

# Многогрупповая классификация следов бойков с помощью полносвязной нейронной сети

В. А. Федоренко<sup>1</sup>, К. О. Сорокина<sup>1</sup>, П. В. Гиверц<sup>2</sup>

<sup>1</sup> Саратовский государственный университет им. Н. Г. Чернышевского, Саратов, Россия

<sup>2</sup> Баллистическая лаборатория полиции Израиля, Иерусалим, Израиль

**Аннотация.** В данной статье рассматривается проблема классификации изображений следов бойков с помощью полносвязной нейронной сети. Целью данной работы являлось исследование эффективности применения клоновых изображений следов бойков с измененными в допустимых пределах признаками для повышения качества обучения полносвязных нейронных сетей, а также оценка точности многогрупповой классификации следов бойков по экземплярам оружия с помощью такой сети. Научная новизна заключается в аугментации обучающей выборки изображений следов бойков огнестрельного оружия путем внесения в соответствии с прогнозируемой вариативностью индивидуальных признаков пространственных и яркостных искажений исходных изображений, достаточных для расширения признакового пространства, но не приводящих к дополнительному смешиванию классов и, за счет этого, повышения эффективности обучения ПНС. Проведенные исследования показали, что точность классификации анализируемых объектов достигает порядка 84% в случае фиксированного значения классифицирующего критерия и 94-98% при классификации по трем наибольшим сигналам на выходных нейронах. Работа представляет интерес для разработчиков программного обеспечения автоматизированных баллистических идентификационных систем.

**Ключевые слова:** следы бойков, полносвязные нейронные сети, многогрупповая классификация, аугментация выборки.

DOI 10.14357/20718632220305

## Введение

Идентификация оружия по следам на стреляных гильзах является одной из важных задач судебной баллистики. Ее решение позволяет связать конкретный экземпляр оружия с местом его криминального применения. Однако, несмотря на формирование на стреляной гильзе множества следов от оружия, процедура идентификации является довольно сложной и порой неоднозначной задачей. При ее решении используются субъективные критерии, зависящие от опыта выполняющего исследования эксперта.

Целью данной работы являлось исследование возможности создания объективного компьютеризированного метода, который может использоваться для выполнения криминалистической идентификации огнестрельного оружия. Одним из этапов работы является проверка возможности эффективного обучения полносвязной нейронной сети за счет аугментации обучающей выборки исходных изображений следов бойков. Аугментация выполнена путем внесения в соответствии с прогнозируемой вариативностью индивидуальных признаков пространственных и яркостных искажений исходных изображений. С использованием аугментированной выборки выполнено

обучение полносвязной нейронной сети и дальнейшая оценка точности многогрупповой классификации следов бойков по экземплярам оружия.

Рассмотрим кратко следы оружия, отображающиеся на стреляных гильзах (Рис. 1). Наиболее информативными являются следы бойков, патронного упора, отражателя, повторного отражения, а также следы, обусловленные автоматикой оружия и т.д. Идентификация оружия чаще всего проводится по следам бойков. В данной работе исследования проводились с изображениями следов бойков полусферической формы.

Разработка эффективного алгоритма автоматической классификации изображений следов бойков по экземплярам оружия является сложной технической задачей, которая обусловлена,




Рис. 1. Следы оружия, отобразившиеся на стреляной гильзе

1 – след бойка; 2 – след окна под отражатель; 3 – след отражателя; 4 – след патронного упора; 5 – след зацепа выбрасывателя; 6 – след сигнальной спицы; 7 – след окна под сигнальную спицу

в первую очередь, большим разнообразием типов микронеоднородностей поверхности бойков, отобразившихся в следах. В качестве примера на Рис. 2 представлены изображения следов бойков с разными типами доминирующих признаков [1]. Кроме этого, в пределах одного класса (в данном случае под одним классом понимаются следы бойков одного экземпляра оружия) возможна значительная вариативность признаков, которая может возникать по многим причинам: использование патронов различных производителей; наличие/отсутствие лакового покрытия на поверхности капсюля; различное количество смазочных материалов в механизме оружия и т.д. Эти факторы серьезно осложняют процесс оценки результатов сравнения следов и, соответственно, идентификации оружия. В качестве примера на Рис. 3 представлены две пары следов. Первая пара представляет следы, сформированные разными бойками (разные классы), а вторая пара – следы, сформированные одним бойком (один класс). Визуально вторая пара следов имеет большие отличия, чем первая.

## 1. Основные причины вариативности следов бойков

Высокая вариативность признаков в следах бойков в пределах одного класса осложняет процедуру автоматического сравнения изображений следов и, в конечном счете, ведет к сни-




Рис. 2. Изображения следов бойков с характерными индивидуализирующими признаками




Рис. 3. Следы бойка

а) - не совпадающие следы; б) – следы одного бойка




Рис. 4. Основные типы неоднородностей поверхности капсюлей, которые могут сохраниться в следах бойков

а) – следы прокатки фольги капсюля; б) – риски, борозды; в) – каверны, обусловленные эрозией поверхности старых капсюлей; г) пятна окисления; д) – следы объемной маркировки капсюлей

жению ее эффективности. Рассмотрим основные факторы, приводящие к высокой вариативности следов.

