

УДК 004.932.2:004.93'1

А. Е. Берестовский, А. Н. Власенко, В. А. Гороховатский
Харьковский национальный университет радиоэлектроники
проспект Ленина, 14, 61166 Харьков, Украина

Нейросетевые технологии самообучения в системах структурного распознавания визуальных объектов

Обсуждаются вопросы анализа и распознавания изображений в интеллектуальных системах компьютерного зрения. На основе сети Кохонена предложена технология самообучения для системы структурного распознавания визуальных объектов. В результате осуществляется трансформация описаний к векторному виду, что снижает вычислительные затраты. Приведены результаты экспериментов.

Ключевые слова: компьютерное зрение, структурное распознавание изображений, характерные признаки, самообучение, сеть Кохонена, кластеризация, векторное описание.

Введение

Системы компьютерного зрения предназначены для автоматизации решения таких актуальных прикладных задач искусственного интеллекта как: распознавание человеческих лиц в целях идентификации; поиск визуальных объектов заданного типа в базах или коллекциях изображений; распознавание фиксированных объектов на сложных изображениях, включая влияние перекрытий объектов, фона и помех; идентификация движущихся объектов в видео-поток и определение их координат. Перспективным подходом к построению методов распознавания в таких ситуациях есть структурный анализ [1].

Структурные методы распознавания изображений используют описания объектов в виде множества дескрипторов — числовых векторов из пространства R^n . Структурное описание $Z \subset R^n$ объекта представляют как конечное множество дескрипторов — характерных признаков (ХП) [1]. Описание, полученное применением метода SURF [2], принадлежит подмножеству $R_1^n = \{z \mid z \in R^n, \|z\| \approx 1\}$, где $R_1^n \subset R^n$ — подмножество n -мерных вещественных векторов с евклидовой нормой, близкой к единице: $\|z\| = \sqrt{\sum_{i=1}^n z_i^2} \approx 1$.

Одним из ключевых моментов функционирования и результативного применения систем распознавания есть способность к обучению (самообучению), что в целом определяет уровень их интеллектуальности. За счет проведения процедур обучения часто достигается новое качество распознавания, например, в плане формирования пространств более эффективных признаков, адаптации к базе изображений, повышения быстродействия процедур обработки, принятия решения и т.д. [3].

Сегодня одним из перспективных подходов к обучению и визуализации результатов анализа многомерных данных можно считать применение сетей и карт Кохонена [3]. Применительно к структурному анализу описаний в виде множеств векторов метод сетей Кохонена позволит, например, осуществить кластеризацию элементов описаний в базе изображений с целью трансформации описаний к векторному виду, что целенаправленно сокращает вычислительные затраты на распознавание [4].

Множество сокращаемых признаков исследователи делят на незначачие, которые слабо связаны с результатами анализа, и избыточные, которые содержат полезную информацию, но и без их использования могут быть получены хорошие результаты. Одним из способов сокращения есть построение системы признаков на основе проекций (OLAP и др. [1, 5]). Другим универсальным путем считается последовательное исключение признаков на основе критерия энтропии [3, 5]. Элиминирование признаков при тщательном изучении, как правило, основано на трудоемком переборе всех возможных подмножеств вариантов и требует обязательной экспериментальной проверки редуцированного представления.

Перспективным методом анализа данных в целях сжатия объема пространства признаков считается кластеризация, которую относят к процедурам самообучения [5, 6]. Кластеризация дает возможность сократить объем данных, сведя их анализ и классификацию к отдельным представителям полученных групп (кластеров). Проведение кластеризации для структурных описаний в виде множеств ХП дает возможность значительно упростить принятие решения о классе визуального объекта за счет предварительной классификации элементов эталонных описаний к фиксированному числу классов-кластеров [4].

Критерием качества, а также мерой схожести процедур кластеризации наиболее часто выступает сумма квадратов ошибок (расстояний) между центром кластера и включенными в него записями

$$E = \frac{1}{s} \sum_{i=1}^k \sum_{z \in C_i} \rho(z, m_i), \quad (1)$$

где $z \in C_i$ — точка данных из кластера C_i ; m_i — центр кластера C_i ; $\rho(z, m_i)$ — расстояние между центром и записью; k — число кластеров; s — число используемых при обучении записей.

Величину (1) также называют ошибкой обучения, погрешностью сети, погрешностью квантования [6, 7].

