

Научная статья

УДК 343.98

EDN PQTRSB

DOI 10.17150/2500-4255.2025.19(1).84-95



## ОПРЕДЕЛЕНИЕ КЛАССИФИКАЦИОННОГО ТИПА ПАПИЛЛЯРНОГО УЗОРА НА ОСНОВЕ НЕЙРОСЕТЕВОГО ПОДХОДА

О.П. Грибунов<sup>1</sup>, С.И. Усачев<sup>2</sup>, Е.А. Усачева<sup>3</sup>

<sup>1</sup> Байкальский государственный университет, г. Иркутск, Российская Федерация

<sup>2</sup> Восточно-Сибирский институт МВД России, г. Иркутск, Российская Федерация

<sup>3</sup> Иркутский юридический институт (филиал) Университета прокуратуры Российской Федерации, г. Иркутск, Российская Федерация

### Информация о статье

Дата поступления

12 февраля 2025

Дата принятия в печать

23 февраля 2025 г.

Дата онлайн-размещения

21 марта 2025 г.

### Ключевые слова

Дактилоскопия; папиллярные узоры; нейросетевой подход; типы папиллярных узоров; судебная дактилоскопическая экспертиза; завитковые узоры; петлевые узоры; дуговые узоры; классификация папиллярных узоров

**Аннотация.** Работа посвящена рассмотрению вопросов, связанных с изучением папиллярных узоров ладоней и пальцев рук человека для дальнейшего решения задач идентификационного и диагностического характера. Авторами отмечается тенденция к стремительному развитию технологий искусственного интеллекта, среди которых особое место занимают нейронные сети. При этом также высказывается мнение о том, что использование нейронных сетей в криминалистике, особенно в задачах дактилоскопии, сопряжено с рядом трудностей, включая сбор, преобразование и обработку данных. Отмечается, что разработка модели по исследованию папиллярных узоров на основе нейросетевого подхода может найти применение как в реальной практике судебной экспертной деятельности и предварительном исследовании следов на месте происшествия лицами не обладающими специальными знаниями (оперативные работники, следователи, дознаватели), так и в образовательной деятельности для подготовки специалистов. В работе авторы описывают архитектуру используемой нейронной сети, процесс подготовки данных, включающий предварительную обработку изображений и создание тренировочного и тестового наборов, а также демонстрируют результаты экспериментальной проверки эффективности предложенного метода, включая показатели точности и полноты.

### Original article

## DETERMINING THE CLASSIFICATION TYPE OF A PAPILLARY PATTERN BASED ON NEURAL NETWORK APPROACH

Oleg P. Gribunov<sup>1</sup>, Sergey I. Usachev<sup>2</sup>, Ekaterina A. Usacheva<sup>3</sup>

<sup>1</sup> Baikal State University, Irkutsk, the Russian Federation

<sup>2</sup> East Siberian Institute of the Ministry of Internal Affairs of Russia, Irkutsk, the Russian Federation

<sup>3</sup> Irkutsk Law Institute (branch) of the University of the Prosecutor's Office of the Russian Federation, Irkutsk, the Russian Federation

### Article info

Received

2025 February 12

Accepted

2025 February 23

Available online

2025 March 21

### Keywords

Fingerprinting; papillary patterns; neural network approach; types of papillary patterns; forensic fingerprinting; whorl patterns; loop patterns; arch patterns; classification of papillary patterns

**Abstract.** The article discusses the issues of examining the papillary patterns of human palms and fingers for the purposes of identification and diagnostics. The authors highlight a trend for a rapid development of artificial intelligence technologies, including neural networks, which hold a special place. They also argue that the use of neural networks in criminalistics, especially in dactyloscopy, is associated with a number of difficulties, including the collection, transformation and processing of data. It is noted that the fingerprint patterns' examination model based on the neural network approach could be used in both the actual practice of court forensic work or the preliminary examination of traces at the crime scene conducted by persons without specialized knowledge (operatives, investigators, inquirers), and in the educational process of training specialists. The authors describe the architecture of the used neural network, the process of preparing data, including the preliminary processing of images and the creation of training and testing sets; they also demonstrate the results of the experimental verification of the effectiveness of the presented method, including the indicators of accuracy and completeness.

В последние годы наблюдается стремительное развитие технологий искусственного интеллекта, среди которых особое место занимают нейронные сети. Глобальные процессы цифровизации во всех сферах жизни социума дали новый импульс развитию IT-технологий в судебно-экспертной деятельности [1, с. 25]. Тем не менее использование нейронных сетей в криминалистике, особенно в задачах дактилоскопии, сопряжено с рядом трудностей, включая сбор, преобразование и обработку данных. Эти проблемы усугубляются несбалансированностью данных, сложностью некоторых узоров и фрагментарностью их отображения.

Дактилоскопия как наука занимается изучением папиллярных узоров для решения диагностических (определение пола человека, оставившего след, давность следа) и идентификационных (определение конкретного лица, которым были оставлены следы ладоней и пальцев рук) задач. Эти узоры обладают уникальностью, устойчивостью и удобством классификации, что делает их незаменимым инструментом в раскрытии и расследовании преступлений. Несомненно, рассматриваемые следы по-прежнему часто обнаруживаются при осмотрах мест происшествий, а также в рамках производства иных следственных действий, в том числе и по причине того, что преступники могут быть ограниченно рациональными [2, с. 1663] при совершении противоправного деяния либо уже при сокрытии следов своей преступной деятельности. Однако в настоящее время речь идет не только об обнаружении этих следов и дальнейшем назначении, производстве соответствующих экспертиз, но и о необходимости формирования отлаженного процесса классификации папиллярных узоров, что, в свою очередь, требует автоматизации, чтобы сократить время и исключить ошибки, которые могут допускаться из-за неопытности специалистов или сложности анализируемых данных.

Интеграция в криминалистику IT-технологий становится неизбежной [3, с. 104], ввиду чего нами предпринята попытка разработки нейросетевой модели для решения задачи классификации папиллярных узоров пальцев рук человека. Для этого изучена теоретическая основа предметной области; подготовлены данные для обучения; создана модель нейронной сети для решения задачи классификации папиллярных узоров пальцев рук; проведена оценка работы созданной модели.

