

С. С. Касаткин, аспирант, antimaterialny@rambler.ru,

В. Т. Калайда, д-р техн. наук, проф., kvt@ioa.ru,

Национальный исследовательский Томский государственный университет, Томск

Метод и реализация системы формализации описания класса изображений методами непараметрической статистики

Рассматривается задача формализации описания класса изображений лица человека. Исследования направлены на поиск методов, повышающих точность описания для задач распознавания. Кратко рассматриваются существующие методы описания. Предлагается методика, позволяющая уменьшить суммарные ошибки первого и второго рода при описании классов изображений на основе функции плотности вероятности.

Ключевые слова: формализованное описание, класс изображений, непараметрическая статистика, коэффициент размытия, метод Нелдера—Мида, математическое программирование

Введение

Системы распознавания лиц представляют собой цифровые программы для автоматической идентификации или верификации человека с сигнала, представленного цифровым изображением или видеопотоком. Поскольку среда и используемые средства регистрации вносят искажения в сигнал, то изображение можно рассматривать как случайное поле. Под классом будем понимать множество реализаций одного и того же образа. Примером являются изображения одного человека, полученные в различных условиях (освещение, ракурс наблюдения, мимика и пр.).

Аппаратные искажения сигнала могут быть компенсированы за счет использования в качестве формализованного описания вектора параметров (например, моментов), инвариантных к аффинным искажениям [1–3]. Однако ошибки, обусловленные средой передачи сигнала, компенсировать сложнее. Для описания класса в этом случае удобно использовать плотность вероятности распределения параметров вектора, описывающего элемент класса [4–6].

Так как в прикладных системах видеонаблюдения и контроля проблематично получить "достаточное" число наблюдений и сложно априори сделать предположение о виде функции плотно-

сти вероятности, то для ее восстановления целесообразно использовать непараметрическую форму представления [4–10]. Данный подход не использует явно гипотезу о виде функции распределения. Еще одним преимуществом непараметрического подхода является наличие в таких функциях плотности вероятности свободных параметров (параметров размытия), изменением которых можно регулировать меру приближения к сформулированным требованиям (повышение точности описания) [4–7].

Сжатое описание некоторых методов формализованного описания класса можно найти в работах [11, 12]. Описание методов описания изображений представлено в работах [13–21].

Исходя из вышесказанного, для описания класса изображений целесообразно использовать методы непараметрической статистики. В качестве меры точности описания будем использовать суммарные ошибки первого и второго рода.

1. Формализация описания класса

Формализацию описания изображений предлагается решать на базе понятия *класса изображений* (образов) — множества изображений лиц одного и того же человека, полу-

ченных при различных условиях съемки (угол, мимика, освещение и пр.).

Описание класса образов может быть выполнено на основе следующих методов:

- 1) k -ближайших соседей [11, 12];
- 2) разделяющей гиперповерхности [11, 12];
- 3) опорной гиперповерхности [11, 12];
- 4) с использованием функции плотности вероятности [10, 12].

Подходы на основе метода *ближайших соседей* определяют метрики, по которым векторы характеристик сравниваются один к одному, т. е. для каждого изображения из исходной обучающей базы, представленного в виде вектора характеристик, заранее заданной метрикой определяется "мера близости" с вектором характеристик распознаваемого изображения. Основным недостатком методов данного подхода заключен в самой идее. При реализации методов данной группы необходимо хранить информацию о каждом экземпляре каждого класса, с которым будет происходить сравнение, на каждом этапе процесса распознавания. Таким образом, методы k -ближайших соседей являются затратными с точки зрения ресурсов обрабатывающей системы [11]. В зависимости от способа реализации это могут быть как затраты оперативной памяти, так и затраты, связанные со сложностью алгоритма в целом за счет необходимости считывать каждый образ из удаленного хранилища. При попытке уменьшить объем хранимой информации путем удаления непрезентабельных векторов или выделения некоторого числа наиболее значимых встает нетривиальная задача анализа многомерных данных и выделения наиболее существенных [11]. Данный метод в общем виде представлен в работе [15]. В работе [12] приведены такие методы, как метод дробящихся эталонов, метод ближайших соседей, правило ближайшего соседа. В работе [20] представлен основной недостаток данного подхода в виде трудоемкости сравнения образов один к одному. В работе [22] в качестве меры близости рассматривается угол между двумя векторами. Классификатор по ближайшему среднему представлен в работе [23]. Другие примеры эталонных векторов и классификаторов на основе меры близости могут быть найдены в работах [24–31].

Метод разделяющей гиперповерхности основывается на переводе исходных векторов

в пространство более высокой размерности и поиске границы с максимальным "зазором" в этом пространстве. Таким образом, например в одномерном случае, по обеим сторонам гиперплоскости строятся две параллельных гиперплоскости, отделяющие класс и определяющие его область определения. Недостаток методов данной группы состоит в том, что они не гарантируют непересечения различных классов. В связи с этим в пространстве признаков возникают зоны, в которых трудно принять решение о принадлежности к конкретному классу и сложности поиска оптимальных разделяющих гиперповерхностей. Теоретические основы метода разделяющей гиперповерхности рассматриваются в работе [32] на примере линейных и квадратичных разделяющих поверхностей.

Метод опорной гиперповерхности основан на использовании минимально отклоняющейся от множества векторов, описывающих образы одного класса, кривой в пространстве признаков. Наиболее часто применяемым методом данной группы является метод минимальных квадратов. При реализации метода в реальных системах идентификации необходимо решить следующие две задачи: оценить порядок полинома опорной гиперповерхности, выделить существенные переменные полинома. Поскольку вклад каждого одночлена полинома будет различен, то необходимо выделить группу одночленов, вносящих наибольший вклад в дисперсию, исключив из полинома остальные. Методы опорной гиперповерхности нацелены на максимизацию отклика на образы своего класса, но никак не минимизируют отклик на элементы других. Кроме того, сложность методов данной группы значительно выше методов разделяющей гиперповерхности.

Метод с использованием функции плотности вероятности позволяет наиболее полно описать класс образов, представленный набором векторов случайных величин. Основная идея заключается в предположении, что опорная гиперповерхность есть аппроксимация лишь участка плотности вероятности векторов, описывающих изображения класса. Кроме того, методы данной группы позволяют решать основные проблемы предыдущих подходов. Функция плотности вероятности позволяет реализовать сравнение один ко многим, когда идентифицируемый образ проходит верификацию не с каждым изображением из каждого класса, но

определяется метрика, позволяющая рассчитать "меру близости" распознаваемого образа с каждым классом, представленным в обучающей выборке целиком (например, метрика максимального правдоподобия). При этом класс рассматривается как единая сущность. Данный метод позволяет статистически обоснованно подойти к определению класса, к которому принадлежит идентифицируемый объект в зонах неопределенности, а также минимизировать эту область и отклик на элементы другого класса за счет уменьшения суммарных ошибок первого и второго рода. Достаточно прост в реализации. Функция плотности вероятности на основе метода потенциальной функции представлена в работе [12]. В работе [26] данный подход представлен байесовским классификатором. Наивный байесовский классификатор рассматривается в работе [32]. Также данный подход рассматривается в источниках [31–35]. В работе [28] рассмотрен байесовский линейный классификатор. Другие исследования байесовского классификатора могут быть найдены в работах [23, 31, 34, 35, 37, 39, 44, 46–51].

