



В.А. Гороховатский¹, В.С. Столяров²

¹Харьковский институт ГВУЗ «Университет банковского дела»,

г. Харьков, Украина, e-mail: gorohovatsky.vl@gmail.com,

²ХНУРЭ, г. Харьков, Украина, e-mail: huccah@gmail.com

КЛАССИФИКАЦИЯ ИЗОБРАЖЕНИЙ НА ОСНОВЕ КЛАСТЕРНОГО ПРЕДСТАВЛЕНИЯ СТРУКТУРНЫХ ОПИСАНИЙ

Обсуждаются методы классификации в структурном распознавании изображений на основе преобразования их описаний к кластерному виду. Применение кластеризации существенно снижает время обработки, в то время как качественные показатели распознавания остаются на высоком уровне. Приведены результаты экспериментов по классификации на моделях структурных описаний.

РАСПОЗНАВАНИЕ ИЗОБРАЖЕНИЙ, СТРУКТУРНЫЕ МЕТОДЫ, ХАРАКТЕРНЫЕ ПРИЗНАКИ, КЛАСТЕРИЗАЦИЯ, ПРОСТРАНСТВО ВЕКТОРОВ, РЕЛЕВАНТНОСТЬ ОПИСАНИЙ, ВЕКТОР ЗНАЧИМОСТИ КЛАССОВ, КЛАССИФИКАЦИЯ

Введение

Структурное распознавание объектов в системах компьютерного зрения основано на вычислении уровня соответствия (степени релевантности) для описаний распознаваемых объектов и базы эталонов [1,2]. Описание объектов при этом представляют как множество векторов, зафиксированных в отдельных специфических точках изображения и инвариантных к допустимым геометрическим преобразованиям объектов [3-5]. Примеры изображений с координатами характерных точек, полученных методом SURF, приведены на рис. 1. Традиционно релевантность определяют как степень подобия, вычисляемую для структур данных типа множество-множество. Величина релевантности является основой для решения таких практических задач, как классификация путем сравнения с эталоном, поиск объектов на изображении, выбор идентичных объектов в базе данных и т.д.

Одним из наиболее эффективных по быстродействию способов сопоставления структурных описаний есть вычисление релевантности данных, представленных в виде интегрированных векторных описаний, формируемых путем трансформации множества признаков к обобщенному вектору, основанному на кластерном преобразовании множества структурных признаков (СП) базы эталонов [2,3].

Кластерное представление есть результат предварительного обучения системы распознавания на конкретном множестве образцов, которые составляют базис для распознавания. Векторную трансформацию структурного описания – множества можно трактовать как аппроксимацию пространства признаков системой кластеров. В результате такого представления становится возможным более продуктивно вычислять релевантность на структурах данных типа вектор-множество и вектор-вектор. В то же время возникает необходимость

детального изучения особенностей и параметрического управления такой трансформацией с точки зрения результативности построенных на её основе процедур распознавания.

Цель работы – разработка и исследование свойств методов структурного распознавания изображений на основе компрессионного кластерного представления данных. За счет применения кластерных характеристик на множестве структурных элементов обеспечивается векторное представление, значительно сокращается объем вычислительных затрат и улучшается быстродействие распознавания.

Задачи – исследование особенностей и усовершенствование информационных технологий распознавания в пространстве структурных признаков – описаний как множеств дескрипторов характерных точек изображений, а также оценивание результативности распознавания путем моделирования.



Рис. 1. Примеры изображений с координатами характерных признаков

1. Классификация на основе вычисления релевантности

На предварительном этапе обработки эталонное множество $Z = \{Z^j\}_{j=1}^J$ СП, включающее все образцы для распознавания (Z^j – эталон, J – число эталонных классов), разбивается на конечное число k кластеров $M = \{M_i\}_{i=1}^k$, так что $M_i \cap M_d = \emptyset$, $M = Z$, кластеры заданы множеством их

