

НЕЙРОИНФОРМАТИКА ТА ІНТЕЛЕКТУАЛЬНІ СИСТЕМИ

НЕЙРОИНФОРМАТИКА И ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ

NEUROINFORMATICS AND INTELLIGENT SYSTEMS

УДК 004.932.2:004.93'1

Гороховатский В. А.¹, Путятин Е. П.², Столяров В. С.³

¹Д-р техн. наук, профессор, профессор кафедры информационных технологий и высшей математики, Харьковский учебно-научный институт государственного высшего учебного заведения «Университет банковского дела», Харьков, Украина

²Д-р техн. наук, профессор, заведующий кафедрой информатики, Харьковский национальный университет радиоэлектроники, Харьков, Украина

³Студент, Харьковский национальный университет радиоэлектроники, Харьков, Украина

ИССЛЕДОВАНИЕ РЕЗУЛЬТАТИВНОСТИ СТРУКТУРНЫХ МЕТОДОВ КЛАССИФИКАЦИИ ИЗОБРАЖЕНИЙ С ПРИМЕНЕНИЕМ КЛАСТЕРНОЙ МОДЕЛИ ДАННЫХ

Актуальность. Повышение результативности и расширение функциональности современных систем компьютерного зрения требуют создания более эффективных методов обработки визуальной информации. Основные задачи структурного распознавания связаны с усовершенствованием информационных технологий классификации в пространстве описаний как множеств дескрипторов ключевых точек изображений, а также необходимостью оценивания действенности распознавания на прикладных образцах. Особое внимание уделяют изучению структуры данных для множества дескрипторов, что напрямую влияет на показатели функционирования систем распознавания.

Цель. Изучение особенностей кластерного представления для множества структурных признаков прикладной базы изображений и оценивание показателей эффективности применения кластерной модели в методах структурного распознавания визуальных объектов в плане получения компактного представления данных.

Метод. Предложено методы распознавания на основе трансформации пространства структурных признаков путем кластеризации и применения кластерных характеристик базы эталонных изображений. Первый метод использует интегральное представление описаний эталонов, второй метод при отнесении структурного элемента к классу опирается на значение вектора статистического распределения в матричном пространстве кластер-эталон. Итогом исследования есть создание методов распознавания и моделей обработки данных в процессе построения векторов релевантности или характеристик классов в трансформированном пространстве признаков.

Результаты. За счет кластерного преобразования пространства структурных признаков сокращается объем вычислительных затрат, и в сотни раз улучшается быстродействие распознавания при сохранении нужной эффективности. Проведено сравнение методов SURF и ORB при формировании структурных признаков, время обработки методом ORB оказалось в 60 раз меньше. С другой стороны, множество дескрипторов SURF более точно отражает особенности формы визуальных объектов.

Проведено моделирование и экспериментальные исследования предложенного метода распознавания в прикладной базе изображений. Подтверждена результативность метода в плане эффективности, получены сравнительные оценки качества распознавания в зависимости от уровня аддитивных помех для анализируемых вариантов обработки.

Выводы. В проведенном исследовании систематизированы и получены перспективные свойства систем распознавания в пространстве структурных признаков изображений. Разработанные методы классификации на основе кластерного описания обеспечивают достаточный уровень различения изображений и высокую помехоустойчивость.

Научная новизна исследования состоит в синтезе метода структурного распознавания изображений путем применения кластерной обработки и построения классифицирующих решений в пространстве кластер-эталон. Переход к векторно-кластерному виду существенно повышает быстродействие распознавания за счет упрощения обработки.

Практическая ценность работы – получение прикладных программных моделей для модификаций метода структурного распознавания и подтверждение результативности и помехоустойчивости предложенной обработки в конкретных примерах баз изображений.

Ключевые слова: компьютерное зрение, структурное распознавание изображений, множество структурных признаков, дескрипторы SURF, дескрипторы ORB, релевантность описаний, вектор характеристик классов, помехоустойчивость метода, быстрое действие распознавания.

НОМЕНКЛАТУРА

$Z = \{Z^j\}_{j=1}^J$ – база эталонных описаний;

Z^j – эталон;

J – число классов;

SURF – Speeded up robust features (ускоренное выделение устойчивых особенностей);

ORB – Oriented FAST and Rotated BRIEF (ориентированный FAST и повернутый BRIEF);

СП – структурный признак;

$M = \{M_i\}_{i=1}^k$ – разбиение на множестве Z ;

k – число классов (кластеров) СП;

$h[Z^j]$ – вектор представления эталона;

$H[Z] = \{h_i^j\}_{j=1}^J \}_{i=1}^k$ – матрица кластерного описания базы изображений;

$m = \{m_1, m_2, \dots, m_k\}$ – множество центров кластеров;

$\{a_i^j\}_{j=1}^J \}_{i=1}^k$ – матрица весов эталонов;

$O = \{o_l\}$ – описание распознаваемого визуального объекта;

$\rho(o_l, m_d)$ – метрика на множестве СП;

δ – порог значимости для метрики ρ ;

$r_j = \beta(\alpha^i[O], \alpha^i[Z^j])$ – расстояние (степень релевантности) между кластеризованными векторными описаниями;

ε – порог значимости для минимума релевантности;

$\Sigma = (\Sigma_1, \Sigma_2, \dots, \Sigma_J)$ – вектор характеристик классов;

$v = \Sigma_{\min} / \Sigma_{\max}$ – показатель эффективности различения эталонов.