Стоит отметить значительные достижения в задачах распознавания образов, полученные при использовании методов вычислительных (нейронных) сетей. Исследование и примеры применения нейронных сетей представлены в работах [24, 25, 31, 41–45]. Вычислительные сети не требуют предварительной подготовки изображений, самостоятельно редуцируют пространство признаков, позволяя хранить в памяти не информацию об изображениях, а только саму структуру сети [40].

Вместе с тем в настоящее время работа с методами данной группы сопряжена с рядом нерешенных проблем (не формализован этап выбора архитектуры, что по вычислительным затратам сопоставимо с методом перебора, высокая требовательность к ресурсам исполняющей системы, переобучение, неинтерпретируемость результатов и, как следствие, непредсказуемость работы на реальных данных после этапа обучения), и попытки решения задач распознавания методами данной группы будут упираться в попытки решить проблемы вычислительных сетей, что не является частью задачи, решаемой в данной работе.

На основании вышесказанного можно сделать вывод о том, что наиболее перспективными методами в задачах распознавания образов

являются методы на основе использования функции плотности вероятности. На первом этапе для применения методов данной группы необходимо получить устойчивое к проективным и аффинным преобразованиям описание отдельного изображения.

2. Получение инвариантных характеристик

Выбор эффективных признаков — одна из базовых задач теории распознавания. Универсального решения, определяющего порядок отыскания оптимальных характеристик для описания изображения, до сих пор не найдено. Основным способом описания остается автоматизированный выбор признаков из некоторого заранее заданного на основе эвристических множества свойств. От результатов решения этой задачи зависят процент ошибок на каждом этапе распознавания изображения, быстрота обработки и объем затрачиваемой при расчетах памяти. Основными требованиями к признакам являются:

- 1) информативность;
- 2) небольшой объем вычислений;
- 3) помехоустойчивость;
- 4) инвариантность к аффинным преобразованиям;
- 5) реализуемость.

В источнике [13] рассмотрены такие методы, как метод гибкого графа, нейронные сети, скрытые марковские модели, метод главных компонент, активные модели внешнего вида, их плюсы и минусы, а также основные проблемы при распознавании лиц людей. Выделяются два основных подхода к описанию изображений и уменьшению пространства признаков — структурный и статический [9]. Структурный подход сводится к описанию образа через выделение и описание отношений тех или иных элементов на изображении. Может быть подразделен на фрактальный, геометрический, структурный и модельный подходы.

Фрактальный при анализе вычисляет фрактальные характеристики. Подход рассмотрен в работе [14] на примере задачи распознавания дорожных знаков в видеопотоке. Обзор по фрактальному подходу к описанию текстур проведен в работе [19].

Геометрический подход воспринимает изображение как составленное из элементарных примитивов. Представлен в работах [15–17].

Структурный подход предполагает, что изображение состоит из простых и почти регулярно повторяющихся текстурных примитивов. В работах [15, 36] этот подход рассмотрен на примере эластичных графов. Подход рассмотрен также в работе [38]. Обнаружение и идентификация объектов на основе их структурных описаний представлены в источнике [18]. Обзор по структурному подходу к описанию текстур проведен в работе [19].

Модельный подход сводится к построению некоторой модели, описывающей реальный объект. В источнике [15] подход рассмотрен на примере гибких контурных моделей, в работе [20] представлен классификатор с сильной вариабельностью формы на базе полиномиальной и марковской моделей контура.

Статистический подход трактует изображение как реализации некоторого случайного процесса. Примерами статистического подхода при формализации описания изображения являются вычисление углового момента, алгебраических моментов, контрастности, энтропии, корреляции и ряд других. Главным недостатком всех структурных методов является высокая сложность структуры, описывающей исходный образ, и необходимость в выработке специализированных методик сравнения, тогда как статистический подход позволяет представлять описание изображения в виде вектора случайных величин и применять широкий набор статистических методик. Обзор по статистическому подходу к описанию текстур проведен в работе [19]. Статистический подход как общий подход и методы распознавания рассмотрены в работах [21, 38].

Во множестве современных работ, посвященных распознаванию, используется статистический подход, а именно интегральное описание изображений. К достоинствам такого описания относят: сравнительную простоту его получения, легкость наращивания ансамбля свойств, высокую помехозащищенность. Одними из наиболее перспективных методов интегрального описания являются методы на основе инвариантных алгебраических моментов на основе полиномов Цернике и Лежандра [1–3], главным достоинством которых, по сравнению с центральными моментами, является их инвариантность относительно аффинных преобразований.

Моменты Цернике принадлежат классу ортогональных моментов и используются, чтобы моменты соответствовали независимым характеристикам объекта в пространстве.

Для обеспечения инвариантности к сдвигу начало координат для вычисления устанавливается в точку "центра масс" изображения. Точка центра масс определяется по следующей формуле:

$$(x_c; y_c) = \left(\frac{m_{10}}{m_{00}}; \frac{m_{01}}{m_{00}} \right),$$

где m_{pq} — геометрические моменты:

$$m_{pq} = \iint x^p y^q f(x, y) dx dy.$$

Величину m_{00} можно интерпретировать как полную "массу" изображения.

Моменты Цернике ZM_{nm} , определенные на единичном круге $0 \leq \sqrt{x^2 + y^2} \leq 1$, вычисляются по формуле для дискретного случая:

$$ZM_{nm} = \frac{n+1}{\pi} \sum_{x=0}^N \sum_{y=0}^M f(x, y) [V_{nm}(x, y)]^*;$$

$$V_{nm} = Z_{nm}(x, y) \exp\left(i \cdot \arctg\left(\frac{y}{x}\right)\right);$$

$$Z_{nm}(x, y) = \sum_{k=0}^{\frac{n-m}{2}} (-1)^k \times$$

$$\times \frac{(n-k)!}{k! \left(\frac{n+m}{2} - k\right)! \left(\frac{n-m}{2} - k\right)!} (x^2 + y^2)^{\frac{n-2k}{2}},$$

где n — порядок момента; m — порядок гармоники; $n \in N^+$, $|m| \leq n$, $(n - |m|)$ четное, символом * обозначается комплексное сопряжение; ZM_{nm} — комплексные моменты Цернике; Z_{nm} — полиномы Цернике; V_{nm} — базисные функции, по которым происходит разложение изображения.