1. Несмотря на унифицированность боеприпасов, каждый выстрел протекает при несколько разных условиях (скорость нарастания давления пороховых газов, значение максимального давления, навески пороха и модификации пороха разных производителей патронов, разное срабатывание капсюльного состава вплоть до осечки и затяжного выстрела и т.д.). Это приводит к формированию следов одного бойка с несколько разной выраженностью индивидуализирующих признаков.

2. Присутствие на поверхности капсюлей, до удара по нему бойком, различного рода неоднородностей в виде следов окисления, лакового покрытия, соринок и т.д. носит случайный характер и способно существенно исказить информационную картину [2]. На Рис. 4 представлены основные типы неоднородностей поверхности капсюлей, не связанные с выстрелом: следы прокатки фольги капсюля; риски и борозды; каверны, обусловленные эрозией поверхности старых капсюлей; пятна окисления; следы объемной маркировки капсюлей. Эти неоднородности способны частично сохраняться в следах бойка, что может серьезно осложнить процесс сравнения следов.

3. Различие механических свойств фольги капсюлей может привести к формированию следов одного бойка с разной глубиной, диаметром (Рис. 3, б) и разной выраженностью индивидуализирующих признаков.

4. Невозможность абсолютно одинаковой установки гильз в каретке сканера при сканировании их донных частей приводит к разному положению совпадающих признаков на разных изображениях следов одного бойка (парных

следов). В результате возможна угловая разориентация одного изображения относительно другого, а также сдвиги изображений анализируемых следов влево-вправо, вверх-вниз. Смещения обычно не превышают 10% от диаметра следа бойка. Таким образом, совпадающие признаки в разных следах одного бойка могут пространственно располагаться по-разному относительно центра изображений.

## 2. Влияние топологии признаков на их устойчивость

Топология неоднородностей рабочей поверхности бойка влияет на устойчивость их отображения в следах. Складки и ребра жесткости микрорельефа бойка достаточно устойчиво отображаются в следах. На Рис. 5 представлены изображения следов одного бойка с резко выраженными границами индивидуализирующих признаков в виде пятен неопределенной формы (отм.1, Рис. 5). Границы пятен достаточно точно совмещаются при их наложении. Аналогичная картина характерна и для других следов с резкими границами признаков. С большой долей вероятности можно предположить, что границы таких признаков слабо изменяются при разных выстрелах патронами




Рис. 5. Следы бойков

отм. 1 – резкие границы признаков;  
отм. 2 – размытые границы признаков

одного производителя. Области с плавно изменяющимся микрорельефом более подвержены изменениям, например, за счет разного максимального давления пороховых газов на внутреннюю поверхность капсюля при разных выстрелах. На Рис. 5 участки с плавно изменяющимся микрорельефом в центральной части обозначены отм.2. Видно, что вариативность центральных участков пятен намного выше вариативности резких внешних границ. Эти особенности можно учитывать при прогнозировании наиболее вероятной вариативности следов бойков, например, при формировании изображений с несколько измененными индивидуализирующими признаками.

В целом, несмотря на вариативность отображения самих признаков и наличие на поверхности капсюлей маскирующих неоднородностей, наличие 3-х следов бойков для каждого экземпляра оружия позволяет оператору визуально выделить совпадающие индивидуальные признаки и при формировании аугментационной выборки целенаправленно вносить искажения в индивидуальные признаки. При этом явно выраженные неоднородности поверхности капсюля частично или полностью удаляются путем наложения на них изображений близлежащих фрагментов поверхности капсюля.

### 3. Методы оценки схожести изображений следов бойков

Рассмотрим кратко основные методы оценки схожести изображений следов бойков. В различных автоматизированных идентификационных баллистических системах схожесть изображений следов бойков оценивается, в основном, по максимуму функции взаимной

корреляции (ФВК), величина которого указывает на степень их подобия. Положение максимума соответствует координатам центрального элемента маски, при котором наблюдается максимальная схожесть изображений (Рис. 6, а). ФВК различающихся изображений обычно характеризуется несколькими равнозначными максимумами с относительно малыми значениями (Рис. 6, б). Следует отметить, что функция взаимной корреляции не инвариантна повороту, масштабу и положению одного изображения относительно другого. Поэтому при реализации данного метода ФВК рассчитывают при различных поворотах одного изображения относительно другого. Это делает практически невозможной процедуру многогрупповой классификации при проведении поиска по электронной гильзотеке, включающей тысячи цифровых изображений следов бойков. Присутствие в изображениях различного рода артефактов и засветок также существенно снижает эффективность корреляционного анализа.

Дж. Сонгом был разработан метод «конгруэнтных совпадающих ячеек» (СМС-Congruent Matching Cells), который позволяет эффективно проводить сравнение цифровых изображений следов патронного упора [3, 4]. Принцип действия этого метода основан на исключении из анализа малоинформативных областей сравниваемых изображений, выявлении конгруэнтно расположенных на изображениях совпадающих неоднородностей. Для этого исследуемые изображения разбиваются на ячейки одного размера. В анализе участвуют только ячейки пригодные к корреляции, в которых присутствуют пространственные неоднородности.

