

Бинаризация изображений следов полей нарезов с помощью сверточной нейронной сети

 В.А. Федоренко¹,  К.О. Сорокина¹,  Е.В. Навроцкая¹,  А.Л. Грибер²

¹ Саратовский национальный исследовательский государственный университет им. Н.Г. Чернышевского, Саратов 410012, Россия

² Баллистическая лаборатория полиции Израиля, Иерусалим 9721247, Израиль

Аннотация. Целью работы является отработка алгоритма автоматического преобразования изображений следов полей нарезов, представленных в градациях серого, в бинарный вид таким образом, как их анализирует эксперт. Задачей является исследование возможности бинаризации изображений вторичных следов с помощью алгоритма семантической бинарной сегментации, реализованного на основе сверточной нейронной сети. Обучающая выборка включала 160 изображений вторичных следов, представленных в градациях серого и сформированных разными полями нарезов. Для аугментации обучающей выборки использовали генератор изображений вторичных следов. Проведенные расчеты показали, что точность бинаризации изображений вторичных следов составила, в соответствии с метриками: Accuracy = $0,88 \pm 0,05$; Recall = $0,76 \pm 0,06$; Precision = $0,83 \pm 0,06$; F1 = $0,79 \pm 0,05$; MCC = $0,71 \pm 0,06$.

Бинаризация изображений необходима для сравнения в автоматическом режиме вторичных следов с помощью одного из алгоритмов машинного обучения. Целью такого процесса может являться бинарная классификация по категориям «следы совпадающие» и «следы не совпадающие». Предварительное исследование показало, что, в соответствии с метрикой Accuracy, точность классификации пар изображений вторичных следов по данным категориям, проведенной с помощью алгоритма «случайный лес», достигает 84–86%.

Ключевые слова: сверточные нейронные сети, семантическая бинарная сегментация, аугментация выборки, идентификация огнестрельного оружия, бинаризация изображений, судебная баллистическая экспертиза

Для цитирования: Федоренко В.А., Сорокина К.О., Навроцкая Е.В., Грибер А.Л. Бинаризация изображений следов полей нарезов с помощью сверточной нейронной сети // Теория и практика судебной экспертизы. 2026. Т. 21. № 2. С. 51–59. <https://doi.org/10.30764/1819-2785-2026-2-51-59>

Binarization of Image of Firearm Land Impressions Using a Convolutional Neural Network

 Vladimir A. Fedorenko¹,  Ksenia O. Sorokina¹,  Elena V. Navrotskaya¹,  Alexandra L. Griber²

¹ Saratov State University named after N.G. Chernyshevsky, Saratov 410012, Russia

² Laboratory of Forensic Firearm Examination, Israel Police HQ, Jerusalem 9721247, Israel

Abstract. The aim of this work is to develop an algorithm for automatically converting grayscale rifling marks into binary data in the way they are analyzed by an expert. The objective of this study is to explore the feasibility of image binarization of secondary traces using a semantic binary segmentation algorithm implemented on the basis of a convolutional neural network. The training set included 160 images of secondary traces, represented in grayscale and formed by different rifling marks. The secondary trace image generator was used to augment the training set. The calculations done in accordance with the metrics showed the following accuracy of image binarization of secondary traces: Accuracy = $0,88 \pm 0,05$; Recall = $0,76 \pm 0,06$; Precision = $0,83 \pm 0,06$; F₁ = $0,79 \pm 0,05$; MCC = $0,71 \pm 0,06$. The binarization of images is necessary for automatic comparison of secondary traces using one of the machine learning algorithms for the purpose of their binary classification into the categories of “matching traces” and “non-matching traces”. The preliminary examination showed that the classification accuracy of pairs of secondary trace images by these categories, carried out using the Random Forest algorithm, was around 84–86%.

