

Обработка сигналов, информации и изображений

DOI 10.66032/2221-2574-2026-1-2-24-30

УДК 621.391

РАСПОЗНАВАНИЕ ИЗОБРАЖЕНИЙ В СИСТЕМАХ ТЕХНИЧЕСКОГО ЗРЕНИЯ НА БАЗЕ НЕЙРОННЫХ СЕТЕЙ И МЕТОДАМИ КОНТУРНОГО АНАЛИЗА

Охотников Сергей Аркадьевич

кандидат технических наук, доцент ФГБОУ ВО «Поволжский государственный технологический университет».

Григорьевых Елена Андреевна

кандидат технических наук, доцент ФГБОУ ВО «Поволжский государственный технологический университет».

Хамарицкая Олеся Алексеевна

студент ФГБОУ ВО «Поволжский государственный технологический университет».

Адрес: 424000, Российская Федерация, г. Йошкар-Ола, пл. Ленина, д. 3.

E-mail для связи: HamaritskayaOA@volgatech.net

Аннотация: Исследованы методы классификации контурных объектов изображений на примере тестовых синтезированных изображений с применением нейронных сетей и математического аппарата контурного анализа. Сгенерированы три набора данных по 6600 одноканальных изображений с размерностью 256x256 пикселей. Спроектирована и обучена свёрточная нейронная сеть распознавания полутоновых (одноканальных) изображений. С использованием нейронных сетей CNN и методов контурного анализа получены характеристики вероятности правильного распознавания от отношения сигнал/шум для аддитивной модели шума, распределённого по нормальному закону. Экспериментальные исследования показали, что методы контурного анализа позволяют классифицировать контурные изображения с различными линейными преобразованиями без ухудшения характеристик распознавания. В свою очередь, у свёрточной нейронной сети при распознавании изображений, совпадающих по форме с изображениями в обучающей выборке, но не участвующих в обучении, данные характеристики ухудшились.

Ключевые слова: контур, форма изображения, классификация, согласованный фильтр, нейронные сети, распознавание изображений.

Введение

Задача обнаружения и распознавания объектов интереса на отдельных изображениях и видеопоследовательностях остаётся актуальной. За последние годы количество приложений, где необходимо решать задачу распознавания, только возрастает. Среди приложений можно отметить задачи, решаемые в радиолокации [1, 2], медицине [3, 4], мониторинге земной поверхности [5], распознавания лиц, дорожных знаков [6, 7], распознавания речи [8] и др. Изначально, методы распознавания образов основывались на сопоставлении шаблонов, где входные данные сравнивались с сохранёнными изображениями из базы [10, 11]. Этот подход неизбежно приводит к повышению чувствительности алгоритмов к изменениям масштаба и угловой ориентации анализируемых изображений, а также к снижению производительности при обработке большого количества пикселей изображения.

Внедрение статистических методов в середине 20-го века заложило основу для более сложных методов классификации. Эти методы опирались на математические модели для классификации наблюдений на основе их признаков. При этом, долгое время основным оставался эмпирический подход конструирования признаков. С ростом сложности сцены такой подход резко теряет свою эффективность, требуя большого экспертного уровня обуча-

ющих. Эффективным решением при этом являются методы глубокого обучения и свёрточных нейронных сетей, которые выделяют существенные признаки автоматически на основе необработанных данных, без необходимости тщательного ручного конструирования [12, 13]. При этом, возможно как создание собственных, так и дообучение существующих архитектур нейронных сетей, показавших эффективность для решаемой задачи. Основным ограничением технологий нейронных сетей является большая вычислительная сложность, и рост доступных вычислительных мощностей в последние десятилетия дал значительный стимул в развитии алгоритмов на их основе.

Несмотря на это, существуют задачи, которые по-прежнему используют классические подходы, такие как алгоритмы машинного обучения и статистические методы. Эти методы, несмотря на эффективность нейронных сетей, имеют определённые преимущества. Так, обучение нейронных сетей обычно требует больших объёмов размеченных данных, что может быть существенным ограничением в ситуациях, где доступность данных для обучения ограничена.