центроидов $m = \{m_i\}_{i=1}^k$. Кластеризация осуществляется отображение конечного множества СП в себя $Z \rightarrow Z$, причем каждый СП принадлежит одному из кластеров. В общем случае в результате кластеризации может оказаться, что $m_i \notin M_i$. Множества Z и Z^j есть мульти множества, где близкие между собой СП считаются эквивалентными [2,7]. После завершения кластеризации эталонного множества осуществляют «просеивание» множеств СП каждого из эталонов, в результате чего описание j -го эталона приобретает вид целочисленного вектора

$$H[Z^j] = (h_1, h_2, \dots, h_l, \dots, h_k)^j, \quad (1)$$

где $h_i = \text{card}\{z \mid z \in Z^j \& z \in M_i\}$, $h_i \in C$ – число элементов эталона Z^j , отнесеных к кластеру M_i , C – множество целых чисел.

Представление (1) – это образ эталона $Z^j \subseteq Z$ в кластерном отображении. Вычисление релевантности для пары образов – числовых векторов вида (1) в вычислительном плане значительно (в десятки раз [3,7]) менее затратное, чем сопоставление описания входного изображения с множествами $\{Z^j\}$. Наиболее практические способы – вычисление расстояния или коэффициента корреляции в пространстве векторов [2].

При определении релевантности применимо также нормализованное кластерное описание объекта $O = \{o_i\}$ в виде вектора

$$H[O_n] = (h_1^n, h_2^n, \dots, h_k^n)^o, \quad h_i^n = h_i / s^o, \quad (2)$$

где $s^o = \text{card}(O) = \sum_{i=1}^k h_i$ – мощность множества O . Нормализация (2) необходима из-за разного в общем случае числа элементов в эталонах и распознаваемом объекте. Однако, в результате нормировки (2) описания, в которых значения h_i^n близки, могут быть признаны идентичными.

Фактически в результате осуществления кластеризации мы имеем дело с двумя разными представлениями эталонного множества Z : в виде набора эталонных описаний $Z = \{Z^j\}_{j=1}^J$ и в виде конечного числа кластеров $Z = M = \{M_i\}_{i=1}^k$. Целью распознавания есть идентификация объекта с одним из эталонов, а кластерное представление применяется для упрощения обработки и повышения быстродействия.

Создадим теперь метод распознавания для отнесения описания $O = \{o_i\}$ неизвестного визуального объекта к одному из классов $\{Z^j\}_{j=1}^J$ на основе кластерного описания M базы эталонов. Метод осуществляет отображение из множества описаний объектов $O \in \{O\}$ в конечное множество номеров классов $\{1, \dots, J\}$ и может быть представлен последовательностью шагов.

1. Причислим каждый элемент $o_i \in O$ распознаваемого объекта к одному из кластеров $M_i \subseteq M$ в

соответствии с правилом оптимальности

$$o_i \rightarrow M_i \mid \arg \min_d \rho(o_i, m_d) = i, \quad (3)$$

где $\rho(o_i, m_d)$ – метрика на множестве СП.

Правило (3) выполняет конкурентное отнесение СП o_i по принципу оптимальной близости в системе кластеров. Характеристикой кластера выступает его центр $m_i \in M_i$. Здесь же реализуют фильтрацию неподходящих (ложных) элементов. Для этого после (3) дополнительно выполняют пороговую верификацию установленного минимума m_i : $\rho(o_i, m_i) \leq \delta$, где δ – некоторый порог значимости для минимума расстояния. Если условие не выполнено, распознаваемый элемент o_i объекта не относится ни к одному из кластеров и считают ошибочным.

2. Реализуем шаг 1 $\forall o_i \in O$, в результате формируются описания вида (1), (2) объекта как $O = (h_1, h_2, \dots, h_k)^o$, где h_i – число элементов, отнесенных в кластер M_i .

3. Вычислим степень r_j релевантности между нормализованными кластерными описаниями (2) объекта и каждого из эталонов как расстояние $r_j = \beta(H[O_n], H[Z_n^j])$ в векторном пространстве R^k .

4. Объект O отнесем к классу $d \in \{1, \dots, J\}$ по правилу $d = \arg \min_j r_j$.