Обнаружение и исследование следов пальцев рук при раскрытии и расследовании преступлений является необходимым средством установления механизма совершения преступления или связи конкретного лица с расследуемым событием. Будучи наиболее часто назначаемой [4, с. 110], судебная дактилоскопическая экспертиза позволяет разрешать криминалистически значимые идентификационные и диагностические задачи, диктуемые следственной и судебной практикой, с высокой степенью достоверности. Папиллярные узоры, расположенные на подушечках ногтевых фаланг пальцев рук, характеризуются индивидуальностью, относительной устойчивостью и восстанавливаемостью, что делает их одним из ключевых объектов криминалистической идентификации, позволяющих своевременно и достоверно получить информацию о фактических обстоятельствах совершения преступления и о личности преступника, без которой зачастую не представляется возможным осуществление раскрытия и расследования преступления.

Наиболее часто криминалистическому анализу подвергаются именно следы рук для решения идентификационных и диагностических задач. Ладонная поверхность руки каждого конкретного человека обладает рядом уникальных естественных и искусственных морфологических признаков рельефа [5, с. 18].

Криминалистическая значимость исследования следов пальцев рук обусловлена тем, что при совершении большинства преступлений неизбежно происходит прикосновение преступника к различного рода предметам, и, независимо от его воли и желания, в силу физиологических свойств кожи (наличие потожировых выделений, остающихся на поверхности следовоспринимающего объекта) остаются отпечатки пальцев, которые в большинстве случаев без особых усилий могут быть обнаружены и изъяты для последующей идентификации конкретного человека, оставившего следы [6, с. 77].

Сама идентификация преступника по отпечаткам пальцев рук также позволяет категорически установить тождество по общим и частным признакам папиллярного узора, располагающегося на подушечках ногтевых фаланг пальцев рук [7, с. 56]. Р.С. Белкин указывает, что различные виды папиллярных узоров образуются из папиллярных линий, которые представляют собой: «прямые или изгибающиеся линейные возвышения незначительной высоты и ширины,

разделяемые бороздками» [8, с. 165]. Криминалистическое значение папиллярных узоров обусловлено анатомо-физиологическими особенностями строения кожи на ладонях рук, которой свойственны следующие признаки: индивидуальность; относительная устойчивость и восстанавливаемость; удобство классификации.

Папиллярный узор образуется в виде уникальной комбинации папиллярных линий, индивидуальность которой подтверждается многолетними криминалистическими исследованиями. Суждение о неповторимости папиллярных узоров, вероятность совпадения которых составляет 1:10 010, распространяется не только в отношении отпечатков пальцев разных людей, но и в отношении папиллярных узоров на разных подушечках ногтевых фаланг одного человека [9, с. 445].

Основанием для классификации папиллярных узоров пальцев рук выступают их общие и частные признаки (детали). Установление этих признаков становится возможным в рамках проводимых экспертиз и исследований, которые являются результатом обучения и опыта в конкретной области [10, с. 1269]. Так, для определения типа узора отпечатков пальцев по общим признакам изучается его центральная часть, в зависимости от расположения папиллярных линий на которой выделяются следующие типы узоров: петлевые, завитковые и дуговые.

Заключение эксперта по результатам проведения экспертизы в рамках судопроизводства является одним из доказательств, подлежащим проверке и оценке в установленном порядке [11, с. 28]. Судебную дактилоскопическую экспертизу можно охарактеризовать как часть учения о дактилоскопии, которая главным образом направлена на решение ряда диагностических и идентификационных задач в целях расследования преступлений [12, с. 17]; данный вид исследований в настоящее время является одним из наиболее распространенных [13, с. 183]. В качестве предмета рассматриваемой экспертизы выступает осуществляемое с помощью специальных знаний исследование экспертом узоров, образуемых папиллярными линиями кожи человека в целях его идентификации в соответствии с необходимостью ответа на вопросы судебной и следственной практики<sup>1</sup>.

Судебная дактилоскопическая экспертиза чаще всего производится при расследовании

уголовных дел, связанных с незаконным проникновением в жилое или иное помещение, с тайным или открытым хищением чужого имущества, а также в иных случаях, когда требуется определение конкретного человека или количества лиц, которым могут принадлежать обнаруженные на месте преступления следы пальцев рук, определить механизм образования таких следов. Кроме того, с помощью дактилоскопической экспертизы возможно выявление невидимых или слабовидимых следов пальцев рук<sup>2</sup>.

Исследование объектов дактилоскопической экспертизы осуществляется в соответствии с методикой осуществления данного вида экспертизы, которая предполагает применение экспертом в ходе исследования системы приемов и технических средств с целью установления фактов, относящихся к предмету судебной экспертизы.

Согласно данной методике перед изучением частных признаков эксперт в обязательном порядке изучает общие признаки, в том числе определяет тип и вид.

Однако из-за большого количества экспертиз, неопытности молодых экспертов [14, с. 3], сложных типов узоров или их фрагментарного отображения эксперт может неверно определить тип узора. В результате такой ошибки в лучшем случае эксперт потратит намного больше времени на сравнительное исследование либо проведет ошибочное исследование.

Таким образом, автоматизация этого процесса путем создания модели нейронной сети, которая была бы способна определять тип узора пальцев рук, позволит упростить работу действующим экспертам, создаст условия для обучения молодых специалистов, впервые получивших допуск на самостоятельное проведение судебной дактилоскопической экспертизы.

В рамках настоящего исследования на основании приведенной нами классификации осуществлено проектирование, обучение, тестирование и оценка эффективности модели нейронной сети для решения задачи классификации папиллярных узоров пальцев рук человека на типы по их изображениям.

Нами использовались обезличенные данные, полученные путем обработки дактилоскопических карт (учебные экспертизы, учебные,

<sup>1</sup> Судебно-дактилоскопическая экспертиза // Судебно-экспертный центр Следственного комитета Российской Федерации : офиц. сайт. URL: <http://sec.sledcom.ru/categories/dakt.html> (дата обращения: 12.10.2024).