Одним из методов распознавания визуальных образов является теория контурного анализа, рассматривающая контуры в качестве информативного признака объектов на изображениях. Такое пред-

ставление обладает инвариантностью к масштабированию, повороту и переносу, значительно уменьшая вычислительную нагрузку. В работе [14] представлен достаточно подробный анализ подходов и методов обнаружения объектов на изображении, как частного случая задачи распознавания изображений. Внимание уделено как подходам на основе математических моделей изображений и отношения правдоподобия, так и свёрточным нейронным сетям, направленным на решение задач распознавания и обнаружения. При этом, для обучения нейронных сетей используются уже не математические модели, а библиотеки реальных снимков. Анализ литературы показывает, что в настоящее время отсутствуют работы, в которых проводилось сравнение классических методов инвариантного распознавания форм с методами глубокого обучения и свёрточных нейронных сетей при решении задачи распознавания контурных изображений объектов, т. к. первый подход основан на математических моделях изображений и объектах интереса, а второй на подходах обучения алгоритмов обнаружения.

Целью работы является сравнение эффективности методов на базе контурного анализа и свёрточных нейронных сетей при распознавании объектов на изображении.

Распознавание изображений методами контурного анализа

Существуют разные способы математического представления контуров изображений, например, в виде цепного кода Фримена, представление полярным кодом, полигональное представление, в виде элементарных векторов, более подробно рассмотренные в работе [11]. В работе при комплекснозначном кодировании контур $\Gamma = \{\gamma(n)\}_{0,s-1}$ представлен в виде стандартных элементарных векторов (ЭВ) $\gamma(n) = \gamma_1(n) + i\gamma_2(n)$, $n = 0, 1, \dots, s-1$. Выделение контуров изображения основывается на исследовании градиента интенсивности цвета. Следует также отметить, что представление контура в виде комплекснозначного кода является инвариантным к линейным преобразованиям поворота и масштаба. В частности, показано, что между кодами исходного Γ и преобразованного путём растяжения в $|\mu|$ раз поворота на угол $\Delta\phi$ и сдвига начальной точки на d ЭВ $\Gamma_\mu^{(d)}$ контуров существует связь вида:

$$\Gamma_\mu^{(d)} = \{|\mu| \exp\{i\Delta\phi\}\gamma(n+d)\}_{0,s-1}.$$

В общем случае задача обнаружения контура Γ сходна с задачей обнаружения сигнала и состоит в следующем [14]. На вход обнаружителя поступает либо шумовой контур $N = Z$, либо зашумлённый контур $N = \Gamma_{(c)} + Z$, элементарные векторы которого характеризуется дисперсией σ^2 . Шумовой контур задаётся нормальным законом распределения с нулевым математическим ожида-

нием. Контур $\Gamma_{(c)}$ представляет собой сигнальный контур, полученный путём линейных преобразований растяжения эталонного контура Γ в $|\mu|$ раз, сдвигом начальной точки на d и поворота на угол $\Delta\phi$. Для принятия обоснованного решения о наличии на входе обнаружителя зашумлённого или шумового контура используется функция правдоподобия [11]

$$\Lambda(N, \Delta\phi, d, |\mu|) = c \exp \left\{ -\frac{1}{2\sigma^2} \|N\|^2 + |\mu|^2 \|\Gamma\|^2 - 2|\mu| \operatorname{Re}(N, \Gamma_{\Delta\phi, d}) \right\}.$$

На основе оценки максимального правдоподобия параметров μ , d , $\Delta\phi$ получим выражение для квадратного корня из логарифма отношения правдоподобия: $\ln L(N) = |\eta(d)|_{\max} / \sqrt{2}\sigma \|\Gamma\|$. Тогда правило обнаружения зашумлённого контура будет иметь вид $|\eta(d)|_{\max} > \sqrt{2}\sigma \|\Gamma\| \sqrt{\ln \Lambda_0} = U_{|\mu|}$. Таким образом, оптимальный обнаружитель формирует k отсчётов контурного согласованного фильтра (КСФ), находит их модули, выбирает максимальный по величине модуль и сравнивает его с порогом U .