Расстояния $\rho(\dots)$ для элементов и $\beta(\dots)$ для векторных описаний в общем случае различны, вместо них применимы также меры подобия, например, коэффициент корреляции, а порог δ определяется уровнем различимости в конкретной базе эталонов и допустимым уровнем помех. На этапе 4 также применима проверка значимости полученного минимума релевантности r_d : $r_d \leq \varepsilon$, где ε – порог. При неудовлетворении неравенства класс объекта считаем неопределенным, т.к. отсутствует значимое соответствие в имеющемся пространстве эталонов.

Рассмотренный метод не учитывает важные для результативного распознавания соотношения характеристик построенных кластеров со свойствами набора взаимно различаемых эталонов в составе базы образцов. Для учета этого ключевого обстоятельства применим в процессе распознавания векторный показатель значимости классов для каждого из признаков $o_i \in O$. Значимость для СП o_i определим в виде вектора α^i весов классов, присписанного отдельному кластеру. Будем формировать α^i на этапе предварительного обучения системы распознавания, учитывая особенности конкретной базы эталонов в аспекте её кластерного представления. Определим α^i для кластера M_i в виде вектора $\alpha^i = (\alpha_1^i, \alpha_2^i, \dots, \alpha_J^i)$, компоненты которого зададим соотношением

$$\alpha_d^i = c_d^i / s_i, \quad (4)$$

где $c_d^i = \text{card}\{z \mid z \in Z^d \text{ & } z \in M_i\}$ – число элементов эталонного класса Z^d , определенных за результатами обучения в кластер M_i , $s_i = \text{card}(M_i)$ – число элементов кластера M_i .

Значение (4) соответствует нормированному представлению (2) для кластерного разложения эталона по множеству классов. Из (4) видно, что $\sum_{d=1}^J \alpha_d^i = 1$, так что α_d^i можно считать оценкой вероятности события, что элемент кластера M_i относится к классу Z^d . Величины α_d^i есть относительные веса СП кластера в плане его отнесения к эталонам классов. В частности, максимальное значение среди компонентов α^i соответствует наиболее вероятному классу, к которому может принадлежать СП. Очевидно, что значения характеристик (4) непосредственно зависят как от содержания базы эталонов, так и от применяемого метода кластеризации, который устанавливает отображение эталон-кластер.

Модифицируем метод распознавания включением вектора весов α^i в процесс принятия решения. Отнесение элемента o_l к одному из кластеров на шаге 1 теперь сопровождается формированием суммы значений априорных векторов α^i , в результате чего после анализа всех значимых $o_l \in O$ на шаге 2 будет сформирован суммарный для элементов объекта вектор характеристик классов

$$\Sigma = \sum_O \alpha^i = (\Sigma_1, \Sigma_2, \dots, \Sigma_J), \quad \Sigma_d = \sum_i \alpha_d^i. \quad (5)$$

Суммирование в (5) осуществляется по всем значимым соответствиям кластерам для множества СП объекта.

Модификация п. 4 метода приобретает вид: объект относим к классу $d \in \{1, \dots, J\}$ по правилу:

$$O \rightarrow d \mid d = \arg \max_j \Sigma_j. \quad (6)$$

В модифицированном методе распознавания также могут быть применены проверки на значимость при отнесении к кластеру (на шаге 1) и на значимость максимума подобия в (6) (шаг 4). В частности, значимость максимума в (6) может быть подтверждена степенью преобладания глобального максимума над ближайшим из локальных [2].

Как видим, первый метод базируется на процедуре голосования (3), в основе которой лежит конкурентный выбор центра кластера для каждого СП объекта и анализ подобия кластерного описания объекта на множестве эталонов. Здесь использовано разложение в разрезе «эталон по кластерам». Идея же модифицированного метода основана на построении интегрального вероятностного распределения кластеров на множестве СП объекта в имеющемся диапазоне классов. Здесь информационной основой есть разложение «кластер по эталонам». Это, по нашему разумению,

должно обеспечить более глубокое согласование со значениями СП эталонных образцов, что в целом улучшит результативность распознавания. Модифицированный метод также можно считать голосованием СП объекта, взвешенным распределением имеющихся классов базы изображений по построенному множеству кластеров.