Keywords: secondary traces, semantic binary segmentation, sample augmentation, firearm identification, image binarization, forensic ballistic examination

For citation: Fedorenko V.A., Sorokina K.O., Navrotskaya E.V., Griber A.L. Binarization of Image of Firearm Land Impressions Using a Convolutional Neural Network. *Theory and Practice of Forensic Science*. 2026. Vol. 21. No. 2. P. 51–59. (In Russ.). <https://doi.org/10.30764/1819-2785-2026-2-51-59>

Введение

При расследовании преступлений, связанных с применением огнестрельного оружия, часто требуется оперативно ответить на вопрос: из одного или разных экземпляров оружия были выстрелены пули, изъятые на месте происшествия? Для этого следы от внутренней поверхности ствола, отобравшиеся на исследуемых пулях, сравнивают между собой методом совмещения [1]. Такие исследования выполняются экспертом-баллистом с использованием сравнительного микроскопа. В случае необходимости проведения поиска по пулегильзотекам используют баллистические идентификационные системы, такие как IBIS, «POISC», «BalScan» и др. Такие системы ранжируют следы в пулегильзотеке по уровню их сходства со следами на исследуемой пуле, после чего эксперт сравнивает наиболее похожие следы. По результатам сравнительного анализа совмещенных следов формируется вывод об одном или разных экземплярах оружия.

Следы от полей нарезов формируются на поверхности пули при прохождении ею канала нарезного ствола и называются вторичными следами. Они представляют собой наборы параллельно расположенных трасс, наклоненных относительно продольной оси пули под углом, равным углу наклона нарезов [2].

В последние десятилетия ведутся активные исследования с целью разработки алгоритма автоматического сравнения таких следов, что позволит не только сократить время исследований, но и уменьшить субъективную составляющую в обосновании категорических выводов «пули выстрелены из одного экземпляра оружия» или «пули выстрелены из разных экземпляров оружия».

Большинство методов автоматического сравнения следов основано на оценке функции взаимной корреляции изображений следов или на подсчете числа совпадающих и несовпадающих трасс в сравниваемых следах, серий последовательно совпадающих трасс и т. п. Эффективность методов, основанных на расчете функции взаимной корреляции [3, 4], зависит от шумовых пространственных неоднородностей

на изображениях, они не эффективны для следов с малым числом трасс. Более перспективным представляется метод сравнения, основанный на подсчете как совпадающих, так и различающихся признаков, таких как число совпадающих трасс, серии последовательно совпадающих и последовательно не совпадающих трасс, отношение числа совпадающих широких трасс к среднему числу широких трасс в анализируемых следах и т. п. [5–10]. Для корректного автоматического подсчета совпадающих и различающихся признаков (трасс) изображения исследуемых следов на поверхности пули необходимо качественно бинаризовать.

Самым простым способом является бинаризация изображений по глобальному порогу [11]. Однако с ее помощью невозможно получить качественные бинарные изображения из-за присутствия пятен окисления на поверхности оболочки пули, неравномерного освещения поверхности пули и по ряду других причин. Применение приемов выравнивания освещения, например метода гомоморфной обработки изображений [11], не позволяет в полной мере решить указанную проблему. Кроме яркостных неоднородностей, отдельные трассы могут иметь достаточно протяженные разрывы, разную яркость (выраженность) и ширину по всей длине, искривления и т. п., поэтому бинаризация изображений по глобальному порогу не позволяет выделить трассы в виде идеально ровных полос. Применение адаптивного порога бинаризации, например методом Отсу (Otsu's method)¹, также не позволяет получать идеализированные бинарные изображения трасс без разрывов, искривлений, локальных утончений и расширений и т. д.

В работах [6, 9] бинаризацию изображений вторичных следов проводят методом сечения кривой яркости. Его суть заключается в построении кривой средней яркости по столбцам пикселей изображения с последующим ее сечением на некоторой высоте. Для этого исходные изображения

¹ Imbinarize // MATLAB Help Center.
<https://www.mathworks.com/help/images/ref/imbinarize.html>

поворачиваются на угол наклона нарезов так, чтобы трассы во вторичных следах приобрели вертикальное положение (рис. 1а, отм. 1). После чего строится кривая яркости (рис. 1б, отм. 2), на которой определяются координаты локальных максимумов и локальных минимумов. Для каждого локального максимума определяется свой порог бинаризации H , который рассчитывается как срединное значение между значениями яркости в точках максимума и ближайшего минимума [6, 9]. Всем пикселям изображения, расположенным между двумя соседними минимумами, присваивается значение 1 (признак), если их яркость превышает значение H , остальные пиксели считаются фоном (отсутствие признака) со значением яркости равным нулю (рис. 1, отм. 3).

