

Классификация следов бойков по экземплярам оружия сверточной нейронной сетью

В. А. Федоренко¹, К. О. Сорокина¹, П. В. Гиверц²

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

²Баллистическая лаборатория полиции Израиля, Иерусалим, Израиль

Аннотация. В статье рассматривается проблема классификации изображений следов бойков с помощью сверточной нейронной сети (СНС). Целью данной работы являлось исследование эффективности применения сверточных нейронных сетей для классификации следов бойков по экземплярам оружия. Научная новизна заключается в оценке эффективности применения СНС для многогрупповой классификации следов бойков в условиях сверхмалого числа исходных объектов обучающей выборки для каждого класса (по 4 исходных изображения в каждом классе). Для обеспечения эффективности обучения СНС была сформирована аугментированная обучающая выборка. Для этого на основе каждого исходного изображения обучающей выборки были получены по 8 новых изображений с измененными в допустимых пределах характеристиками. Исследования показали, что для выборки, включающей 40 классов (экземпляров оружия), точность классификации СНС достигает порядка 93% в случае учета максимального сигнала на одном выходном нейроне и 97-98% при классификации по трем наибольшим сигналам на выходных нейронах. Работа представляет интерес для разработчиков программного обеспечения автоматизированных баллистических идентификационных систем и для сотрудников региональных криминалистических лабораторий.

Ключевые слова: следы бойков, сверточные нейронные сети, многогрупповая классификация, аугментация выборки, идентификация оружия.

DOI 10.14357/20718632240109

EDN ZHVVQQ

Введение

При расследовании преступлений, связанных с применением огнестрельного оружия, наравне с другими следственными действиями, выполняется баллистическая экспертиза, при которой часто возникает необходимость сравнения гильз. Результаты исследования позволяют связать конкретный экземпляр оружия с местом его криминального применения. В большинстве случаев экспертное исследование можно свести к решению двух задач [1].

1. Выполнение "бинарного" сравнения, т.е. установление тождества или его отсутствия между двумя гильзами. Это могут быть гильзы,

обнаруженные на месте преступления, или гильза с места преступления и гильза, полученная при экспериментальном отстреле изъятого оружия.

2. Поиск по гильзотекам (проведение проверок), когда необходимо установить применялось ли ранее оружие, использованное в расследуемом преступлении. В этом случае из множества гильз, хранящихся в гильзотеке, нужно выделить гильзы, имеющие наибольшее соответствие идентифицирующих признаков. В дальнейшем, эксперт-баллист решает задачу "бинарного" сравнения для каждой выделенной гильзы.

Иногда возникает необходимость в решении дополнительных задач. Так, бывают ситуации, когда на месте происшествия обнаружено большое количество гильз и имеется конечное множество единиц оружия участвовавших в стрельбе. К таким случаям можно отнести: происшествия на стрельбищах или военных училищах; криминальные перестрелки, возможно с участием сил охраны правопорядка, когда все участники известны и оружие изъято и т.п. Тогда возникает необходимость в распределении изъятых гильз по классам, соответствующим каждому изъятому экземпляру оружия.

Для решения задач "бинарного" сравнения эксперты-баллисты используют оптические сравнительные микроскопы, позволяющие сопоставлять следовую картину на двух исследуемых гильзах. Для решения задачи поиска по гильзотекам и учетам стреляных гильз, изъятых с мест преступлений, которые ведутся в региональных экспертно-криминалистических центрах, применяются различные автоматизированные баллистические идентификационные системы типа «POISC», «АБИС РАМЭК», «Арсенал» и др. [2, 3]. Следует отметить, что не все региональные экспертно-криминалистические центры оснащены такими системами. Однако, все криминалистические баллистические лаборатории снабжены микроскопами, позволяющими получать цифровые изображения следов бойков при одном и том же увеличении и направлении освещения. Проведение поиска по базам данных (БД) таких изображений в ручном режиме может быть достаточно трудоемким и продолжительным по времени. Поэтому практи-

ческий интерес представляет применение алгоритма машинного обучения, адаптированного на проведение проверок по таким базам данных цифровых изображений следов бойков. Известно, что сверточные нейронные сети предназначены для анализа и классификации изображений [4], поэтому определение эффективности их применения в качестве классификатора изображений следов бойков представляет интерес.

Целью данной работы является исследование возможности создания на основе сверточной нейронной сети объективного автоматизированного классификатора изображений следов бойков по экземплярам оружия региональных баз данных (гильзотек), включающих десятки экземпляров (классов) оружия одной модели.

1. Методы компьютерного анализа и сравнения следов бойков

Разработка эффективного алгоритма автоматической классификации изображений следов бойков по экземплярам оружия является сложной технической задачей, которая обусловлена, в первую очередь, большим разнообразием типов микронеоднородностей поверхности бойков, отобразившихся в следах [5]. На Рис. 1 в качестве примера представлены изображения нескольких следов бойков с разными типами индивидуализирующих признаков. Сложно разработать единый алгоритм выделения и сравнения столь различающихся признаков.