Метод корреляционных ячеек близкий к методу СМС был предложен в работе [5]. Он




Рис. 6. Функция взаимной корреляции

а) — изображений двух следов одного бойка; б) — изображений двух следов различающихся бойков

также основан на разбиении анализируемых изображений следов на сетку равных ячеек, нахождении максимума ФВК для одноименных ячеек первого и второго изображения и определении сдвигов одного изображения относительно нанесенной на него сетки (Рис. 7, а, б) при которых наблюдается наибольшее число парных ячеек с максимальными значениями ФВК. Близость значений координат сдвигов, при которых наблюдается наибольшее число парных ячеек с максимальным значением ФВК (Рис. 7, в), характеризует степень совпадения распределенных на сравниваемых изображениях неоднородностей (признаков). Метод корреляционных ячеек может быть успешно применен как для анализа изображений следов патронного упора, так и для изображений следов бойков.

К недостаткам СМС метода и метода корреляционных ячеек можно отнести слабую эффективность при анализе статических следов бойков и патронного упора с признаками в виде дуг и окружностей, а также сложность их применения для многогрупповой классификации.




Рис. 7. Метод корреляционных ячеек

а) — изображение первого следа бойка с нанесенной сеткой эквидистантных ячеек; б) — изображение (подвижное по  $x$  и по  $y$ ) второго следа бойка с нанесенной сеткой эквидистантных ячеек; в), г) — распределения максимальных значений ФВК на диаграмме сдвигов для изображений следов одного и разных бойков соответственно




Рис. 8. Методы сравнения следов бойков с индивидуализирующими признаками в виде крупных пятен

а) – выделение дескрипторов в следе бойка; б) - система координат и описание границы объекта комплексными координатами, граница объекта обозначена пунктиром

когда изображение является бинарным и значимая для идентификации информация содержится в границах объектов. Для представления признаков в виде контуров граница каждого признака описывается единичными векторами, которые соединяют точки в соответствии с направлениями 8-связной системы (Рис. 8 б). Контур, кодируемый таким образом, обладает замечательными свойствами, а именно: максимальное значение модуля нормированного скалярного произведения анализируемых контуров инвариантно их повороту, положению на плоскости и масштабу [10]. При этом модуль нормированного скалярного произведения указывает на степень сходства контуров, а аргумент на угол их разориентации. К недостаткам данного метода следует отнести слабую эффективность при анализе контуров по форме близких к окружности и при наличии нескольких признаков в каждом следе.

Для исследования совпадения следов огнестрельного оружия также могут применяться методы машинного обучения. В работе [11] исследуется применение нейронной сети для классификации изображений следов патронного упора на поверхности капсюля. Исходные изображения подвергались предварительной обработке без пространственных искажений индивидуализирующих признаков. В этой работе все 747 гильз, следы патронного упора которых формируют обучающую и тестовую выборку, были стреляны всего в 5 экземплярах пистолета Parabellum Vector SPI 9 mm model. Малое число классов не позволяет качественно оценить точность классификации нейронной сети. Поскольку на 5 классов приходилось 747 исходных изображений, то авторам не требовалось формировать аугментационную выборку и проводить оценку эффективности ее применения.

В работе [12] представлено описание применения сиамской нейронной сети для проведения бинарной классификации изображений следов бойков по категориям: «совпадающие»; «несовпадающие». В качестве исходных изображений использовались не двумерные изображения, а облака точек, сформированные на основе 3-D сканирования следов бойков с помощью конфокальной микроскопии. Кроме того, целью данной работы являлось проведение

бинарной классификации следов по категориям «совпадающие», «несовпадающие», а не проведение многогрупповой классификации (когда задано несколько заранее определенных классов и нужно сортировать по ним заданные изображения).

Таким образом, обзор ранее опубликованных работ позволяет сделать вывод об отсутствии универсального метода многогрупповой классификации следов бойков с разными типами индивидуализирующих признаков в условиях малого числа объектов в каждом классе.

#### 4. Нейронные сети

В последнее время достаточно широкое применение в криминалистике находят нейронные сети. Одними из самых простых являются полносвязные нейронные сети (ПНС), которые хорошо зарекомендовали себя при решении задач многогрупповой классификации [13 - 15]. Полносвязная нейронная сеть состоит из слоя входных нейронов, нескольких скрытых слоев и слоя выходных нейронов. Количество входных и выходных нейронов строго регламентировано, первые определяются числом пикселей ( $M$ ) анализируемых изображений, а вторые числом классов ( $N$ ), формирующих обучающую выборку (Рис. 9). Число нейронов в скрытых слоях и число скрытых слоев не регламентировано.