К основным недостаткам данного метода можно отнести генерацию на бинарном изображении несуществующих трасс из-за яркостных локальных неоднородностей, слияние близко расположенных трасс с размытыми границами. В результате полученное бинарное изображение может отличаться от следовой картины, которую представляет эксперт-баллист.

Метод решения задачи исследования

Как уже отмечалось, целью работы является исследование возможности бинаризации изображений вторичных следов с помощью алгоритма семантической бинарной сегментации, реализованного на основе сверточной нейронной сети. Ожидается, что нейронная сеть, обученная на выборке изображений следов, размеченных экс-

пертом, будет «видеть» трассы в бинарном виде так же, как их видит эксперт-баллист.

Семантическая бинарная сегментация разделяет пиксели анализируемого изображения по категориям. В результате часть пикселей определяется как фон, а другая часть – как объект² [13], которым в данном случае является трасса шириной 1 пиксель. Например, трасса шириной 4 пикселя будет представлена в виде набора из четырех подряд следующих трасс шириной 1 пиксель каждая.

Идея бинаризации изображений вторичных следов с помощью такой модели заключается в следующем. Изображение вторичного следа, повернутое на угол наклона нарезов (рис. 1б), представляет собой набор вертикальных линий различной яркости, выраженности, с локальными утончениями/утолщениями и т. п. Их можно представить в виде идеализированных столбцов пикселей с яркостью 1 и 0, где 1 соответствует трассе, а 0 – фону. Двумерное бинарное изображение с вертикальными линиями можно перевести в одномерную вектор-строку без потери информации. Каждый элемент такой строки будет принимать значение 0 или 1. Если каждому элементу вектор-строки будет соответствовать выходной нейрон полносвязной нейронной сети, то задачей модели будет формирование значения бинарного сигнала на каждом выходном нейроне. Это будет соответствовать определению цвета (белый или черный) каждого столбца исходного изображения следа.

² Эволюция архитектур нейросетей в компьютерном зрении: сегментация изображений // Хабр. 11.12.2024.: <https://habr.com/ru/companies/slsoft/articles/864994>



Рис. 1. Преобразование исходного изображения, представленного в градациях серого, в бинарный вид: а – фрагмент кривой яркости; б – исходное изображение следа (1) с кривой средней яркости по столбцам (2), исходное изображение в бинарном виде, полученное методом сечения кривой яркости (3)

Fig. 1. Transformation of the original image presented in grayscale into binary form: а – fragment of the brightness curve; б – original trace image (1) with the average brightness curve by columns (2), original image in binary form obtained by the brightness curve section method (3)

Архитектура сверточной нейронной сети (СНС)

Используемая в работе СНС представляет собой стандартную сверточную сеть, включающую полносвязную сеть с функцией активации sigmoid (рис. 2).




Рис. 2. Блок-схема сверточной нейронной сети, используемой в работе

Fig. 2. Block diagram of a convolutional neural network used in the work

На этапе предварительных исследований было оптимизировано число сверточных слоев, размеры и число фильтров свертки. Применение пакетной нормализации (mini-batch normalization) позволяет выровнять значимость каждого признака путем нормализации диапазонов их значений. В данной работе использовались мини-пакеты, включающие по 64 объекта обучающей выборки каждый. В сверточной части нейросети применялась стандартная функция активации ReLU, которая позволяет уменьшить затухание градиента. В третьем сверточном слое применялась

функция maxpooling с шагом, равным единице по горизонтали и двум по вертикали.

В полносвязной нейронной сети использовалась функция активации sigmoid. В качестве функции потерь в данной сети используется функция бинарной кросс-энтропии (BinaryCrossEntropyloss) по аналогии с многометочной классификацией³.