На примере двух классов изображений контуров рассмотрим задачу распознавания зашумлённых контуров. Пусть контуры $\Gamma_{(1)} = \{\gamma_{(1)}(n)\}_{0,s-1}$ и $\Gamma_{(2)} = \{\gamma_{(2)}(n)\}_{0,s-1}$ – эталонные контуры соответственно двух классов. На устройство распознавания подается либо зашумлённый контур первого класса $N_{(1)} = \Gamma_{(1)} + Z$, либо второго класса $N_{(2)} = \Gamma_{(2)} + Z$, где Z – шумовой контур, заданный по нормальному закону распределения с нулевым математическим ожиданием. Необходимо обоснованно отнести зашумлённый контур N к одному из двух классов контуров.

В работе [11] показано, что для принятия решения необходимо сформировать безусловное отношение правдоподобия и сравнить его с пороговым значением. Функции правдоподобия контуров $N_{(1)}$ и $N_{(2)}$ имеют, соответственно, вид:

$$\Lambda_C(N) = c \exp \left\{ -\frac{1}{2\sigma^2} \left[\|N\|^2 + \|\Gamma_{(1)}\|^2 - 2\operatorname{Re}(N, \Gamma_{(1)}) \right] \right\},$$


$$\Lambda_C(N) = c \exp \left\{ -\frac{1}{2\sigma^2} \left[\|N\|^2 + \|\Gamma_{(2)}\|^2 - 2\operatorname{Re}(N, \Gamma_{(2)}) \right] \right\}.$$

Логарифм безусловного отношения правдоподобия будет иметь вид

$$\ln L(N) = -\frac{1}{2\sigma^2} \left\{ \|\Gamma_{(1)}\|^2 - \|\Gamma_{(2)}\|^2 - 2 \left[\operatorname{Re}(N, \Gamma_{(1)}) - \operatorname{Re}(N, \Gamma_{(2)}) \right] \right\}.$$

Правило принятия решения в пользу класса K_1 записывается как:

$$\operatorname{Re}(N, \Gamma_{(1)}) - \operatorname{Re}(N, \Gamma_{(2)}) \geq \sigma^2 \ln \Lambda_0 + 0,5 \left(\|\Gamma_{(1)}\|^2 - \|\Gamma_{(2)}\|^2 \right),$$



где Λ_0 — пороговое значение отношения правдоподобия. Таким образом, для принятия решения о классе распознаваемого контура необходимо сформировать разность реальных частей скалярных произведений распознаваемого контура $\mathbf{N}$ с каждым из эталонных контуров и сравнить её с пороговой величиной.

В общем случае количество эталонных изображений необходимых для распознавания больше двух. Соответственно, на вход распознающего устройства подаётся зашумлённый контур из некоторого алфавита объёмом M классов. В этом случае задача распознавания предусматривает многоканальную по числу классов процедуру. В каждом канале находится фильтр, согласованный с эталонным контуром соответствующего класса, и экстремальное устройство, вырабатывающее мгновенное значение с максимальным модулем. Далее отмечается канал, модуль мгновенного значения на выходе которого превышает модули выходных сигналов остальных каналов. Если величина максимального модуля больше порогового значения, то распознаваемый контур относится к классу, номер которого равен номеру канала.

Оценка эффективности контурной модели

Для решения задачи распознавания изображений зададим базу из трёх эталонных контуров $\Gamma_{(1)}$, $\Gamma_{(2)}$, $\Gamma_{(3)}$ (рис. 1). Для нахождения нормированного скалярного произведения все контурные изображения были приведены к одной размерности $N = 50$. Для выравнивания размерностей использовалась процедура эквализации [11].

Построен график зависимости вероятности правильного распознавания от отношения сигнал/шум (рис. 2) при последовательной подаче на вход системы распознавания зашумлённых контуров представленных на рис. 1 (при фиксированном пороге обнаружения $U = 0,9$). Графики получились почти одинаковыми, что связано с «псевдо-ортогональностью» заданных контуров.