На предварительном этапе проводится обучение сети в процессе которого она выделяет признаки, характерные для каждого класса объектов. Обучение нейронных сетей основано на получении сигнала ошибки, его обратном распространении и корректировке весовых коэффициентов  $w_{ij}$ , связывающих нейроны соседних слоев (Рис. 9). В начальный момент обучения весовые коэффициенты связей между нейронами




Рис. 9. Типичная архитектура полносвязной нейронной сети

соседних слоев задаются случайным образом, но для каждого слоя их суммарное значение обычно не превышает 1. При обучении веса связей нейронов корректируются так, чтобы при поступлении на вход тестового изображения класса  $i$  на выходном нейроне, соответствующему этому классу, получался сигнал близкий к единице, а на других выходных нейронах сигнал был бы близок к 0. В процессе обучения веса связей так корректируются, чтобы достигался установленный критерий качества работы нейронной сети. В данном исследовании за такой критерий принималось условие, что разность сигналов ( $\epsilon$ ) на каждом выходном нейроне должна быть меньше установленного максимально допустимого значения, например, 0.05:

$$|d_j - y_j| = \epsilon_j < 0.05 \text{ для } j = [1, \dots, N],$$

где  $d_j$  – идеальный сигнал на  $j$ -м выходном нейроне (0 или 1);  $y_j$  – реальный сигнал на  $j$ -м выходном нейроне,  $N$  – число классов.

В результате в процессе обучения ПНС учится игнорировать на изображениях обучающей выборки различные случайные артефакты, но при этом выделять признаки, характерные для конкретного класса.

Применение нейронных сетей для идентификации огнестрельного оружия по цифровым изображениям следов бойков осложняется малым числом объектов для каждого экземпляра оружия. Обусловлено это тем, что при контрольном отстреле оружия для сбора образцов гильз отстреливается малое число патронов. Например, в Российской Федерации из каждого экземпляра оружия отстреливается по 3 патрона, в других странах от 2 до 5 патронов. При этом известно, что для эффективного обучения нейронной сети для каждого класса требуется большое число изображений, представленных в разном масштабе, с разной ориентацией и положением в кадре, ракурсом, разным перекрытием объекта другими предметами и т.д. Чем больше разнообразие объектов для каждого класса, тем лучше обучается сеть, и тем точнее она будет классифицировать.

Анализ изображений следов бойков позволяет предположить, что для эффективного обучения полносвязной нейронной сети может потребоваться обучающая выборка с гораздо

меньшим числом объектов для каждого класса, чем это необходимо при решении традиционных задач классификации изображений. Действительно, исследуемые изображения следов бойков пригодные к идентификации имеют один масштаб, одно разрешение, одинаково центрированы и практически всегда представляют полное изображение следа. Поэтому можно предположить, что для обучения нейронной сети для каждого класса может быть достаточно 2-х - 3-х десятков изображений.

## 5. Формирование изображений с искаженными индивидуализирующими признаками

Проблему малого числа объектов обучающей выборки можно решить путем преобразования каждого исходного изображения во множество изображений с измененными в допустимых пределах индивидуализирующими признаками. Для этого на первом этапе формировались исходные изображения размером 500x500 пс, центр следа бойка располагался в центре кадра. Области кадра не относящиеся к следу заливались черным цветом. Затем изображения подвергались гомоморфной обработке [8, 9] с целью выравнивания яркости (Рис. 10, а). На втором этапе для получения расширенной обучающей выборки формировались изображения в соответствии со следующей методикой.

1. Яркость областей с малым градиентом изменялась в пределах 10-15% от всего динамического диапазона.

2. Контурные крупные признаки с резко очерченными границами деформировались не более чем на 5 % от их линейных размеров.

3. Область непосредственно следа бойка на новых изображениях случайным образом смещалась в пределах 5-7% от линейного размера кадра (500x500 пс).

4. Все изображения с измененными признаками поворачивались с шагом 7-9 градусов на углы от 0 до  $\pm 35$  градусов. Для каждого исходного изображения получалось по 1 изображению с измененными признаками и 8 его поворотов на  $\pm 7-9^\circ$ ,  $\pm 15-17^\circ$ ,  $\pm 23-25^\circ$  и  $\pm 32-35^\circ$  градусов (Рис. 10, в, г). В принципе, можно взять повороты в пределах  $\pm 180^\circ$  и таким




Рис. 10. Пример исходного изображения и его копий с измененными признаками

а) – исходное изображение; б) – изображение с измененными признаками без поворота; в), г), – изображения с измененными признаками, повернутые на угол  $7^\circ$  и  $15^\circ$  по часовой стрелке соответственно

образом исключить необходимость обеспечения единой ориентации изображений, но тогда потребуется большее число изображений с измененными признаками и, соответственно, большее время обучения.

После формирования изображений с измененными признаками и их поворотов каждый класс можно представить в виде нескольких наборов однотипных изображений (ветвей). Число ветвей определяется числом исходных изображений (Рис. 11, а). При необходимости на основе каждого исходного изображения можно получить не по одному, а по два-три изображения с несколько по-разному измененными признаками. Для обучения полносвязной нейронной сети все изображения были уменьшены до размеров  $75 \times 75$  пс. Такое уменьшение разрешения было выполнено с целью уменьшения времени обучения и необходимых ресурсов на этапе исследования эффективности предлагаемого метода. В дальнейшем, при разработке модели с целью ее применения в реальных задачах будет необходимо использовать изображения большего размера. Исходные двумерные изображения следов бойков для обучающей и тестовой выборок были получены с помощью баллистических сканеров «POISC» (Россия) и «IBIS» (Канада). Все изображения приведены к одному размеру и имеют одно разрешение.