Формирование обучающей выборки

Особенностью применения методов машинного обучения и глубокого обучения в задачах баллистической идентификации является ограниченность в формировании репрезентативной обучающей выборки. Обусловлено это необходимостью многократного отстрела большого числа экземпляров оружия. Для формирования обучающей выборки было отобрано 160 изображений вторичных следов размером 60 x 250 пс, содержащих в среднем от 20 до 45 трасс разной ширины. Авторами была проведена разметка столбцов матрицы исходных изображений: отмечено, какой столбец относится к фону и на бинарном изображении должен быть окрашен в черный цвет, а какой столбец относится к трассе и должен быть окрашен в белый цвет. Таким образом, для каждого исходного изображения была получена бинарная вектор-строка, которая определяла идеальные сигналы на выходных нейронах.

Как отмечено выше, в рамках исследования было отобрано и обработано 160 изображений вторичных следов. Каждый след представлял собой отдельный класс, который характеризовался своим уникальным набором бинаризованных трасс. Так как требуется обучить нейронную сеть определять бинарную яркость каждого столбца изображения, необходимо использовать наборы, включающие как минимум несколько десятков изображений. Для решения этой проблемы применяют различные методы расширения набора собранных данных (аугментация) [12], которые могут существенно различаться в зависимости от исходных данных. Для реализации аугментации обучающей выборки исходные изображения вторичных следов были дополнены искусственно сгенерированными изображениями.

В целом, объекты обучающей выборки представляли три категории изображений: изображения реальных вторичных следов с

³ Multilabel Image Classification Using Deep Learning // MATLAB Help Center. <https://www.mathworks.com/help/deeplearning/ug/multilabel-image-classification-using-deep-learning.html>

вертикально ориентированными трассами (160 исходных изображений); клоновые изображения, построенные на основе исходных изображений; изображения вторичных следов в градациях серого, искусственно сгенерированные на основе бинарных вектор-строк для исходных изображений обучающей выборки. В качестве исходных изображений использовали изображения вторичных следов на пулях, выстреленных из пистолета Макарова.

Методика формирования клоновых изображений заключалась в следующем. Исходное изображение, представляющее собой матрицу размером $m \times n$ (где m – количество строк, n – количество столбцов), разбивали на k полос, имеющих m/k строк и n столбцов. Далее все k полос изображения перемешивали и соединяли обратно в матрицу размером $m \times n$. Получившаяся матрица являлась «клоном» исходного изображения, в котором сохранены характеристики яркости и расположение признаков-трасс, но случайным образом послойно перемешаны яркостные неоднородности. Для каждого исходного изображения было получено по 20 клоновых изображений.

Генерацию новых изображений обучающей выборки с заведомо известными распределениями трасс проводили следующим образом. Каждое исходное изображение (рис. 3а) было преобразовано экспертом в бинарную вектор-строку, на основе которой формировали бинарное изображение размером 60 x 250 пс (рис. 3б). Далее бинарное изображение подвергали разного рода искажениям, чтобы визуально приблизить его к изображениям реальных следов.

Случайные искажения включали в себя: небольшие локальные сдвиги трасс влево-вправо на разной высоте на 1–3 пикселя в зависимости от их ширины; локальные разрывы трасс; рандомные утончения с разрывом отдельных трасс; плавную по развертке следа модуляцию яркости трасс, что позволяло имитировать разную яркость трасс; наложение изображения поверхности пули без следов канала ствола (фон) с прозрачностью слоя порядка 50% на искусственное изображение; нанесение на конечной стадии на изображение случайным образом шумовых пространственных неоднородностей. В качестве примера на рисунке 3вг представлены изображения в градациях серого, сгенерированные на основе бинарного изображения, представленного на рисунке 3б.

Для каждого объекта обучающей выборки было сформировано по 20 искусствен-

ных изображений. Таким образом, в общем на каждое исходное изображение обучающей выборки приходилось по 40 новых изображений. С целью эффективного обучения модели нейронной сети и предотвращения ее переобучения все изображения обучающей выборки делили на 10 сегментов по 25 пикселей каждый. После бинаризации фрагменты сшивали в соответствующем порядке и вновь формировали изображения следов размером 60 x 250 пс.

Программа алгоритма

Программа включает следующие основные блоки:

1. Загрузка обучающей и тестовой выборок (тестовая выборка составляла 10% от числа исходных изображений обучающей выборки), а также бинарных масок для каждого исходного изображения.