Для проведения поиска (проверок) в автоматическом режиме по базам данных цифровых изображений следов применяются указанные

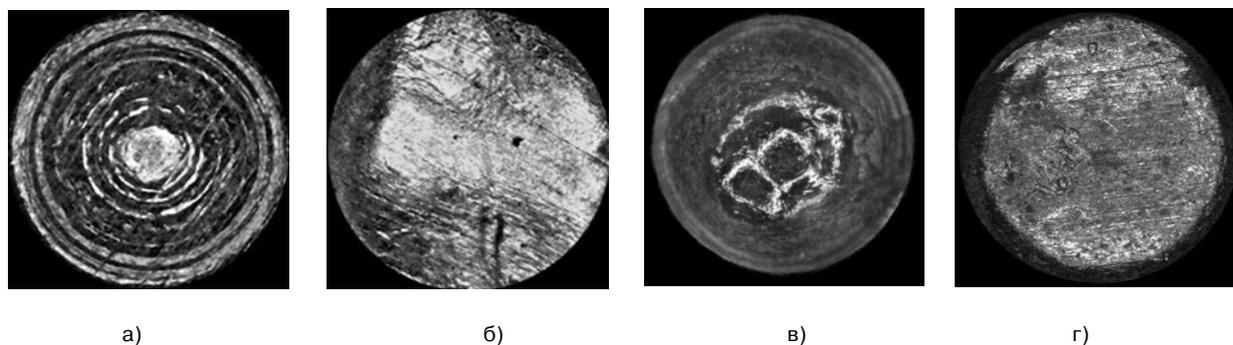


Рис. 1. Изображения следов бойков с разными типами индивидуализирующих признаков
а) в виде окружностей; б) в виде крупных неоднородностей произвольной формы; в) в виде пятен;
г) в виде однородной плоскости со слабо выраженными особенностями

выше автоматизированные баллистические идентификационные комплексы. С их помощью проводится сканирование донных частей стреляных гильз, получение цифровых изображений следов бойков и последующее сравнение изображения исследуемого следа бойка с изображениями следов бойков такой же модели оружия, имеющихся в региональной базе данных. Сравнение производится методом построения функции взаимной корреляции (ФВК): чем больше максимум функции, тем более схожими являются сравниваемые изображения. По величине максимумов ФВК (от большего к меньшему) формируется приоритетный список схожести исследуемого изображения с изображениями следов бойков БД. Успехом считается, если в первую пятерку (десятку) попадает изображение парного (оставленного тем же бойком) следа. К недостаткам таких систем можно отнести негативное влияние разного рода засветок и артефактов (например, следов производства капсюлей) на поведение ФВК.

Одним из перспективных методов оценки схожести следов бойков в настоящее время считается метод «конгруэнтных совпадающих ячеек» (СМС - Congruent Matching Cells), разработанный Дж. Сонгом [6, 7]. Суть методики заключается в разбиении сопоставляемых следов на равные ячейки, поиске методами корреляционного анализа на втором следе ячеек со сходными характеристиками, сопоставлении положения хорошо коррелирующих ячеек на анализируемых изображениях. К несомненным достоинствам данного метода следует отнести произвольную ориентацию сопоставляемых изображений и автоматический поиск ячеек со схожими фрагментами изображений. Данный метод позволяет исключать из анализа разного рода засветки и артефакты на изображениях сравниваемых следов. В конечном счете вместо одного глобального значения коэффициента корреляции для полных изображений на выходе получается множество значений коэффициентов корреляций для хорошо коррелирующих фрагментов изображений сопоставляемых пар ячеек.

Однако СМС-метод не лишен и недостатков. Во-первых, метод рассчитан на бинарную классификацию следов бойков. Во-вторых, для

корректного расчета коэффициента правдоподобия выдвинутой гипотезы (следы совпадающие или несовпадающие), необходимо определить статистические характеристики сравниваемых следов для различных моделей оружия и производителей патронов [8], что является чрезвычайно трудоемкой задачей, учитывая большое число производителей оружия и боеприпасов. Обусловлено это тем, что коэффициент правдоподобия LR выдвинутой гипотезы q (например, что следы совпадающие) определяется по формуле:

$$LR = P(q|I)/P(d|I), \quad (1)$$

где: $P(q|I)$ – плотность вероятности события I (например, распределение числа пар ячеек, имеющих высокий коэффициент корреляции) при условии q (следы совпадающие); $P(d|I)$ – плотность вероятности события I при условии d , противоположного условию q (следы несовпадающие). Плотности вероятностей представляют собой распределения Пуассона. Неоднородности микрорельефа поверхностей капсюлей разных производителей могут сильно различаться, в результате распределения Пуассона для них также будут отличаться и, соответственно, коэффициенты правдоподобия.