ВВЕДЕНИЕ

Узловые задачи компьютерного зрения связаны с формированием полезных выводов и результативных управленческих решений относительно физических объектов реального мира на основе анализа их изображений [1–11]. Преимуществами структурных методов в анализе изображений есть представление визуальных объектов в виде множества независимых структурных элементов, что позволяет в процессе распознавания осуществлять результативные решения по подмножествам элементов и обеспечить нужную устойчивость к помехам на анализируемом изображении [1–3]. Перспективы структурного распознавания связаны с усовершенствованием информационных технологий классификации в пространстве описаний в виде множеств дескрипторов ключевых точек изображений, а также необходимостью оценивания действенности распознавания на прикладных образцах.

Объект исследования – структурное распознавание изображений в компьютерном зрении, описание которых представлено множествами характерных признаков.

Предмет исследования – кластерная модель представления структурного описания объектов с учетом пара-

метров числа кластеров и порогов подобия структурных элементов.

Цель работы – изучение свойств и особенностей кластерного представления для множества структурных признаков прикладной базы изображений и оценивание показателей эффективности применения кластерной модели в методах структурного распознавания визуальных объектов в плане получения компактного представления данных.

1 ПОСТАНОВКА ЗАДАЧИ

Фундаментом структурного распознавания есть априорно заданная база описаний эталонных изображений (алфавит классов), представленная их общей совокупностью СП в виде множества $Z = \{Z^j\}_{j=1}^J$.

Осуществим на множестве Z разбиение $Z = M = \{M_i\}_{i=1}^k$, $M_i \cap M_d = \emptyset$, $M_i \neq \emptyset$. Считаем элементы $z \in M_i$ эквивалентными (равноценными) между собой. Получим две системы классификации $\forall z \in Z$: $\{Z^j\}$ – для эталонных изображений и $\{M_i\}$ – для СП. За счет разбиения $\{M_i\}_{i=1}^k$ описание Z^j эталона трансформируется к целочисленному вектору

$$h[Z^j] = \langle h_1^j, h_2^j, \dots, h_i^j, \dots, h_k^j \rangle, \quad (1)$$

где $h_i^j = \text{card}\{z \mid z \in Z^j \ \& \ z \in M_i\}$. Представление (1) – это образ эталона, полученный в результате кластерного представления, а конечное множество векторов (1) базы из J образцов образует матрицу $H[Z] = \{h_i^j\}_{j=1}^J \}_{i=1}^k$. Строка матрицы H отражает кластерное описание отдельного эталона, а столбец – содержание кластера из числа равноценных элементов разных эталонов.

Представляет интерес изучение свойств и особенностей полученной кластерной структуры данных в плане показателей функционирования методов распознавания, построенных на ее основе.

2 ОБЗОР ЛИТЕРАТУРЫ

Современные структурные методы анализа визуальной информации основаны на оценивании подобия дескрипторных описаний анализируемого и эталонного изображений, представленных в виде множеств особых точек – СП [1, 4–6]. Величина подобия отражает степень выполнения бинарного отношения релевантности для двух информационных единиц как описаний визуальных объектов в некотором пространстве признаков.

Множество СП в виде совокупности числовых векторов формируется применением специальных детекторов, наиболее известными среди которых в настоящее время считают SURF и более быстрый при реализации, но менее устойчивый к масштабированию, ORB [3, 5, 7]. SURF оперирует дескрипторами размером 64, ORB –

32 компонента, оба детектора инвариантны к геометрическим преобразованиям смещения, поворота, масштаба. Методы SURF и ORB реализованы в программных средах OpenCV, Matlab, ORB можно использовать в Веб-браузере посредством библиотеки JSFeat.

Построение разбиения в плане получения модели эталонов как групп равнозначных структурных элементов решается различными способами [1]. Один из развиваемых путей – применение кластеризации на множестве Z . Кластерное разбиение можно настроить на имеющуюся структуру данных, определяемую базой. Несомненным преимуществом применения векторной модели (1) при вычислении релевантности образов в целях распознавания в вычислительном плане значительно (в десятки раз) менее затратное, чем сопоставление описания изображения с совокупностью эталонных множеств $\{Z^j\}$ [4].