<sup>2</sup> Дактилоскопическая экспертиза // Кузбасский институт судебных экспертиз : офиц. сайт. URL: <https://kuzise.ru/dopolnitelnye-uslugi/daktiloskopicheskie> (дата обращения: 12.10.2024).

учебно-методические пособия и практикумы по дактилоскопии).

Полученный датасет состоит из 1 842 файлов с изображениями следов пальцев рук, разделенный по трем классам: arches, loops и whorls, что соответствует дуговому, петлевому и завитковому типам узоров. Пример изображения представлен на рис. 1.



Рис. 1. Изображение петлевого узора

Fig. 1. Loop pattern

Важно отметить, что датасет по объективным причинам является несбалансированным и, соответственно, это может сказаться на результатах обучения.

Дополнительной предобработки данных не требуется, формирование обучающей и тестовой выборки будет осуществляться при помощи ImageDataGenerator библиотеки keras<sup>3</sup>.

Листинг 2.1. Формирование объекта ImageDataGenerator

```
datagen = ImageDataGenerator(
    rescale=1.0/255,
    rotation_range=20,
    width_shift_range=0.2,
    height_shift_range=0.2,
    shear_range=0.2,
    zoom_range=0.2,
    horizontal_flip=True,
    fill_mode='nearest',
    validation_split=0.20 # 20%
    данных для валидации)
```

<sup>3</sup> tf.keras.preprocessing.image.ImageDataGenerator // TensorFlow. URL: [https://www.tensorflow.org/api\\_docs/python/tf/keras/preprocessing/image/ImageDataGenerator](https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/image/ImageDataGenerator) (дата обращения: 13.10.2024).

Этот код формирует объект datagen, который используется для генерации и аугментации изображений в процессе обучения нейронной сети. Далее необходимо создать генераторы выборки, создадим их отдельно для обучения и тестирования.

Листинг 2.2. Формирование генераторов обучающей и тестовой выборки

```
# Путь к основной директории с данными
train_dir = '/content/all_classes/fingerprints'

# Генератор для тренировочных данных
train_generator = datagen.flow_from_directory(
    train_dir,
    target_size=(150, 150),
    batch_size=32,
    class_mode='categorical',
    subset='training' # Указываем, что это тренировочные данные)

# Генератор для валидационных данных
validation_generator = datagen.flow_from_directory(
    train_dir,
    target_size=(150, 150),
    batch_size=32,
    class_mode='categorical',
    subset='validation' # Указываем, что это валидационные данные)
```

После выполнения этого кода в консоль выводится информация о том, что были найдены изображения, распределенные на три класса.

После того как были подготовлены генераторы выборки (рис. 2), можно приступить к проектированию архитектуры модели нейронной сети.

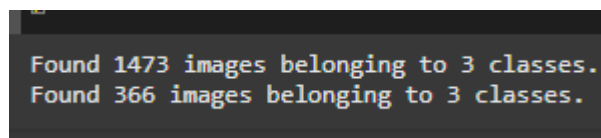


Рис. 2. Результат формирования генераторов выборки

Fig. 2. Batch generators' formation results



В данной работе использована свёрточная [15, с. 10] модель нейронной сети. На начальном этапе модель принимает на вход изображения размером  $150 \times 150$  пикселей с тремя каналами (RGB). Первый слой — это свёрточный слой Conv2D, который применяет 32 фильтра размером  $3 \times 3$  для выделения признаков. За ним следует слой подвыборки MaxPooling2D с размером фильтра  $2 \times 2$ , что позволяет уменьшить пространственные размеры данных и выделить наиболее значимые признаки. Для предотвращения переобучения уже на этом этапе добавлен слой Dropout с коэффициентом 0.2.

Аналогичная структура повторяется для второго и третьего свёрточных блоков, где количество фильтров увеличивается до 64 и 128 соответственно, что позволяет модели захватывать более сложные и высокоуровневые признаки. Значения коэффициента Dropout для этих слоев также изменяются, становясь больше (0.3 и 0.5), чтобы соответствовать увеличивающейся сложности модели. После третьего свёрточного блока данные преобразуются в одномерный вид с помощью слоя Flatten, чтобы подготовить их для дальнейшей обработки плотными слоями.

Полновязный слой (Dense) содержит 512 нейронов с функцией активации relu для обработки извлеченных признаков. Для дальнейшей регуляризации перед выходным слоем также применяется Dropout с коэффициентом 0.25. Наконец, выходной слой имеет 3 нейрона и функцию активации softmax, что позволяет получить вероятности принадлежности входного изображения одному из трех классов. Схема архитектуры и распределение параметров по слоям модели указаны на рис. 3 и 4 соответственно.

Ввиду того что датасет является несбалансированным и в одном из классов намного меньше данных, чем в других, и без изначального уменьшения данных и балансировки по размеру выборок, использован метод `compute_class_weight`<sup>4</sup>, с помощью которого распределен вес для классов:

Листинг 2.3. Распределение веса для классов

```
class_indices = train_generator.class_indices
class_indices # Словарь с индексами классов
labels = train_generator.classes
# Список меток для всех изображений
```

<sup>4</sup> `compute_class_weight` // Scikit-learn. URL: [https://scikit-learn.org/dev/modules/generated/sklearn.utils.class\\_weight.compute\\_class\\_weight.html](https://scikit-learn.org/dev/modules/generated/sklearn.utils.class_weight.compute_class_weight.html) (дата обращения: 15.10.2024).

```
class_weights = compute_class_weight(class_weight='balanced',
                                     classes=np.unique(labels),
                                     y=labels)
class_weights_dict = dict(enumerate(class_weights))
print("Веса классов:", class_weights_dict)
```