В работе F. Riva и C. Champod [9] сравнение следов бойков проводится с помощью алгоритма совпадающих точек (ICP), который сравнивает два изображения, представленных в 3D формате, минимизируя расстояния между выделенными точками одного следа и конфигурацией точек в другом следе. На выходе формируется набор следующих признаков, характеризующих степень схожести следов: среднее значение евклидовых расстояний между точками первого следа и ближайшими точками второго следа; коэффициент корреляции, учитывающий количество точек, совмещенных в сравниваемых следах; среднее значение разницы угла вектора нормали в каждой точке обеих поверхностей. Для выборки заведомо совпадающих следов и выборки заведомо не совпадающих следов строятся кривые распределения объектов в 3-мерном пространстве признаков. На основе распределений строятся кривые коэффициентов правдоподобия для гипотез, что следы совпадающие, и следы несовпадающие. По кривым коэффициентов правдоподобия

определяется класс, к которому следует отнести сравниваемую пару следов. Как следует из самой методики, она рассчитана на проведение бинарной классификации, а не многогрупповой. Кроме этого, как и в предыдущем случае, для корректного расчета коэффициента правдоподобия предварительно необходимо определить статистические характеристики сравниваемых следов для различных моделей оружия.

Для сравнения изображений следов бойков в работе [10] предложено использовать сиамскую нейронную сеть. В ходе исследований была сформирована сиамская нейронная сеть, включающая в себя две идентичные сверточные нейронные сети и проведено ее обучение. Для обучения и валидации модели сети была подготовлена база данных изображений следов бойков, полученных сканированием донных частей гильз, стреляных в 300 экземплярах огнестрельного оружия. База данных включала как исходные изображения следов, так и их клоновые копии со слегка измененными индивидуализирующими признаками. По результатам исследований были рассчитаны следующие характеристики:

- точность истинно положительных прогнозов TPR , которая оказалась равной 87%;
- точность истинно отрицательных прогнозов TNR , которая оказалась равной 88%;
- сбалансированная точность прогнозирования $Balanced Accuracy (BA)$, равная 87,5%.

$$TPR = TP / (TP + FN), \quad (2)$$

$$TNR = TN / (TN + FP), \quad (3)$$

$$BA = (TPR + TNR) / 2, \quad (4)$$

где: TP – истинно положительный прогноз; FP – ложно положительный прогноз; FN – ложно отрицательный прогноз; TN – истинно отрицательный прогноз.

В работе [5] предлагается проведение проверки с помощью полносвязных нейронных сетей (ПНС). Показано, что точность прогнозирования по одному выходному нейрону достигает 85%. Увеличение точности прогнозирования ограничено малыми размерами изображений (75x75 пс) и семантическим разрывом, обусловленным переводом на входе ПНС матриц исходных изображений в вектор столбец. Поэтому применение для этих целей сверточных нейронных сетей

(СНС), ориентированных на анализ и сравнение изображений, представляется более рациональным. Следует отметить, что нейронная сеть в процессе обучения самостоятельно учится выделять признаки, индивидуализирующие каждый класс, а не каждый объект обучающей выборки. Это выгодно отличает алгоритм многогрупповой классификации с помощью нейронных сетей от других алгоритмов машинного обучения, таких, как «Случайный лес», «к-ближайших соседей» и т.д.

Цифровые изображения следов бойков могут быть получены как с помощью баллистических сканеров типа «POISC», «АБИС РАМЭК», ABIS и др., так и с помощью цифровых микроскопов при одних и тех же условиях съемки всех объектов выборки.

2. Предварительная обработка исследуемых объектов

При формировании криминалистических пулетек и гильзотек в каждом экземпляре оружия отстреливается по три патрона. Поэтому в гильзотеках в основном содержится по 3 гильзы, стреляных в одном экземпляре оружия. С мест происшествий также редко изымается более 3-4-х гильз, стреляных в 1 экземпляре оружия. При этом из научной литературы известно, что для эффективного обучения нейронной сети необходимо иметь сотни изображений для каждого класса. Однако, поскольку изображения следов бойков можно получить при одном увеличении, разрешении, освещении и примерно при одной ориентации, можно предположить, что для обучения СНС потребуется гораздо меньшее число объектов.

С целью получения аугментированной выборки следов бойков на основе каждого исходного изображения были сформированы клоновые изображения. Клоны представляли собой исходные изображения, повернутые на углы ± 5 , ± 10 , ± 15 и ± 20 градусов со слегка искаженными признаками [5]. Таким образом, на основе каждого исходного изображения генерировалось еще 8 новых.