Можно рассматривать полученный образ (1) объекта как некоторую комбинаторную конфигурацию [8–11], которая организуется из элементов базового множества $m = \{m_1, m_2, \dots, m_k\}$, $m_i \in M_i$, образованного сформированной кластерной структурой. В такой конфигурации визуальный объект изображаем вектором (1), компонента которого равна числу вхождений базового элемента (СП) в описание объекта. Здесь применим также термин «рейтинг встречаемости» для СП. Процесс построения таких конфигураций можно считать самоорганизацией «порядка из беспорядка». Полученное в результате кластеризации базовое множество m центров напрямую зависит от банка образцов $\{Z^j\}$, служащих опорными точками в неограниченном пространстве распознаваемых изображений.

3 МАТЕРИАЛЫ И МЕТОДЫ

Наряду с векторной моделью (1) эталонов распознавание в кластерном представлении имеет дело с матричной информацией: матрица кластерного описания $H[Z] = \{\{h_i^j\}_{j=1}^J\}_{i=1}^k$, на основе которой вычисляется матрица весов $\{\{\alpha_i^j\}_{j=1}^J\}_{i=1}^k$ эталонов, а также матрицы подобия/расстояний, которые вычисляются при сопоставлении описаний внутри базы с применением мер сходства в рамках моделей признакового пространства.

В целях построения кластерного описания, которое отображает статистическое распределение классов внутри кластеров и не зависит от числа СП в эталоне, предлагается матрицу H нормировать, причем целесообразна двухэтапная обработка:

1) нормирование в строке матрицы H на число элементов эталона

$$H^* = \{\{h_i^{j*}\}_{j=1}^J\}_{i=1}^k = \{\{h_i^j / s_j\}_{j=1}^J\}_{i=1}^k, \quad (2)$$

где $s_j = \text{card}(Z^j)$ – число элементов в эталоне Z^j ;

2) нормирование матрицы (2) на сумму элементов в столбце, чтобы получить распределение классов внутри отдельного кластера

$$H^{**} = \{\{\alpha_i^j\}_{j=1}^J\}_{i=1}^k = \{\{h_i^{j*} / \sum_{j=1}^J h_i^{j*}\}_{j=1}^J\}_{i=1}^k. \quad (3)$$

Вектора-строки α^i соответствуют образу эталона в признаковом пространстве кластеров, они есть результатом обучения системы в используемой базе образцов.

Из (3) видно, что $\sum_{d=1}^J \alpha_d^i = 1$, так что α_d^i (относительные веса СП кластера) можно считать оценкой вероятности события, что элемент кластера M_i относится к классу Z^d . В частности, максимальное значение среди компонентов α^i соответствует наиболее вероятному классу принадлежности СП. Очевидно, что значения характеристик α_d^i непосредственно зависят как от содержания базы эталонов, так и от применяемого метода кластеризации, устанавливающего отображение эталон-кластер.

Распознавание в рамках кластерной модели исходит из теоретико-множественного описания данных и реализовано на основе статистико-вероятностного представления (1). Под распознаванием понимаем отнесение описания $O = \{o_l\}$ неизвестного визуального объекта к одному из классов $\{Z^j\}_{j=1}^J$, в результате осуществляется отображение из множества описаний объектов $\{O\}$ в конечное множество номеров классов $\{1, \dots, J\}$.

Сопоставление описания визуального объекта с использованием векторной модели эталонов осуществляется двумя основными способами [6]:

1) путем непосредственного сравнения интегральных характеристик вида (1);

2) поэлементно – каждый элемент объекта отнесем к одному из кластеров M_i , весовые характеристики которого накапливаются на множестве СП объекта.

Рассмотрим формальное содержание методов более подробно.

Метод 1.

1. Причислим элемент $o_l \in O$ объекта к кластеру $M_i \subseteq M$ в соответствии с конкурентным правилом

$$o_l \rightarrow M_i \mid \arg \min \rho(o_l, m_d) = i. \quad (4)$$

Для фильтрации ложных элементов в ходе реализации (4) выполним верификацию минимума m_i : $\rho(o_l, m_l) \leq \delta$. Если условие не выполнено, элемент O_l не относят ни к одному из кластеров.

2. В результате реализации шага 1 $\forall o_l \in O$ формируется описание (1) объекта $O = (h_1, h_2, \dots, h_k)^o$.

3. Вычислим степень r_j релевантности между нормализованными кластерными описаниями (3) объекта и эталонов как расстояние $r_j = \beta(\alpha^i[O], \alpha^i[Z^j])$ между соответствующими строками матриц $\{\alpha^i\}$ объекта и эталона в векторном пространстве R^k .

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

В общем случае векторные расстояния $\rho(\dots)$ и $\beta(\dots)$ различны, вместо них применимы также меры подобия, например, коэффициент корреляции, а порог δ опреде-

ляется установленной априорно степенью различимости в базе эталонов и уровнем помех. На шаге 4 применяется проверка значимости минимума релевантности $r_d : r_d \leq \varepsilon$, где ε – порог. При неудовлетворении неравенства класс объекта считаем неопределенным, т.к. не установлено значимое соответствие в имеющемся пространстве эталонов.