В прикладных исследованиях при наличии помех целесообразно рекомендовать схему анализа на шаге 1 рассмотренных методов, когда каждый кластер базы эталонов «отбирает» соответствующие ему элементы объекта, т.е. поиск соответствия для СП осуществляется «от эталона», а не «от объекта». Нормализация при этом может быть выполнена на основе числа отобранных признаков анализируемого объекта.

2. Анализ качества кластерного представления

Обобщая проведенный анализ, отметим, что исходными данными для распознавания есть целочисленная матрица кластерного представления H размерами $J \times k$, где число строк равно количеству эталонов, а число столбцов – количеству кластеров. Стока матрицы – это разложение имеющихся данных вида «эталон по кластерам», а столбец – вида «кластер по эталонам». Каждый из срезов (строки, столбцы) допускает проведение дополнительной обработки в целях улучшения свойств распознавания. Однако при этом нужно вводить изменения и в метод распознавания. Другим направлением усовершенствования есть изменение результатов кластеризации за счет применения других методов.

Матрица кластерного представления H есть основой процедуры распознавания. Проанализируем теперь возможности изучения ее качественных свойств в целях улучшения распознавания, а также возможность ее дополнительной логической обработки. Заметим, что изменение матрицы повлияет и на весовые коэффициенты α^i . Такую обработку осуществляют на предварительном этапе, поэтому время распознавания не возрастает. Дополнительная логическая обработка может быть необходима в целях дальнейшего сжатия и уточнения трансформированных описаний, исключения кластеров незначительного объема, т.е. для формирования конструктивной системы кластеров, в рамках которой можно реализовать качественное распознавание. Другим приемом обработки может быть исключение (обнуление) в столбцах матрицы незначимых по сравнению с остальными элементов.

Для анализа или логической обработки значений h_i столбцов матрицы H , характеризующих кластер M_i , применим критерий [2]

$$\gamma_i = \sum_{a=1}^{J-1} \sum_{b>a} |h_i[a] - h_i[b]|, \quad (7)$$

где $h_i[a]$ – компонента i -го столбца.

Величина (7) равна нулю в случае полного совпадения значений в столбце и возрастает с увеличением их различия между собой. Вместо (7) можно применить также дисперсионные характеристики значений столбцов. Обработка может состоять в вычислении величины (7) для столбцов матрицы H и отбрасывании как непригодных для распознавания столбцов с наименьшими значениями критерия. В результате получим усеченную по числу столбцов матрицу H . Заметим, что введение логической обработки приводит к трансформации имеющихся данных и к необходимости в связи с этим некоторого изменения алгоритма распознавания. Окончательная эффективность таких эвристических обработок может быть оценена только на основе экспериментов по распознаванию в прикладной задаче. В то же время, величина компонент вектора γ_i может выступить критерием качества кластерного представления: чем более удалены значения (7) от нуля, тем лучше качество кластеризации в аспекте распознавания по сформированной системе кластеров.

3. Результаты экспериментов

В ходе моделирования в ряде наших экспериментов сформированы равномерно распределенные на множестве $\{0, \dots, 9\}$ дискретные значения СП в составе структурных описаний, где число кластеров взято равным $k=10$. В качестве $\rho(\dots)$ для элементов использована метрика изолированных точек (СП равны в случае их совпадения), а в качестве меры $\beta(\dots)$ для кластерных описаний выбрана евклидова метрика. Для объема эталонных описаний в 100 элементов многоразовое вычисление релевантности показало, что значение r для разных реализаций образцов в евклидовой метрике было не меньше величины 0,16, что говорит о достаточноной надежности и работоспособности разработанного метода сопоставления описаний даже в условиях одинаково распределенных значений СП разных эталонов. В целом полученный диапазон значений релевантности в этом эксперименте определяется отрезком [0,16–0,34].