2. Предварительная обработка изображений, включающая фильтр сглаживания (3 x 1) исходных изображений и подпрограмму выравнивания яркости изображений.

3. Разбиение исходных изображений на фрагменты равной длины, в данном случае – разбиение на 10 фрагментов длиной по 25 пс каждый.

4. Формирование для СНС с помощью бинарных масок идеальных выходов, состоящих из нулей и единиц.

5. Сверточная нейронная сеть с полносвязной нейронной сетью с сигмоидной функцией активации на выходе.

6. Восстановление полных изображений из фрагментов.

7. Бинаризация по глобальному порогу (в данном случае порог равен 0.5) значений элементов вектор строки, сформированной на выходных нейронах СНС.

8. Оценки с помощью различных метрик⁴ точности формирования в бинарном виде тестовых изображений.

Генераторы клоновых изображений не включены в основную программу, поскольку они применялись отдельно на предварительном этапе.

Обучение СНС и бинаризация изображений вторичных следов

В качестве эталона использовали бинарные вектор-строки, полученные пятью экспертами в ручном режиме для исходных изображений обучающей выборки. Программа

⁴ Метрики в задачах машинного обучения // Блог компании Open Data Science. <https://fmsha-programming.github.io/seminars/2022-01-20/target.pdf>




Рис. 3. Генерация новых изображений: а – исходное изображение; б – исходное изображение в бинарном виде; в, г – изображения, построенные на основе бинарного, представленного на рис. 3б
Fig. 3. Generation of new images: a – original image; b – original image in binary form; c, d – images constructed on the basis of the binary image shown in fig. 3 b

формировала обобщенную вектор-строку к каждому исходному изображению на основе анализа вектор-строк, представленных всеми экспертами. Элементы вектор-строки, выделенные тремя и более экспертами как относящиеся к трассе, таковыми и считались, и на обобщенной вектор-строке им присваивалось значение 1. Остальные элементы считали относящимися к фону и им присваивалось значение, равное нулю. Это позволило уменьшить субъективный фактор, но не исключить его полностью.

Расчеты проводили при разных значениях гиперпараметров нейронной сети: скорость обучения изменялась в пределах от 0,2 до 0,00002; момент изменялся от 0,1 до 0,9; число эпох изменялось от 2 до 25; исследуемые изображения следов разбивались на 25, 10, 5 сегментов; изменялась конфигурация фильтров свертки; изменялась вариативность клоновых изображений.

Проведенные расчеты показали, что для обучения сети достаточно 15–25 эпох обучения. При малом числе эпох (пять и менее) на бинарных изображениях возможно формирование нескольких шумовых трасс. При скорости обучения 0,1 и более алгоритм прекращает обучаться. По остальным гиперпараметрам можно отметить слабую зависимость результатов расчетов от их значений. По результатам предварительного исследования были выбраны следующие параметры сети: скорость обучения 0,0002 и 0,00002;

момент 0,6; число эпох 25; изображения разбивались на 10 сегментов (по 25 пикселей); фильтры сверточных слоев имели следующие размеры – 9 x 5 (1-й слой), 7 x 5 (2-й слой), 5 x 3 (3-й слой), 3 x 1 (4-й слой).

На рисунке 4 представлены изображения двух тестовых следов в градациях серого (сверху), совмещенных с бинарными изображениями следов, сформированных алгоритмом (в центре), а также с бинарными изображениями этих следов, сформированными экспертами (снизу).

Сравнение бинарных изображений, сгенерированных СНС, с изображениями, полученными специалистами, показало следующее.

1. Абсолютное большинство трасс, выделенных специалистами и алгоритмом, совпадает хотя бы частично. То есть алгоритм «увидел» трассы, выделенные специалистами.

2. Основной вклад в ошибку вносит несоответствие ширин и положений центров трасс, выделенных специалистами и алгоритмом.

3. Вклад в ошибку вносят также трассы, сформированные алгоритмом там, где они были случайно пропущены экспертами (иногда 1–2 трассы в одном следе). В результате ошибка может возрасти даже тогда, когда нейронная сеть бинаризовала трассы лучше, чем специалисты.