В данной работе использовались изображения следов бойков, полученные с помощью баллистического сканера «POISC». Центральная часть следа в форме окружности диаметром 230 пс

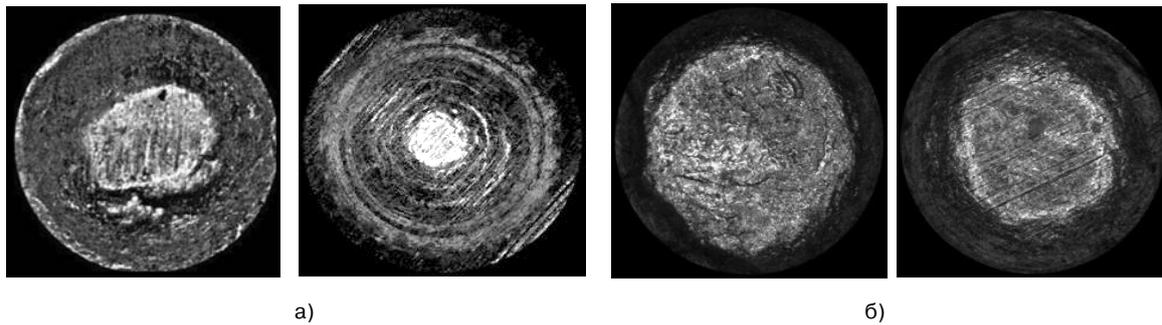


Рис. 2. Следы бойков круглой формы размером 240x240 пс

а) с ярко выраженными индивидуализирующими признаками; б) со слабо выраженными индивидуализирующими признаками

вырезалась и размещалась по центру кадра с черным фоном размером 240x240 пс (Рис. 2). Исходные изображения следов бойков получены при одинаковой ориентации стреляных гильз (как они располагались в патроннике в момент выстрела) в каретке баллистического сканера. В результате было сформировано 2 выборки изображений следов бойков, включающих 16 и 24 класса (БД1 и БД2 соответственно), а также выборка, представляющая собой объединение первых двух. В первой выборке доминировали следы с ярко выраженными признаками в виде пятен неопределенной формы или в виде окружностей (Рис. 2, а). Во второй выборке, включающей 24 класса, в следах доминировали слабо выраженные признаки (Рис. 2, б). В каждом классе содержалось от 5 до 8 изображений следов, сформированных бойком соответствующего экземпляра оружия. Всего было отсканировано 280 гильз, стреляных в 40 экземплярах оружия.

3. Обучение и тестирование СНС

Для исследований была выбрана сверточная нейронная сеть, состоящая из 6 сверточных слоев, 1 полносвязного слоя за которым следует функция (слой) *softmax* $\sigma(x_j)$ (5) и классифицирующий слой (Рис. 3). *Softmax* функция переводит наборы чисел на выходе полносвязного слоя в вероятности, причем сумма последних равна единице. Для ускорения обучения между каждым сверточным слоем и соответствующей функцией активации *ReLU* вставлен слой пакетной нормализации *batchNormalizationLayer*. За

каждой функцией активации следует слой *MaxPooling*. Алгоритм реализован на основе программы, представленной в библиотеке *MathWorks* [11].

$$\sigma(x_j) = \frac{e^{x_j}}{\sum_{i=1}^n e^{x_i}}, \quad (5)$$

где: i, j – порядковые номера выходных нейронов; n – число выходных нейронов.

Оценка точности классификации в процессе обучения используемой СНС проводится по следующему алгоритму. Исходная выборка делится на обучающую и тестовую. На каждой эпохе обучающая выборка случайным образом полностью делится на указанное оператором число мини-пакетов. Далее берется первый мини-пакет и для каждого его объекта рассчитывается ошибка, затем определяется средняя ошибка. В соответствии с величиной средней ошибки проводится корректировка весовых коэффициентов. Затем проводится оценка точности классификации по этому же пакету с занесением полученного значения на график *Training* (Рис. 4). Берется следующий мини-пакет и для него вся процедура повторяется вплоть до нанесения следующей точки точности классификации на графике *Training*. Аналогичным образом процедура повторяется для всех мини-пакетов. Затем начинается новая эпоха, в начале которой заново случайным образом формируется заданное число мини-пакетов, и описанный выше набор действий повторяется. Можно констатировать, что в данном алгоритме обучения валидационность реализуется на уровне эпох. В пределах одной эпохи кросс-валидация отсутствует.