При различных порогах обнаружения исследованы зависимости правильного распознавания. Эталонный контур представленный на рис. 1, а) подаётся на вход системы распознавания. Пороги обнаружения U зададим равными 0,5; 0,7; 0,9 соответственно. Графики зависимости вероятности правильного распознавания контура от отношения сигнал/шум приведены на рис. 3. Исходя из полученных графиков можно сделать вывод об ухудшении

характеристик правильного распознавания с увеличением порога обнаружения. Так, вероятность правильного распознавания $P_{np} = 0,8$ достигается при отношении сигнал/шум $q = 3$ и пороге обнаружения $U = 0,5$; $q = 5,5$, $U = 0,7$; и $q = 11$, $U = 0,9$ соответственно.

Исследовано влияние на характеристики вероятности правильного распознавания при подаче на вход системы распознавания контура с неизвестными параметрами растяжения и поворота контура. В качестве примера, на вход системы распознавания был подан контур (рис. 1, а), подвергнутый преобразованиям масштабирования $\mu = 2$ и поворота $\varphi = 127$ (рис. 4, а), и построены соответствующие зависимости (рис. 4, б).

Анализируя характеристики распознавания (рис. 3, рис. 4, б), можно сделать вывод, что изменение линейных параметров преобразования контурного изображения (поворот, масштабирование) не влияет на характеристики обнаружения.

Распознавание на базе свёрточных нейронных сетей

Проектирование нейронной сети распознавания изображений включает в себя несколько основных этапов [15]: подготовка набора данных, проектирование архитектуры сети и конфигурации слоёв, обучение и повышение точности.

Так как контурные сцены обычно представляют




Рис. 2. Вероятность правильного распознавания контуров от отношения сигнал/шум при пороге обнаружения $U = 0,9$







Рис. 3. Зависимости вероятности правильного распознавания контура от отношения сигнал/шум (рис. 1, а) при порогах обнаружения 0,5; 0,7 и 0,9



собой бинарные изображения, их распознавание представляет собой относительно несложную задачу. В связи с этим, в работе не используются стандартные архитектуры свёрточных сетей. Для обучения была спроектирована сеть CNN приведённая на рис. 5.

Простейшая CNN распознавания объектов на изображениях состоит из входного слоя, комбинации слоёв свёртки и прореживания, и выходного слоя. В работе была использована следующая конфигурация. Монохромное изображение размером 256×256 пикселей со входного слоя последовательно проходит чередующиеся слои 2D-свёртка + MaxPooling. Размеры окон свёртки — 3×3 для всех слоёв, окно субдискретизации — 2×2 . Далее, полученный массив признаков преобразуется в одномерный и классифицируется двумя полносвязными слоями с функциями активации ReLU и SoftMax соответственно, давая на выходе значения вероятности принадлежности изображения к определённому классу.

Оценка эффективности полученной конфигурации

Для решения задачи распознавания с помощью нейронной сети CNN (рис. 5) синтезировано три набора по 6600 изображений по каждой группе размерностью 256×256 пикселей. Из каждой группы случайным образом бралось 1000 изображений в качестве проверочной выборки (всего 3000 изображений). Изображения формировались путём растяжения и поворота на произвольные коэффициенты $\Delta\varphi$ и $|\mu|$. Примеры синтезированных контурных растровых изображений с одним каналом яркости представлены на рис. 6.




Рис. 7. Потери на этапе обучения и проверки нейронной сети CNN (рис. 5)




Рис. 8. Изображения с масштабом $\mu = 30$ и углом поворота $\varphi = 248$ подаваемые на вход нейронной сети: а — первая группа, б — вторая группа, в — третья группа

Произведено обучение нейронной сети CNN (рис. 5). После обучения получены значения функции потерь и точности обучения (рис. 7). По рисунку можно сделать вывод, что обучение сети завершилось на 4 эпохе. Это связано тем, что синтезированные изображения задавались одним каналом цвета и количество групп для обучения было небольшим и равнялось трём.

Для решения задачи классификации на вход нейронной сети подадим последовательно три изображения по одному из каждой группы (рис. 8).