Метод 2. Модифицируем распознавание включением векторов α^i в процесс решения. Отнесение элемента o_l в правиле (4) к одному из кластеров на шаге 1 будем сопровождать формированием суммы значений векторов α^i , после анализа всех значимых $o_l \in O$ на шаге 2 получим суммарный для элементов объекта вектор характеристик классов

$$\Sigma = \Sigma_O \alpha^i = (\Sigma_1, \Sigma_2, \dots, \Sigma_J), Z_d = \Sigma_i \alpha_d^i. \quad (5)$$

Суммирование в (5) осуществляем по всем δ -значимым соответствиям кластеров для множества СП объекта. Шаг 4 метода 2 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 методе 2 также могут быть применены проверки значимости при определении кластера (шаг 1) и максимума подобия в (6) (шаг 4). Значимость максимума в (6) может быть подтверждена величиной преобладания глобального максимума над ближайшим из локальных максимумов [1].

Отметим, что поэлементное сопоставление СП в методе 2 в реальных ситуациях обеспечивает большую устойчивость к помехам аномального типа, связанных с ложными объектами и фоном, что характерно для сигналов изображений.

Результативность распознавания в рамках базы изображений (конечного числа классов) с применением конкретного метода и модели данных может быть оценена значениями симметричной матрицы расстояний (метод

1) или матрицей подобия (метод 2). Анализ отклонения минимального значения от нуля в строке матрицы расстояний показывает, насколько близок наиболее похожий среди других эталон с анализируемым, стоящим на диагонали. В матрице подобия эффективность различения эталонов оценим показателем $v = \Sigma_{\min} / \Sigma_{\max}$ отношения локального и глобального максимумов при условии, что максимум Σ_{\max} находится на диагонали (событие правильного распознавания).

4 ЭКСПЕРИМЕНТЫ

Нами разработана программная среда для моделирования и исследования предложенных методов, она включает нахождение эталонных множеств ключевых точек на основе SURF и ORB дескрипторов (библиотеки OpenCV 3.2 и JSFeat), кластеризацию (JavaScript, библиотека K-Means), и вычисление матриц расстояний и подобия для базы изображений.

Изучим свойства и особенности реализации методов распознавания на примере экспериментальной базы морских млекопитающих (рис. 1) при представлении их структурных описаний в рамках 10 кластеров. Заметим, что визуально исследуемые изображения значительно похожи между собой, и в реальных условиях наблюдений их сложно классифицировать даже человеку. Другой особенностью базы есть визуальное подобие 1 и 4-го изображений (кит и китенок). Размеры изображений – 139x309 пикселей. Численный состав эталонов методом SURF [3]: 39, 69, 55 и 28 СП. Кластеризация описаний базы осуществлена методом k-средних [2]. В результате получено описание базы (матрица H) в виде табл. 1.

Наши вычисления показали, что с применением обоих методов достигается безошибочное различение эталонов по 10-ти кластерному представлению, причем эталоны 1 и 4 наиболее схожи между собой, что подтверждается и визуально. Однако для метода 2 кластерные образы эталонов 2–4 оказались в высокой степени подобными, что не гарантирует надежного распознавания в условиях помех. Полученная в результате нормирования матрица весов показана в табл. 2.




Рисунок 1– Изображения морских животных базы и координаты СП SURF

Таблица 1 – Количество СП эталонов в кластерном представлении

| H | M_1 | M_2 | M_3 | M_4 | M_5 | M_6 | M_7 | M_8 | M_9 | M_{10} |
|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|----------|
| Z^1 | 3 | 6 | 2 | 2 | 5 | 3 | 6 | 8 | 0 | 4 |
| Z^2 | 11 | 12 | 0 | 15 | 8 | 14 | 9 | 0 | 0 | 0 |
| Z^3 | 3 | 2 | 0 | 14 | 5 | 0 | 18 | 13 | 0 | 0 |
| Z^4 | 4 | 1 | 2 | 3 | 4 | 5 | 6 | 1 | 1 | 1 |

Таблица 2 – Матрица весов для базы морских животных

| α^i | M_1 | M_2 | M_3 | M_4 | M_5 | M_6 | M_7 | M_8 | M_9 | M_{10} |
|------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|----------|
| Z^1 | 0,18 | 0,38 | 0,42 | 0,08 | 0,27 | 0,17 | 0,19 | 0,43 | 0 | 0,74 |
| Z^2 | 0,37 | 0,43 | 0 | 0,34 | 0,24 | 0,44 | 0,16 | 0 | 0 | 0 |
| Z^3 | 0,13 | 0,09 | 0 | 0,40 | 0,19 | 0 | 0,40 | 0,50 | 0 | 0 |
| Z^4 | 0,33 | 0,09 | 0,58 | 0,17 | 0,30 | 0,39 | 0,26 | 0,07 | 1,00 | 0,26 |

Как можно увидеть, полученное в табл. 2 представление выглядит достаточно эффективным, т.к. в столбцах 2, 3, 8, 9, 10 наблюдается существенное преобладание весовых коэффициентов для ограниченного числа эталонов. Матрицу подобия (метод 2) для эталонов базы можно вычислить, умножая столбец весов кластера на число СП эталона, оказавшихся в кластере (табл. 1). Матрица расстояния и матрица подобия представлены в табл. 3, 4.