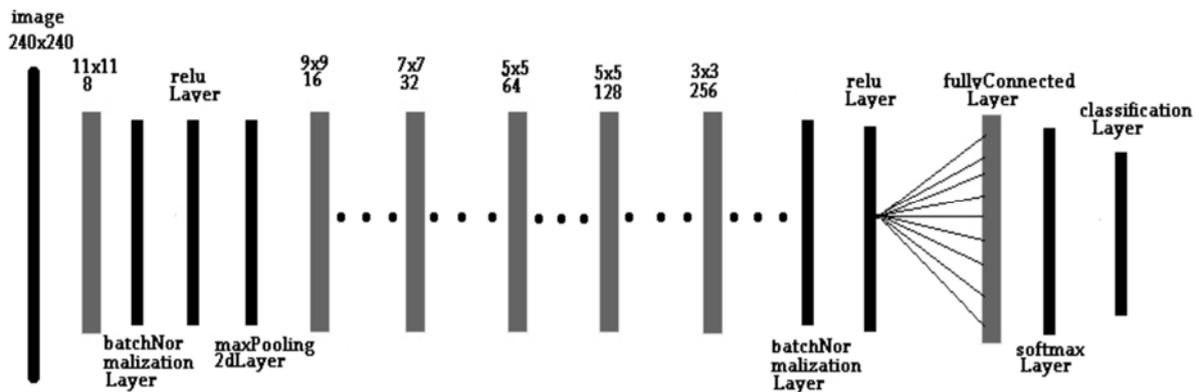


Рис. 3. Архитектура примененной сверточной нейронной сети



Рис. 4. Кривые точности классификации

Кроме этого с заданным шагом строится график точности классификации Test (Рис. 4) в соответствии с метрикой Accuracy, рассчитанной по тестовой выборке. Именно эти зависимости и используются в дальнейшем в данной работе в качестве индикатора качества прогнозирования.

На предварительном этапе было определено оптимальное число фильтров в сверточных слоях для данной архитектуры СНС. Для этого сверточную сеть с разным числом фильтров в каждом слое обучали на «коротких» выборках, включающих 16 и 24 класса. Определено, что для эффективного обучения сверточной сети для классификации изображений следов бойков, достаточным является следующее число фильтров: в первом слое – 8, во втором слое – 16, в третьем – 32, в четвертом – 64, в пятом – 128, в шестом слое – 256 (Рис. 3). При меньшем числе фильтров падает точность прогнозирования, а при большем числе значительно увеличивается

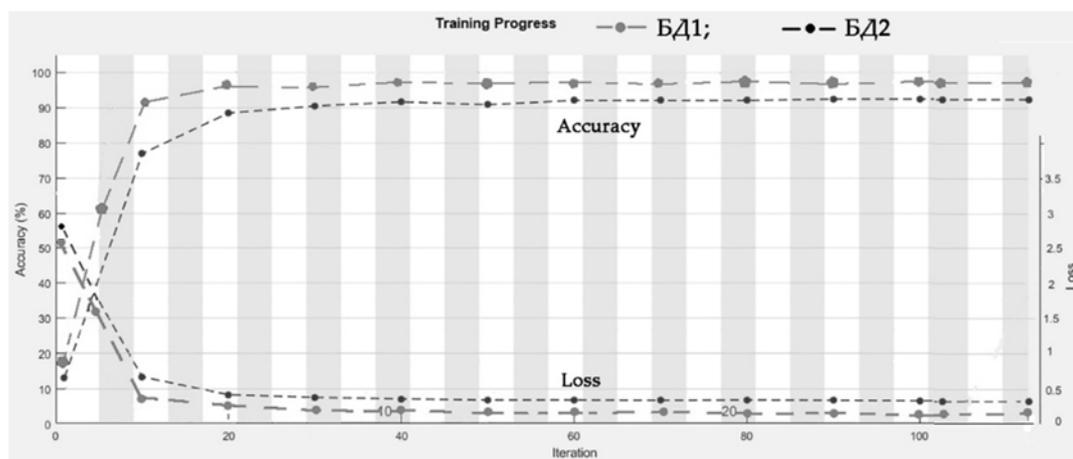
время обучения без заметного увеличения точности.

На первом этапе сверточную сеть обучали по выборкам, в каждый класс которых было включено по 3 исходных изображения и по 8 их клонов. Таким образом, в обучающую часть выборки каждого класса входило по 27 изображений, а оставшиеся исходные изображения формировали тестовую часть выборки. При обучении по первой базе данных была получена точность классификации 91-93% в соответствии с метрикой Accuracy, которая определяется по следующей формуле:

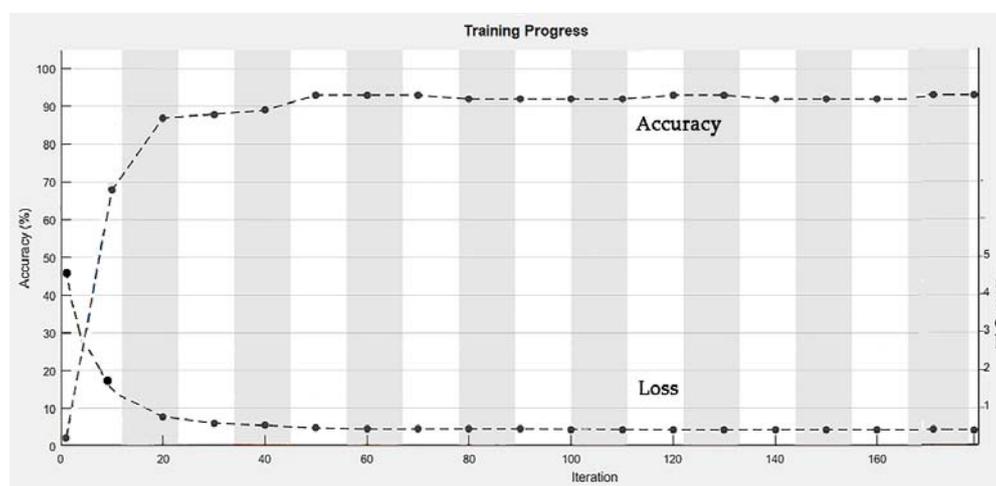
$$Accuracy = \frac{Correct}{Total}, \quad (6)$$