Для этих исходных данных для 4-х равномерно распределенных эталонных множеств при $k=10$ вычислены представления $H[Z^j]$ (табл. 1) и веса α^i кластеров (табл. 2).

Как видим, веса кластеров в столбцах табл. 2, значения которых непосредственно используются во втором методе, оказались достаточно близкими из-за того, что эталоны имеют одинаковое распределение. Наиболее благоприятные для

распознавания весомые различия между эталонами наблюдаются в кластерах 1, 3, 5, 7, а в кластере 9 имеем полное совпадение значений, что говорит о невозможности различия эталонов в рамках этого кластера. Эти факторы в целом затрудняют процесс распознавания. Примером логической обработки здесь может быть удаление из рассмотрения кластера 9 (одинаковые элементы), а также обнуление значения 0,08 в кластере 5 табл. 2 (незначимость). Значения критерия γ в табл. 1 позволяют установить полезность кластеров: кластеры 8, 9, 10 наименее пригодны, а кластеры 1, 4, 5, 7 позволяют в наилучшей степени различать классы. В других экспериментах со случайно выбранными значениями данных величина компонент вектора (7) достигала значений 70.

Таблица 1
Кластерные представления $H[Z^j]$ и значения (7)

H	M_1	M_2	M_3	M_4	M_5	M_6	M_7	M_8	M_9	M_{10}
Z^1	7	9	9	9	14	15	6	11	11	9
Z^2	8	11	8	16	3	14	13	9	11	7
Z^3	15	7	3	13	9	18	7	8	11	9
Z^4	10	8	8	13	13	12	7	11	11	7
γ	26	13	18	21	37	19	21	11	0	8

Таблица 2
Весовые коэффициенты α^i

α^i	M_1	M_2	M_3	M_4	M_5	M_6	M_7	M_8	M_9	M_{10}
Z^1	0.17	0.26	0.32	0.18	0.36	0.25	0.18	0.28	0.25	0.28
Z^2	0.20	0.31	0.29	0.31	0.08	0.24	0.39	0.23	0.25	0.22
Z^3	0.38	0.20	0.11	0.25	0.23	0.31	0.21	0.21	0.25	0.28
Z^4	0.25	0.23	0.29	0.25	0.33	0.20	0.21	0.28	0.25	0.22

Отметим, что в реальных условиях структурного распознавания ситуация с низкими значениями критерия (7) возникает достаточно редко [6], потому что структурные описания изображений все-таки значимо отличаются между собой. В то же время преобладание отдельных значений в столбцах матрицы H свойственны СП изображений.

Для второго метода с использованием весов α^i для тех же исходных данных в исследовании также достигнута безошибочная классификация. Для входных векторов эталонов с номерами 1, 4, где получена релевантность $r=0,16$ по первому методу, второй метод также показал незначительное отличие в значениях вектора Σ : для эталонов 1 и 4 он равен 25,48, а при сравнении эталона 4 с самим собой – 25,57. Такие ничтожные различия подчеркивают более высокую чувствительность второго метода.

Проведены эксперименты с учетом влияния помех, когда каждая компонента исходного

описания (случайный вектор из 100 элементов) изменялась с заданной вероятностью θ на другое случайное значение, выбранное из того же диапазона. При значениях θ на промежутке $[0, \dots, 0,7]$ вероятность правильного распознавания случайных векторов уменьшалась от 1 до 0,47. При этом для малого уровня помех $\theta < 0,3$ большая вероятность наблюдалась у первого метода (вероятность более 0,85), в то время как при значительном уровне помех $\theta \geq 0,3$ преимущество имеет второй метод (вероятность равна 0,7). Этот факт можно объяснить тем, что первый метод строит и сопоставляет интегральные по кластерной системе описания, в то время как второй метод классифицирует каждый элемент в отдельности, что делает этот подход более конкурентоспособным.

В целях более глубокого изучения свойств кластерного представления выбраны другие реализации эталонов, обладающие существенным различием в построенном пространстве. Конкретно для первого метода расстояние между выбранными описаниями составило более 0,42. Соответственно усилились различия и для второго метода. По результатам экспериментов в условиях помех представлена табл. 3.