Сеть Кохонена (СК) — разновидность системы самоорганизующихся признаков (нейронные сети с самоорганизацией на основе конкуренции), основное пред-

назначение которой — преобразование объемных многомерных наборов данных в более простую структуру фиксированной размерности. СК эффективно применимы для задач кластерного анализа, когда требуется обнаружить скрытые закономерности [3, 6]. Базовая форма алгоритма самоорганизации позволяет оценить положение центров групп данных (кластеров), на которые подразделяется многомерное пространство.

СК состоит из узлов, вокруг которых процедурно образуются кластеры объектов. Близкие к узлам объекты по смыслу схожи между собой. В основе построения двухслойной СК лежит принцип конкурентного обучения. Узлы-нейроны выходного слоя настраиваются на множестве входных данных путем подстройки своих весов (значений) на основе оценивания их связи (близости) с входными значениями. Нейроны выходного слоя упорядочивают при этом в одномерную или двумерную решетку (рис. 1).

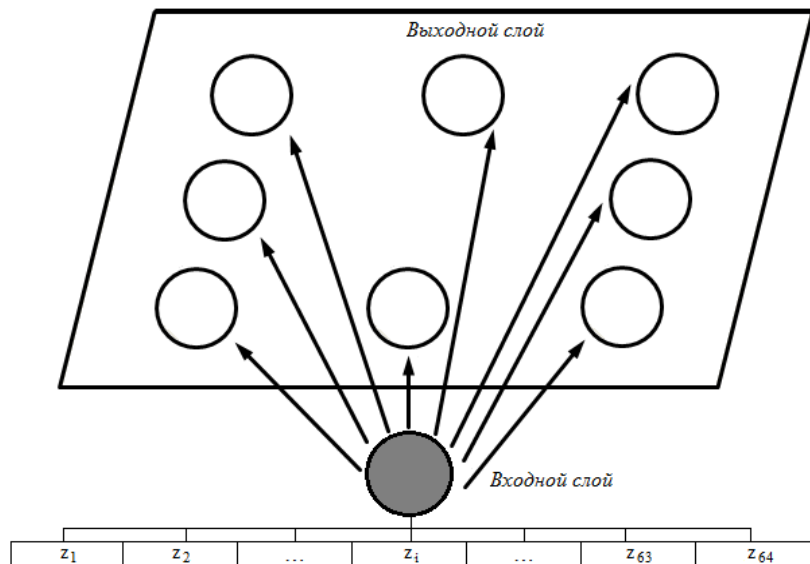


Рис. 1. Схема построения двухслойной сети Кохонена для 8-ми кластеров

Можно заметить, что принцип применения СК для кластеризации, где на каждом шаге вместе с нейроном-победителем определяют схожее подмножество нейронов выходного слоя, практически соответствует принципу голосования признаков входного слоя за один или несколько нейронов выходного слоя [1]. Исключительным свойством СК есть компрессия данных, состоящая в том, что образующие кластер группы данных представляются единственным вектором весов нейрона-победителя. В результате происходит квантование пространства признаков. Это компрессия с потерями, которая сопровождается определенной погрешностью квантования.

Результаты кластеризации посредством СК в значительной степени зависят от начальных весов нейронов, которые зачастую инициализируют случайным образом. Вариантом уменьшения степени эвристичности есть использование в качестве начальных значений непосредственно векторов из обучающей выборки. Другим важным моментом является анализ равномерности активизации разных ней-

ронов выходного слоя в процессе конкуренции. Для этого осуществляют подсчет «побед» каждого нейрона с целью учета его активности в процессе обучения. Если нейрон слишком активен, то для активации других нейронов прибегают к искусственному завышению расстояния между активным нейроном и векторами признаков объекта [3].

Целью работы есть изучение возможности применения аппарата сетей Кохонена для самообучения системы структурного распознавания на множестве характерных признаков в плане построения кластерного компрессионного представления базы изображений. Осуществление кластеризации позволяет перейти к векторному описанию эталонов, что значительно сокращает объем вычислительных затрат и увеличивает быстродействие распознавания.

Задачами исследования является изучение особенностей процедуры самообучения сети Кохонена применительно к множествам дескрипторов характерных признаков изображений, а также оценивание качества и эффективности применения кластеризации для конкретных прикладных примеров баз изображений.