Модули векторов моментов Цернике инвариантны к повороту:

$$|ZM_{nm}^{ROTATED}| = |ZM_{nm}|.$$

Векторы признаков Цернике порядка N формируются согласно формуле

$$ZMI_N = \left(\frac{|ZM_{11}|}{m_{00}}, \frac{|ZM_{20}|}{m_{00}}, \frac{|ZM_{22}|}{m_{00}}, \dots, \frac{|ZM_{NN}|}{m_{00}} \right)^T.$$

Каждая компонента вектора признаков делится на массу изображения m_{00} , которая пропорциональна его размеру и обеспечивает инвариантность объекта к изменению масштаба.

Таким образом, с помощью инвариантных моментов Цернике может быть получен набор характеристик, пригодных для инвариантного относительно аффинных преобразований описания одиночного изображения.

3. Восстановление функции плотности вероятности

Поскольку применение методов на основе функции распределения требует наличия априорной функции распределения, далее необходимо определиться с методом восстановления функции плотности вероятности.

В настоящее время существуют два направления методов восстановления функции плотности распределения случайной величины по эмпирическим данным. Кратко рассмотрим эти подходы.

1. *Параметрический подход* реализуется в случаях, когда вид распределения известен заранее и по обучающему набору необходимо сделать оценку значений этих параметров. Имеет несколько существенных недостатков, основными из которых являются следующие:

- делается предположение о виде распределения неизвестной случайной величины;
- параметрические методы являются усредняющими по выборке случайных величин.

2. *Непараметрический подход* не использует явно гипотезу о виде распределения, элементы выборки считаются независимыми случайными величинами с одинаковым распределением [4].

Для выбора наиболее оптимального с точки зрения точности описания метода восстановления функции был проведен эксперимент по восстановлению плотности вероятности параметрическим и непараметрическим методами. Генерировалась выборка, распределенная по нормальному закону. Далее оценивались параметры параметрического распределения и непараметрического метода Парзена—Розенблатта. Затем критерием Пирсона оценивалось соответствие восстановленных функций гистограмме, построенной по исходным данным. На основании тестирования выявлено, что нормированное значение критерия Пирсона для

параметрически восстановленной функции в среднем на 20 % хуже, чем для функции, восстановленной методом Парзена—Розенблатта.

Для формализованного описания класса плотностью вероятности в байесовские функции подставим непараметрические оценки Розенблатта—Парзена:

$$\bar{p}(x) = \frac{1}{Mc} \sum_{i=1}^M \Phi\left(\frac{x - x^i}{c}\right),$$

где Φ — ядро (четная, нормированная функция); c — коэффициент размытости; M — число наблюдений (число изображений).

Из байесовской решающей функции следует, что исследуемый образ принадлежит тому классу, плотность вероятности которого больше.

Параметрами данной модели является вектор коэффициентов размытия для функций плотностей вероятностей. Тогда задача построения решающего правила сводится к оцениванию $N \times D$ параметров, где N — число классов; D — размерность пространства признаков.

В современных работах для упрощения задачи оптимизации принимается, что коэффициент размытия представляется в виде произведения некоторого общего коэффициента и оценок среднеквадратических отклонений:

$$c_d = c\sigma_d, \quad d = \overline{1, D}.$$

Оценки среднеквадратических отклонений для каждого признака в классах можно записать следующим образом:

$$\sigma_d = \sqrt{\frac{1}{M-1} \sum_{i=1}^M \left(x_d^i - \frac{1}{M} \sum_{i=1}^M x_d^i\right)^2}, \quad d = \overline{1, D}.$$

Тогда непараметрические оценки плотности вероятности при синтезе решающего правила в многомерном пространстве примут вид:

$$p_t = \left(M \prod_{v=1}^D c_v\right)^{-1} \sum_{i=1}^M \prod_{v=1}^D \Phi\left(\frac{x_v - x_v^i}{c_v}\right), \quad t = \overline{1, N},$$

где d — индекс коэффициента размытия; N — число классов; M — число изображений для класса.

Таким образом, задача оптимизации непараметрического решающего правила сводится к поиску одного оптимального общего коэффициента. Подробно изложение метода можно найти в работе [10].

Однако принятие идеи, что коэффициенты размытия могут быть найдены через произведение общего коэффициента на соответствующие среднеквадратичные отклонения, предполагает, что исходная выборка репрезентативна, а также, что распределение параметров симметрично относительно общего коэффициента. К сожалению, в реальных задачах нельзя гарантировать, что эти утверждения верны. Таким образом, использование общего коэффициента размытия может привести к пересечениям функций плотности вероятностей, в то время как этого можно было бы избежать (или по крайней мере значительно снизить значения суммарных ошибок первого и второго рода), если использовать альтернативные методы поиска параметров оптимизируемой функции [4].

4. Оценка коэффициента размытия

Поскольку восстановленные плотности вероятности, в зависимости от выбранных ядерных функций (например, треугольная), могут иметь разрывы первого рода, необходимо использовать безградиентные методы, не вычисляющие производные (методы нулевого порядка), например методы: Хука — Дживса, Розенброка, Нелдера — Мида, Пауэлла.

Ни один из алгоритмов не оказался значительно лучше с точки зрения поиска минимума, выбор метода определяется конкретной задачей и опытом исследователя [52]. Метод Хука—Дживса в случае сильно вытянутых, изогнутых или обладающих острыми углами линий уровня целевой функции может оказаться неспособным обеспечить продвижение к точке минимума. Эффективность метода Розенброка зависит от выбора начальной точки поиска экстремума. Для метода Пауэлла так же, как предыдущих, число проб целевой функции линейно растет при увеличении размерности пространства, что негативно сказывается на эффективности при минимизации сложной целевой функции [52]. Метод Нелдера — Мида на каждой итерации алгоритма, как правило, один-два раза вычисляет значения функции, что чрезвычайно эффективно. В связи с этим для оценки коэффициентов размытия без потерь в точности целесообразно с точки зрения алгоритмической сложности использовать алгоритм Нелдера — Мида.

В качестве целевой функции используем суммарную ошибку первого и второго рода для

плотностей вероятностей, восстановленных непараметрическим методом:

$$\sum_{i=1}^{n-1} \sum_{j=1+1}^{n-1} (p_{i,j}^1(c) + p_{i,j}^2(c)) \rightarrow \min,$$

где n — число классов; $p_{i,j}^1(c)$ — ошибка первого рода для i и j классов; $p_{i,j}^2(c)$ — ошибка второго рода для i и j классов.

