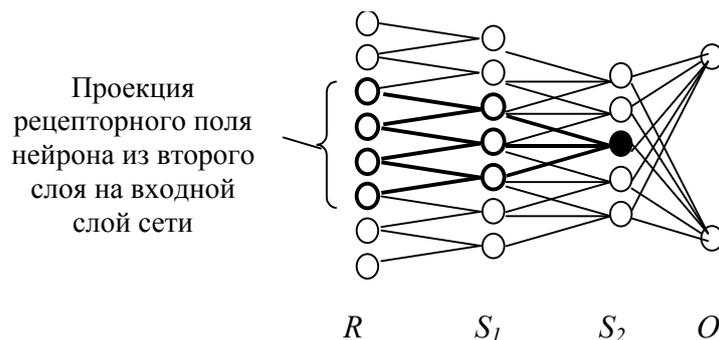


Рис. 7. Метод построения проекции рецепторного поля

Таким образом, для одного обучающего изображения получим K обучающих изображений для некоторого i -го слоя сети:

$$K = N_{in} - N_i + 1,$$

где N_{in} – размер входных данных; N_i – размер проекции рецепторного поля i -го слоя сети.

Желательно, чтобы обучающее множество содержало только изображения повышенной информативности. Будем считать, что обучающие данные для i -го слоя сети являются информативными, если выполняются условия

$$F_{in}/F_k \leq 0,8$$

или

$$F_k/F_{in} \leq 0,8,$$

где F_{in} – средняя частота смены уровня яркости входного изображения; F_k – средняя частота смены уровня яркости изображения, получаемого в окне рецепторного поля.

Получив обучающее множество для каждого слоя, легко заметить, что задача обучения слоя сводится к задаче кластеризации входных данных слоя, получаемых из обучающего множества.

6. Алгоритм обучения слоя сети

В связи с тем что нейроны, входящие в одну группу, имеют одинаковые матрицы весовых коэффициентов, всю группу можно представить в виде одного нейрона, а слой представить в виде однослойной нейронной сети, в которой каждый нейрон соответствует одной из групп. Для обучения такой сети будем использовать алгоритм кластеризации, где каждый кластер соответствует одному нейрону. После обучения сети будем использовать такую нейронную сеть как прототип для построения искомого слоя в многослойной сети, где количество нейронов в прототипе будет соответствовать количеству групп, а весовые коэффициенты нейронов из прототипа – весовым коэффициентам у нейронов из соответствующих групп.

В случае когда обучающее множество слоя невелико и известно желаемое количество кластеров (т. е. групп нейронов), для решения задачи нечеткой кластеризации удобно применить алгоритм «fuzzy C-means» [14]. Если количество кластеров неизвестно, то для решения задачи нечеткой кластеризации наиболее подходит алгоритм пикового группирования [14].

В случае когда обучающее множество слоя велико и неизвестно желаемое количество кластеров, для решения задачи кластеризации предложен алгоритм [15], который основан на алгоритме FOREL [16, 17] и строит псевдооптимальное разбиение входного признакового пространства. Достоинством алгоритма является то, что он дает возможность построить это разбиение за малое количество проходов по множеству входных данных. Это, в свою очередь, по-

зволяет снизить временные затраты, если входные данные представляют достаточно большую выборку. Количество проходов не превышает шести.

Введем в рассмотрение ε – параметр шага дискретизации входного пространства признаков. Исходными данными является обучающее множество $M = \{A_i | i = 1, \dots, L\}$.

1. Установить шаг дискретизации исходного пространства ε .
2. Добавить новый кластер с весовыми коэффициентами W , равными значениям A_1 .
3. Цикл по всему обучающему множеству $M = \{A_i | i = 1, \dots, L\}$.
 - 3.1. Рассчитать коэффициент нечеткого различия для текущих входных данных A_i и каждого центра кластера во множестве кластеров по формуле (2) и выбрать кластер «победитель» с наименьшим различием D_{min} .
 - 3.2. Если $\varepsilon \geq D_{min}$, то усреднить входные данные с центром кластера победителя по формуле (3), иначе добавить новый кластер с весовыми коэффициентами W , равными значениям A_i входных обучающих данных.
- Конец цикла.
4. Если в цикле был добавлен новый кластер, то перейти к п. 3.
5. Конец.

К недостатку алгоритма можно отнести необходимость подбора параметра шага дискретизации входного пространства признаков ε .

7. Тестирование модели МННС

В качестве тестовых использовались изображения слоя металлизации интегральных микросхем (рис. 8).

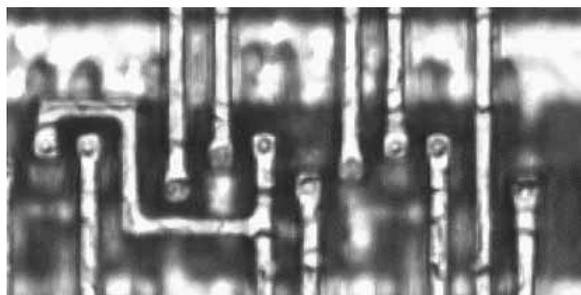


Рис. 8. Пример тестовых данных

Обучающая выборка состояла из девяти образов контактных площадок, направленных вверх, и девяти – направленных вниз (рис. 9).

