

Исследование возможности повышения точности распознавания нейронной сети при фиксированном числе активных нейронов¹

С.А. Гладилин, Д.П. Николаев, Д.В. Полевой, Н.А. Соколова

Аннотация. В статье исследуется возможность повышения точности нейросетевого классификатора в системе реального времени без ухудшения временных характеристик за счет замены нейронной сети составным классификатором, являющимся двухуровневым деревом. Такая схема позволяет при том же времени классификации увеличить общее число нейронов, задействованных в классификаторе, повышая тем самым его выразительную силу. Экспериментальное исследование предложенного метода производится на примере задачи распознавания символов, тисненых на пластиковых картах.

Ключевые слова: обучение машин, статистические методы распознавания, распознавание символов, многослойные нейронные сети, признаковые пространства, распознавание в реальном времени.

Введение

Разработка и усовершенствование распознающих систем зачастую требует решения задачи двухкритериальной оптимизации, критериями в которой выступают точность и время. Опыт показывает, что в пределах фиксированной общей архитектуры распознавателя при увеличении допустимого времени вычисления удается добиться большей точности, чем в системах, более ограниченных во времени. И, наоборот, снижение требований по точности позволяет построить более быстрые системы. Важным является случай систем реального времени, когда необходимо обеспечить максимальное качество при фиксированных требованиях по скорости работы.

Классификация есть вычисление расположения точки в некотором пространстве относительно классифицирующей функции. Сложность оптимальной разделяющей функции можно считать сложностью задачи классификации. При классификации с использованием нейронной сети каждая связь сети задает степень свободы, т.е. чем сложнее задача классификации, тем в общем случае больше связей должно быть в нейронной сети, аппроксимирующей классифицирующую функцию. Однако при работе нейронной сети каждая связь требует выполнения операции умножения, т.е. чем больше связей в сети, тем больше время вычисления.

В то же время другие вычислительные архитектуры не подвержены подобным ограничениям, например, при использовании решающих де-

¹ Работа выполнена при поддержке РФФИ (гранты №13-07-12178 и №13-07-12170).

ревьев скорость вычисления зависит не от общего числа связей в дереве, а от длины его ветвей. Таким образом, для увеличения точности распознавания при сохранении времени вычислений актуальным является исследование различных вычислительных архитектур, позволяющих обойти ограничения, которым подвержены классические нейросетевые классификаторы.

Тесно связанной с рассматриваемой проблемой является известная архитектура составного классификатора, состоящего из ансамбля классификаторов нижнего уровня (в качестве которых могут выступать, например, классические нейронные сети) и некоторого узла, объединяющий результаты их работы. Разработка различных схем составных классификаторов – одно из активно развивающихся направлений исследований [1-5]. Однако больше внимания в работах уделяется составным классификаторам, решение в которых принимается на основании ответов всего ансамбля классификаторов нижнего уровня. Это позволяет:

- использовать классификаторы нижнего уровня с достаточно низкой обобщающей способностью. Их совместное использование в составном классификаторе может дать выигрыш в точности (так, например, работают разнообразные варианты “бустинга”);

- использовать параллельные вычисления.

Однако на последовательных машинах такой способ позволяет уменьшить время работы только при условии упрощения классификаторов нижнего уровня. Менее распространен тип составных классификаторов, в котором решение принимается всего одним классификатором из ансамбля. Такая схема позволяет увеличить скорость распознавания (или повысить качество при фиксированной скорости) за счет отказа от вычисления ответов остальных классификаторов нижнего уровня.

В данной работе исследовался метод увеличения точности классификации без увеличения времени вычисления путем замены классической нейронной сети на составной классификатор, являющийся двухуровневым деревом. На верхнем уровне дерева находится функция выбора, на нижнем – классификаторы-нейронные сети (согласованные по числу с числом выходных классов функции выбора). При распозна-

вании система в зависимости от значения функция выбора определяет нейронную сеть нижнего уровня, которая будет применена для классификации.

Таким образом, время работы предлагаемого классификатора не превышает суммы времени работы функции выбора и самого медленного из классификаторов нижнего уровня. Количество нейронов в каждой сети нижнего уровня ограничено в соответствии с требованиями ко времени работы классификатора, однако общее количество нейронов в дереве можно неограниченно увеличивать за счет подключения большего числа сетей нижнего уровня. Для того, чтобы такая схема повышала качество распознавания, функция выбора должна разделять все входные изображения на классы, в пределах каждого из которых задача распознавания имеет меньшую сложность, чем в общем случае.