Из табл. 3, 4 видим существенные различия эталонов в пространстве кластеров, в то время как эталоны 1, 4 остаются наиболее схожими.

Ключевым параметром кластерного представления есть число кластеров, которое теоретически связано с порогом эквивалентности для СП. Сокращение объёма вычислений при распознавании прямо пропорционально числу кластеров, в то время как значение вероятности правильного распознавания зависит обратно пропорционально. Матрица кластерного представления в рамках 5 кластеров для базы изображений рис. 1 представлена в табл. 5, а матрица подобия – в табл. 6.

Гистограмма представления первого изображения (рис. 1) в системе 5 и 10 кластеров приведена на рис. 2.

Проведено сравнительное исследование помехоустойчивости разработанных методов при действии аддитивных помех. Компоненты вектора помехи формировались в виде нормально распределенной случайной величины с нулевым математическим ожиданием и заданным значением среднеквадратического отклонения σ , характеризующего отношение сигнал-шум [1]. При $\sigma = 0,1$ для 10-ти кластеров первый метод обеспечивает безошибочное распознавание в пределах изучаемой базы, в то время как для второго метода вероятность P правильного распознавания составила $P = 0,92$. Снижение вероятности связано в основном с высокой степенью подобия изображений 1 и 4 (рис. 1). При $\sigma = 0,2$ вероятности составили 0,91 и 0,9, а при $\sigma = 0,3 - 0,76$ и 0,78. Как видим, в случае аддитивной помехи устойчивость первого метода несколько выше, но не значительно.

Таблица 3 – Матрица расстояний классов

| Эталон | 1 | 2 | 3 | 4 |
|--------|----|----|----|----|
| 1 | 0 | 58 | 42 | 21 |
| 2 | 58 | 0 | 58 | 51 |
| 3 | 42 | 58 | 0 | 47 |
| 4 | 21 | 51 | 47 | 0 |

Таблица 4 – Матрица подобия

| Эталон | 1 | 2 | 3 | 4 |
|--------|-------|-------|-------|-------|
| 1 | 13,21 | 7,89 | 9,02 | 8,88 |
| 2 | 13,96 | 23,99 | 13,62 | 17,42 |
| 3 | 12,72 | 10,86 | 20,74 | 10,68 |
| 4 | 6,38 | 7,07 | 5,44 | 9,11 |

Таблица 5 – Кластерное представление для 5 кластеров

| H | M_1 | M_2 | M_3 | M_4 | M_5 |
|-------|-------|-------|-------|-------|-------|
| Z^1 | 10 | 11 | 3 | 7 | 8 |
| Z^2 | 19 | 14 | 0 | 20 | 16 |
| Z^3 | 7 | 12 | 4 | 26 | 5 |
| Z^4 | 8 | 4 | 3 | 6 | 7 |

Таблица 6 – Матрица подобия для 5 кластеров

| Эталон | 1 | 2 | 3 | 4 |
|--------|-------|-------|-------|-------|
| 1 | 10,43 | 9,65 | 8,95 | 9,96 |
| 2 | 17,08 | 18,60 | 16,43 | 16,89 |
| 3 | 12,39 | 12,85 | 16,58 | 12,17 |
| 4 | 7,15 | 6,86 | 6,31 | 7,68 |

5 РЕЗУЛЬТАТЫ

Кластерное преобразование пространства структурных признаков сокращает объем вычислительных затрат, и в сотни раз улучшается быстрдействие распознавания при сохранении нужной эффективности. Проведено сравнение методов SURF и ORB при формировании структурных признаков: время обработки методом ORB в десятки раз меньше, однако, множество SURF более точно отражает форму визуальных объектов.

Проведено моделирование и экспериментальные исследования предложенных методов распознавания в




Рисунок 2 – Гистограмма кластеров изображения рис. 1 (зеленый – 5 кластеров, синий – 10 кластеров)

прикладной базе изображений. Подтверждены их работоспособность и результативность, получены сравнительные оценки качества распознавания в зависимости от уровня аддитивных помех для анализируемых вариантов обработки.