## 6. Формирование обучающей и тестовой выборок

Формирование выборок проводилось в соответствии со следующим правилом. Если класс с условным номером  $i$  содержал три ветви, то две из них формировали класс  $i$  в обучающей выборке, а третья ветвь этот же класс в тестовой выборке (Рис. 11 а, б). Таким образом, изобра-

жения или их модификации, используемые в тестовой выборке для оценки характеристик модели, никогда не использовались для обучения самой модели. Каждая ветвь содержала исходное изображение, как минимум одно исходное изображение с измененными в определенных пределах индивидуальными признаками и 8 повернутых на разные углы в диапазоне  $\pm 35$  градусов изображений с измененными индивидуальными признаками. Кроме этого, в тестовую выборку были включены классы, которые не были представлены в обучающей выборке.

Для лучшего описания структуры выборок и для краткости были введены определения групп классов. Классы тестовой выборки, которые присутствуют и в обучающей, будем называть «парными». Остальные классы тестовой выборки будем считать «непарными». Было сформировано два варианта обучающей и тестовой выборок, позволяющие оценить точность классификации «парных» и точность выявления «непарных» классов. В первом варианте (Рис. 11, б) обучающая и тестовая выборка содержат по 30 «парных» классов (порядка 700 изображений в обучающей выборке и 350 изображений в тестовой выборке), и 78 «непарных» классов включено в тестовую выборку (порядка 900 изображений). Во втором варианте (Рис. 11, в) обучающая и тестовая выборки также содержат по 30 «парных» классов (700 и 350 изображений соответственно), и по одному объединенному классу, которые были сформированы следующим образом. 78 «непарных» классов, относящихся к тестовой выборке в варианте 1 (Рис. 11, б) были разделены на 2 группы. В одну группу, которую включили в обучающую выборку, вошли классы с наиболее ярко выраженными типами индивидуальных признаков. Во вторую группу вошли все

остальные «непарные» классы. Как видно из Рис. 11, в) «непарные» классы, входящие в объединенный класс обучающей выборки не совпадают с «непарными» классами, включенными в объединенный класс тестовой выборки.

Включение объединенного класса в обе выборки позволяет обучить нейронную сеть выделять признаки «непарных» классов и оценить с помощью матрицы ошибок (*confusion matrix*) точность их определения.




Рис.11. Формирование обучающей и тестовой выборки

а) — типичная структура одного аугментационного класса; б) — формирование обучающей и тестовой выборки в соответствии с первым вариантом; в) - формирование обучающей и тестовой выборки в соответствии с вариантом 2

Чтобы при обучении нейронной сети не тратьте объекты проверяемой выборки на формирование объединенного класса, в качестве таких объектов можно использовать изображения следов бойков с аналогичными размерными и геометрическими характеристиками (диаметр следа порядка 1.5 мм, полусферический профиль следа бойка и т. д.) иных моделей оружия. Например, для нейронной сети, обучаемой классифицировать по экземплярам оружия следы бойков пистолета Макарова (гильза размером 9x18 мм), объединенные классы можно сформировать из следов бойков с аналогичными характеристиками пистолетов «Таурас», «Беретта-92» и т. д. (гильза 9x19 мм).

## 7. Обучение полносвязной нейронной сети

Для исследования эффективности применения аугментационной обучающей выборки, образованной путем искажения индивидуализирующих признаков на исходных изображениях следов бойков, была сформирована полносвязная нейронная сеть [13] с двумя скрытыми слоями. Сеть имела следующую структуру: входной слой включал 5625 входных нейронов (по числу пикселей изображений); первый скрытый слой состоял из 625 нейронов; второй слой включал 156 нейронов, а в выходном слое число нейронов определялось числом классов в обучающей выборке (Рис. 12). В результате нейронная сеть в среднем содержала порядка 3.5 миллионов регулируемых весовых коэффициентов.

Обучение нейронной сети проводилось поэтапно. На первом этапе обучающая выборка включала только исходные изображения. Сначала на вход подавали изображения с хорошо




Рис. 12. Архитектура применявшейся полносвязной нейронной сети

выраженными индивидуализирующими признаками, затем изображения с менее выраженными признаками. На втором этапе обучающая выборка была расширена за счет изображений с искаженными индивидуальными признаками без поворотов. На третьем этапе обучающая выборка включала изображения с искаженными индивидуальными признаками случайным образом повернутыми относительно начального положения на углы в пределах  $\pm 35$  градусов.

Предварительные исследования ПНС показали, что включение в обучающую выборку изображений с искаженными индивидуальными признаками увеличивает точность классификации в соответствии с метрикой *accuracy* на несколько процентов, включение еще и изображений с разными поворотами дополнительно увеличивает точность на 8-10%. Поэтому в дальнейшем рассматриваются результаты обучения ПНС по выборке, включающей повернутые изображения с искаженными индивидуальными признаками. В целом было обучено более 50 нейронных сетей с разными стартовыми весовыми коэффициентами, заданными случайным образом.

Успехом для «парных» классов считалось появление сигнала больше порога классификации на соответствующем выходном нейроне или в случае нефиксированного порога классификации, появление наибольшего сигнала на соответствующем выходном нейроне. Неудачей считалось появление сигнала на соответствующем выходном нейроне менее порога классификации или в случае отсутствия фиксированного порога классификации появление максимального сигнала на несоответствующем выходном нейроне.