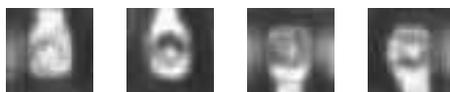


Рис. 9. Примеры обучающих изображений

Сеть состояла из трех слоев, где размер рецепторного слоя равнялся 32x32 точки, размер рецепторного поля первого слоя равнялся 3x3 точки, размер рецепторного выходного слоя – 30x30 точек.

После обучения значения параметров R и B для каждого слоя составили: для первого слоя $R = 1$, $B = 28$; для выходного слоя $R=1$, $B=39$. Количество групп нейронов для первого слоя – 61, для выходного слоя – 4.

На рис. 10 области изображения, которые были отнесены к одному из классов контактных площадок, направленных вверх или вниз, обведены черным квадратом. В результате из 57 контактных площадок правильно было найдено 46, количество ошибочных срабатываний составило 3, количество ненайденных – 11. Итого, распознавание составило 80 %, ошибки – 25 %.

Процент распознавания можно повысить за счет включения в обучающую выборку изображений, которые не были распознаны.

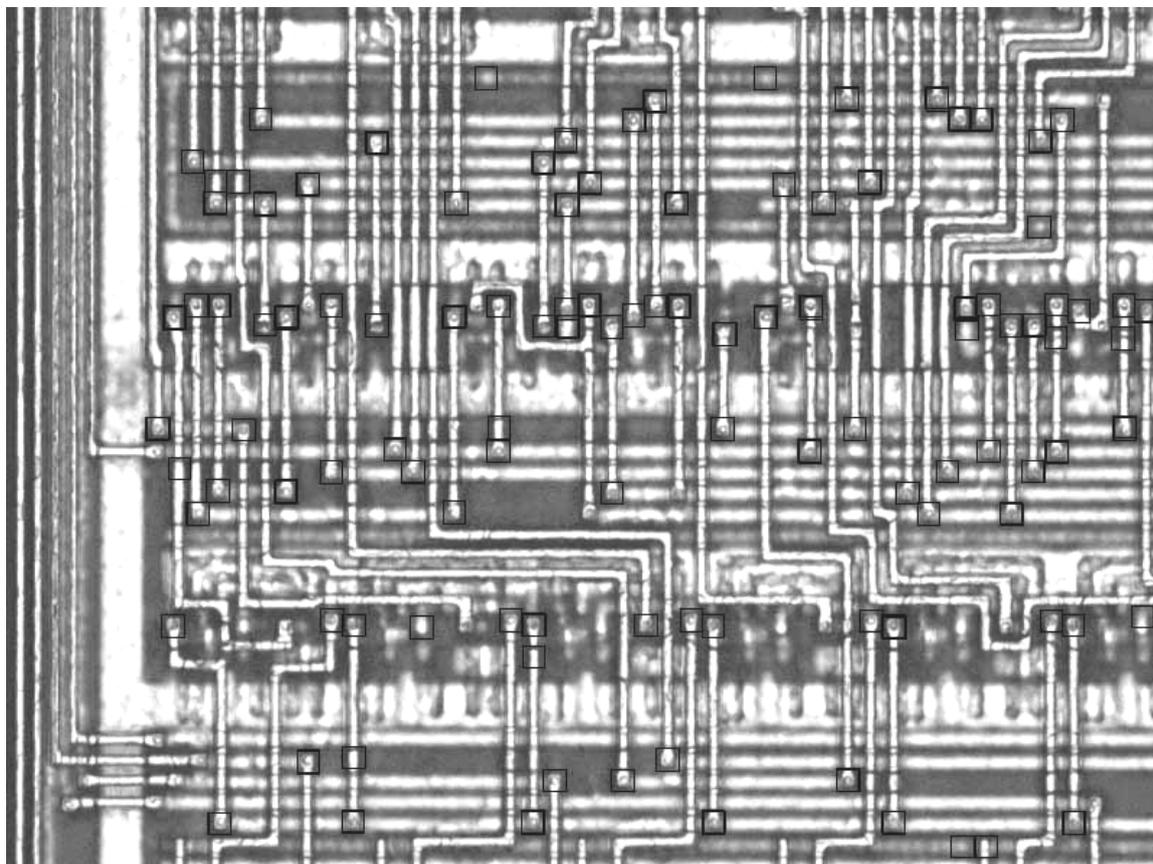


Рис. 10. Результаты тестирования модели МННС

Заключение

В статье проводится анализ структуры, а также алгоритмов нейронной сети «неокогнитрон» с целью улучшения характеристик скорости обработки информации и точности распознавания. Архитектура разработанной нейронной сети представляет собой новый класс многослойных нейронных сетей, базирующихся на многоуровневом процессе распознавания. В основе правила активации нейронов лежит новый метод сравнения матриц яркостей изображений, который позволяет сравнивать матрицы с нечетким позиционированием соответствующих элементов матриц. Данный метод, в свою очередь, основывается на расчете геометрических и яркостных искажений по набору изображений объекта. Особенностью данного правила активации является инвариантность результатов сравнения к локальным искажениям формы объекта.