6 ОБСУЖДЕНИЕ

Сравнивая значения релевантности Σ для эталонов в табл. 6 и табл. 4 (метод 2), видим, что в строках табл. 6 по сравнению с табл. 4 показатель ν отношения локального и глобального максимумов значительно выше, что говорит о невысоком уровне различимости классов. В табл. 4 величина ν колеблется в пределах 0,63–0,75, в то время как в табл. 6 – $\nu \in [0,78 - 0,95]$. Таким образом, подобие эталонов между собой в рамках 5 кластеров выше, чем для 10 кластеров. Аналогичная ситуация (снижение различия классов) наблюдается и для матриц расстояний: если минимум среди недиагональных элементов табл. 3 равен 21, а максимум – 58, то для аналогичной таблицы в рамках 5 кластеров они равны 11 и 47. В целом же оба метода при числе кластеров 5 и 10 обеспечивают безошибочное распознавание.

Сравнение методов распознавания при применении разных детекторов (SURF и ORB) показывает, что первый метод более точный и чувствительный к схожести описаний, он различает даже очень близкие между собой изображения. В плане различия близких изображений методы SURF и ORB ведут себя аналогично. Но для ORB наблюдается более высокое значение показателя ν : для 10 кластеров он находится в пределах отрезка 0,85–0,98. Увеличение числа кластеров также не улучшает ситуации.

Детектор ORB формирует примерно в два раза больше дескрипторов: 80, 304, 137 и 46 СП для базы рис. 1. При этом числом дескрипторов можно управлять. Но за

счет более коротких дескрипторов в 32 элемента время кластеризации и распознавания для дескрипторов ORB на порядок меньше, чем для SURF. Для одного из экспериментов время формирования SURF в среднем составило в 62 раза большее значение (8,29e–4 сек). С другой стороны, множество дескрипторов SURF, на наш взгляд, более точно отражает особенности формы обрабатываемых визуальных объектов. Дескрипторы ORB при этом образуют скученные множества практически в одних и тех же точках изображения. Пример изображения 2 с координатами дескрипторов ORB приведен на рис. 3.



Рисунок 3 – Изображение и координаты дескрипторов ORB

ВЫВОДЫ

Таким образом, можно считать, что разработанные методы классификации на основе кластерного описания обеспечивают достаточный уровень различения изображений и высокую помехоустойчивость. Кластерное представление в десятки раз сокращает временные затраты на распознавание.

В то же время результативность кластерного распознавания существенно зависит от сформированной системы кластеров в прикладной базе классов, задаваемых эталонами. На этапе обучения системы целесообразно достигать приблизительно равночисленного представле-

ния для множеств структурных признаков эталонов, чтобы полученное кластерное представление приводило к примерно равноценному влиянию всех структурных элементов на результат. Для близких изображений (рис. 1, эталоны 1 и 4) целесообразно строить единое эталонное описание.

Исследования подтвердили мнение о том, что число кластеров в прикладных задачах компьютерного должно быть в диапазоне 5...10.

Эксперименты показали, что формирование дескрипторов ORB осуществляется в десятки раз быстрее, чем дескрипторов SURF. В то же время множество дескрипторов SURF точнее отражает форму объектов.

В зависимости от типа помех предложенные методы имеют разную помехоустойчивость. Первый метод рекомендуем применять при аддитивной помехе и объемных базах изображений, он обеспечивает нужную чувствительность. Зато второй метод на основе анализа каждого структурного элемента обладает лучшей помехоустойчивостью при влиянии локальных (импульсных) помех, приводящих к частичному искажению множества структурных признаков, образующих описание.

Такие параметры методов, как порог эквивалентности структурных признаков, пороги для значимости подобию и степени релевантности при решении о классе, а также число кластеров определяются в процессе обучения для конкретных прикладных баз изображений.

БЛАГОДАРНОСТИ

Работа выполнена в рамках госбюджетной научно-исследовательской темы Харьковского национального университета радиоэлектроники «Разработка гибридных систем и методов вычислительного интеллекта для обработки потоков нечеткой информации в условиях нестационарности и неопределенности» (номер гос. регистрации 0116U002539).

Гороховатский В. О.¹, Путятин Е. П.², Столяров В. С.³

¹Д-р техн. наук, профессор, профессор кафедры информационных технологий та вищої математики, Харківський навчально-науковий інститут державного вищого навчального закладу «Університет банківської справи», Харків, Україна

²Д-р техн. наук, профессор, завідувач кафедри інформатики, Харківський національний університет радіоелектроніки, Харків, Україна

³Студент, Харківський національний університет радіоелектроніки, Харків, Україна

ДОСЛІДЖЕННЯ РЕЗУЛЬТАТИВНОСТІ СТРУКТУРНИХ МЕТОДІВ КЛАСИФІКАЦІЇ ЗОБРАЖЕНЬ З ВИКОРИСТАННЯМ КЛАСТЕРНОЇ МОДЕЛІ ДАНИХ

Актуальність. Підвищення результативності та розширення функціональності сучасних систем комп'ютерного зору вимагають створення більш ефективних методів обробки візуальної інформації. Основні завдання структурного розпізнавання пов'язані з удосконаленням інформаційних технологій класифікації в просторі описів як множин дескрипторів ключових точок зображень, а також необхідністю оцінювання дієвості розпізнавання на прикладних зразках. Особливу увагу приділяють вивченню структури даних для множини дескрипторів, що безпосередньо впливає на показники функціонування систем розпізнавання.