В работе рассмотрены два подхода к построению функции выбора, которая бы ограничила области пространства признаков сетей нижнего уровня. При первом подходе функция выбора предварительно кластеризовала входную выборку по признакам, релевантным целевой классификации, при втором - оценивала степень резкости входного изображения, то есть использовала признак, инвариантный к целевому классу. В соответствии с этим пространство признаков разбивалось на рабочие области, для каждой из которых обучалась своя сеть нижнего уровня.

В процессе исследования результаты обучения составных классификаторов сравнивались с результатами, полученными для классического нейросетевого классификатора, имеющего ту же структуру, что и сети нижнего уровня. При его создании использовалась вся обучающая выборка, а число нейронов было подобрано таким образом, что время работы составного классификатора не превышало времени работы классического.

1. Постановка задачи

В качестве модельной рассмотрим задачу распознавания номеров, тисненых на пластиковых карточках. Источниками изображений служат камеры мобильных телефонов. Данная задача является одношрифтовой, т.е. требую-



Рис. 1. Изображения символа "0" с неокрашенными границами символа

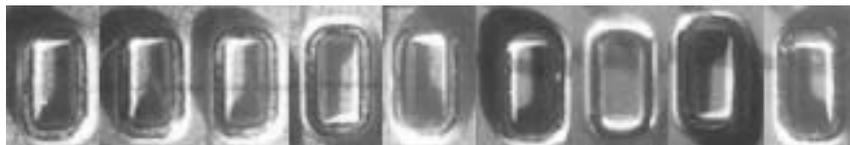


Рис. 2. Изображения символа "0" при различном освещении



Рис. 3. Изображения символа "0" на ярких фонах.

щей распознавания символов, написанных одним конкретным шрифтом. Алфавит состоит из 11 символов: 10 цифр и пробельного символа. Но, несмотря на кажущуюся простоту, в данной задаче есть ряд сложностей:

- часто символы не окрашены и различимы лишь благодаря теням и бликам, зависящим от освещения и геометрии сцены, которые могут меняться в широких пределах, так как съемка производится на камеру мобильного телефона в неконтролируемых условиях (Рис. 1, Рис. 2);

- карточки имеют фоновое изображение, что в некоторых случаях существенно усложняет задачу распознавания символов (Рис. 3).

2. Вектор признаков

Особенности распознаваемого шрифта потребовали разработки специфического вектора признаков. Он опирается на то, что

- шрифт преимущественно состоит из вертикальных и горизонтальных линий;

- шрифт выдавлен, т.е. изображение цифры, представляющей собой трехмерное тело, формируется тенями и бликами, которые дают значительный вклад одновременно во всех цветовых каналах изображения в отличие от пестрых фоновых текстур, дающих основной вклад лишь в определенном канале.

Для учета того, что символы в распознаваемом шрифте представлены вертикальными и

горизонтальными контрастными элементами, сначала в каждой точке картинки вычисляются соответствующие функции H и V .

Пусть на прямоугольном растре Ω размера $m \times n$ задано k -канальное изображение $I = (I_1, I_2, \dots, I_k) : \Omega \rightarrow R^k$.

Обозначим необходимые нам гауссовские ядра сверток через $G_x[\sigma](x, y) = \exp(-x^2/\sigma^2)$ и $G_y[\sigma](x, y) = \exp(-y^2/\sigma^2)$.

Далее, введем функции g_x и g_y , свертки с которыми будут порождать производные вдоль осей x и y соответственно:

$$g_x(x, y) = \begin{cases} 1, & \text{при } x=1, y=0 \\ -1, & \text{при } x=-1, y=0, \\ 0, & \text{иначе} \end{cases}$$

$$g_y(x, y) = \begin{cases} 1, & \text{при } x=0, y=1 \\ -1, & \text{при } x=0, y=-1. \\ 0, & \text{иначе} \end{cases}$$

Определим теперь вспомогательные операторы над изображениями Hor и Ver , предназначенные для получения изображений вертикальных и горизонтальных линий исходного изображения при фиксированных числах σ_x, σ_y , задающих эффективные окна гауссовских ядер соответственно поперек и вдоль направления выделяемых линий:

$$\begin{aligned} Hor(I) &= G_x[\sigma_-] * |g_y * G_y[\sigma_x] * I|, \\ Ver(I) &= G_y[\sigma_-] * |g_x * G_x[\sigma_x] * I|. \end{aligned}$$

Как можно заметить, помимо производных в горизонтальном и вертикальном направлениях, здесь используются два гауссовских сглаживания: первое – для подавления шума при взятии производной, второе – для устранения небольших разрывов в границе, наблюдаемой после вычисления производной.