Список литературы

1. Абламейко С.В., Лагуновский Д.М. Обработка изображений: технология, методы, применение. – Мн.: Ин-т техн. кибернетики НАН Беларуси, 2000. – 304 с.
2. Cheng-Yuan L., Hsing-Chang Y. Hand printed Character Recognition Based on Spatial Topology Distance Measurement // IEEE Transaction on Pattern Analysis and Machine Intelligence. – V. 18 (9). – 1996.
3. Головки В.А. Нейроинтеллект: теория и применение. В 2 кн. Кн. 1: Организация и обучение нейронных сетей с прямыми и обратными связями. – Брест: Изд-во БПИ, 1999. – 264 с.;

Кн. 2: Самоорганизация, отказоустойчивость и применение нейронных сетей. – Брест: Изд-во БПИ, 1999. – 228с.

4. Fukushima K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position // *Biol. Cybern.* – V. 36. – 1980. – P. 193–202.

5. Fukushima K., Miyake S. Neocognitron: A new algorithm for pattern recognition tolerant of deformations and shifts in position // *Pattern Recognition.* – V. 15. – 1982. – P. 455–469.

6. Fukushima K., Miyake S., Ito T. Neocognitron: A neural network model for a mechanism of visual pattern recognition // *IEEE Trans. Syst., Man, Cybern.* – V. SMC-13. – 1983. – P. 826–834.

7. Fukushima K., Wake N. Handwritten alphanumeric character recognition by the Neocognitron // *IEEE Trans. on Neural Networks.* – V. 2. – № 3. – 1991. – P. 355–365.

8. Hubel D.H., Wiesel T.N. Receptive fields, binocular interaction and functional architecture in cat's visual cortex // *J. Physiol (London).* – V. 160. – Jan. 1962. – P. 106–154.

9. Hubel D.H., Wiesel T.N. Receptive fields and functional architecture in two nonstriate visual area (18 and 19) of the cat // *J. Neurophysiol.* – V. 28. – 1965. – P. 229–289.

10. Sadykhov R., Vatin M. New training algorithm of neural network «neocognitron» for recognition of hand-written symbols // *Proc. of 6 International conf. «Pattern recognition and information processing».* V. 1. – Minsk (Belarus), May 18–20, 2001. – P. 203–212.

11. Sadykhov R.Kh., Klimovich A.N., Vatin M. The models of neural networks for videoimage processing in industrial applications // *NATO advanced study institute on neural networks for instrumentation, measurement, and related industrial applications.* – Crema, Italy, 2001. – P. 78–84.

12. Садыхов Р.Х., Ваткин М.Е. Алгоритм обработки полутоновых изображений интегральных микросхем на базе нейронной сети «неокогнитрон» // *Цифровая обработка изображений.* – Мн.: Ин-т техн. кибернетики НАН Беларуси, 2001. – С. 68–75.

13. Ваткин М.Е. Оптимизация структуры и алгоритмов нейронной сети «неокогнитрон» // *Информатика.* – 2004. – № 1. – С. 61–71.

14. Осовский С. Нейронные сети для обработки информации. – М.: Финансы и статистика, 2004. – 344 с.

15. Ваткин М.Е. Распознавание рукописных символов на основе модифицированной SOM нейронной сети // *Мат. I Междунар. конф.* – Мн.: Изд-во БГУ, 2002. – Ч. 2. – С. 201–206.

16. Загоруйко Н.Г., Елкина В.Н., Лбов Г.С. Алгоритмы обнаружения эмпирических закономерностей. – Новосибирск: Наука, 1985. – 110 с.

17. Прикладная статистика: классификация и снижение размерности / С.А. Айвазян, В.М. Бухштабер, И.С. Енюков, Л.Д. Мешалкин. – М.: Финансы и статистика, 1989.

Поступила 30.03.05

*Объединенный институт проблем
информатики НАН Беларуси,
Минск, Сурганова 6
e-mail: vatkin@tut.by,
doudkin@newman.bas-net.by*

M.E. Vatin, A.A. Doudkin

MULTILAYER FUZZY NEURAL NETWORK FOR OBJECTS CLASSIFICATION ON HALFTONE IMAGES

Construction peculiarities of neural network neocognitron were considered in application to image recognition task. A new structure of multilayer neural network based on fuzzy logic was developed, that was designed for classification of objects having pixel shift distortions on halftone images. This neural network allows to increase significantly the recognition accuracy.