Мета. Вивчення особливостей кластерного уявлення для множини структурних ознак прикладної бази зображень і оцінювання показників ефективності застосування кластерної моделі в методах структурного розпізнавання візуальних об'єктів в плані отримання компактного подання даних.

Метод. Запропоновано методи розпізнавання на основі трансформації простору структурних ознак шляхом кластеризації і застосування кластерних характеристик бази еталонних зображень. Перший метод використовує інтегральне уявлення описів еталонів, другий метод при віднесенні структурного елементу до класу спирається на значення вектора статистичного розподілу в матричному просторі кластер-еталон. Підсумком дослідження є створення методів розпізнавання і моделей обробки даних в процесі побудови векторів релевантності або характеристик класів в трансформованому просторі ознак.

Результати. За рахунок кластерного перетворення простору структурних ознак скорочується обсяг обчислювальних витрат, і в сотні разів поліпшується швидкість розпізнавання при збереженні потрібної ефективності. Проведено порівняння методів SURF і ORB при формуванні структурних ознак, час оброблення методом ORB виявився в 60 разів менше. З іншого боку, множина дескрипторів SURF більш точно відображає особливості форми візуальних об'єктів.

СПИСОК ЛІТЕРАТУРИ

1. Гороховатский В. А. Структурный анализ и интеллектуальная обработка данных в компьютерном зрении / В. А. Гороховатский. – Х. : Компания СМИТ, 2014. – 316 с.
2. 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.
3. Bay H. Surf: Speeded up robust features / H. Bay, T. Tuytelaars, L. Van Gool // Computer Vision: Ninth European Conference on Computer Vision, Graz, 7–13 May, 2006: proceedings. – Berlin: Springer, 2006. – P. 404–417.
4. 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.
5. Rublee E. ORB: an efficient alternative to SIFT or SURF / [E. Rublee, V. Rabaud, K. Konolige, G. Bradski] // IEEE International Conference on Computer Vision (ICCV), November 06–13, 2011, P. 2564–2571. Режим доступа http://www.willowgarage.com/sites/default/files/orb_final.pdf
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. Karami E. Image Matching Using SIFT, SURF, BRIEF and ORB: Performance Comparison for Distorted Images / E. Karami, S. Prasad, M. Shehata. – Режим доступа <https://www.researchgate.net/publication/292157133>
8. Szeliski R. Computer Vision: Algorithms and Applications / R. Szeliski. – London : Springer, 2010. – 979 p.
9. Duda R.O. Pattern classification / R. O. Duda, P. E. Hart, D. G. Stork. – 2ed., Wiley, 2000. – 738 p.
10. Manning C. D. Introduction to Information Retrieval / C. D. Manning, P. Raghavan, H. Schutze. – Cambridge, University Press, 2008. – 528 p.
11. Shapiro L. Computer vision / L. Shapiro and G. Stockman. – Prentice Hall, 2001. – 625 p.

Статья поступила в редакцию 16.02.2017.

После доработки 03.03.2017.

Проведено моделювання та експериментальні дослідження запропонованого методу розпізнавання для прикладної бази зображень. Підтверджено результативність методу в плані ефективності, отримані порівняльні оцінки якості розпізнавання в залежності від рівня адитивних перешкод для аналізованих варіантів обробки.

Висновки. У проведеному дослідженні отримані і систематизовані перспективні властивості систем розпізнавання у просторі структурних ознак зображень. Розроблені методи класифікації на основі кластерного опису забезпечують достатній рівень розрізнення зображень і високу стійкість перед перешкодами.

Наукова новизна дослідження полягає в синтезі методу структурного розпізнавання зображень шляхом застосування кластерної обробки і побудови класифікаційних рішень у просторі кластер-еталон. Перехід до векторно-кластерного подання істотно підвищує швидкість розпізнавання за рахунок спрощення обробки.

Практична значущість роботи – отримання прикладних програмних моделей для модифікацій методу структурного розпізнавання і підтвердження результативності та завадостійкості запропонованої обробки в конкретних прикладах баз даних зображень.

Ключові слова: комп'ютерний зір, структурне розпізнавання зображень, множина структурних ознак, дескриптори SURF, дескриптори ORB, релевантність описів, вектор характеристик класів, стійкість методу, швидкість розпізнавання.