Теперь обозначим $J_i = Hor(I_i)^2 + Ver(I_i)^2$. Здесь изображения – результаты операторов Hor и Ver возводятся в квадрат и суммируются поэлементно. Определим теперь амплитуду "теневых" изображений горизонтальных и вертикальных линий в точке $p \in \Omega$:

$$\begin{aligned} H(p) &= Hor(I_r)(p), \quad V(p) = Ver(I_r)(p), \\ r &= \arg \min J_i(p), \quad \text{при } 1 \leq i \leq k. \end{aligned}$$

Попиксельный выбор канала с минимальным значением $J_i(p)$ обоснован указанным выше предположением, что тени дают значительный вклад в границы символа во всех цветных каналах одновременно.

Значения H и V быть проинтерпретированы как полутоновые изображения, которые мы будем называть слоями вектора признаков.

Сформируем 2S-мерный вектор признаков, в качестве элементов которого возьмем подвыборки из H и V на регулярной решетке размера $S = M \times N$, $M \leq m, N \leq n$ над областью Ω :

$$F_i = \begin{cases} H\left(\left[x \cdot \frac{N}{n}\right], \left[y \cdot \frac{M}{m}\right]\right), & \text{где } x = \lfloor i/M \rfloor, \\ y = i \bmod M, \text{ при } 0 \leq i < S; \\ V\left(\left[x \cdot \frac{N}{n}\right], \left[y \cdot \frac{M}{m}\right]\right), & \text{где } x = \lfloor (i-S)/M \rfloor, \\ y = (i-S) \bmod M, \text{ при } S \leq i < 2S \end{cases}$$

На Рис. 4. приведены исходные изображения и Ver и Hor части описанного вектора признаков.

3. Составной классификатор

Составной классификатор состоит из функции выбора и ансамбля нейронных сетей нижнего уровня. На вход ему поступает вектор признаков, вычисленный по входному изображению (далее - *входной вектор*), на выходе классификатор возвращает распределение псевдовероятностной оценки по распознаваемым классам (значениям распознанного символа).

Составной классификатор обучается с использованием размеченной обучающей выборки, в которой каждому входному вектору поставлен в соответствие правильный класс.

Функция выбора определяет разбиение множества всех возможных входных векторов на непересекающиеся подмножества. Каждая сеть нижнего уровня предназначена для распознавания векторов только из соответствующего ей подмножества, которое будем называть ее *рабочей областью*. Таким образом, обучение клас-

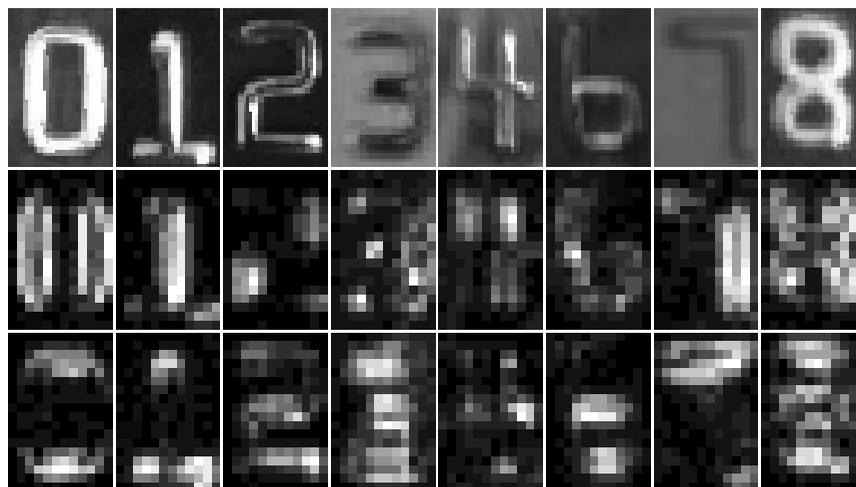


Рис. 4. Исходные изображения символов (верхний ряд), первая часть вектора признаков, выделяющая вертикальные элементы (средний ряд), вторая часть вектора признаков, выделяющая горизонтальные элементы (нижний ряд)

сификатора состоит в построении разбиения и обучении каждой отдельной нейронной сети нижнего уровня.