Для обеспечения непрерывности функций в области определения начальное значение коэффициента размытия установим равным половине максимального значения стандартной девиации для интервала:

$$c_d^0 = \max_j \left(\frac{\max_i (x_{i,d}^j - x_{i-1,d}^j)}{2\sigma_d^j} \right),$$

$$j = \overline{1, N}, i = \overline{2, M}, d = \overline{1, D},$$

где d — индекс коэффициента размытия; i — индекс изображения внутри класса; j — индекс класса; N — число классов; M — число изображений для класса; D — длина вектора коэффициентов размытия (размерность пространства признаков); σ_d^j — среднеквадратичное отклонение значений характеристик для класса с индексом j и коэффициентом размытия с индексом d .

Для обеспечения этого условия в целевую функцию вводится штраф $e(c)$:

$$\sum_{i=1}^{n-1} \sum_{j=1+1}^{n-1} (p_{i,j}^1(c) + p_{i,j}^2(c)) + e(c) \rightarrow \min;$$

$$e(c) = \begin{cases} 1, \exists (c_d - c_d^0 < 0), & d = \overline{1, D}, \\ 0, & \text{иначе;} \end{cases}$$

где c_d^0 — стартовое, минимальное значение коэффициента размытия; d — индекс коэффициента размытия.

5. Программная реализация

Формулировка задачи: для подготовленной базы изображений, где каждое изображение помечено группой, к которой оно принадлежит, необходимо найти такое описание, которое минимизирует суммарную ошибку первого и второго рода. В этом случае программная система должна реализовывать следующие функции:

1) расчет инвариантных характеристик (CID — calculate invariant description);

- 2) расчет коэффициентов размытия (СВС — calculate blur coefficients);
- 3) расчет суммарной ошибки первого и второго рода (СТЕ — calculate total error);
- 4) проверка критерия останова (ОС — out criteria).

Функция расчета вектора инвариантных характеристик (CID) применяет моменты Цернике для инвариантного относительно аффинных и проективных преобразований описания изображений в виде вектора характеристик. На вход подаются сгруппированные по принадлежности к классу изображения. Выход данной функции — набор векторов инвариантных характеристик, описывающих изображение, сгруппированных по принадлежности к классу. Выход данной функции подается на вход функции расчета коэффициентов размытия.

Функция расчета коэффициентов размытия по формуле для c_d^0 рассчитывает стартовое значение первой стартовой точки для симплекса. Все остальные находятся путем смещения на заданный шаг найденной ранее точки по одной не смещенной ранее координате. Смещение происходит строго в положительную сторону. Выходом функции будет упорядоченный набор векторов коэффициентов размытия, соответствующий порядку классов изображений.

Главной функцией является расчет суммарных ошибок первого и второго рода. Входом функции будут наборы изображений, сгруппированные по принадлежности к классу распознаваемых образов, а также наборы векторов коэффициентов размытия. На выходе получим

минимальную достигнутую суммарную ошибку первого и второго рода для заданных классов изображений и коэффициентов размытия. Выход функции поступает в функцию проверки критерия останова.

Проверка критерия останова сводится к сравнению суммарной ошибки первого и второго рода с заданным минимальным значением. Если условия выполнены, то результат достигнут. В противном случае деформируется симплекс, состоящий из векторов коэффициентов размытия и подается в функцию СТЕ.

Диаграмма деятельности в нотации UML для программной реализации на основе выделенных функций представлена на рисунке.

6. Результаты расчетов

В задаче описания массива изображений в качестве векторного описания изображения используются девять инвариантных моментов Цернике:

$$\{m_{1,1}, m_{2,0}, m_{2,2}, m_{3,3}, m_{4,0}, m_{4,2}, m_{4,4}, m_{6,0}, m_{6,4}\}.$$

По полученным наборам векторов восстанавливалась функция плотности вероятности. При этом были использованы классический подход [9] и метод на основе оптимизации Нелдера—Мида. Для этих плотностей вероятностей оценивались суммарные ошибки первого и второго рода.

В качестве классов изображений были использованы:

1) CMU AMP face expression (13 классов изображений лиц людей по 75 полутоновых изображений разрешением 64×64 каждая. Общее число изображений равно 975);

2) Georgia Tech face (50 классов изображений лиц людей по 15 цветных изображений различного размера. Общее число изображений равно 750).

Результаты расчетов представлены в таблице.

Сравнение суммарных ошибок

Метод оценки	Суммарная ошибка	
	CMU AMP	Georgia Tech
Классический	$1,04 \cdot 10^{-9}$	0,023
Нелдера—Мида	$4,49 \cdot 10^{-10}$	0,009

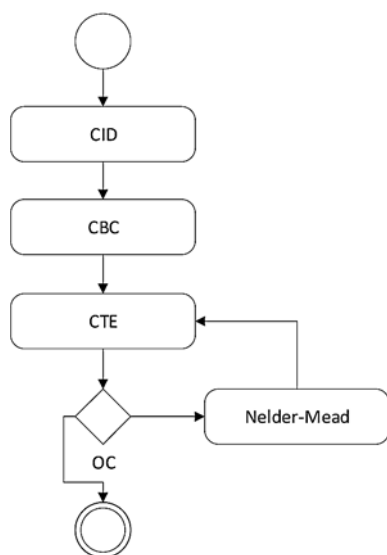


Диаграмма деятельности UML

Заключение

На основании представленных результатов расчетов можно сделать предположение о том, что оптимизация индивидуальных коэффициентов размытия методами нулевого порядка вместо оптимизации общего коэффициента размытия позволяет уменьшить суммарные ошибки первого и второго рода на порядок.