Применение сети Кохонена для кластеризации на множестве характерных признаков

Рассмотрим конечное множество $Z = \{Z^i\}_{i=1}^J$ описаний, соответствующее фиксированной базе в виде J изображений эталонов. Обозначим мощности множеств Z , Z^i как s, s^i . При этом $s = \sum_{i=1}^J s_i$. Каждое Z^i представляет собой конечное множество из s_i векторов-дескрипторов SURF размерностью 64 [2]. Поставим задачу осуществить кластеризацию Z на k кластеров путем применения СК. В качестве обучающей выборки будем использовать множество Z векторов описаний, а нейроны выходного слоя $W = (W_1, W_2, \dots, W_k)$ инициализируем в виде k векторов:

$$\begin{aligned} W_1 &= (w_{1,1}, w_{1,2}, \dots, w_{1,64}), \\ W_2 &= (w_{2,1}, w_{2,2}, \dots, w_{2,64}), \\ &\dots \\ W_k &= (w_{k,1}, w_{k,2}, \dots, w_{k,64}). \end{aligned} \quad (2)$$

Нейрон-победитель на шаге обучения h определяем из соотношения

$$a = \arg \min_{1 \leq d \leq k} \rho(W_d, z(h)), \quad (3)$$

где $\rho(W, z(h))$ — расстояние между нейроном и обучающим вектором; a — номер нейрона-победителя.

Обычно в качестве $\rho[W_j, z]$ для векторов-дескрипторов ХП используют евклидово расстояние, которое в применении к признакам SURF конкретизируется как $\rho[W_j, z(h)] = \sqrt{\sum_{i=1}^{64} (w_{j,i} - z_i(h))^2}$.

В обучении по Кохонену применяется линейная схема подстройки нейрона-победителя (и подмножества нейронов-соседей) по правилу [3, 7]

$$w_{a,i}(h+1) = w_{a,i}(h) + \eta[z_i(h) - w_{a,i}(h)], \quad (4)$$

где $0 < \eta < 1$ — коэффициент скорости обучения; $z_i(h)$ — i -я компонента входного вектора $z \in Z$ на шаге h , $i = \overline{1,64}$.

Согласно теории Кохонена, скорость обучения $\eta(h)$ должна быть уменьшающейся функцией от числа его итераций. Процесс обучения сети обычно разделяют на фазы грубой и точной подстройки. Во второй фазе η уменьшается, что позволяет более точно подстраивать веса. Параметром инициализации является также радиус обучения r , который определяет подмножество W^* соседей нейрона-победителя, их веса также подстраиваются по формуле (4). Множество W^* определяют как $W^* = \{W_d \mid \rho(W_d, z) \leq r\}$. Обычно радиус выбирают максимальным вначале и по ходу обучения уменьшают.

Адаптация по формуле (4) теоретически соответствует градиентному методу обучения, основанному на минимизации целевой функции (1). При таком способе обучения функция плотности распределения нейронов сводится к дискретизированной плотности распределения множества Z [6].

Алгоритм самообучения Кохонена применительно к множеству ХП представим в виде последовательности действий.

1. Инициализация. Для k нейронов сети устанавливаются начальные веса, скорость η и радиус r обучения
2. Возбуждение. На входной слой подается вектор воздействия z , содержащий поля записи обучающей выборки.
3. Конкуренция. Для каждого выходного нейрона W_d вычисляется расстояние $\rho[W_d, z]$ до входного вектора, в виде (3) определяется нейрон, для которого расстояние окажется наименьшим, он и будет победителем.
4. Объединение. Определяется подмножество нейронов, расположенных в пределах радиуса обучения относительно победителя.
5. Подстройка. Веса нейронов подстраиваются в соответствии с выражением (4).
6. Коррекция параметров радиуса и скорости обучения в соответствии с заданным законом.

Анализ технологий обучения сети при выполнении кластеризации

Эффективность осуществления кластеризации путем самообучения СК напрямую зависит от стратегии или технологии обучения [6, 7]. Основным критерием считается значение ошибки (1), которая должна снижаться в ходе обучения, а параметрами выступают радиус и правило изменения скорости η . Применительно к задаче структурного распознавания на основе сформированных кластеров ХП ошибку (1) нельзя считать ключевым параметром, так как основополагаю-

щим фактором здесь все-же есть величина критерия вероятности верного распознавания объектов [1]. Однако ошибка обучения (1) все-таки отображает уровень качества представления данных в концентрированном виде, поэтому в процессе обучения желательно добиваться как можно меньшего ее значения. Как видим из конструкции применения СК, уточнение центров происходит после предъявления каждого очередного вектора из множества обучающих данных. Окончательно центры формируются после предъявления всех элементов множества.