Построение разбиения осуществлялось в три этапа. На первом этапе выбиралось *пространство кластеризации*, точками которого являлись всевозможные входные вектора.

На втором этапе в пространстве кластеризации строилось предварительное разбиение, а именно: точки, соответствующие обучающей выборке, разбивались на кластеры при помощи алгоритма *k*-средних [6, 7] с евклидовой метрикой.

На третьем этапе строилось окончательное разбиение: внутренняя область кластера становилась элементом формируемого разбиения, а области на границах полученных кластеров отделялись от них и формировали отдельное подмножество, называемое *межкластерным пространством*.

Элементы построенного таким образом разбиения становились рабочими областями отдельных нейронных сетей нижнего уровня. Данные нейронные сети обучались на подмножествах обучающей выборки (далее - *обучающих подвыборках*), относящихся к их рабочим областям. Однако для успешного обучения нейронной сети к обучающей выборке предъявляется требование равночастотного представительства примеров каждого класса, а формально сформированная по рабочей области обучающая подвыборка могла ему не удовлетворять. Для решения этой проблемы использовались расширенные или уравновешенные обучающие подвыборки S^b . Уравновешенная подвыборка может быть получена случайным прореживанием элементов избыточно представленных классов и многократным добавлением бедно представленных классов. Однако в случае ничтожного размера представительства класса в выборке этот метод непригоден. Для преодоления этой трудности для уравновешивания предлагается использовать расширенную подвыборку.

Обозначим всю обучающую выборку как T , подвыборку – S . Уравновешенная подвыборка S^b формируется как мультимножество, состоящее из $|T \setminus S|$ и k раз добавленного S , где k – минимальное натуральное целое число, такое что $|S| \cdot k \geq |T \setminus S|$. Таким образом, обучение сети нижнего уровня происходило фактически

на всей обучающей выборке (а не только на подмножестве из рабочей области), но больший вес в оптимизируемом функционале был приписан векторам из рабочей области (за счет подачи их на обучение k раз). Использовалась обученная таким образом сеть нижнего уровня только на входных векторах из рабочей области.

3.1. Выбор пространства кластеризации

В экспериментах использовались два разных пространства кластеризации. Координатами в первом являлись горизонтальная и вертикальная проекции центра масс и моменты инерции относительно горизонтальной и вертикальной оси двух слоев вектора признаков (H и V). В дальнейшем будем называть это пространство *ПЦММИ*, его размерность равна 8. Кластеризация в пространстве ПЦММИ работает как предварительная классификация, что связано с особенностями шрифта, и распределение меток по кластерам может быть неравномерным. Пример разбиения на 5 кластеров в этом пространстве представлен на Рис. 5.

Координатами во втором пространстве были значения пятого и пятидесятого перцентилей модуля градиента полутонового изображения знакоместа. Размерность этого пространства равна 2. Положение точки в этом пространстве характеризует четкость и контрастность соответствующего изображения. Пример разбиения на 3 кластера представлен на Рис. 6.

3.2. Выделение межкластерного пространства

Опишем подробнее, как происходило выделение межкластерного пространства на третьем шаге построения разбиения множества входных векторов на рабочие области сетей нижнего уровня.

Пусть в результате алгоритма *k*-средних получено n кластеров. Для каждого элемента множества входных изображений обозначим ближайший и второй по близости к нему кластеры A и B соответственно. Пусть расстояния до центров этих кластеров будут a и b . Пусть c – расстояние от центра A до центра ближайшего к нему соседнего кластера. Зададим теперь правило, по которому элемент входного множества может быть отнесен к межкластерному пространству.