Для «непарных» классов (вариант 1) успехом считалось появление максимального сигнала менее порога классификации на всех выходных нейронах, а неудачей появление сигнала выше порога классификации хоть на одном выходном нейроне. При отсутствии фиксированного порога классификации невозможно оценить точность определения «непарных» классов. Поэтому во втором варианте был введен так называемый объединенный класс, обучение по которому позволило оценить точность выявления «непарных» классов.

## 8. Оценка точности классификации

Точность прогнозирования классов объектов тестовой выборки оценивалась в соответствии с метриками *Accuracy*, *Recall*, *Precision*, *F1*.

Метрика  $Accuracy = (TP + TN) / (TP + TN + FP + FN)$  указывает на число правильных прогнозов к общему числу прогнозов. Где: *TP* — истинно положительный прогноз; *TN* — истинно отрицательный прогноз; *FP* — ложноположительный прогноз; *FN* — ложноотрицательный прогноз.

Метрика  $Recall = TP / (TP + FN)$  указывает на долю ложноотрицательных предсказаний (пропуски), которые являются очень значимым параметром классификатора при проведении проверок по базе данных следов бойков.

Метрика  $Precision = TP / (TP + FP)$  указывает на долю ложноположительных предсказаний, характеризует способность отличать один класс от других близких классов.

Метрика *F1* объединяет две предыдущие метрики:  $F1 = 2 * Precision * Recall / (Precision + Recall)$

С целью оценки возможной точности классификации предварительно было проведено обучение нескольких ПНС по 30 классам изображений следов бойков. Для одной из наиболее удачно обученных нейронных сетей с помощью матрицы ошибок (*Confusion Matrix*) для категории «парные» классы были построены значения метрик в зависимости от порогового уровня сигнала на одном из выходных нейронов выходного слоя (Рис. 13). Из графика видно, что для данной ПНС оптимальным порогом является уровень сигнала 0.7, когда все метрики имеют достаточно высокие значения точности порядка 78-82 %.

Далее было проведено тестирование обученных нейронных сетей, как по фиксированному порогу классификации, так и по максимальному сигналу на выходных нейронах без порога классификации (Табл. 1). Предварительно было проведено обучение нейронных сетей двумя способами. В соответствии с первым способом параллельно обучалось несколько сетей с разными начальными наборами весовых коэффициентов связей, выбиралась одна ПНС наилучшим образом обученная и для нее определялась точность классификации. Вторым способом заключался в обучении множества




Рис. 13. Эффективность прогнозирования ПНС в соответствии с разными метриками в зависимости от порогового значения на выходных нейронах

нейронных сетей с разными начальными наборами весовых коэффициентов (не менее 10 сетей), отборе 3-х сетей с наилучшими показателями, формировании новой нейронной сети с весовыми коэффициентами, усредненными по отобранным ПНС, с последующим дообучением новой сети на этой же выборке. В Табл. 1 первый способ обучения обозначен как «1 ПНС», второй как «оптимизация по 3 ПНС».

Из таблицы видно, что точность классификации при заданном пороговом значении сигнала на выходных нейронах для «парных» классов лежит от 63% до 84%, а для «непарных» от 80% до 95%. Если же пороговое значение не фиксировано, то точность прогнозирования составляет для «парных» классов от 72% до 96% при классификации по максимальному сигналу на одном выходном нейроне и от 95% до 98% при отнесении к успеху появления сигнала на соответствующем нейроне, входящим в тройку выходных нейронов с наибольшими значениями сигнала.

Анализ данных, представленных в Табл. 1, позволяет сформировать следующие выводы:

1. Конструирование из нескольких ПНС одной с усредненными весовыми коэффициентами позволяет повысить точность классификации, вероятно, за счет уменьшения эффекта переобучения нейронной сети.

2. Классификация по максимальному значению сигнала на выходном нейроне (на трех выходных нейронах) без фиксированного порогового значения позволяет повысить точность классификации объектов по «парным» классам.

Табл. 1 Точность классификации

| Варианты выборки         | Пороговое значение                                        | Парные классы, точность |               |               | Непарные классы, точность |               |               |
|--------------------------|-----------------------------------------------------------|-------------------------|---------------|---------------|---------------------------|---------------|---------------|
|                          |                                                           | 1 вых нейрон            | 2 вых нейрона | 3 вых нейрона | 1 вых нейрон              | 2 вых нейрона | 3 вых нейрона |
| В1:<br>1 ПНС             | без порога<br>(Recall)<br>с порогом<br>0,75<br>(Accuracy) | <b>0,88</b>             | <b>0,9</b>    | <b>0,95</b>   |                           |               |               |
|                          |                                                           | <b>0,8</b>              | <b>0,8</b>    | <b>0,8</b>    | <b>0,8</b>                | <b>0,8</b>    | <b>0,8</b>    |
|                          | без порога<br>(Recall)<br>с порогом<br>0,70<br>(Accuracy) | <b>0,96</b>             | <b>0,97</b>   | <b>0,98</b>   |                           |               |               |
|                          |                                                           | <b>0,84</b>             | <b>0,84</b>   | <b>0,84</b>   | <b>0,84</b>               | <b>0,84</b>   | <b>0,84</b>   |
| В2: оптимизация по 3 ПНС | без порога<br>(Accuracy)                                  | <b>0,72</b>             | <b>0,97</b>   | <b>0,98</b>   | <b>0,96</b>               | <b>0,98</b>   | <b>0,99</b>   |
|                          | с порогом<br>0,50<br>(Accuracy)                           | <b>0,63</b>             | <b>0,66</b>   | <b>0,66</b>   | <b>0,95</b>               | <b>0,95</b>   | <b>0,95</b>   |