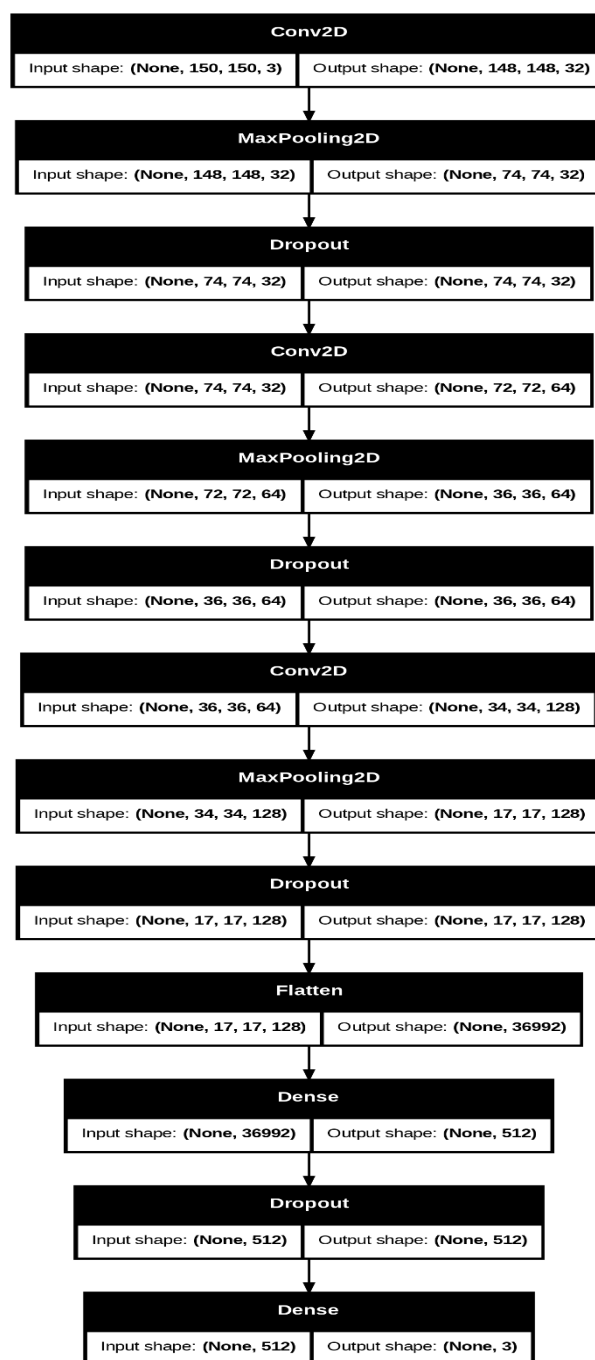


Рис. 3. Архитектура модели  
Fig. 3. Model's architecture

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 148, 148, 32)	896
max_pooling2d (MaxPooling2D)	(None, 74, 74, 32)	0
dropout (Dropout)	(None, 74, 74, 32)	0
conv2d_1 (Conv2D)	(None, 72, 72, 64)	18,496
max_pooling2d_1 (MaxPooling2D)	(None, 36, 36, 64)	0
dropout_1 (Dropout)	(None, 36, 36, 64)	0
conv2d_2 (Conv2D)	(None, 34, 34, 128)	73,856
max_pooling2d_2 (MaxPooling2D)	(None, 17, 17, 128)	0
dropout_2 (Dropout)	(None, 17, 17, 128)	0
flatten (Flatten)	(None, 36992)	0
dense (Dense)	(None, 512)	18,940,416
dropout_3 (Dropout)	(None, 512)	0
dense_1 (Dense)	(None, 3)	1,539
Total params: 19,035,203 (72.61 MB)		
Trainable params: 19,035,203 (72.61 MB)		
Non-trainable params: 0 (0.00 B)		

Рис. 4. Распределение параметров модели

Fig. 4. Distribution of the model's parameters

Таким образом, вес распределился соответствующим образом (рис. 5).

Непосредственный процесс обучения помимо прочего связан с вопросами недопу-

щения переобучения, для чего был введен ModelCheckpoint, который будет отслеживать характеристики модели и сохранять результаты обучения только с лучшими метриками:

```
from sklearn.utils.class_weight import compute_class_weight
import numpy as np

# Получаем метки классов и количество изображений в каждом классе из генератора
class_indices = train_generator.class_indices # Словарь с индексами классов
labels = train_generator.classes # Список меток для всех изображений

# Вычисляем веса классов
class_weights = compute_class_weight(class_weight='balanced', classes=np.unique(labels), y=labels)
class_weights_dict = dict(enumerate(class_weights))
print("Веса классов:", class_weights_dict)

Веса классов: {0: 4.504587155963303, 1: 0.4851778656126482, 2: 1.3948863636363635}
```

Рис. 5. Распределение веса классов

Fig. 5. Class weights distribution

## Листинг 2.4. ModelCheckpoint

```
checkpoint = ModelCheckpoint(
    'best_model.keras',
    monitor='val_accuracy',
    save_best_only=True,
    mode='max',
    verbose=1)
```

Также был добавлен EarlyStopping, для завершения процесса обучения.

## Листинг 2.5. EarlyStopping

```
early_stopping = EarlyStopping(
    monitor='val_accuracy',
    patience=10,
    mode='max',
    verbose=1,
    restore_best_weights=True)
```

Для начала обучения было выставлено обучение на протяжении 100 эпох:

## Листинг 2.6. Обучение модели

```
history = model.fit(
    train_generator,
    epochs=100,
    validation_data=validation_
generator,
    callbacks=[checkpoint,
early_stopping],
    class_weight=class_weights_
dict # Передаем веса классов)
```

Результаты обучения представлены на рис. 6.