Список литературы

1. Касаткин С. С., Калайда В. Т. Программная система для вычисления формализованных характеристик полутонового изображения, не зависящих от условий съемки // Научная сессия ТУСУР—2014. Ч. 4. 2014. С. 47—49.
2. Тарбаев Б. Б., Калайда В. Т. Разработка алгоритма программной системы формализованного описания полутоновых изображений, инвариантных к аффинным преобразованиям // Матер. Всеросс. науч.-техн. конф. студентов, аспирантов и молодых ученых "Научная сессия ТУСУР—2014". Ч. 4. 2014. С. 52—45.
3. Abdul Kadir, Lukito Edi Nugroho, Adhi Susanto, P. Insap Santosa. Experiments of zernike moments for leaf identification // Journal of Theoretical and Applied Information Technology. 15 July 2012. Vol. 41, N. 1. P. 82—93.
4. Калайда В. Т., Тарбаев Б. Б., Касаткин С. С. Распознавание полутонового изображения лица на основе формализации описания класса непараметрическими статистиками // Мир науки и инноваций. 2016. Т. 10, № 1 (3). С. 44—56.
5. Касаткин С. С., Калайда В. Т. Идентификация полутонового изображения лица человека // Научная сессия ТУСУР—2015. Ч. 2. 13—15 мая 2015. С. 205—208.
6. Тарбаев Б. Б., Калайда В. Т. Вычисление формальных инвариантных признаков, описывающих изображение // Матер. Всеросс. науч.-техн. конф. студентов, аспирантов и молодых ученых "Научная сессия ТУСУР—2015. Ч. 2. 2015. С. 244—247.
7. Агеева Н. М., Антонов В. Н., Калайда В. Т. и др. Наука и инновации в современном мире: техника и технологии. В 3 книгах. Кн. 3. Одесса: Куприенко С. В., 2017. 157 с.
8. Касаткин С. С., Калайда В. Т. Анализ методов распознавания изображений // Наука и инновации в современном мире: техника и технологии. 2017. Т. 3. С. 110—116.
9. Kasatkin S. S. The methods of pattern recognition: A Review // АПР: Труды Международной молодежной научной школы. 25—26 сентября 2017. С. 128—131.
10. Лапко А. И., Лапко В. А. Непараметрические модели и алгоритмы обработки информации: учеб. пособие. Красноярск: Сиб. гос. аэрокосмич. ун-т, 2010. 220 с.
11. Калайда В. Т., Елизаров А. И. Метод опорной гиперповерхности для идентификации изображения лица человека // Вычислительные технологии. 2012. Т. 17, № 5. С. 65—70.
12. Волошин Г. Я. Методы распознавания образов (конспект лекций). URL: http://abc.vvsu.ru/Books/Metody_r/default.asp (дата обращения: 07.06.2018).
13. Анализ существующих подходов к распознаванию лиц. URL: <http://habrahabr.ru/company/synesis/blog/238129/> (дата обращения: 18.08.2018).
14. Минаев Е. Ю., Никоноров А. В. Детектирование и распознавание объектов в системах автомобильной безопасности на основе фрактального анализа // Компьютерная оптика. 2012. Т. 36, № 1. С. 124—130.

15. Выделение и распознавание лиц. б.д. URL: http://wiki.technicalvision.ru/index.php/выделение_и_распознавание_лиц (дата обращения: 18.08.2018).
16. Дуда Р., Харт П. Распознавание образов и анализ сцен. М.: МИР, 1976. С. 509.
17. Бутенков С. А. Обобщенные геометрические модели и многоуровневый анализ изображений в интеллектуальных системах // Известия Южного федерального университета. Технические науки. 2003. С. 21—28.
18. Визильтер Ю. В., Желтов С. Ю., Бондаренко А. В., Ососков М. В., Моржин А. В. Обработка и анализ изображений в задачах машинного зрения. М.: Физматкнига, 2010. 689 с.
19. Фисенко В. Т., Фисенко Т. Ю. Компьютерная обработка и распознавание изображений. Санкт-Петербург: ИТМО, 2008. 195 с.
20. Фурман Я. А., Юрьев А. Н., Яншин В. В. Цифровые методы обработки и распознавания бинарных изображений. Красноярск: Изд. Краснояр. ун-та, 1992. 248 с.
21. Лифшиц Ю. Статистические методы распознавания образов. Лекции. URL: <http://yury.name/modern/07modernnote.pdf> (дата обращения: 18.08.2018).
22. Немировский В. Б., Стоянов А. К. Распознавание нечетких дубликатов изображений, основанное на ранговом распределении мощностей кластеров яркости // Компьютерная оптика. 2014. Т. 38, № 4. С. 811—817.
23. Шапиро Л., Стокман Д. Компьютерное зрение. М.: Бином. Лаборатория знаний, 2013. 752 с.
24. Брилюк Д., Старовойтов В. Распознавание человека по изображению лица нейросетевыми методами. URL: <http://www.masters.donntu.org/2008/kita/baglikov/library/4.htm> (дата обращения: 18.08.2018).
25. Форсайт Д. А., Понс Ж. Компьютерное зрение. Современный подход. М.: Вильямс, 2004. 928 с.
26. Ту Дж., Гонсалес Р. Принципы распознавания образов. М.: Мир, 1978. 416 с.
27. Верхаген К., Дейн Р., Грун Ф. Распознавание образов: состояние и перспективы. М.: Радио и связь, 1985. 117 с.
28. Фукунага К. Введение в статистическую теорию распознавания образов. М.: Наука, 1979. 368 с.
29. Загоруйко Н. Г. Методы распознавания и их применение. М.: Книга по Требованию, 2012. 221 с.
30. Чанышев О. Г. Курс лекций "Введение в ИИ". Часть II. Распознавание образов. Лекция 13. Алгоритмы распознавания образов. URL: <http://deadbeef.narod.ru/work/docs/ai/11.pdf> (дата обращения: 18.08.2018).
31. Гонсалес Р., Вудс Р. Цифровая обработка изображений. М.: Техносфера, 2012. 1104 с.
32. Воронцов К. В. Лекции по статистическим (байесовским) алгоритмам классификации. Лекции URL: <http://www.ccas.ru/voron/download/Bayes.pdf> (дата обращения: 18.08.2018).
33. Мокеев В. В., Томилов С. В. О решении задачи распознавания изображений методом главных компонент и линейным дискриминантным анализом // Компьютерная оптика. 2014. Т. 38, № 4. С. 871—880.
34. Вапник В. Н., Червоненкис А. Я. Теория распознавания образов (статистические проблемы обучения). М.: Наука, 1974. 416 с.
35. Волошин Г. Я., Бурлаков И. А., Косенкова С. Т. Статистические методы решения задач распознавания, основанные на аппроксимационном подходе. Владивосток: Изд. Тихоокеан. океанол. ин-т. ДВО РАН, 1992. С. 260—270.
36. Фу К. Структурные методы в распознавании образов. М.: МИР, 1977. 20 с.
37. Апраушева Н. Н., Сорокин С. В. Заметки о гауссовых смесях. М.: ВЦРАН, 2015. 145 с.