На рисунке 5 представлен след, сформированный полем нарезки автомата Калаш-




Рис. 4. Исходные изображения двух тестовых следов на пулях, выстреленных из пистолета Макарова, представленные в градациях серого (сверху); бинарные изображения данных следов, спрогнозированные алгоритмом (в центре); изображения, полученные на основе бинарных вектор-строк, сформированных экспертами (снизу)

Fig. 4. Original grayscale images of two test traces on bullets fired from a Makarov pistol (top); binary images of these traces predicted by an algorithm (center); images made from binary vector rows generated by experts (bottom)

никова калибра 7.62 мм. Видно, что следы, характерные для АКМ, существенно отличаются по выраженности и плотности трасс от следов на пулях, выстреленных из пистолета Макарова, которые формировали обучающую выборку. Однако обученная модель достаточно качественно проводит бинаризацию изображений следов, характерных для автомата семейства «Калашников», на которых она не обучалась.

Классификация пар изображений вторичных следов по категориям «следы совпадающие» и «следы не совпадающие»

С целью оценки пригодности бинарных изображений, полученных с помощью алгоритма, к последующей классификации по категориям «следы совпадающие» (в криминалистическом смысле) и «следы не совпадающие» проводили предварительное исследование.

Формировали новую выборку пар изображений вторичных следов, включающую 335 пар заведомо совпадающих и 335 пар не совпадающих следов. Все изображения следов были бинаризованы предварительно обученным алгоритмом. Далее изображения каждой пары следов сдвигали относительно друг друга и определяли позицию, при которой наблюдалось наибольшее число совпадающих трасс. Считали, что в этой позиции они имеют максимальное сходство между

собой. В таком положении для каждой пары следов подсчитывали совпадающие и различающиеся признаки, такие как число совпадающих трасс, серии последовательно совпадающих и последовательно не совпадающих трасс, отношение числа трасс в одном следе к числу трасс во втором следе и т. д. Таким образом, каждая пара следов характеризовалась набором из 11 совпадающих и различающихся признаков.

Для бинарной классификации пар следов по выделенным признакам применяли метод случайного леса (англ. Random Forest). 10% пар совпадающих и различающихся следов (по 35 пар каждого типа) отбирали для тестовой выборки случайным образом. После обучения модели точность классификации объектов тестовой выборки в соответствии с метрикой Accuracy составила порядка 84–86%. Предварительный анализ классификационной значимости отдельных признаков показал потенциальную возможность дальнейшего повышения точности классификации как за счет улучшения бинаризации, так и за счет оптимизации номенклатуры признаков.

Заключение

Исследования показали работоспособность предложенного метода бинаризации изображений следов полей нарезов, основанного на применении семантической би-




Рис. 5. Исходное изображение тестового следа на пуле, выстреленной из автомата Калашникова модернизированного, представленное в градациях серого (сверху); бинарное изображение данного следа, спрогнозированное алгоритмом (в центре); изображение, полученное на основе бинарных вектор-строк, сформированных экспертами (снизу)

Fig. 5. Initial grayscale images of two test traces on bullets fired from a modernized Kalashnikov assault rifle (top); binary images of these traces predicted by an algorithm (center); images made from binary vector rows generated by experts (bottom)

нарной сегментации. Точность бинаризации изображений вторичных следов составляет, в соответствии с метриками: Accuracy = $0,88 \pm 0,05$, Recall = $0,76 \pm 0,06$, Precision = $0,83 \pm 0,06$, $F_1 = 0,79 \pm 0,05$, MCC = $0,71 \pm 0,06$.

Проведенные исследования показали перспективность применения сверточной нейронной сети с такой архитектурой для

бинаризации изображений вторичных следов с целью их последующей классификации по категориям «следы совпадающие» и «следы не совпадающие».

Работа представляет интерес для специалистов в области идентификации огнестрельного оружия и разработчиков программного обеспечения автоматизированных баллистических идентификационных систем.