Одна из технологий обучения состоит в том, что параметр η уменьшается во времени. Обучающие векторы предъявляются по несколько раз в случайном порядке вплоть до стабилизации значений центров. Здесь обучение продолжают до тех пор, пока погрешность (1) при s входных векторах не станет достаточно малой величиной [6].

Наряду с этим, коррекция параметров обучения (радиус, скорость) может быть осуществлена для структурных признаков после использования на этапах 1–5 всего множества векторов входного воздействия.

Параметр скорости обучения η может напрямую зависеть от шага обучения, т.е. от номера входного элемента и быть функцией $\eta(h)$ в выражении подстройки (4). В некоторых задачах выбирают $\eta(h) = 1/k(h)$, где $k(h)$ — число раз, когда нейрон был победителем на предыдущих шагах обучения (по методу K -средних). Чтобы добиться равномерного участия нейронов, применяют схемы учета их нейронов. Применительно к нашей задаче равномерную активность нейронов нельзя считать ключевым требованием. Учитывая, что норма векторов ХП в соответствии с методом SURF близка к 1, нормировка входных данных в данном случае также не требуется.

Одна из эффективных современных стратегий основана на адаптивном подборе коэффициента η с учетом фактической динамики величины целевой функции E суммарной погрешности обучения [7]. Если погрешность на очередной итерации увеличивается больше, чем в допустимых пределах, т.е. $E_h > \gamma_E E_{h-1}$ (γ_E — коэффициент допустимого прироста погрешности), то значение η должно пропорционально уменьшаться в виде $\eta_h = \gamma_\eta \eta_{h-1}$, где γ_η — коэффициент уменьшения. Если же погрешность на очередном шаге становится меньше, коэффициент обучения должен быть увеличен по аналогичной формуле. Такие стратегии часто позволяют существенно (в несколько раз) ускорить процесс обучения. Адаптивный метод подбора η зависит от вида целевой функции и значений коэффициентов. Построение эффективной технологии для конкретной проблемы есть отдельной задачей обучения.

В качестве вариантов выбора начальных весов, кроме традиционных подходов, можно взять, например, множество векторов выбора дискретных значений компонентов на отрезке $[0,1]$. Ограничением для начальных условий есть $\|W_d\| = 1$, что определяет сходимость алгоритма. Выбрать начальные веса нейронов, определяющих кластеры ХП, можно также на основе характеристик уникальности значений ХП каждого из эталонов [4].

Число кластеров k (нейронов выходного слоя) также является параметром задачи и зависит от применения. Понятно, что с увеличением k улучшается точ-

ность представления данных. В то же время при этом растет как время обучения, так и время распознавания на основе сформированного числа кластеров. Наилучшим признано такое размещение результирующих центров, при котором они располагаются в областях, содержащих наибольшее количество предъявленных для обучения векторов. При таком подборе центры будут представлять векторы данных с наименьшей суммарной погрешностью.

С увеличением числа нейронов выходного слоя погрешность может быть значительно ниже. Заметим, что погрешность (1) для задачи структурного распознавания непосредственно не влияет на результат последующего применения. Она отражает лишь качество аппроксимации имеющегося множества данных конкретным числом и значениями кластеров.

Распознавание на основе обученной сети

В результате кластеризации получено новое представление базы Z , где каждый эталон Z^i теперь представляет собой вектор из k целочисленных элементов: $Z^i \rightarrow C^i = (c_1, c_2, \dots, c_k)^i$, где c_v — число элементов эталона Z^i , принадлежащих кластеру с номером v . На основе нового вида эталонов перейдем к представлению базы в виде матрицы O размером $J \times k$ относительных весов (матрица наблюдений). Для этого получим из векторов C^i строки матрицы O , число которых равно количеству J эталонов базы:

$$O = \left\{ \begin{array}{l} o_{1,1}, \dots, o_{k,1} \\ o_{1,2}, \dots, o_{k,2} \\ \dots \dots \dots \\ o_{1,J}, \dots, o_{k,J} \end{array} \right\}.$$

Далее осуществим нормирование матрицы O , чтобы она отражала относительные веса элементов каждого класса в кластерном описании. Для этого вначале нормируем матрицу вдоль строки на число элементов эталона s_j , а затем осуществим нормирование полученного i -го столбца для обеспечения условия $\sum_{v=1}^k o_{v,i} = 1$. Для этого каждый элемент столбца делим на сумму $\sum_{v=1}^k o_{v,i}$. Второе нормирование, в принципе, не обязательно, оно позволяет лишь сбалансировать веса элементов в пределах отрезка $[0,1]$.