Обучение проходило в течение 44 эпох, лучшей по метрикам была 34-я эпоха, точность на валидационной выборке составила 97,16 % (рис. 7).

```
Epoch 34: val_accuracy improved from 0.98361 to 0.98907, saving model to best_model.keras
47/47 ————— 22s 261ms/step - accuracy: 0.9569 - loss: 0.1269 - val_accuracy: 0.9891 - val_loss: 0.0724
Epoch 35/100
46/47 ————— 0s 194ms/step - accuracy: 0.9633 - loss: 0.1206
Epoch 35: val_accuracy did not improve from 0.98907
47/47 ————— 19s 232ms/step - accuracy: 0.9636 - loss: 0.1198 - val_accuracy: 0.9754 - val_loss: 0.0758
Epoch 36/100
46/47 ————— 0s 193ms/step - accuracy: 0.9762 - loss: 0.1076
Epoch 36: val_accuracy did not improve from 0.98907
47/47 ————— 13s 245ms/step - accuracy: 0.9759 - loss: 0.1080 - val_accuracy: 0.9727 - val_loss: 0.0905
Epoch 37/100
46/47 ————— 0s 175ms/step - accuracy: 0.9815 - loss: 0.0984
Epoch 37: val_accuracy did not improve from 0.98907
47/47 ————— 12s 230ms/step - accuracy: 0.9812 - loss: 0.0994 - val_accuracy: 0.9809 - val_loss: 0.0816
Epoch 38/100
46/47 ————— 0s 158ms/step - accuracy: 0.9705 - loss: 0.1032
Epoch 38: val_accuracy did not improve from 0.98907
47/47 ————— 11s 216ms/step - accuracy: 0.9704 - loss: 0.1034 - val_accuracy: 0.9781 - val_loss: 0.0672
Epoch 39/100
46/47 ————— 0s 190ms/step - accuracy: 0.9699 - loss: 0.1017
Epoch 39: val_accuracy did not improve from 0.98907
47/47 ————— 21s 229ms/step - accuracy: 0.9699 - loss: 0.1016 - val_accuracy: 0.9754 - val_loss: 0.0809
Epoch 40/100
46/47 ————— 0s 178ms/step - accuracy: 0.9767 - loss: 0.1056
Epoch 40: val_accuracy did not improve from 0.98907
47/47 ————— 21s 231ms/step - accuracy: 0.9766 - loss: 0.1058 - val_accuracy: 0.9727 - val_loss: 0.0995
Epoch 41/100
46/47 ————— 0s 178ms/step - accuracy: 0.9650 - loss: 0.1250
Epoch 41: val_accuracy did not improve from 0.98907
47/47 ————— 20s 216ms/step - accuracy: 0.9653 - loss: 0.1241 - val_accuracy: 0.9809 - val_loss: 0.0711
Epoch 42/100
46/47 ————— 0s 193ms/step - accuracy: 0.9650 - loss: 0.1602
Epoch 42: val_accuracy did not improve from 0.98907
47/47 ————— 21s 232ms/step - accuracy: 0.9654 - loss: 0.1588 - val_accuracy: 0.9809 - val_loss: 0.0889
Epoch 43/100
46/47 ————— 0s 167ms/step - accuracy: 0.9485 - loss: 0.1715
Epoch 43: val_accuracy did not improve from 0.98907
47/47 ————— 12s 226ms/step - accuracy: 0.9488 - loss: 0.1710 - val_accuracy: 0.9836 - val_loss: 0.0804
Epoch 44/100
46/47 ————— 0s 163ms/step - accuracy: 0.9655 - loss: 0.1105
Epoch 44: val_accuracy did not improve from 0.98907
47/47 ————— 14s 271ms/step - accuracy: 0.9655 - loss: 0.1109 - val_accuracy: 0.9645 - val_loss: 0.0943
Epoch 44: early stopping
Restoring model weights from the end of the best epoch: 34.
```

Рис. 6. Результаты обучения нейронной сети

Fig. 6. Neural network's training results

```
# Оценка точности на валидационном наборе
val_loss, val_accuracy = model.evaluate(validation_generator, steps=validation_generator.samples // validation_generator.batch_size)
print(f'Validation accuracy: {val_accuracy * 100:.2f}%')

11/11 ————— 3s 283ms/step - accuracy: 0.9689 - loss: 0.1003
Validation accuracy: 97.16%
```

Рис. 7. Точность на валидационной выборке

Fig. 7. Accuracy in the validation batch

Далее был выстроен график обучения для полученной модели (рис. 8).

Следующим этапом является построение матрицы ошибок (confusion matrix) для наглядного отображения результатов предсказания модели на тестовых данных (где она ошибалась) (рис. 9).

Как можно увидеть, из 366 предсказаний модель допустила четыре ошибки, что свидетельствует о высоком уровне обобщения модели и ее успешном предсказании на тестовых данных. В ходе экспериментов улучшить точность выше 97 % не удалось ввиду несбалан-




Рис. 8. График обучения модели

Fig. 8. Graph of the model's training




Рис. 9. Матрица ошибок

Fig. 9. Mistake matrix



сированного датасета и сложности данных для обучения.

Далее представлена матрица предсказаний на 25 изображениях (рис. 10).

Как можно увидеть на рис. 10, из 25 случайных изображений, выбранных для предсказаний, модель классифицировала эти изображения безошибочно, что также является демонстрацией высокого уровня обобщения модели.

Таким образом, нами разработана архитектура модели, оптимизированная под задачу

классификации папиллярных узоров, которая продемонстрировала высокую эффективность. На тестовых данных точность классификации составила 97,16 %; это свидетельствует о том, что обученная модель успешно справляется с поставленной задачей. Кроме того, график точности (ассигасы) на обучающем и валидационном наборах данных показал, что модель достигла значений, близких к 1, что свидетельствует о ее высокой точности в предсказании целевых значений.