СПИСОК ЛИТЕРАТУРЫ

1. Дильдин Ю.М., Мартынов В.В. Типовые экспертные методики исследования вещественных доказательств. Часть 1. М.: Интеркрим-пресс, 2010. 568 с.
2. Кокин А.В., Ярмак К.В. Судебная баллистика и судебно-баллистическая экспертиза : учебник. М.: Юнити-дана: Закон и право, 2017. 350 с.
3. Chen Z., Chu W., Soons J.A., Thompson R.M., Song J., Zhao X. Fired Bullet Signature Correlation Using the Congruent Matching Profile Segments (CMPS) Method // *Forensic Science International*. 2019. Vol. 305. P. 10–19. <https://doi.org/10.1016/j.forsciint.2019.109964>
4. Chen Z., Song J., Soons J.A., Thompson R.M., Zhao X. Pilot Study on Deformed Bullet Correlation // *Forensic Science International*. 2020. Vol. 306. P. 1–11. <https://doi.org/10.1016/j.forsciint.2019.110098>
5. Biasotti A.A. Statistical Study of the Individual Characteristics of Fired Bullets // *Journal of Forensic Sciences*. 1959. Vol. 4. No. 1. P. 34–50.
6. Федоренко В.А., Навроцкая Е.В. Критерии и алгоритм оценки уникальности комплексов совпадающих трасс в следах на выстреленных пулях // *Информационные технологии и вычислительные системы*. 2019. № 1. С. 110–120. <https://doi.org/10.14357/20718632190110>

REFERENCES

1. Dil'din Yu.M., Martynov V.V. *Typical Expert Methods for Examination of Physical Evidence. Part 1*. Moscow : INTERKRIM-PRESS, 2010. 568 p. (In Russ.).
2. Kokin A.V., Yarmak K.V. *Forensic Ballistics and Forensic Ballistic Examination. Textbook*. Moscow: Yuniti-dana: Zakon i pravo, 2017. 350 p. (In Russ.).
3. Chen Z., Chu W., Soons J.A., Thompson R.M., Song J., Zhao X. Fired Bullet Signature Correlation Using the Congruent Matching Profile Segments (CMPS) Method. *Forensic Science International*. 2019. Vol. 305. P. 10–19. <https://doi.org/10.1016/j.forsciint.2019.109964>
4. Chen Z., Song J., Soons J.A., Thompson R.M., Zhao X. Pilot Study on Deformed Bullet Correlation. *Forensic Science International*. 2020. Vol. 306. P. 1–11. <https://doi.org/10.1016/j.forsciint.2019.110098>
5. Biasotti A.A. Statistical Study of the Individual Characteristics of Fired Bullets. *Journal of Forensic Sciences*. 1959. Vol. 4. No. 1. P. 34–50.
6. Fedorenko V.A., Navrotskaya E.V. Criteria and Algorithm of the Evaluation of the Uniqueness of the Complexes of Matching Tracks in the Traces on the Shot Bullets. *Journal of Information Technologies and Computation Systems*. 2019. No. 1. P. 110–120. (In Russ.). <https://doi.org/10.14357/20718632190110>