где: *Correct* – общее число правильных прогнозов; *Total* – общее число прогнозов.

При обучении по второй базе данных была достигнута точность классификации порядка 70%. Включение в обучающую часть выборки в



а)



б)

Рис. 5. Точность прогнозирования в соответствии с метрикой Accuracy и функция потерь Loss в зависимости от номера итерации

а) для базы данных 1 (БД1) и базы данных 2 (БД2); б) для базы данных, включающей 40 классов

каждый класс по 4 исходных изображения с их клонами позволило повысить точность классификации для первой базы данных до 97%, а для второй базы данных до 92% (Рис. 5, а). Таким образом было показано, что для достаточно эффективного обучения сверточной нейросети необходимо минимум 4 исходных изображения для каждого класса. Включение в обучающую часть выборки в каждый класс по 5 и более исходных изображений не было проведено, поскольку это привело бы к резкому сокращению классов в тестовой части выборки.

Затем сверточная нейронная сеть с данной архитектурой (Рис. 3) была обучена на объеди-

ненной выборке, включающей 40 классов. Обучающая часть выборки в каждом классе содержала изображения четырех следов бойка с их клонами (по 36 изображений в каждом классе). Было обучено и протестировано несколько нейронных сетей с данной архитектурой. Точность классификации сетей в соответствии с метрикой Accuracy составила 93-94% (Рис. 5, б). Матрица ошибок (*Confusion Matrix*) представлена на Рис. 6. Видно, что было дано шесть ошибочных прогнозов из 99 попыток. Если учитывать наибольшие сигналы на трех выходных нейронах, то точность классификации достигает 97-98%.

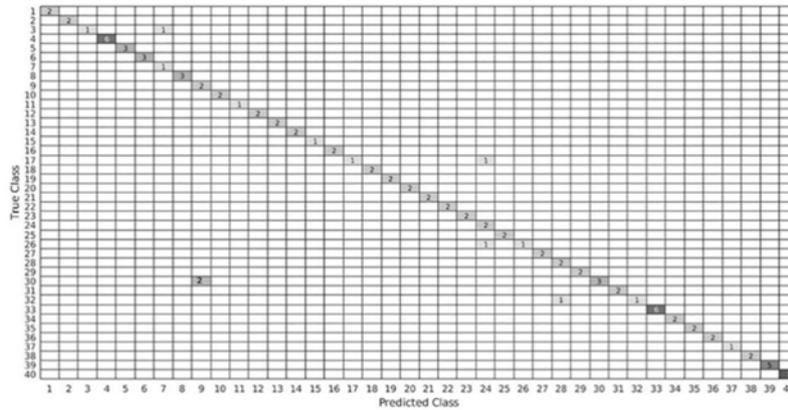


Рис. 6. Confussion Matrix при классификации по выборке, включающей 40 классов (точность прогнозирования 94%)

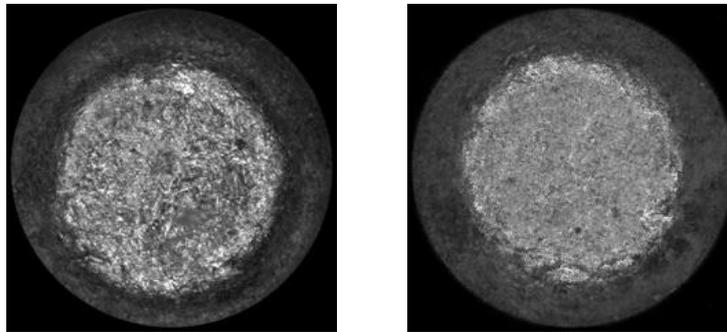


Рис. 7. Сложные для сравнения следы одного экземпляра оружия

Обученная сверточная нейросеть достаточно чувствительна к совпадающим признакам объектов одного класса. На Рис. 7. представлены два характерных следа одного бойка с невыразительными совпадающими признаками. Система не допустила ошибок в классификации изображений данного класса.