3. Обучение ПНС на объединенном классе, сформированном из «непарных» классов, позволяет повысить точность выявления «непарного» класса до 95% при фиксированном пороге и до 99% без фиксированного порога.

Следует отметить достаточно высокую избирательность обученной полносвязной нейронной сети. На Рис. 14 представлены изображения следов бойков двух экземпляров пистолета Макарова с заводскими номерами 1784 и 1699 с топологически близкими индивидуализирующими признаками. Сеть уверенно дифференцировала эти изображения по соответствующим классам.

## 9. Дискуссия

Очевидно, для увеличения точности классификации необходимо увеличить размер изображений, поскольку при уменьшении исходных изображений до размеров 75x75 пс происходит сглаживание неоднородностей с потерей информации о мелких деталях индивидуализирующих признаков. Однако для анализа изображений размером 250x250 пс и более необходимо перейти к сверточной нейронной сети, адаптированной к работе с изображениями.

Следует увеличить число классов в обучающей и тестовой выборках.




Рис. 14. Изображения следов бойков двух экземпляров оружия с близкой топологией индивидуализирующих признаков

- а), б) — изображения следов боя на гильзах, стреляных в одном экземпляре пистолета Макарова;  
в) — изображение следа боя на гильзе, стреляной в ином экземпляре пистолета Макарова

## Заключение

Проведенные исследования показали:

- принципиальную возможность создания системы классификации следов огнестрельного оружия с применением ПНС, которая может обеспечить характеристики, позволяющие ее применение при проведении криминалистических исследований;

- применение искусственно генерированных изображений следов бойков с искаженными в некоторых пределах признаками при малом количестве исходных объектов в каждом классе позволяет применять полносвязные нейронные сети для классификации следов по экземплярам оружия;

- классификация изображений следов бойков с помощью полносвязной нейронной сети «парных» классов возможна с точностью порядка 84% в случае фиксированного значения классифицирующего критерия, порядка 96% при классификации по максимальному (не фиксированному) сигналу на одном выходном нейроне и порядка 98% в случае классификации по трем наибольшим сигналам на выходных нейронах;

- детектирование (обнаружение) «непарных» классов возможно с точностью порядка 95% в случае фиксированного значения классифицирующего критерия и 99% в случае детектирования по трем наибольшим сигналам на выходных нейронах;

- формирование из нескольких ПНС одной с усредненными весовыми коэффициентами с последующим дообучением новой сети, а также учет максимальных сигналов не только на одном выходном нейроне, но и на 2-х и 3-х выходных нейронах позволяет повысить точность классификации.

В целом, проведенные исследования показали перспективность аугментации выборок изображений следов бойков путем целенаправленного изменения индивидуальных признаков с целью обеспечения условий для эффективного обучения нейронных сетей и последующего их применения для проведения проверок по базам данных цифровых изображений следов бойков.

**Федоренко Владимир Александрович.** ФГБОУ ВО «Саратовский национальный исследовательский государственный университет им. Н.Г. Чернышевского», Саратов, Россия, заведующий лабораторией, кандидат физико-математических наук, доцент. Количество печатных работ: более 110 (в т.ч. 2 монографии). Область научных интересов: идентификация огнестрельного оружия, обработка цифровых изображений. E-mail: fed77@yandex.ru