7. Hare E., Hofmann H., Carriquiry A. Algorithmic Approaches to Match Degraded Land Impressions // *Law, Probability and Risk*. 2017. Vol. 16. No. 4. P. 203–221.
<https://doi.org/10.1093/lpr/mgx018>
8. Hare E., Hofmann H., Carriquiry A. Automatic Matching of Bullet Land Impressions // *The Annals of Applied Statistics*. 2017. Vol. 11. No. 4. P. 2332–2356.
<https://doi.org/10.1214/17-AOAS1080>
9. Fedorenko V., Sorokina K., Giverts P. Analysis of Traces on Discharged Bullets by the Congruent Matching Profile Segments Method and k-Nearest Neighbors // *Programming and Computer Software*. 2023. Vol. 49. No. 2. P. 72–81.
<https://doi.org/10.1134/S036176882310002X>
10. Федоренко В.А., Сорокина К.О., Гиверц П.В. Анализ следов на выстреленных пулях методами конгруэнтно совпадающих сегментов профилей и k-ближайших соседей // *Информационные технологии и вычислительные системы*. 2021. № 1. С. 70–82.
<https://doi.org/10.14357/20718632210108>
11. Гонсалес Р., Вудс Р. Мир цифровой обработки. Цифровая обработка изображений / пер. с англ.; под ред. П.А. Чочиа. М.: Техносфера, 2019. 1104 с.
12. Китов В.В. Аугментация данных // *Машинное и глубокое обучение*. Онлайн-учебник. <https://deepmachinelearning.ru/docs/Neural-networks/Regularization/Augmentation>
7. Hare E., Hofmann H., Carriquiry A. Algorithmic Approaches to Match Degraded Land Impressions. *Law, Probability and Risk*. 2017. Vol. 16. No. 4. P. 203–221.
<https://doi.org/10.1093/lpr/mgx018>
8. Hare E., Hofmann H., Carriquiry A. Automatic Matching of Bullet Land Impressions. *The Annals of Applied Statistics*. 2017. Vol. 11. No. 4. P. 2332–2356.
<https://doi.org/10.1214/17-AOAS1080>
9. Fedorenko V., Sorokina K., Giverts P. Analysis of Traces on Discharged Bullets by the Congruent Matching Profile Segments Method and k-Nearest Neighbors. *Programming and Computer Software*. 2023. Vol. 49. No. 2. P. 72–81.
<https://doi.org/10.1134/S036176882310002X>
10. Fedorenko V.A., Sorokina K.O., Giverts P.V. Analysis of Traces on the Discharged Bullets by the Congruent Matching Profile Segments Method and k-Nearest Neighbors. *Journal of Information Technologies and Computation Systems*. 2021. No. 1. P. 70–82. (In Russ.).
<https://doi.org/10.14357/20718632210108>
11. Gonsales R., Vuds R. *The World of Digital Processing. Digital Image Processing*. P.A. Chochia (ed.). Moscow: Tekhnosfera, 2019. 1104 p. (In Russ.).
12. Kitov V.V. *Data Augmentation. Machine and Deep Learning. Online Textbook*. (In Russ.). <https://deepmachinelearning.ru/docs/Neural-networks/Regularization/Augmentation>

ИНФОРМАЦИЯ ОБ АВТОРАХ

Федоренко Владимир Александрович – к.ф.-м.н., доцент, заведующий учебно-научной лабораторией криминалистического материаловедения института физики Саратовского национального исследовательского государственного университета им. Н.Г. Чернышевского;
e-mail: fed77@yandex.ru

Сорокина Ксения Олеговна – программист учебно-научной лаборатории криминалистического материаловедения института физики Саратовского национального исследовательского государственного университета им. Н.Г. Чернышевского; e-mail: lorredos@gmail.com

Навроцкая Елена Владимировна – к.ф.-м.н., программист учебно-научной лаборатории криминалистического материаловедения, доцент кафедры динамического моделирования и биомедицинской инженерии Саратовского национального исследовательского государственного университета им. Н.Г. Чернышевского;
e-mail: sidakev@gmail.com

Грибер Александра Леонидовна – эксперт по огнестрельному оружию Баллистической лаборатории полиции Израиля;
e-mail: gribersandra@gmail.com

ABOUT THE AUTHORS

Fedorenko Vladimir Aleksandrovich – Candidate of Physico-Mathematical Sciences, Associate Professor, Head of Educational and Scientific Laboratory of Forensic Materials Engineering, Saratov State University, Russia;
e-mail: fed77@yandex.ru

Sorokina Ksenia Olegovna – Programmer of Educational and Scientific Laboratory of Forensic Materials Engineering, Saratov State University, Saratov, Russia; e-mail: lorredos@gmail.com

Navrotskaya Elena Vladimirovna – Candidate of Physico-Mathematical Sciences, Programmer of the Educational and Scientific Laboratory of Forensic Materials Engineering, Saratov State University, Saratov, Russia; e-mail: sidakev@gmail.com

Griber Alexandra Leonidovna – B.Sc. и MBA, Firearm Expert, Forensic Laboratory of Firearm Examination, Israel Police HQ;
e-mail: gribersandra@gmail.com

Статья поступила: 02.12.2025
После доработки: 10.04.2026
Принята к печати: 30.04.2026

Received: December 02, 2026
Revised: April 10, 2026
Accepted: April 30, 2026