На этапе распознавания объекта, представленного структурным описанием с последующим кластерным представлением обученной сети Кохонена, выполним порядок действий:

- а) для каждого ХП анализируемого объекта путем вычисления расстояния до центров кластеров определить, к какому кластеру он относится;
- б) применить к ХП операцию построения вектора значимости в виде набора относительных весов для одного или нескольких классов;
- в) выполнить суммирование вектора значимости для классов либо отнести ХП к классу, имеющему наибольший относительный вес среди эталонных классов;

г) по результатам агрегирования векторов значимости для множества ХП объекта определить класс с максимальным значением совокупного веса.

Ключевым параметром метода есть построение вектора значимости для ХП объекта. Отметим, что в конструкции подхода на этапе а) применена конкуренция Кохонена. Схема распознавания представлена на рис. 2.

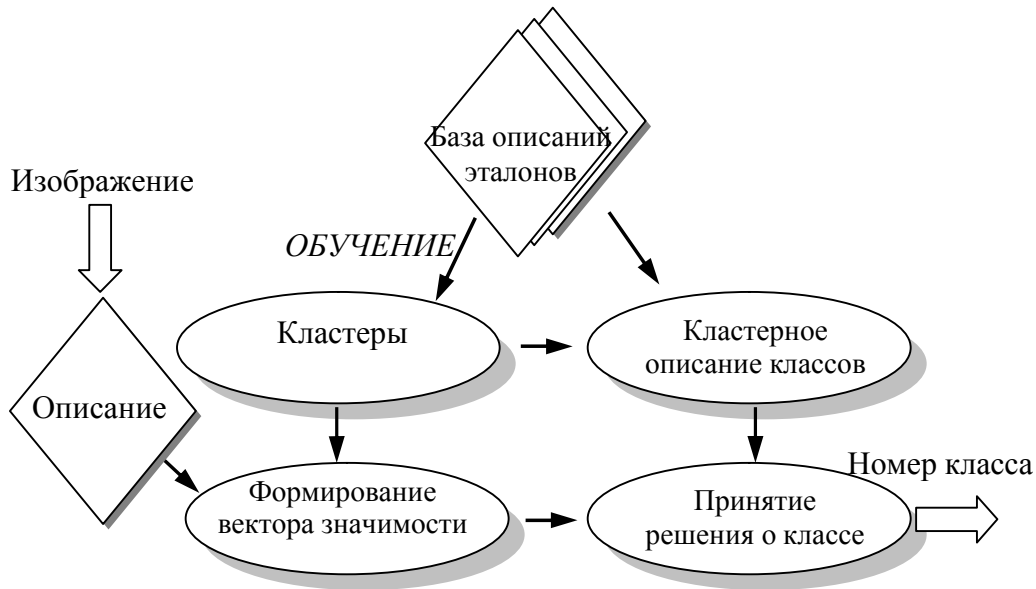


Рис. 2. Схема распознавания на основе системы кластеров

Еще один способ реализации этапов б) – г) может состоять в нечеткой интерпретации. Вектор значимости строим так, чтобы очередной ХП относился ко всем кластерам либо к подмножеству кластеров, но со своими весами. Здесь возможны промежуточные варианты, когда выделяются 2–3 наиболее близких центра кластеров, и по ним формируем сумму весов для каждого эталона.

В результате агрегирования векторов значимости для всех элементов описания вне зависимости от способа формирования получим вектор $\beta_j, j = \overline{1, J}$, значимости классов для распознаваемого объекта. В результате объект отнесем к классу j в соответствии с правилом

$$j = \arg \max_{d=1, \dots, J} \beta_d, \quad (5)$$

т.е. по максимуму среди компонентов β_j .

Подсчитаем в сравнительном плане число операций, необходимых при сравнении двух описаний объемом из s элементов традиционным методом голосования ХП, и предлагаемым методом на основе кластерного описания. Ключевым моментом здесь есть вычисление скалярного произведения: для традиционного метода — между векторами размерностью 64, а для предлагаемого — размерностью k . Если обозначить время такой операции для вектора размером 64 через t_c ,

то при векторе размером k для его вычисления необходимо время $kt_c / 64$. Соотношение числа операций имеет вид

$$\alpha = \frac{s^2(t_c + t_\delta + t_+)}{sk(t_c + t_k) + k^2(kt_c / 64)}, \quad (6)$$

где t_δ — время для пороговой обработки; t_+ — время сложения (инкрементации); t_k — время для построения вектора значимости.