Получены графики зависимости вероятности правильного распознавания изображений (рис. 8, а) от отношения сигнал/шум q при пороге обнаружения U равном 0,5; 0,7 и 0,9. Характеристики распознавания представлены на рис. 9. Так же построены зависимости вероятности правильного распознавания от отношения сигнал/шум (рис. 10) при пороге обнаружения $U = 0,9$ для первой, второй и третьей групп изображений (рис. 8, а–в). Анализ рис. 9, показывает, что для заданной вероятности правильного распознавания изменение порога обнаружения U ведёт к увеличению отношения сигнал/шум.

Исследованы зависимости вероятности правильного распознавания нейронной сети CNN, когда на её вход подавалось одно изображение, но с разными параметрами масштабирования и поворота (рис. 6, ж–и). Характеристики обнаружения представлены на рис. 11. Видим, что масштабный коэффициент очень сильно влияет на вероятность распознавания при заданном отношении сигнал/шум. Это связано с тем, что энергия изображения с большим масштабом выше, что ведёт ухудшению распознавания.

Получены зависимости правильного распознавания от отношения сигнал/шум нейронной сети CNN при подаче на вход контурных растровых изображений, которые не входили в обучающую

выборку. Так, при подаче изображения первого класса с масштабным коэффициентом $\mu = 69$ углом поворота $\varphi = 348$ градусов вероятность правильного распознавания при отношении сигнал/шум $q = 20$ составила 0,27.

Заключение

Исследованы зависимости правильного распознавания изображений от отношения сигнал/шум для аддитивной модели шума, распределённого по нормальному закону, полученные с использованием нейронных сетей CNN и методов контурного анализа. В качестве примера рассмотрена задача классификации трёх произвольных контурных изображений. Экспериментально установлено, что изменение линейных преобразование контуров, заданных на комплексной плоскости, не влияет на графики зависимостей вероятности правильного распознавания. Это связано с инвариантностью преобразований комплекснозначных контуров. Соответственно при формировании базы данных контурных изображений достаточно внести одно описание для каждой формы контура изображения. При решении задачи распознавания нейронной сетью получено: первое – при подаче на вход изображения, участвовавшего в обучении, задача распо-




Рис. 9. Характеристики обнаружения изображения первой группы (рис. 8, а) от отношения сигнал/шум при пороге обнаружения U равным 0,5, 0,7, 0,9



Рис. 10. Характеристики вероятности правильного распознавания изображений первой, второй и третьей группы (рис. 8, а–в) от отношения сигнал/шум при пороге обнаружения $U = 0,9$



Рис. 11. Характеристики вероятности правильного распознавания изображений третьей группы (рис. 6, ж–и) от отношения сигнал/шум q

знавания решается; второе — если на вход сети подать изображение, которое отсутствовало в обучающей выборке, но по форме совпадало с изображениями входящих в обучающую выборку, то результаты классификации могут быть непредсказуемыми. Для решения данной проблемы необходимо увеличить объём данных обучающей выборки, включив в неё все возможные комбинации и произвести «дообучение» модели нейронной сети. При проектировании нейронных сетей приходится эмпирически выбирать варьируемые параметры сети, которых достаточно много. Эти параметры существенно влияют на результат классификации.