38. Харалик Р. М. Статистический и структурный подходы к описанию текстур // ТИИЭР. 1979. Т. 67, № 5.
39. Патрик Э. А. Основы теории распознавания образов. М.: Советское радио, 1980. 407 с.
40. Болотова Ю. А., Спицын В. Г., Рудометкина М. Н. Распознавание автомобильных номеров на основе метода связанных компонент и иерархической временной сети // Компьютерная оптика. 2015. Т. 39, № 2. С. 275—280.
41. Лукьяница А. А., Шишкин А. Г. Цифровая обработка видеозображений. М.: Ай-Эс-Эс Пресс, 2009. 518 с.
42. Савченко А. В. Распознавание изображений на основе вероятностной нейронной сети с проверкой однородности // Компьютерная оптика. 2013. Т. 37, № 2. С. 254—262.
43. Кирюшина А. Е. Распознавание математических символов с использованием сверточной нейронной сети // Наукоемкие информационные технологии. 2013. С. 5.
44. Местецкий Л. М. Математические методы распознавания образов. Курс лекций. М.: Изд. МГУ, 2004. 85 с.
45. Солдатова О. П., Гаршин А. А. Применение сверточной нейронной сети для распознавания рукописных цифр // Компьютерная оптика. 2010. Т. 34, № 2. С. 252—259.
46. Грешилов А. А. Математические методы принятия решений. М.: МГТУ, 2014. 647 с.
47. Кузнецов А. В., Мясников В. В. Сравнение алгоритмов управляемой поэлементной классификации гиперспектральных изображений // Компьютерная оптика. 2014. Т. 38, № 3. С. 494—502.
48. Савченко А. В. Выбор параметров алгоритма распознавания изображений на основе коллектива решающих правил и принципа максимума апостериорной вероятности // Компьютерная оптика. 2012. Т. 36, № 1. С. 116—123.
49. Горелик А., Скрипкин В. Методы распознавания. М.: Высшая школа, 1984. 208 с.
50. Лапко А. И., Лапко В. А. Регрессионная оценка плотности вероятности и ее применение // XII всероссийское совещание по проблемам управления ВСПУ. 2014. С. 1101—1107.
51. Соيفер В. А. Методы компьютерной обработки изображений. М.: Физматлит, 2003. 784 с.
52. Хмельблау Д. Прикладное нелинейное программирование. М.: Мир, 1975. 536 с.

S. S. Kasatkin, Postgraduate Student, e-mail: antimaterialny@rambler.ru,
V. T. Kalajda, D. Sc., Professor, e-mail: kvt@ioa.ru,
National Research Tomsk State University, Tomsk, Russian Federation

Method and Implementation of the Formalization System for Describing the Class of Images using Nonparametric Statistics

The paper deals with the task of formalizing the description of a class of images of a person's face. The research is aimed at finding methods that increase the accuracy of the description for recognition problems. The existing methods of description are briefly considered, such as nearest neighbor methods, separating hypersurface methods, support hypersurface methods, and probability density function methods. A technique is proposed that makes it possible to reduce the total errors of the first and second kind when describing image classes based on the probability density function. The problem of reconstructing the probability density function is also considered. Based on the experiments carried out, the advantage of the nonparametric Rosenblatt—Parzen method was revealed in comparison with the parametric approach, and a decision was made to apply this method to restore the density function based on experimental data. The recovery of probability density functions based on the Rosenblatt—Parzen method is interrelated with the search for a vector of optimal blur coefficients for each function. To solve this problem, it was proposed to use the gradientless Nelder—Mead method known as the simplex method. As a result:

1) *The description of the realization of the method of formalized description of the image class based on the reconstruction of the probability density function based on experimental data with the help of the non-parametric Nelder—Mead method was proposed*

2) *Testing of this method was performed in comparison with the classical parametric reconstruction of the probability density function and the advantage of the proposed approach was revealed.*

Keywords: *formalized description, image class, nonparametric statistics, blur coefficient, Nelder—Mead method, mathematical programming*

DOI: 10.17587/it.25.86-96

References

1. Kasatkin S. S., Kalajda V. T. *Programmная система для вычисления formalizovannykh характеристик полутонного изображения, не зависящих от условий съемки* (A software system for calculating the formalized characteristics of a halftone image independent of the shooting conditions), *Nauchnaja sessija TUSUR*, 2014, Part 4, pp. 47—49 (in Russian).

2. Tarbaev B. B., Kalajda V. T. *Razrabotka algoritma programmnoj sistemy formalizovannogo opisaniya polutonovykh*

izobrazhenij, invariantnykh k affinnym preobrazovanijam (Development of an algorithm for a software system for the formalized description of halftone images that are invariant to affine transformations), *Materijaly Vserossijskoj nauchno-tehnicheskoi konferencii studentov, aspirantov i molodykh uchenykh "Nauchnaja sessija TUSUR—2014"*, Part 4, 2014, pp. 52—45 (in Russian).

3. Abdul Kadir, Lukito Edi Nugroho, Adhi Susanto, P. Insap Santosa. Experiments of zernike moments for leaf identification, *Journal of Theoretical and Applied Information Technology*, 15 July 2012, vol. 41, no. 1, pp. 82—93.