Таблица 3

**Значения вероятности правильного распознавания
в условиях помех**

Уровень помех θ	0,1	0,2	0,3	0,4	0,5	0,6
Первый метод	1,0	1,0	0,98	0,95	0,86	0,73
Второй метод	1,0	1,0	0,99	0,97	0,91	0,80

Как видим из табл. 3, оба метода обладают высокой помехоустойчивостью: приискажении до 30% числа СП из описаний они обеспечивают практически безошибочное распознавание с вероятностью выше 0,98. В сравнительном плане второй метод обеспечивает более устойчивое функционирование в условиях помех, т.к. при уровне $\theta \in [0, \dots, 0,3]$ вероятности для обоих методов примерно одинаковы, а при $\theta > 0,3$ значения вероятности для второго метода несколько выше.

Выводы

Рассмотренные методы реализуют процедуру распознавания визуального объекта на основе кластерного представления в пространстве структурных признаков в форме двух срезов: «эталон по кластерам» и «кластер по эталонам». Критерий (7) при этом описывает качество представления второго типа. Аналогично (7) можно применить некоторый критерий и к строкам матрицы табл. 1. Однако, разнообразие внутри строки для первого метода не так существенно влияет на распознавание, как

различия между строками. Эти различия отражаются в матрице расстояний между эталонами в построенном пространстве признаков.

Каждый из предложенных методов имеет свои особенности в плане результативности. Оба метода опираются на использованную процедуру кластеризации. В примере сложной ситуации равномерного распределения признаков эталонов по классам более эффективным оказался второй метод. В сравнительном плане значения вероятности правильного распознавания второй метод обеспечивает более устойчивое функционирование в условиях помех.

Научная новизна исследования состоит в синтезе метода структурного распознавания изображений на основе кластерного представления описаний. Переход к векторному виду существенно увеличивает быстродействие распознавания за счет упрощения обработки.

Практическая ценность работы – получение прикладных программных моделей для модификаций структурного распознавания и подтверждение результативности предложенной обработки в конкретных примерах модельных сигналов.

Рассмотренные методы достаточно универсальны и могут быть использованы для анализа и классификации произвольных наборов данных, представленных в виде множеств.

Список литературы:

1. Берестовский А.Е. Нейросетевые технологии самообучения в системах структурного распознавания визуальных объектов / А.Е. Берестовский, А.Н. Власенко, В.А. Гороховатский // Реєстрація, зберігання і обробка даних. – 2015. – Т. 17, № 1. – С. 108–120.
2. Гороховатский В.А. Структурный анализ и интеллектуальная обработка данных в компьютерном зрении: монография / В.А. Гороховатский. – Х.: Компания СМІТ, 2014. – 316 с.
3. Gorokhovatsky V.A. Efficient Estimation of Visual Object Relevance during Recognition through their Vector Descriptions / V.A. Gorokhovatsky // Telecommunications and Radio Engineering. – 2016, Vol. 75, No 14. – P. 1271–1283.
4. Bay H. Surf: Speeded up robust features / H. Bay, T. Tuytelaars, L. Van Gool // European Conference on Computer Vision. – 2006. – P. 404 – 417.
5. Szeliski R. Computer Vision: Algorithms and Applications / R. Szeliski. – London: Springer, 2010. – 979 p.
6. Гороховатский В.А. Структурное распознавание изображений с применением моделей интеллектуальной обработки и самоорганизации признаков / В.А. Гороховатский, А.В. Гороховатский, А.Е. Берестовский // Радиоэлектроника, информатика, управление.–2016. – №3 (38). – С. 39–46.
7. Гороховатский В.А. Изучение свойств методов кластеризации применительно к множествам характерных признаков изображений / В.А. Гороховатский, М.Д. Дунаевская, В.А. Струненко // Системи обробки інформації. – 2016. – Вип. 5 (142). – С. 124–127.

Поступила в редакцию 12.10.2016