Литература

1. Zherdev D.A., Minaev E.Y., Procudin V.V., Fursov V.A. Object recognition using real and modelled SAR images // *Procedia Engineering*. 2017. Vol. 201. Pp. 503–510. DOI: 10.1016/j.proeng.2017.09.473.
2. Aduenko A.A., Vasileisky A.S., Karelov A.I., Reyer I.A., Rudakov K.V., Strijov V.V. Algorithms of detection and registration of persistent scatterers in satellite radar images // *Computer Optics*. 2015. Vol. 39, Iss. 4. Pp. 622–630. DOI: 10.18287/0134-2452-2015-39-4-622-630.
3. Mikhaylichenko A.A., Demyanenko Ya.M. Detection of the bone contours of the knee joints on medical X-ray images // *Computer Optics*. 2019. Vol. 43, Iss. 3. Pp. 455–463. DOI: 10.18287/2412-6179-2019-43-3-455-463.
4. Raghu M., Zhang C., Kleinberg J., Bengio S. Transfusion: Understanding transfer learning for medical imaging // *Proc. 33rd Conf. on Neural Information Processing Systems (NeurIPS)*. 2019. Vol. 1. Pp. 1–22.
5. Prati A., Shan C., Wang K. Sensors, vision and networks: From video surveillance to activity recognition and health monitoring // *Journal of Ambient Intelligence and Smart Environments*. 2019. Vol. 11, Iss. 1. Pp. 5–22. DOI: 10.3233/AIS-180510.
6. Dolginov S.D. Digital Video Images in Forensic Identification // *Ex iure*. 2022. № 3. Pp. 116–127. DOI: 10.17072/2619-0648-2022-3-116-127.
7. Еришов М.Д., Шубин Н.Ю. Алгоритмы обработки изображений для решения задач анализа дорожной обстановки // *Цифровая Обработка Сигналов*. 2017. № 3. С. 63–67.
8. Охотников С.А., Хафизов Р.Г., Яранцева Т.В. Система распознавания речи по контурам изображения губ // *Проектирование и технология электронных средств*. 2016. № 2. С. 13–17.
9. Chochia P.A. Image segmentation based on analysis of distances in feature space // *Optoelectronics, Instrumentation and Data Processing*. 2015. Vol. 50, Iss. 6. Pp. 613–624. DOI: 10.3103/S8756699014060107.
10. Гонсалес Р., Вудс Р. Цифровая обработка изображений / пер. с англ. М.: Техносфера, 2005. 1072 с.
11. Введение в контурный анализ и его приложение к обработке изображений и сигналов / под ред. Я.А. Фурмана. М.: ФИЗМАТЛИТ, 2002. 592 с.
12. LeCun Y., Bengio Y., Hinton G. Deep learning // *Nature*. 2015. Vol. 521. Pp. 436–444. DOI: 10.1038/nature14539.
13. LeCun Y., Boser B., Denker J.S., Henderson D., Howard R.E., Hubbard W., Jackel L.D. Backpropagation applied to handwritten Zip Code recognition // *Neural Computation*. 1989. Vol. 1, Iss. 4. Pp. 541–551.
14. Хафизов Р.Г., Григорьевых Е.А., Мелешко А.В. Расчёт характеристик обнаружения сигналов для приёмника на базе инверсного фильтра в условиях неопределённости // *Радиотехнические и телекоммуникационные системы*. 2023. №4. С. 51–58.
15. Шолле Ф. Глубокое обучение на Python. 2-е междунар. изд. СПб.: Питер, 2023. 576 с.

Поступила 12 ноября 2025 г.

English

IMAGE RECOGNITION IN VISION SYSTEMS BASED ON NEURAL NETWORKS AND CONTOUR ANALYSIS METHODS

Sergey Arkadievich Ohotnikov — PhD. in Engineering, Associate Professor, Volga State University of Technology.

Elena Andreevna Grigorevych — PhD. in Engineering, Associate Professor, Volga State University of Technology.

Olesya Alekseevna Hamaritskaya — Student, Volga State University of Technology.

Address: 394064, Russian Federation, Voronezh, Starykh Bolshevikov str., 54a.

E-mail: HamaritskayaOA@volgatech.net

Abstract: The task of detecting and recognizing objects in photos and videos remains relevant. In recent years, the number of its applications has only increased. The main advantage of such methods is the ease of implementation and quality of work. At the same time, the urgent task is to increase the speed and reduce the computational costs of these methods. In addition, the question of the choice of variable network parameters remains open. Having a significant impact on the classification result, in practice, due to their large number, they are usually selected empirically. In contrast, classical recognition algorithms may still have an advantage due to their theoretical sophistication. Thus, recognition approaches based on contour analysis, having comparable characteristics in a number of practical applications, can be more computationally