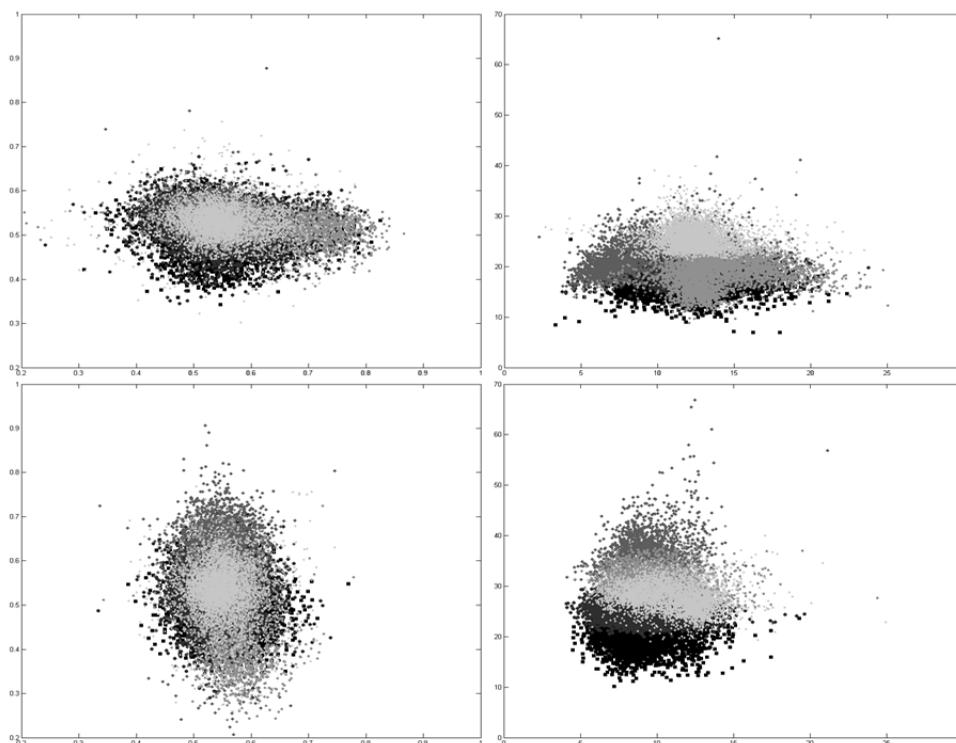


Рис. 5. Обучающая выборка, разбитая на 5 кластеров, каждый кластер окрашен в соответствующий цвет
 На верхних изображениях представлены проекции Ver подпространства, на нижних – Ног
 На левых изображениях проекции на плоскость центров масс, на правых - на плоскость моментов инерции

Рассматривались три варианта:

1. Простое правило: разбиение на подмножества в точности соответствует разделению на кластеры.

2. “Окружности Аполлония”: будем относить точку к элементу разбиения, соответствующему ближайшему кластеру, если $\frac{b-a}{a} \geq p$,

где p – некоторый параметр. В противном случае отнесем ее к межкластерному пространству. В двумерном случае граница между двумя подмножествами будет соответствовать дуге окружности Аполлония. При $p = 0$ разбиение переходит в ячейки Вороного.

3. Минимальный радиус: будем относить точку к подмножеству, соответствующему ближайшему кластеру, если $a \leq p \cdot c$, где p – некоторый параметр. В противном случае отнесем ее к межкластерному пространству. В двумерном случае границы подмножеств являются дугами окружностей.

Выделение межкластерного пространства как отдельного подмножества позволяет от-

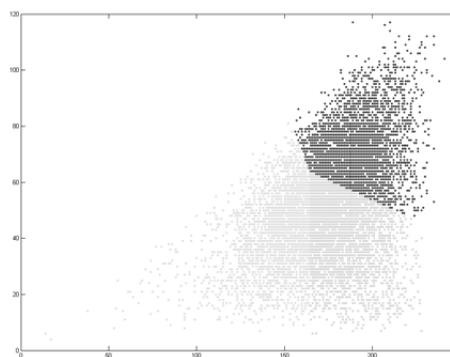


Рис. 6. Обучающая выборка, разбитая на 3 кластера в пространстве четкости, каждый кластер окрашен в соответствующий цвет

фильтровать изображения, находящиеся на границах кластеров (“маргинальные” примеры), и собрать из них рабочую область отдельной нейронной сети нижнего уровня.

4. Эксперимент

В рамках настоящей работы была проведена серия экспериментов, в которых построенный составной классификатор сравнивался с клас-

сическим нейросетевым, использованным как контрольный.

В экспериментах использовались обучающая и тестовая выборки, состоящие из 1000 и 600 уникальных изображений на каждый символ алфавита, соответственно. Нейронные сети нижнего уровня и контрольная классическая нейронная сеть являлись многослойными перцептронами с 2 скрытыми слоями. Классическая сеть содержала 432 входа, 153 нейрона в первом скрытом слое, 102 во втором и 11 выходов (по числу символов алфавита). Она была обучена на всей обучающей выборке. Ее качество (точность $\times 100\%$) составило **97.36%**.