Если в соотношении (6) из-за незначительного веса пренебречь величинами t_δ, t_+, t_k и осуществить сокращения, то получим, что выигрыш во времени обработки с применением кластерного представления пропорционален значению $\alpha \approx 64s / (64k + k^3)$. Для практических значений $k = 8$ и $s = 100$ значение $\alpha \approx 19$. Выигрыш возрастает с ростом числа признаков s и уменьшением числа кластеров k . Проведенные эксперименты подтверждают эти выводы.

Результаты экспериментов

Вычисление ХП методом SURF осуществлено для базы из 25 изображений гербов городов Украины. На рис. 2, *a–d* приведены примеры 5 изображений, на рис. 2, *e* — расположение 20-ти ХП из описания изображения 2, *в*. Табл. 1 содержит количества ХП в описаниях изображений рис. 2, *a–d*.



Рис. 3. Изображения гербов городов из базы *a)–d)*;
e — пример 20 элементов из множества ХП для изображения 2, *в*

Рис. 4 демонстрирует вид одного из векторов — нейронов второго слоя до и после обучения на множестве описаний базы с шагом $\eta = 0,5$. На рисунке видны изменения нейрона по результатам самообучения СК.

Путем применения СК осуществлена кластеризация 1539 ХП (векторы размером 64 элемента) описаний 5 изображений базы гербов городов Украины для 8-ми кластеров с шагом обучения 0,5. Табл. 2 содержит значения числа элементов каждого из эталонов, которые очутились в сформированных 8-ми кластерах для базы. Здесь же приведены вычисленные по результатам обучения значения итоговой ошибки (1) для отдельных эталонов и базы в целом.

Таблица 1. Количества ХП в описаниях изображений рис. 2, а–д

Гербы	Днепропетровск	Львов	Киев	Харьков	Кременчуг
Число ХП	252	328	301	342	316




Рис. 4. Нейрон второго слоя до и после обучения

Таблица 2. Количества ХП в кластерном представлении эталонов

Гербы	Номер кластера								Ошибка E
	1	2	3	4	5	6	7	8	
Днепропетровск	35	31	19	11	18	26	51	61	0,187
Львов	41	20	64	24	69	41	54	15	0,236
Киев	65	45	54	10	9	15	51	52	0,189
Харьков	28	20	33	98	32	43	63	25	0,200
Кременчуг	27	59	11	31	49	85	9	45	0,243
База	97	100	88	88	218	308	329	311	0,236

Как видим, ошибка E для базы при шаге обучения $\eta = 0,5$ составляет 0,23, а для отдельных эталонов не превышает значения 0,19. Достаточно равномерное

распределение ХП по полученной системе кластеров доказывает возможность эффективного представления описаний в виде вектора с целочисленными элементами.

Для применения в процедуре распознавания полученных данных по результатам обучения (в виде матрицы O) вычислены относительные веса признаков каждого эталона внутри кластера (табл. 3).

Таблица 3. Экспериментальная матрица O весов

Днепропетровск	0,178	0,177	0,104	0,063	0,101	0,123	0,223	0,308
Львов	0,209	0,114	0,353	0,137	0,389	0,195	0,236	0,075
Киев	0,331	0,257	0,298	0,057	0,050	0,071	0,223	0,262
Харьков	0,142	0,114	0,182	0,563	0,180	0,204	0,276	0,126
Кременчуг	0,137	0,337	0,060	0,178	0,276	0,404	0,039	0,227

Вычислены значения результирующей погрешности обучения E для отдельных эталонов и всей базы E_{all} при разных величинах скорости обучения η (табл. 4).