efficient by reducing the amount of information processed. The purpose of the work: to compare the characteristics of image recognition using methods based on convolutional neural networks and contour analysis. Three datasets of 6600 single-channel images each, measuring 256x256 pixels, were generated. A convolutional neural network for recognizing grayscale (single-channel) images has been designed and trained. As part of the contour approach, three classes of image contours were also defined. To make a decision on the contour class, the maximum likelihood method was used based on the minimum difference between the real parts of the scalar products of the recognized contour and each of the reference contours. For both methods, a simulation was performed of the recognition process of a noisy image rotated in 2-degree increments and scaled with a zoom factor in the range of 1..4. The characteristics of the probability of correct recognition from the signal-to-noise ratio for an additive noise model distributed according to a normal law are obtained. The simulation results showed that contour analysis methods make it possible to classify contour images with various linear transformations without compromising recognition characteristics. In turn, the method based on convolutional neural networks has limited scaling invariance. When recognizing images that match the shape of the images in the training sample, but did not participate in the training (a scale factor of more than 4), recognition efficiency decreased.

Keywords: contour, image shape, classification, matched filter, neural networks, image recognition.

References

1. Zherdev D.A., Minaev E.Y., Procudin V.V., Fursov V.A. Object recognition using real and modelled SAR images. *Procedia Engineering*. 2017. Vol. 201. Pp. 503–510. DOI: 10.1016/j.proeng.2017.09.473.
2. Aduenko A.A., Vasileisky A.S., Karelov A.I., Reyer I.A., Rudakov K.V., Strijov V.V. Algorithms of detection and registration of persistent scatterers in satellite radar images. *Computer Optics*. 2015. Vol. 39, Iss. 4. Pp. 622–630. DOI: 10.18287/0134-2452-2015-39-4-622-630.
3. Mikhaylichenko A.A., Demyanenko Ya.M. Detection of the bone contours of the knee joints on medical X-ray images. *Computer Optics*. 2019. Vol. 43, Iss. 3. Pp. 455–463. DOI: 10.18287/2412-6179-2019-43-3-455-463.
4. Raghu M., Zhang C., Kleinberg J., Bengio S. Transfusion: Understanding transfer learning for medical imaging. *Proc. 33rd Conf. on Neural Information Processing Systems (NeurIPS)*. 2019. Vol. 1. Pp. 1–22.
5. Prati A., Shan C., Wang K. Sensors, vision and networks: From video surveillance to activity recognition and health monitoring. *Journal of Ambient Intelligence and Smart Environments*. 2019. Vol. 11, Iss. 1. Pp. 5–22. DOI: 10.3233/AIS-180510.
6. Dolginov S.D. Digital Video Images in Forensic Identification. *Ex jure*. 2022. № 3. Pp. 116–127. DOI: 10.17072/2619-0648-2022-3-116-127.
7. Ershov M.D., Shubin N.Yu. Image processing algorithms for road situation analysis. *Cifrovaya Obrabotka Signalov*. 2017. No. 3. Pp. 63–67.
8. Okhotnikov S.A., Khafizov R.G., Yarantseva T.V. Speech recognition system based on lip contour images. *Proektirovanie i tekhnologiya elektronnykh sredstv*. 2016. No. 2. Pp. 13–17.
9. Chochia P.A. Image segmentation based on analysis of distances in feature space. *Optoelectronics, Instrumentation and Data Processing*. 2015. Vol. 50, Iss. 6. Pp. 613–624. DOI: 10.3103/S8756699014060107.
10. Gonzalez R., Woods R. *Digital image processing*. Moscow: Tehnosfera, 2005. 1072 p.
11. Introduction to contour analysis and its application to image and signal processing. Ed. by Ya.A. Furman. Moscow: FIZMATLIT, 2002. 592 p.
12. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*. 2015. Vol. 521. Pp. 436–444. DOI: 10.1038/nature14539.
13. LeCun Y., Boser B., Denker J.S., Henderson D., Howard R.E., Hubbard W., Jackel L.D. Backpropagation applied to handwritten Zip Code recognition. *Neural Computation*. 1989. Vol. 1, Iss. 4. Pp. 541–551.
14. Khafizov R.G., Grigorievkh E.A., Meleshko A.V. Calculation of signal detection characteristics for a receiver based on an inverse filter under uncertainty conditions. *Radioengineering and Telecommunication Systems*. 2023. No. 4. Pp. 51–58.
15. Chollet F. *Deep learning with Python*. 2nd international ed. St. Petersburg: Piter, 2023. 576 p.