В первом эксперименте сравнивалось качество работы классической сети и составных классификаторов, сети нижнего уровня которых обучались только на примерах, принадлежащих соответствующему кластеру, с использованием первого правила разбиения множества (“простое правило”, п. 3.2). Разбиение производилось на 4, 5, 6, 7, и 8 подмножеств. Кластеризация осуществлялась в пространстве ПЦММИ. Число нейронов в слоях классификаторов нижнего уровня было выбрано таким образом, что время работы составного классификатора не превосходило времени работы классического. Сети нижнего уровня имели одинаковую архитектуру, включающую 432 входа, 150 нейронов на первом скрытом слое, 100 на втором и 11 выходов. Лучший результат достигнут при разбиении на 5 подмножеств – составной классификатор обеспечил качество 96.7%, что ниже, чем у классической сети. Однако один из классификаторов нижнего уровня при этом показал на соответствующем подмножестве лучший результат, чем классическая сеть. Это соответствовало гипотезе о возмож-

ности построения сетей нижнего уровня, более точных на соответствующих подмножествах чем классическая сеть, обученная на всем множестве, при сохранении скорости работы. Именно это разбиение использовалось в дальнейшей работе с пространством кластеризации ПЦММИ.

В следующей серии экспериментов исследовалась зависимость качества распознавания классификатора от размера маргинальной области при введении межкластерного пространства. Проверялась гипотеза о том, что возможно увеличение точности распознавания сетей нижнего уровня путем выделения входных изображений, находящиеся на границах кластеров, в рабочую область отдельной нейронной сети нижнего уровня.

Первое построение межкластерного пространства производилось методом окружностей Аполлония (п. 3.2). При этом для распознавания на рабочих областях, построенных на основе кластеров, использовались нейронные сети нижнего уровня, обученные на полных кластерах, а на межкластерном пространстве в качестве сети нижнего уровня использовался классический классификатор. Следует заметить, что построенный таким образом составной классификатор был на входных изображениях из межкластерного пространства немного (на время работы функции выбора) медленнее классического. Рассматривалось несколько вариантов значения параметра p , используемого при построении окружностей Аполлония. Результаты эксперимента представлены в Табл. 1. Лучшее качество было достигнуто при $p=2.4$ и составило 97.53%, что обеспечивает на 6% меньше ошибок, чем у классического классификатора. Повышение качества было получено

Табл. 1. Результаты распознавания рабочих областей сетями нижнего уровня при построении межкластерного пространства методом окружностей Аполлония и кластеризации в пространстве ПЦММИ

p	Точности сетей, %							Объемы кластеров, шт.					
	№1	№2	№3	№4	№5	МП	СК	1	2	3	4	5	МП
0.0	97.80	97.44	96.77	97.59	93.40	-	96.70	1366	2191	650	1120	1273	0
2.4	98.62	98.52	99.37	99.00	95.58	97.19	97.53	651	744	317	299	565	4024
6.0	100.0	99.67	100.0	97.37	95.35	97.24	97.42	176	307	132	76	215	5694

№№1-5 - сети нижнего уровня, обученные на пяти кластерах, МП - классический нейросетевой классификатор, использованный для распознавания межкластерного пространства. Также приведена общая точность составного классификатора (СК), а также объемы рабочих областей при разном значении параметра p

за счет уменьшения рабочих областей нейронных сетей нижнего уровня.

Аналогичный эксперимент был поставлен для межкластерного пространства, формируемого методом минимального радиуса (п. 3.2). Результаты эксперимента представлены в Табл. 2. Лучшее качество было достигнуто при $p=0.9$ и составило 97.48%, что выше, чем у классического классификатора, но ниже, чем при использовании окружностей Аполлония с $p=2.4$. При этом можно заметить, что при p , таких, что удастся превысить качество классического классификатора, размеры кластеров при использовании метода минимального радиуса становятся очень небольшими, т.е. основное распознавание производится за счет сети, соответствующей межкластерному пространству. В связи с этим, в дальнейших экспериментах межкластерное пространство строилось с использованием окружностей Аполлония.

Как было указано выше, в первой серии экспериментов с использованием “простого правила” формирования рабочих областей сетей нижнего уровня (без межкластерного пространства)

превзойти качество классического классификатора не удалось. Это могло быть связано с тем, что размер обучающей выборки достаточно мал и после разделения его на подмножества возникали нерепрезентативные обучающие выборки. Так, с одной стороны, могли появиться кластеры, содержащие черты, не характерные в среднем для всех распознаваемых объектов, с другой - некоторые характерные и важные черты могли не войти в какие-то кластеры.