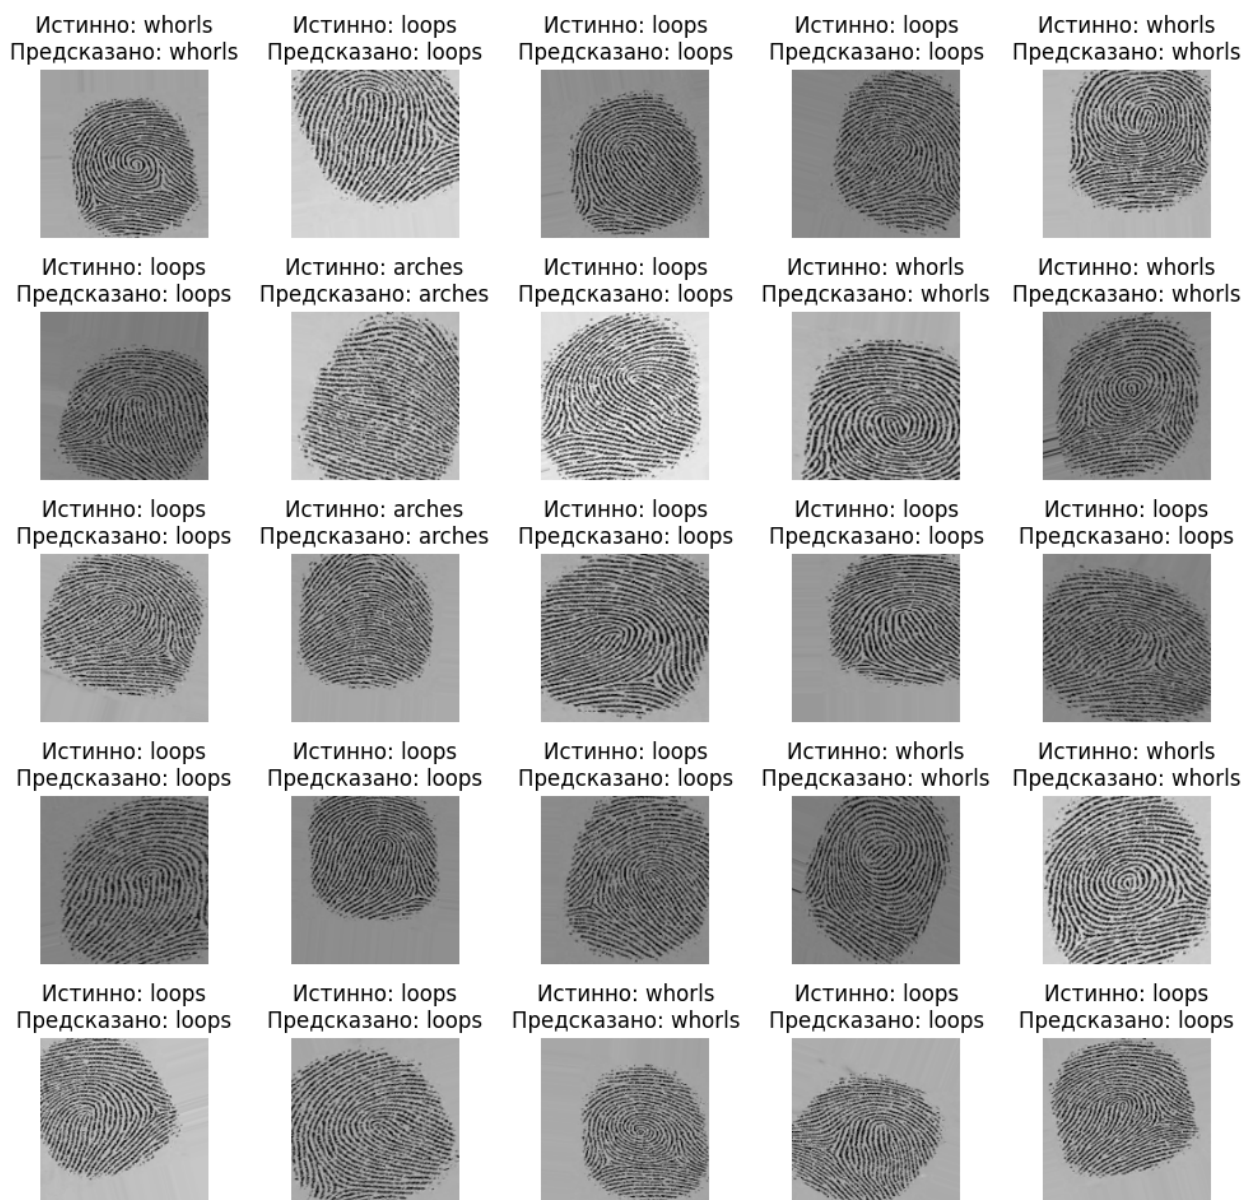


Рис. 10. Матрица предсказаний

Fig. 10 Prediction matrix

Высокая точность модели на тестовых данных подтверждает ее хорошую обобщающую способность, т.е. способность правильно классифицировать узоры на данных, не использовавшихся в процессе обучения. Это особенно важно для практического применения в судебной дактилоскопической экспертизе и при исследовании следов на месте происшествия (для получения ориентирующей оперативной информации), где точность и надежность имеют ключевое значение.

В заключение следует подчеркнуть, что разработанная модель, основанная на сверточных нейронных сетях, демонстрирует высокую эффективность в задаче классификации папиллярных узоров пальцев рук. Эти результаты подтверждают значимость и перспективы использования нейросетевых методов для автоматизации в решении дактилоскопических задач. Разработанная модель может найти применение как в реальной практике судебной экспертной деятельности и предварительном

исследовании следов на месте происшествия лицами, не обладающими специальными знаниями (оперативные работники, следователи, дознаватели), так и в образовательной деятельности для подготовки специалистов. Таким образом, очевидно, что с помощью возможностей искусственного интеллекта и повсеместного внедрения информационных технологий, а также все большей распространенности использования биометрических данных [16, с. 89] возможно разрабатывать различные программные продукты, облегчающие деятельность правоохранительных органов за счет автоматизирования многих процессов.

Достиженные в ходе исследования результаты могут быть использованы при разработке автоматизированных систем криминалистического анализа, а полученная нейросетевая модель, способная классифицировать папиллярные узоры с высокой точностью, может в разы упростить и ускорить процесс проведения судебной дактилоскопической экспертизы.

#### СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Россинская Е.Р. Нейросети в судебной экспертологии и экспертной практике: проблемы и перспективы / Е.Р. Россинская — DOI 10.17803/2311-5998.2024.115.3.021-033. — EDN FZKHHN // Вестник Университета имени О.Е. Кутафина (МГЮА). — 2024. — № 3 (115). — С. 21–33.
2. Classical deterrence theory revisited: An empirical analysis of Police Force Areas in England and Wales / J. Abramovaite, S. Bandyopadhyay, N. Cowen, S. Bhattacharya // *European Journal of Criminology*. — 2023. — Vol. 20, no. 5. — P. 1663–1680.
3. Савенков А.Н. Вектор развития криминалистической науки в условиях глобальной цифровизации / А.Н. Савенков, Е.Р. Россинская. — DOI 10.31857/S102694520025650-6. — EDN WRFJQC // Государство и право. — 2023. — № 5. — С. 100–110.
4. Васюков В.Ф. Проблемы производства дактилоскопических экспертиз на современном этапе развития компьютерных технологий / В.Ф. Васюков, И.В. Зюзина. — DOI 10.24411/2073-3313-2019-10122. — EDN YFATJ // Закон и право. — 2019. — № 3. — С. 110–111.
5. Дерюгин Р.А. О некоторых вопросах проведения дактилоскопической экспертизы / Р.А. Дерюгин. — EDN KZXWOL // Сборник материалов криминалистических чтений. — 2019. — № 16. — С. 18–19.
6. Криминалистические аспекты разработки и применения темных дактилоскопических порошков для выявления латентных следов рук / В.А. Васильев, Т.А. Ермакова, Ю.А. Дружинин, И.Б. Афанасьев. — EDN KQIEOM // Судебная экспертиза. — 2024. — № 2 (78). — С. 74–83.
7. Яровенко В.В. Применение цифровых технологий в дактилоскопии (переход на создание, хранение и исследование материалов в электронном формате) / В.В. Яровенко, О.В. Пяткова, А.В. Чередниченко. — DOI 10.25136/2409-7136.2022.2.35038. — EDN DJIEN // Юридические исследования. — 2022. — № 2. — С. 51–62.
8. Белкин Р.С. Криминалистическая энциклопедия / Р.С. Белкин. — 2-е изд., доп. — Москва : Мегатрон XXI, 2000. — 333 с.
9. Балко В.И. Современная классификация свойств папиллярных узоров рук и ног человека для решения идентификационных и неидентификационных задач в судебно-экспертной деятельности / В.И. Балко. — DOI 10.19073/2658-7602-2021-18-4-445-459. — EDN CFIBKG // Сибирское юридическое обозрение. — 2021. — Т. 18, № 4. — С. 445–459.
10. A comparison of younger and older burglars undertaking virtual burglaries: the development of skill and automaticity / A. Meenaghan, C. Nee, Z. Vernham, M. Otto // *Journal of Experimental Criminology*. — 2023. — Vol. 20, no. 4. — P. 1269–1292.
11. Нестеров А.В. Пошатнулась ли криминалистика (судебная экспертиза)? / А.В. Нестеров, Я.В. Комиссарова. — DOI 10.18572/2072-442X-2024-2-28-31. — EDN ESKZEY // Эксперт-криминалист. — 2024. — № 2. — С. 28–31.
12. Фоминых И.С. Судебная дактилоскопия : учеб. пособие / И.С. Фоминых. — Томск : ТМЛ-Пресс, 2010. — 128 с. — EDN QSGNAV.
13. Милос А.И. Совершенствование методики расследования краж нефти и нефтепродуктов, совершаемых при их хранении и транспортировке на объектах топливно-энергетического комплекса : дис. ... канд. юрид. наук : 5.1.4 / А.И. Милос. — Иркутск, 2023. — 236 с. — EDN PNOTJV.

14. Белозерова Н.С. Недостатки и пути их устранения при использовании перчаток в процессе работы с дактилоскопическими объектами / Н.С. Белозерова, А.В. Антропов, Д.В. Бахтеев. — DOI 10.18572/1812-3783-2020-1-3-8. — EDN JQZNPS // Российский следователь. — 2020. — № 1. — С. 3–8.
15. Маршалко Д.А. Архитектура свёрточных нейронных сетей / Д.А. Маршалко, О.В. Кубанских. — EDN HOCSSF // Ученые записки Брянского государственного университета. — 2019. — № 4 (16). — С. 10–13.
16. Дяблова Ю.Л. Возможность использования дерматоглифики в криминалистическом изучении личности / Ю.Л. Дяблова, Д.С. Куршев. — EDN KOWOID // Известия Тульского государственного университета. Экономические и юридические науки. — 2020. — № 2. — С. 81–89.