Gorokhovatsky V. A.¹, Putyatin Y. P.², Stolyarov V. S.³

¹Dr. Sc., Professor, Department of Information Technology and Higher Mathematics, Kharkov Educational and Scientific Institute of Public Higher Education “University of Banking”, Kharkov, Ukraine

²Dr. Sc., Professor, Head of Department of Computer Science, National University of Radio Electronics Kharkov, Kharkov, Ukraine

³Student, Kharkiv National University of Radio Electronics, Kharkov, Ukraine

RESEARCH OF EFFECTIVENESS OF STRUCTURAL IMAGE CLASSIFICATION METHODS USING CLUSTER DATA MODEL

Context. Increasing of productivity and extension of the functionality of modern computer vision systems require more effective methods for visual information processing. Main goals of structural recognition are related with the improvement of information classification technology in the space of features in a form of image key point descriptors, as well as the necessity of recognition performance estimation for application datasets. Particular attention is related to the investigation of data structure for the set of descriptors that directly affects the functioning of the recognition system.

Objective. Investigation of cluster representation for the set of structural features of application dataset was performed as well as the evaluation of cluster model performance in methods of visual objects structural recognition to provide compact representation of data was proposed.

Method. Methods of recognition based on transformation of structural features space by clustering and usage of cluster dataset image features were proposed. First method uses the integral representation of etalon images descriptions, the second one is based on the value of statistical distribution vector in matrix space cluster model during building the association between structural element and class. Result of research is creation of recognition methods and data models during construction of relevance vectors and features of classes in the transformed feature space.

Results. Using cluster transformation of the space of structural features allows to reduce the amount of computational costs, and improves recognition performance preserving desired efficiency in a hundred of times. Comparison between SURF and ORB methods for the formation of structural features was performed, processing time by ORB has appeared to be 60 times less. On the other hand, the set of SURF descriptors closely reflects the shape of visual objects.

Modeling and experimental investigations of proposed recognition method for application dataset was performed. Effectiveness of the method in terms of efficiency was confirmed, comparative estimations of recognition quality depending on the level of additive noise for the analyzed treatment options were obtained.

Conclusions. Paper proposed the systematization and obtaining of perspective properties of recognition systems in the space of structural features of images. Classification methods based on cluster descriptions provide a sufficient level of image discrimination and high noise immunity.

Scientific novelty of the research consists of synthesis of a method of structural image recognition based on the use of cluster processing and the construction of classification decisions in space of etalon cluster. Conversion to the vector-cluster presentation allows to significantly increase the speed of recognition by processing simplification.

Practical value of paper is the obtaining of application program models for the modifications of structural image recognition method with the confirmation of the effectiveness and noise immunity of the proposed approach in a specific image dataset.

Keywords: computer vision, structural image recognition, set of structural features, SURF descriptors, ORB descriptors, relevance of descriptions, vector of characteristics of classes, noise immunity, recognition performance.

REFERENCES

1. Gorohovatskij V. A. Strukturnyj analiz i intellektual'naja obrabotka dannyh v komp'yuternom zrenii. H. Kompanija SMIT, 2014, 316 p.
2. Gorohovatskij V. A., Dunaevskaja M. D., Strunenکو V. A. Izuchenie svojstv metodov klasterizacii primenitel'no k mnozhestvam harakternyh priznakov izobrazhenij, *Sistemi obrobki informacii*, 2016, Vip. 5 (142), pp. 124–127.
3. Bay H., Tuytelaars T., Van L. Gool Surf: Speeded up robust features, *Computer Vision : Ninth European Conference on Computer Vision, Graz, 7–13 May, 2006: proceedings*. Berlin, Springer, 2006, pp. 404–417.
4. Gorokhovatsky V. A. Efficient Estimation of Visual Object Relevance during Recognition through their Vector Descriptions, *Telecommunications and Radio Engineering*, 2016, Vol. 75, No. 14, pp. 1271–1283.
5. Rublee E., Rabaud V., Konolige K., Bradski G. ORB: an efficient alternative to SIFT or SURF, *IEEE International Conference on Computer Vision (ICCV), November 06G.13, 2011*, pp. 2564–2571. Rezhim dostupa http://www.willowgarage.com/sites/default/files/orb_final.pdf
6. Gorohovatskij V. A., Gorohovatskij A. V., Berestovskij A. E. Strukturnoe raspoznavanie izobrazhenij s primeneniem modelej intellektual'noj obrabotki i samoorganizacii priznakov, *Radio Electronics, Computer Science, Control*, 2016, No. 3 (38), pp. 39–46.
7. Karami E., Prasad S., Shehata M. Image Matching Using SIFT, SURF, BRIEF and ORB: Performance Comparison for Distorted Images. Rezhim dostupa <https://www.researchgate.net/publication/292157133>
8. Szeliski R. Computer Vision: Algorithms and Applications. London, Springer, 2010, 979 p.
9. Duda R. O., Hart P. E., Stork D. G. Pattern classification, 2ed. Wiley, 2000, 738 p.
10. Manning C. D., Raghavan P., Schütze H. Introduction to Information Retrieval, Cambridge, University Press, 2008, 528 p.
11. Shapiro L. and Stockman G. Computer vision. Prentice Hall, 2001, 625 p.