Для оценки точности прогнозирования истинно отрицательного вывода, когда исследуемый след не принадлежит ни одному классу обучающей выборки, был сформирован 41-й класс. Для обучения в него были включены изображения следов разных бойков, не относящихся ни к одному из 40 классов, а для проведения тестов были использованы объекты, не парные ни одному изображению обучающей выборки этого класса. Затем нейросеть обучили распознавать объекты сорока одного класса. Точность прогнозирования в соответствии с метрикой *Accuracy* (6) для всех классов, включая и класс непарных следов, составила 85.5%. Для классов парных следов (40 классов) составила 90%, а для класса непарных следов

порядка 68%. Невысокая точность прогнозирования класса непарных объектов обусловлена гораздо большим многообразием признаков для данного класса. Очевидно, для обучения нейронной сети распознавать непарные следы, необходимо принципиально расширить обучающую часть выборки этого класса.

В целом можно констатировать, что сверточная нейронная сеть для классификации следов бойков может быть успешно обучена на выборке, в каждый класс которой входят изображения 4-х следов одного бойка, а также их клоны, повернутые на разные углы.

Заключение

1. Сверточная нейронная сеть с представленной архитектурой может быть успешно обучена на выборке изображений следов бойков, в каждый класс которой входят изображения 4-х следов одного бойка, а также их клоны, повернутые на разные углы.

2. Сверточная нейронная сеть может быть применена для проведения проверок по региональным базам данных цифровых изображений следов бойков, включающих несколько десятков классов с совпадающими групповыми признаками.

Дискуссия

Для оценки эффективности классификации данной сети по выборке, включающей сотни и более классов однотипных следов бойков, необходимо провести дополнительные исследования, связанные, в первую очередь, с отстрелом большого числа экземпляров оружия.

Рекомендуется формировать криминалистические гильзотеки на основе отстрела 5 патронов в каждом экземпляре оружия для более эффективного учета вариативности следов бойков в процессе обучения сверточной нейронной сети.

Литература

- Типовые экспертные методики исследования вещественных доказательств: ч. 1 / под ред. Ю.М. Дильдина; общ. ред. В.В. Мартынов. М.: ЭКЦ МВД России, 2010. 568 с.
 - Области применения Технологии «ПОИСК» и задачи баллистической экспертизы, решаемые с помощью данной технологии [Электронный ресурс] // ООО «СДЦ». URL: <https://www.sbc-spb.com> (дата обращения: 01.08.2023)
 - Автоматизированная Баллистическая Идентификационная Система [Электронный ресурс] // Компания РАМЭК. URL: <https://www.ramec.ru/otraslevyie-resheniya/resheniya-dlya-silovyix-struktur/avtomatizirovannaya-ballisticheskaya-identifikazionnaya-sistema.html> (дата обращения: 01.08.2023)
 - Форсайт Д.А., Понс Д. Компьютерное зрение. Современный подход. М.: Вильямс, 2018. 960 с.
 - Федоренко В.А., Сорокина К.О., Гиверц П.В. Многогрупповая классификация следов бойков с помощью полносвязной нейронной сети // Информационные технологии и вычислительные системы. 2022. N 3. С. 43-57. doi: 10.14357/20718632220305
 - Song J. Proposed “NIST Ballistics Identification System (NBIS)” Based on 3D Topographic Measurements on Correlation Cells // AFTE Journal. 2013. Vol. 45(2). P. 184-194.
 - Song J. Proposed “Congruent Matching Cells (CMC)” Method for Ballistic Identification and Error Rate Estimation // AFTE Journal. 2015. Vol. 47(3). P. 177-185.
 - Song J., Song H. Reporting likelihood ratio for casework in firearm evidence identification // Journal Forensic Sciences. 2022. Vol. 68(2). P. 399-406. doi:10.1111/1556-4029.15186
 - Riva F., Champod C. Automatic comparison and evaluation of impressions left by a firearm on fired cartridge cases // Journal Forensic Sciences. 2014. Vol. 59(3). P. 637-647. doi: 10.1111/1556-4029.12382
 - Giverts P., Sorokina K., Fedorenko V. Examination of the possibility to use Siamese networks for the comparison of firing pin marks // Journal Forensic Sciences. 2022. Vol. 67(6). P. 2416-2424. doi: 10.1111/1556-4029.15143
 - Statistics and Machine Learning Toolbox [Электронный ресурс] // MathWorks. URL: <https://www.mathworks.com/products/statistics.html> (дата обращения: 01.08.2023)
- Федоренко Владимир Александрович.** ФГБОУ ВО «Саратовский национальный исследовательский государственный университет им. Н.Г. Чернышевского», Саратов, Россия. Заведующий лабораторией, кандидат физико-математических наук, доцент. Область научных интересов: идентификация огнестрельного оружия, обработка цифровых изображений. E-mail: fed77@yandex.ru
- Сорокина Ксения Олеговна.** ФГБОУ ВО «Саратовский национальный исследовательский государственный университет им. Н.Г. Чернышевского», Саратов, Россия. Программист. Область научных интересов: идентификация огнестрельного оружия, обработка цифровых изображений, информационные технологии. E-mail: lorredos@gmail.com
- Гиверц Павел Витальевич.** Баллистическая лаборатория криминалистического управления полиции Израиля, Иерусалим, Израиль. Доктор философии. Область научных интересов: судебная баллистика, идентификация огнестрельного оружия. E-mail: pavel.giverts@gmail.com