4. Kalajda V. T., Tarbaev B. B., Kasatkin S. S. *Raspoznavanie polutonovogo izobrazhenija lica na osnove formalizacii opisaniya klassa neparametricheskimi statistikami* (Recognition of a halftone image of a person on the basis of formalization of a class description by non-parametric statisticians), *Mir Nauki i Innovacij*, 2016, part 10, no. 1 (3), pp. 44–56 (in Russian).
5. Kasatkin S. S., Kalajda V. T. *Identifikacija polutonovogo izobrazhenija lica cheloveka* (Identification of a halftone image of a person's face), *Nauchnaja sessija TUSUR—2015*, part 2, 2015, pp. 205–208 (in Russian).
6. Tarbaev B. B., Kalajda V. T. *Vychislenie formal'nyh invariantnyh priznakov, opisyvajushhih izobrazhenie* (Calculation of formal invariant characteristics describing an image), *Materialy Vserossijskoj nauchno-tehnicheskoy konferencii studentov, aspirantov i molodyh uchenyh "Nauchnaja sessija TUSUR—2015"*, part 2, 2015, pp. 244–247 (in Russian).
7. Ageeva N. M., Antonov V. N., Kalajda V. T. et al. *Nauka i innovacii v sovremennom mire: tehnika i tehnologii* (Science and Innovations in the Modern World: Technology and Technology), Odessa, Kuprienko SV, 2017, 157 p. (in Russian).
8. Kasatkin S. S., Kalajda V. T. *Analiz metodov raspoznavanija izobrazhenij* (Analysis of image recognition methods), *Nauka i innovacii v sovremennom mire: tehnika i tehnologii*, 2017, part. 3, pp. 110–116 (in Russian).
9. Kasatkin S. S. The methods of pattern recognition: A Review, *Trudy Mezhdunarodnoj molodezhnoj nauchnoj shkoly*, 2017, pp. 128–131.
10. Lapko A. I., Lapko V. A. *Neparametricheskie modeli i algoritmy obrabotki informacii: ucheb. posobie* (Nonparametric models and algorithms for information processing), Krasnojarsk, Publishing house of Sib. gos. ajerokosmich. un-t, 2010, 220 p. (in Russian).
11. Kalajda V. T., Elizarov A. I. *Metod opornoj giperpoverhnosti dlja identifikacii izobrazhenija lica cheloveka* (Method of a reference hypersurface for identification of the image of a person's face), *Vychislitel'nye Tehnologii*, 2012, part. 17, no. 5, pp. 65–70 (in Russian).
12. Voloshin G. Ja. *Metody raspoznavanija obrazov* (Methods of pattern recognition), available at: http://abc.vvsu.ru/Books/Metody_r/default.asp (date of access: 07.06.2018) (in Russian).
13. *Analiz sushhestvujushhih podhodov k raspoznavaniju lic* (Analysis of existing approaches to face recognition), available at: <http://habrahabr.ru/company/synesis/blog/238129/> (date of access: 18.08.2018) (in Russian).
14. Minaev E. Ju., Nikonorov A. V. *Detektirovanie i raspoznavanie ob'ektov v sistemah avtomobil'noj bezopasnosti na osnove fraktal'nogo analiza* (Detection and recognition of objects in automotive safety systems based on fractal analysis), *Komp'yuternaja Optika*, 2012, vol. 36, no. 1, pp. 124–130 (in Russian).
15. *Vydelenie i raspoznavanie lic. b.d.* (Isolation and facial recognition. b.d.), available at: http://wiki.technicalvision.ru/index.php/vydelenie_i_raspoznavanie_lic (date of access: 18.08.2018) (in Russian).
16. Duda R., Hart P. *Raspoznavanie obrazov i analiz scen* (Pattern Recognition and Scene Analysis), Moscow, MIR, 1976, 509 p. (in Russian).
17. Butenkov S. A. *Obobshhennye geometricheskie modeli i mnogourovnevnyj analiz izobrazhenij v intellektual'nyh sistemah* (Generalized geometric models and multi-level image analysis in intelligent systems), *Izvestija Juzhnogo federal'nogo universiteta. Tehnicheskie nauki*, 2003, pp. 21–28 (in Russian).
18. Viziľter Ju. V., Zheltov S. Ju., Bondarenko A. V., Ososkov M. B., Mopzhin A. V. *Obrabotka i analiz izobrazhenij v zadachah mashinnogo zrenija* (Image processing and analysis in computer vision tasks), Moscow, Fizmatkniga, 2010, 689 p. (in Russian).
19. Fisenko V. T., Fisenko T. Ju. *Komp'yuternaja obrabotka i raspoznavanie izobrazhenij* (Computer processing and image recognition), Sankt-Peterburg, Publishing house of ITMO, 2008, 195 p. (in Russian).
20. Furman Ja. A., Jur'ev A. N., Janshin V. V. *Cifrovye metody obrabotki i raspoznavanija binarnyh izobrazhenij* (Digital methods of processing and recognition of binary images), Krasnojarsk, Publishing house of Krasnojarsk. un-t, 1992, 248 p. (in Russian).
21. Lifshic Ju. *Statisticheskie metody raspoznavanija obrazov. Lekcii* (Statistical methods of pattern recognition. Lectures), available at: <http://yury.name/modern/07modernnote.pdf> (date of access: 18.08.2018) (in Russian).
22. Nemirovskij V. B., Stojanov A. K. *Raspoznavanie nechjotkih dublikatov izobrazhenij, osnovannoe na rangovom raspredelenii moshhnoej klasterov jarkosti* (Recognition of fuzzy duplicate images based on the rank power distribution of brightness clusters), *Komp'yuternaja Optika*, 2014, vol. 38, no. 4, pp. 811–817 (in Russian).
23. Shapiro L., Stokman D. *Komp'yuternoe zrenie* (Computer vision), Moscow, Binom. Laboratorija znaniy, 2013, 752 p. (in Russian).
24. Briljuk D., Starovojtov V. *Raspoznavanie cheloveka po izobrazheniju lica nejrosetevymi metodami* (Recognition of a person by the image of a person using neural network methods), available at: <http://www.masters.donntu.org/2008/kita/baglikov/library/4.htm> (date of access: 18.08.2018) (in Russian).
25. Forsajt D. A., Pons Zh. *Komp'yuternoe zrenie. Sovremennyy podhod* (Computer vision. Modern approach), Moscow, Vil'jams, 2004, 928 p. (in Russian).
26. Tu Dzh., Gonsales R. *Principy raspoznavanija obrazov* (Principles of pattern recognition), Moscow, Mir, 1978, 416 p. (in Russian).
27. Verhagen K., Dejn R., Grun F. *Raspoznavanie obrazov: sostojanie i perspektivy* (Pattern Recognition: State and Prospects), Moscow, Radio i svjaz', 1985, 117 p. (in Russian).
28. Fukunaga K. *Vvedenie v statisticheskuyu teoriju raspoznavanija obrazov* (Introduction to statistical pattern recognition theory), Moscow, Nauka, 1979, 368 p. (in Russian).
29. Zagorujko N. G. *Metody raspoznavanija i ih primenenie* (Recognition methods and their application), Moscow, Kniga po Trebovaniju, 2012, 221 p. (in Russian).
30. Chanyshv O. G. *Kurs lekcij "Vvedenie v II.". Chast' II. Raspoznavanie obrazov Lekcija 13. Algoritmy raspoznavanija obrazov* (Course of lectures "Introduction to AI.". Part II. Pattern Recognition Lecture 13. Pattern Recognition Algorithms), available at: <http://deadbeef.narod.ru/work/docs/ai/11.pdf> (date of access: 18.08.2018) (in Russian).
31. Gonsales R., Vuds R. *Cifrovaja obrabotka izobrazhenij* (Digital image processing), Moscow, Tehnosfera, 2012, 1104 p. (in Russian).
32. Voroncov K. V. *Lekcii po statisticheskim (bajesovskim) algoritmam klassifikacii. Lekcii* (Lectures on statistical (Bayesian) classification algorithms. Lectures), available at: <http://www.ccas.ru/voron/download/Bayes.pdf> (date of access: 18.08.2018) (in Russian).
33. Mokeev V. V., Tomilov S. V. *O reshenii zadachi raspoznavanija izobrazhenij metodom glavnih komponent i linejnym diskriminantnym analizom* (On the solution of the problem of image recognition by the method of principal components and linear discriminant analysis), *Komp'yuternaja Optika*, 2014, vol. 38, no. 4, pp. 871–880 (in Russian).
34. Vapnik V. N., Chervonenkis A. Ja. *Teorija raspoznavanija obrazov (statisticheskie problemy obuchenija)* (Pattern Recognition Theory (Statistical Learning Problems)), Moscow, Nauka, 1974, 416 p. (in Russian).
35. Voloshin G. Ja., Burlakov I. A., Kosenkova S. T. *Statisticheskie metody reshenija zadach raspoznavanija, osnovannye na ap-proksimacionnom podhode* (Statistical methods for solving recognition problems based on the approximation approach), Vladivostok, Publishing house of Tihookean. okeanol. in-t DVO RAN, 1992, pp. 260–270 (in Russian).