Таблица 4. Значения погрешностей обучения при разных величинах η

η	E_1	E_2	E_3	E_4	E_5	E_{all}
0,5	0,1871	0,2360	0,1886	0,2003	0,2425	0,2358
0,1	0,2028	0,1997	0,191	0,1833	0,2006	0,1986
0,02	0,2157	0,2108	0,2	0,2105	0,2242	0,2064

Анализ табл. 4 показывает, что при простой технологии обучения (постоянное η) ошибка обучения практически не зависит от величины η и находится в пределах 0,18–0,24. По результатам обучения вычислены значения нормированного коэффициента корреляции

$$\beta(a, b) = (a, b) / [\|a\| \cdot \|b\|]$$

между вектором, представляющим изображение герба Харькова и остальными эталонами для исходных (табл. 2) и нормированных (табл. 3) данных. Вычислены также нормированные значения подобия в исходном пространстве признаков для тех же пар описаний путем голосования элементов (табл. 5).

Таблица 5. Результаты сравнения пар описаний

Пары изображений	$\beta(a, b)$ табл. 2	$\beta(a, b)$ табл. 3	Мера подобия
Харьков-Днепропетровск	0,700	0,660	0,274
Харьков-Львов	0,774	0,740	0,453
Харьков-Киев	0,644	0,604	0,350
Харьков-Кременчуг	0,675	0,677	0,374

Как видим из табл. 5, при переходе к векторному представлению подобие разных описаний между собой в сравнении с голосованием (последний столбец) прогнозируемо возрастает, что, в принципе, может привести к снижению уровня помехозащищенности. Кроме того, видно, что нормировка признаков существенным образом не повлияла на значение подобия. В целом, как показывают результаты наших предыдущих исследований [4], помехозащищенность методов структурного распознавания на основе векторной трансформации описаний не уступает, а в некоторых ситуациях, например, при аддитивном шуме, даже выше, чем у традиционного подхода голосования.

В плане оценки быстродействия традиционного и предложенного метода на основе кластеризации ($s = 300$, $k = 8$, $J = 5$) можно отметить, что быстродействие разработанного метода примерно в 20 раз выше. С ростом числа признаков базы этот выигрыш возрастает.

Выводы

Особенностью обучения на множестве характерных признаков базы изображений есть необходимость использования всей имеющейся информации (полное описание базы). Другой особенностью применения сети Кохонена к множеству дескрипторов изображений можно считать не критичность значений таких параметров, как равномерная активность нейронов, скорость и ошибка обучения, т.к. качество распознавания определяется другими факторами. В то же время ошибка обучения отражает точность представления сформированной кластерной структурой множества векторов описаний.

Важными для распознавания на основе обученной сети считаем число кластеров и способ их инициализации.

Научная новизна проведенного исследования состоит в эффективном применении сетей Кохонена для самообучения системы структурного распознавания изображений путем построения кластерного сжатого представления. Это позволяет перейти к векторному описанию эталонов, и как результат, существенно увеличивается быстродействие распознавания.

Практическая ценность — получение оценок качества и эффективности применения кластеризации для конкретных прикладных примеров баз изображений.

Перспективой применения нейросетевых технологий обучения на множестве описаний в виде характерных признаков изображений может быть распространение их на сферу обучения с учителем, т.к. класс характерного признака в составе эталона в таких задачах распознавания априорно считается известным.

1. *Гороховатский В.А.* Структурный анализ и интеллектуальная обработка данных в компьютерном зрении: монография / В.А. Гороховатский. — Х.: Компания СМИТ, 2014. — 316 с.

2. *Bay H.* Surf: Speeded up robust features / H. Bay, T. Tuytelaars, L. Van Gool // European Conference on Computer Vision. — 2006. — P. 404–417.

3. *Паклин Н.Б.* Бизнес-аналитика: от данных к знаниям: учеб. пособ. / Н.Б. Паклин, В.И. Орешков. — СПб.: Питер, 2013. — 704 с.

4. *Гороховатский В.А.* Грануляция значений признаков объектов как способ повышения результативности методов структурного распознавания / В.А. Гороховатский, Ю.А. Куликов // Реєстрація, зберігання і оброб. даних. — 2014. — Т. 16, № 3. — С. 67–78.

5. *Прикладная статистика: Классификация и снижение размерности: справ. изд.* / С.А. Айвазян, В.М. Бухштабер, И.С. Енюков, Л.Д. Мешалкин; под ред. С.А. Айвазяна. — М.: Финансы и статистика, 1989. — 607 с.

6. *Осовский С.* Нейронные сети для обработки информации / С. Осовский; пер. с польск. И.Д. Рудинского. — М.: Финансы и статистика, 2002. — 344 с.

7. *Kohonen T.* Self-organizing maps / Т. Kohonen. — Berlin: Springer Verlag, 1995.

Поступила в редакцию 20.02.2015