Для решения проблем, возникающих из-за малого размера обучающих выборок, был произведен эксперимент по расширению обучающих выборок сетей нижнего уровня с помощью уравнивания. На полученных расширенных обучающих выборках были обучены новые сети. Результаты работы обученного таким образом составного классификатора приведены в Табл. 3. Четыре из пяти сетей нижнего уровня превзошли результаты классического классификатора в своей рабочей области. Итоговое качество составного классификатора составило 97.76%, что выше, чем у классического (на 15% меньше ошибок).

Табл. 2. Результаты распознавания рабочих областей сетями нижнего уровня при построении межкластерного пространства методом минимального радиуса и кластеризации в пространстве ПЦММИ

p	Точности сетей, %							Объемы кластеров, шт.					
	1	2	3	4	5	МП	СК	1	2	3	4	5	МП
0.0	-	-	-	-	-	97.36	97.36	0	0	0	0	0	6600
0.9	99.58	98.82	98.80	98.52	94.94	97.27	97.48	236	678	167	135	257	5127
6.0	97.80	97.44	96.76	97.58	93.40	100.0	96.70	1366	2191	649	1118	1273	3

№№1-5 - сети нижнего уровня, обученные на пяти кластерах, МП - классический нейросетевой классификатор, использованный для распознавания межкластерного пространства. Также приведена общая точность составного классификатора (СК), а также объемы рабочих областей при разном значении параметра p

Табл. 3. Сравнение составного классификатора, сети нижнего уровня которого обучены на кластерах в пространстве ПЦММИ, с обученным на уравнированных обучающих выборках

№ кластера	Объем кластера, шт.	Точности сетей, %		
		Сети нижнего уровня	Классический классификатор	Сети нижнего уровня, обученные с уравниванием
1	1366	97.80	98.10	98.39
2	2191	97.44	98.13	97.44
3	650	96.77	97.85	98.92
4	1120	97.59	98.39	98.52
5	1273	93.40	94.11	94.82
Итоговые точности, %		96.70	97.36	97.76

В строках 1-5 приведены результаты отдельных сетей нижнего уровня на соответствующих рабочих областях и их сравнение с работой классического классификатора на тех же областях. В последней строчке приведено качество классификатора в целом

Табл. 4. Результаты распознавания рабочих областей сетями нижнего уровня при построении межкластерного пространства (МП) методом окружностей Аполлония и кластеризации в пространстве ПЦММИ

p'	Точности сетей, %							Объемы кластеров, шт.					
	1	2	3	4	5	МП	СК	1	2	3	4	5	МП
0.0	98.39	98.04	98.92	98.75	95.13	-	97.76	1366	2191	650	1120	1273	0
2.2	98.73	98.49	100.0	99.38	95.83	97.47	97.80	709	797	343	324	599	3828
6.0	100.0	99.67	100.0	98.68	96.28	97.44	97.64	176	307	132	76	215	5694

Сети обучались с использованием техники уравнивания на рабочих областях, построенных методом окружностей Аполлония с $p = 2.4$. Также приведена общая точность составного классификатора (СК), а также объемы рабочих областей при разном значении параметра p'

Табл. 5. Результаты распознавания составным и классическим классификаторами без выделения межкластерного пространства при кластеризации в пространстве четкости

№ кластера	Объем, шт.	Точность сетей, %		
		Сети нижнего уровня	Составной классификатор	Классический классификатор
1	2085	97.70	97.41	97.36
2	1577	97.21		
3	2938	97.31		

В заключительной серии экспериментов в пространстве кластеризации ПЦММИ техника уравнивания использовалась в сочетании с выделением межкластерного пространства. Из первоначальных пяти кластеров сначала было сформировано разбиение на шесть подмножеств, полученных методом окружностей Аполлония при $p = 2.4$. Обучающие выборки на 6 рабочих областях были уравновешены и на полученных наборах были обучены сети нижнего уровня. При распознавании все множество входных изображений также разбивалось на шесть подмножеств методом окружностей Аполлония, но с другим значением параметра, которое обозначим p' . Зависимость качества и объема рабочих областей от параметра p' представлена в Табл. 4. Наибольшее качество **97.80%** было получено при $p' = 2.2$ и превзошло как классический классификатор (на 17% меньше ошибок), так и все обученные ранее составные. То есть сочетание этих техник позволило добиться лучшего результата, чем использование их по отдельности.