36. **Fu K.** *Strukturnye metody v raspoznavanii obrazov* (Structural methods in pattern recognition), Moscow, MIR, 1977, 320 p. (in Russian).
37. **Aprausheva N. N., Sorokin S. V.** *Zametki o gaussovykh smesjah* (Notes on Gaussian Mixtures), Moscow, VCRAN, 2015, 145 p. (in Russian).
38. **Haralik R. M.** *Statisticheskij i strukturnyj podhody k opisaniju tekstur* (Statistical and structural approaches to the description of textures), *TIIIJeR*, 1979, vol. 67, no. 5 (in Russian).
39. **Patrik Je. A.** *Osnovy teorii raspoznavanija obrazov* (Basics of pattern recognition theory), Moscow, Sovetskoe radio, 1980, 407 p. (in Russian).
40. **Bolotova Ju. A., Spicyn V. G., Rudometkina M. N.** *Raspoznavanie avtomobil'nyh nomerov na osnove metoda svjaznyh komponent i ierarhicheskoj vremennoj seti* (Recognition of license plates based on the method of connected components and a hierarchical temporary network), *Komp'juternaja Optika*, 2015, vol. 39, no. 2, pp. 275–280 (in Russian).
41. **Luk'janica A. A., Shishkin A. G.** *Cifrovaja obrabotka videoizobrazhenij* (Digital video processing), Moscow, Aj-Jes-Jes Press, 2009, 518 p. (in Russian).
42. **Savchenko A. V.** *Raspoznavanie izobrazhenij na osnove verojatnostnoj neyronnoj seti s proverkoj odnorodnosti* (Image recognition based on a probabilistic neural network with uniformity testing), *Komp'juternaja Optika*, 2013, vol. 37, no. 2, pp. 254–262 (in Russian).
43. **Kirjushina A. E.** *Raspoznavanie matematicheskikh simvolov s ispol'zovaniem svertochnoj neyronnoj seti* (Recognition of mathematical symbols using a convolutional neural network), *Naukoemkie Informacionnye Tehnologii*, 2013, p. 5 (in Russian).
44. **Mesteckij L. M.** *Matematicheskie metody raspoznavanija obrazov. Kurs lekcij* (Mathematical methods of pattern recognition. Lecture course), Publishing house of MSU, 2004, 85 p. (in Russian).
45. **Soldatova O. P., Garshin A. A.** *Primenenie svertochnoj neyronnoj seti dlja raspoznavanija rukopisnyh cifr* (Application of convolutional neural network for handwriting recognition), *Komp'juternaja Optika*, 2010, vol. 34, no. 2, pp. 252–259 (in Russian).
46. **Greshilov A. A.** *Matematicheskie metody prinjatija reshenij* (Mathematical decision making methods), Moscow, Publishing house of MGTU, 2014, 647 p. (in Russian).
47. **Kuznecov A. V., Mjasnikov V. V.** *Sravnenie algoritmov upravljaemoj pojelementnoj klassifikacii giperspektral'nyh izobrazhenij* (Comparison of algorithms for controlled elementwise classification of hyperspectral images), *Komp'juternaja Optika*, 2014, vol. 38, no. 3, pp. 494–502 (in Russian).
48. **Savchenko A. V.** *Vybor parametrov algoritma raspoznavanija izobrazhenij na osnove kollektiva reshajushhih pravil i principa maksimuma aposteriornoj verojatnosti* (The choice of parameters of the image recognition algorithm based on a team of decision rules and the principle of maximum a posteriori probability), *Komp'juternaja Optika*, 2012, vol. 36, no. 1, pp. 116–123 (in Russian).
49. **Gorelik A., Skripkin V.** *Metody raspoznavanija* (Recognition methods), Moscow, Vysshaja shkola, 1984, 208 p. (in Russian).
50. **Lapko A. I., Lapko V. A.** *Regressionnaja ocenka plotnosti verojatnosti i ee primenenie* (Regression estimation of probability density and its application), *XII vserossijskoe soveshhanie po problemam upravlenija VSPU*, 2014, pp. 1101–1107 (in Russian).
51. **Sojfer V. A.** *Metody komp'juternoj obrabotki izobrazhenij* (Computer image processing methods), Moscow, Fizmatlit, 2003, 784 p. (in Russian).
52. **Himel'blaju D.** *Prikladnoe nelinejnoe programmirovanie* (Applied nonlinear programming), Moscow, Mir, 1975, 536 p. (in Russian).

V МЕЖДУНАРОДНАЯ КОНФЕРЕНЦИЯ И МОЛОДЕЖНАЯ ШКОЛА «ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ И НАНОТЕХНОЛОГИИ (ИТНТ—2019)»

С 21 по 24 мая 2019 года в Самаре на базе Самарского национального исследовательского университета имени академика С. П. Королева и Института систем обработки изображений РАН — филиала ФНИЦ «Кристаллография и фотоника» Российской Академии Наук состоится V Международная конференция и молодежная школа «Информационные технологии и нанотехнологии» (ИТНТ-2019).

Целью проведения **Конференции ИТНТ—2019** является предоставление возможности научных дискуссий и обсуждения результатов фундаментальных и прикладных исследований в области информационных технологий и нанотехнологий, привлечение молодежи в сферу передовых научных исследований, обмен опытом научно-образовательной деятельности при подготовке ИТНТ-специалистов.

Основные направления конференции

- **Секция 1** «Компьютерная оптика и нанофотоника» (дифракционная оптика и нанофотоника, оптика наноструктур, оптические информационные технологии)
- **Секция 2** «Обработка изображений и дистанционное зондирование Земли» (обработка и анализ сигналов и изображений, компьютерное зрение, распознавание зрительных образов, геоинформационные технологии, обработка и анализ данных дистанционного зондирования Земли)
- **Секция 3** «Математическое моделирование физико-технических процессов и систем»
- **Секция 4** «Науки о данных» (интеллектуальный анализ данных, «большие данные», машинное обучение, криптография, криптоанализ, суперкомпьютерные технологии).

Организаторы

Самарский национальный исследовательский университет имени академика С. П. Королева
Институт систем обработки изображений РАН — филиал ФНИЦ «Кристаллография и фотоника» РАН

Контакты

Ответственный секретарь: Козлова Елена Сергеевна, тел.: +7 (846) 332-57-87.

Веб-сайт конференции: itnt-conf.org.

Ответственный секретарь: secretary@itnt-conf.org.