The Classification of Firing Pin Impressions Using the Convolutional Neural Network (CNN)

V. A. Fedorenko¹, K. O. Sorokina¹, P. V. Giverts^{II}

¹Saratov State University, Saratov, Russia

^{II} Division of Identification and Forensic Science, National Police HQ, Jerusalem, Israel

Abstract. The article discusses the possibility of classification of images of Firing Pin Impressions with the use of Convolutional Neural Network (CNN). The aim of the work is to investigate the effectiveness of CNN for multiclass classification of Firing Pin impressions for several firearms. The scientific novelty of the research is in the development of the CNN for the classification of Firing Pin Impressions under the condition of a small number of source objects used for the CNN training (only 4 images for each class). In order to prove the effectiveness of the CNN training the augmented training database was prepared. For this purpose, each source image in the training database was cloned and eight new images with limited modifications were made. The results of the examination of developed CNN with the database including 40 different classes (firearms) show that the accuracy is about 93% if only one maximal result is considered. In case of considering three highest results, the accuracy increases to 97-98%. The presented work can be of interest for developers of software for automatic ballistic identification system and for firearms examiners of regional forensic ballistic laboratories working with digital microscopes.

Keywords: Firing Pin Impressions, Convolutional Neural Network, multiclass classification, augmentation, firearms identification.

DOI 10.14357/20718632240109

EDN ZHVVQQ

References

1. Dil'din Ju.M., Martynov V.V. Typical expert methods for the study of material evidence. Part 1. Moscow: E'KC MVD Rossii. 2010; 568 p. (In Russ).
2. Fields of application of the "POISK" Technology and the tasks of ballistic examination, solved with the help of this technology. OOO «SDC». Available from: <https://www.sbc-spb.com> [Accessed 01 August 2023]
3. Automated Ballistic Identification System. Kompaniya RAME'K. Available from: <https://www.ramec.ru/otraslevyie-resheniya/resheniya-dlya-silovyix-struktur/avtomatizirovannaya-ballisticheskaya-identifikaczionnaya-sistema.html> [Accessed 01 August 2023]
4. Forsajt D.A., Pons D. Computer vision. Modern approach. Moscow: Vil'yams. 2018; 960 p. (In Russ).
5. Fedorenko V.A., Sorokina K.O., Giverts P.V. Multigroup classification of firing pin marks with the use of a fully connected neural network. *Informacionnye texnologii i vychislitel'nye sistemy*. 2022; 3: 115-120 (In Russ). doi: 10.14357/20718632220305
6. Song J. Proposed "NIST Ballistics Identification System (NBIS)" Based on 3D Topographic Measurements on Correlation Cells. *AFTE Journal*. 2013; 45(2): 184-194.
7. Song J. Proposed "Congruent Matching Cells (CMC)" Method for Ballistic Identification and Error Rate Estimation. *AFTE Journal*. 2015; 47(3): 177-185.
8. Song J., Song H. Reporting likelihood ratio for casework in firearm evidence identification // *Journal Forensic Sciences*. 2022; 68(2): 399-406. doi:10.1111/1556-4029.15186
9. Riva F., Champod C. Automatic comparison and evaluation of impressions left by a firearm on fired cartridge cases. *Journal Forensic Sciences*. 2014; 59(3): 637-647. doi: 10.1111/1556-4029.12382
10. Giverts P., Sorokina K., Fedorenko V. Examination of the possibility to use Siamese networks for the comparison of firing pin marks // *Journal Forensic Sciences*. 2022; 67(6): 2416-2424. doi: 10.1111/1556-4029.15143
11. Statistics and Machine Learning Toolbox. MathWorks. Available from: <https://www.mathworks.com/products/statistics.html> [Accessed 01 August 2023]

Fedorenko Vladimir A. Candidate of Physico-Mathematical Sciences. Head of the educational and scientific laboratory of forensic materials engineering of the Saratov State University, 83, Astrakhanskaya Str., Saratov, 410012, Russia. E-mail: fed77@yandex.ru

Sorokina Ksenia O. Programmer of the educational and scientific laboratory of forensic materials engineering of the Saratov State University, 83, Astrakhanskaya Str., Saratov, 410012, Russia. E-mail: lorredos@gmail.com

Giverts Pavel V. PhD. Division of Identification and Forensic Science, National Police HQ, Haim Bar-Lev road, Jerusalem, 91906, Israel. E-mail: pavel.giverts@gmail.com