Дальнейшие исследования производились в пространстве четкости. В первом эксперименте множество входных изображений разделялось на три кластера, которые в соответствии с “простым правилом” и были разбиением множества всех входных изображений на подмножества, являющиеся рабочими областями для 3

сетей нижнего уровня. Объемы кластеров, качество распознавания сетей нижнего уровня и составного классификатора в целом представлены в Табл. 5. Как видно из таблицы, даже без выделения межкластерного пространства и уравнивания обучающих выборок, составной классификатор превзошел классический.

В следующем эксперименте на этом же разбиении на кластеры было добавлено межкластерное пространство на основе окружностей Аполлония с параметром $p = 4.4$, а все обучающие выборки *уравновешены*. Точности обученных таким образом сетей нижнего уровня составили 97.60%, 97.27%, 97.24% для сетей, соответствующих кластерам №№1-3 и 99.47% для межкластерной сети. Точность составного классификатора в целом составила **98.63%**, что заметно выше точности классического (97.36%), т.е. число ошибок сократилось в 1.92 раза.

Заключение

В работе предложен метод построения составного классификатора как замены классического нейросетевого. Построенный составной классификатор имеет вид двухуровневого дерева, на верхнем уровне которого находится функция выбора, а на нижнем - нейронные сети, предназначенные для распознавания только в выделенной “рабочей области”. С помощью

выбора подходящего пространства кластеризации, построения разбиения множества на “рабочие области” на основе кластеров методом окружностей Аполлония и уравнивания обучающей выборки удалось в рассматриваемой модельной задаче добиться сокращения числа ошибок почти в два раза без увеличения времени работы.

Литература

1. Masoudnia, S., Ebrahimpour, R., “Mixture of experts: a literature survey”, *Artificial Intelligence Review*, (2012).
2. Woźniak, M., Graña, M., & Corchado, E. “A survey of multiple classifier systems as hybrid systems”, *Information Fusion*, 16(13), 3–17 (2014).
3. Dietterich, T. G., “Ensemble Methods in Machine Learning”, *Multiple Classifier Systems SE - 1* (Vol. 1857, pp. 1–15), (2000).
4. Giacinto, G., & Roli, F., “Dynamic Classifier Selection”, *Proceedings of the First International Workshop on Multiple Classifier Systems* (pp. 177–189). London, UK, UK: Springer-Verlag, (2000).
5. Ko, A. H. R., Sabourin, R., & Britto, Jr., A. S., “From dynamic classifier selection to dynamic ensemble selection”, *Pattern Recognition*, 41(5), 1718–1731, (2008).
6. Steinhaus H. “Sur la division des corps materiels en parties”, *Bull. Acad. Polon. Sci.*, C1. III vol. IV: 801–804, (1956).
7. Jain, A. K., & Lansing, E., “Data Clustering”, *50 Years Beyond K-Means Michigan State University*, (2009).

Гладилин Сергей Александрович. Научный сотрудник ИППИ РАН. Окончил МГУ им. М.В. Ломоносова в 2002 году. Кандидат физико-математических наук. Автор 16 печатных работ. Область научных интересов: зрительные системы, обработка изображений, распознавание образов. E-mail: gladilin@iitp.ru

Николаев Дмитрий Петрович. Заведующий лабораторией ИППИ РАН. Окончил Московский государственный университет имени М.В. Ломоносова в 2000 году. Кандидат физико-математических наук. Автор 168 печатных работ. Область научных интересов: машинное зрение, быстрые алгоритмы обработки изображений, распознавание образов. E-mail: dimonstr@iitp.ru

Полевой Дмитрий Валерьевич. Старший научный сотрудник ИСА ФИЦ ИУ РАН, доцент НИТУ “МИСиС”. Окончил Московский физико-технический институт (государственный университет) в 2004 году. Кандидат технических наук. Автор 14 печатных работ. Область научных интересов: методы искусственного интеллекта, компьютерное зрение, робототехника. E-mail: dvpsun@gmail.com

Соколова (Тарасова) Наталья Андреевна. Научный сотрудник ООО “Смарт Энджинс Рус”. Окончила Московский физико-технический институт (государственный университет) в 2013 году. Автор пяти печатных работ. Область научных интересов: машинное обучение, распознавание образов, нейронные сети. E-mail: nilsonii.nt@gmail.com