## REFERENCES

1. Rossinskaya E.R. Neural Networks in Forensic Expertology and Expert Practice: Problems and Prospects. *Vestnik Universiteta imeni O.E. Kutafina = Courier of the Kutafin Moscow State Law University*, 2024, no. 3, pp. 21–33. (In Russian). EDN: FZKHNN. DOI: 10.17803/2311-5998.2024.115.3.021-033.
2. Abramovaite J., Bandyopadhyay S., Cowen N., Bhattacharya S. Classical Deterrence Theory Revisited: An Empirical Analysis of Police Force Areas in England and Wales. *European Journal of Criminology*, 2023, vol. 20, no. 5, pp. 1663–1680.
3. Savenkov A.N., Rossinskaya E.R. The Development Vector of Criminalistic Science in the Conditions of Global Digitalization. *Gosudarstvo i pravo = State and Law*, 2023, no. 5, pp. 100–110. (In Russian). EDN: WRFJCQ. DOI: 10.31857/S102694520025650-6.
4. Vasyukov V.F., Zyuzina I.V. Problems of Production of Fingerprint Examinations at the Present Stage of Development of Computer Technologies. *Zakon i pravo = Law and Right*, 2019, no. 3, pp. 110–111. (In Russian). EDN: YYFATJ. DOI: 10.24411/2073-3313-2019-10122.
5. Deryugin R.A. On Some Aspects of the Fingerprint Examination. *Sbornik materialov kriminalisticheskikh chtenii = Collected Materials of Criminalistic Readings*, 2019, no. 16, pp. 18–19. (In Russian). EDN: KZXWOL.
6. Vasilyev V.A., Ermakova T.A., Druzhinin Yu.A., Afanasyev I.B. Forensic Aspects of Development and Application of Dark Fingerprint Powders to Detect Latent Fingerprints. *Sudebnaya ekspertiza = Forensic Examination*, 2024, no. 2, pp. 74–83. (In Russian). EDN: KQIEOM.
7. Yarovenko V.V., Pyatkova O.V., Cherednichenko A.V. Application of Digital Technologies in Fingerprinting (Transition to Creation, Storage and Research of Materials in Electronic Format). *Yuridicheskie issledovaniya = Legal Studies*, 2022, no. 2, pp. 51–62. (In Russian). EDN: DJIEN. DOI: 10.25136/2409-7136.2022.2.35038.
8. Belkin R.S. *The Forensic Encyclopedia*. Moscow, Megatron XXI Publ., 2000. 333 p.
9. Balko V.I. Modern Classification of the Properties of Papillary Patterns of Human Hands and Feet for the Solution of Identification and Non-identification Problems in Forensic Expert Activities. *Sibirskoe yuridicheskoe obozrenie = Siberian Law Review*, 2021, vol. 18, no. 4, pp. 445–459. (In Russian).
10. Meenaghan A., Nee C., Vernham Z., Otto M. A Comparison of Younger and Older Burglars Undertaking Virtual Burglaries: the Development of Skill and Automaticity. *Journal of Experimental Criminology*, 2023, vol. 20, no. 4, pp. 1269–1292.
11. Nesterov A.V., Komissarova Ya.V. Is Criminalistics (Forensic Examination) Cracking? *Ekspert-kriminalist = Expert-Criminalist*, 2024, no. 2, pp. 28–31. (In Russian). EDN: ESKZEY. DOI: 10.18572/2072-442X-2024-2-28-31.
12. Fominykh I.S. *Forensic Fingerprinting*. Tomsk, TML-Press Publ., 2010. 128 p.
13. Milyus A.I. *Improving the Methodology of Investigating Thefts of Oil and Oil Products Conducted during the Storage and Transportation at the Objects of Fuel and Energy Complex*. Cand. Diss. Irkutsk, 2023. 236 p. EDN: PNOTJV.
14. Belozerova N.S., Antropov A.V., Bakhteev D.V. Disadvantages and Means to Eliminate them when Using Gloves when Working with Dactyloscopic Objects. *Rossiiskii sledovatel' = Russian Investigator*, 2020, no. 1, pp. 3–8. (In Russian). EDN: JQZNPS. DOI: 10.18572/1812-3783-2020-1-3-8.
15. Marshalko D.A., Kubanskiy O.V. Convolutional Neural Network Architecture. *Uchenye zapiski Bryanskogo gosudarstvennogo universiteta = The Bryansk State University Memoirs*, 2019, no. 4, pp. 10–13. (In Russian). EDN: HOCSSF.
16. Dyablova Ju.L., Kurshev D.S. The Possibility of Using Dermatoglyphics in the Criminalistic Study of Personality. *Izvestiya Tul'skogo gosudarstvennogo universiteta. Ekonomicheskie i yuridicheskie nauki = Izvestiya of the Tula State University. Economic and Legal Sciences*, 2020, no. 2, pp. 81–89. (In Russian). EDN: KOWOID.

## ИНФОРМАЦИЯ ОБ АВТОРАХ

Грибунов Олег Павлович — исполняющий обязанности ректора Байкальского государственного университета, доктор юридических наук, профессор, г. Иркутск, Российская Федерация, e-mail: gribunov@mail.ru, SPIN-код: 6215-1184, AuthorID РИНЦ: 303242.

Усачев Сергей Игоревич — доцент кафедры криминалистики Восточно-Сибирского института МВД России, кандидат юридических наук, г. Иркутск, Российская Федерация, e-mail: ysachef@list.ru, SPIN-код: 3314-4779, AuthorID РИНЦ: 994377.

Усачева Екатерина Анатольевна — доцент кафедры организации и методики уголовного преследования Иркутского юридического института (филиала) Университета прокуратуры Российской Федерации, кандидат юридических наук, г. Иркутск, Российская Федерация, e-mail: malykhina\_ek@mail.ru, SPIN-код: 4433-6093, AuthorID РИНЦ: 874860.

## INFORMATION ABOUT THE AUTHORS

Gribunov, Oleg P. — Acting Rector, Baikal State University, Doctor of Law, Professor, Irkutsk, the Russian Federation, e-mail: gribunov@mail.ru, SPIN-Code: 6215-1184, AuthorID RSCI: 303242.

Usachev, Sergey I. — Ass. Professor, Department of Criminalistics, East Siberian Institute of the Ministry of Internal Affairs of Russia, Ph.D. in Law, Irkutsk, the Russian Federation, e-mail: ysachef@list.ru, SPIN-Code: 3314-4779, AuthorID RSCI: 994377.

Usacheva, Ekaterina A. — Ass. Professor, Department of the Organization and Methods of Criminal Prosecution, Irkutsk Law Institute (Branch) of the University of the Prosecutor's Office of the Russian Federation, Ph.D. in Law, Irkutsk, the Russian Federation, e-mail: malykhina\_ek@mail.ru, SPIN-Code: 4433-6093, AuthorID RSCI: 874860.

**ВКЛАД АВТОРОВ**

Все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

**CONTRIBUTION OF THE AUTHORS**

The authors contributed equally to this article. The authors declare no conflicts of interests.

**ДЛЯ ЦИТИРОВАНИЯ**

Грибунов О.П. Определение классификационного типа папиллярного узора на основе нейросетевого подхода / О.П. Грибунов, С.И. Усачев, Е.А. Усачева. — DOI 10.17150/2500-4255.2025.19(1).84-95. — EDN PQTRSB // Всероссийский криминологический журнал. — 2025. — Т. 19, № 1. — С. 84–95.

**FOR CITATION**

Gribunov O.P., Usachev S.I., Usacheva E.A. Determining the Classification Type of a Papillary Pattern Based on Neural Network Approach. *Vserossiiskii kriminologicheskii zhurnal = Russian Journal of Criminology*, 2025, vol. 19, no. 1, pp. 84–95. (In Russian). EDN: PQTRSB. DOI: 10.17150/2500-4255.2025.19(1).84-95.