## Литература

1. Федоренко В.А., Корнилов М.В. Оценка схожести следов бойков огнестрельного оружия по их цифровым изображениям// Информационные технологии и вычислительные системы/ 2015, №3, с. 92-100.
2. Федоренко В.А., Гвоздков С.Н., Грабовец Е.Е. Влияние неоднородностей поверхности капсюлей на вариативность статических следов бойков// Известия Саратовского университета. Новая серия. Серия экономика. Управление. Право / 2018 г., №2, с.202-208.
3. Song J. 2013. Proposed "NIST Ballistics Identification System (NBIS)" Based on 3D Topographic Measurements on Correlation Cells. *AFTE Journal*. 45(2), p.184-194.
4. John Song, Proposed "Congruent Matching Cells (CMC)" Method for Ballistic Identification and Error Rate Estimation// *AFTE* 2015, Vol.47, №3, pp.177-185.
5. Сорокина К. О., Федоренко В. А., Гиверц П. В. Оценка схожести изображений следов патронного упора методом корреляционных ячеек // Информационные технологии и вычислительные системы/ 2019, №3, с. 3-15.
6. Bailey, Ken (1994). "Numerical Taxonomy and Cluster Analysis". *Typologies and Taxonomies*. p. 34. ISBN 9780803952591.
7. Федоренко В.А., Корнилов М.В. Применение методов кластерного анализа для оценки схожести следов бойков // Известие Саратовского ун-та. Нов. Сер. Экономика. Управление. Право. 2014. Т.14, вып.1. С.187-190.
8. Fedorenko V.A., Kornilov M.V. Automatic Comparison of Firing Pin Marks Against Descriptors Independent of Image Orientation // *AFTE* 2018, pp. 169-175.
9. Гонсалес Р., Вудс Р. Цифровая обработка изображений. Москва, Техносфера, 2019. – 1104с.
10. Фурман Я.А. и др. Введение в контурный анализ и его приложения к обработке изображений и сигналов// М. Физматлит. 2003. С. 25-32.
11. S.B.A. Kamaruddin, N.A.M. Ghani, C.-Y. Liong, A.A. Jemain, Firearm Classification using Neural Networks on Ring of Firing Pin Impression Images, *Adv. Distrib. Comput. Artif. Intell. J.* 1 (2012) 27–35. <https://doi.org/10.14201/ADCAIJ20121312734>
12. O. Giudice, L. Guarnera, A.B. Paratore, G.M. Farinella, S. Battiato, Siamese Ballistics Neural Network, in: 2019 IEEE Int. Conf. Image Process., IEEE, 2019: pp. 4045–4049. <https://doi.org/10.1109/ICIP.2019.8803619>.
13. Создаем нейронную сеть, Т. Рашид, СПб.: ООО «Альфа-книга», 2017, 272 с.
14. Николенко С., Кадурин А., Архангельская Е.. Глубокое обучение. Погружение в мир нейронных сетей. Изд. Питер, 2018, 480 с.
15. David A. Forsyth, Jean Ponce "Computer Vision. A Modern Approach" 2018, p. 960.

**Сорокина Ксения Олеговна.** ФГБОУ ВО «Саратовский национальный исследовательский государственный университет им. Н.Г. Чернышевского», Саратов, Россия, программист. Количество печатных работ: 6. Область научных интересов: идентификация огнестрельного оружия, обработка цифровых изображений, информационные технологии. E-mail: lorredos@gmail.com

**Гиверт Павел Витальевич.** Баллистическая лаборатория криминалистического управления полиции Израиля, г. Иерусалим, Израиль. Доктор философии. Количество печатных работ: 50. Область научных интересов: судебная баллистика, идентификация огнестрельного оружия. E-mail: pavel.giverts@gmail.com

## Multigroup classification of Firing Pin Marks with the use of a Fully Connected Neural Network

V. A. Fedorenko<sup>1</sup>, K. O. Sorokina<sup>1</sup>, P. V. Giverts<sup>11</sup>

<sup>1</sup>Saratov State University, 83, Astrakhanskaya Str., Saratov, 410012, Russia

<sup>11</sup> Division of Identification and Forensic Science, National Police HQ, Haim Bar-Lev road, Jerusalem, 91906, Israel

**Abstract.** The article discusses the problem of classifying the images of firing pin marks using a fully connected neural network. The purpose of this work was to study the effectiveness of using clone images of firing pin marks with modified features in order to improve the quality of training of fully connected neural networks, as well as to evaluate the accuracy of multigroup classification of firing pin marks made by different weapons using this type of network. The scientific novelty of the work is the formation of clone images of firing pin marks in order to increase the number of objects in the training sample and to artificially increase the feature diversity of objects of each class. The conducted studies have shown that the classification accuracy of the analyzed objects reaches approximately 84% in the case of a fixed value of the classifying criterion and 94-98% when classified according to the three largest signals on the output neurons. The work is of interest to developers of software for automated ballistic identification systems.

**Keywords:** firing pin marks, fully connected neural networks, multigroup classification, sampling augmentation.

DOI 10.14357/20718632220305

## References

1. Fedorenko V.A., Kornilov M.V. 2015. Ocenka skhozhesti sledov bojkov ognestrel'nogo oruzhya po ih cifrovim izobrazheniyam [Assessing similarities firing pin traces of firearms on their digital images]. Informacionnye tehnologii i vychislitel'nye sistemy [Information Technology and Computing Systems]. 3:92-100.
2. Fedorenko V.A., Gvozdkov S.N., Grabovec E.E. 2018. Vliyanie neodnorodnostej poverhnosti kapsulyey na variativnost' staticheskikh sledov bojkov [Influence of Inhomogeneities of the Surface of Caps on Variability of Static Firing Pin Traces]. Izv. Saratov Univ. (N.S.), Ser. Economics. Management. Law. 18.(2):202-207.
3. Song J. 2013. Proposed "NIST Ballistics Identification System (NBIS)" Based on 3D Topographic Measurements on Correlation Cells. AFTE Journal. 45(2), p.184-194.
4. John Song, Proposed "Congruent Matching Cells (CMC)" Method for Ballistic Identification and Error Rate Estimation// AFTE 2015, Vol.47, №3, pp.177-185.
5. Sorokina K.O., Fedorenko V.A., Giverts P.V. Evaluation of the Similarity of Images of Breech Face Marks Using the Method of Correlation Cells. Informatsionnye tehnologii i vychislitel'nye sistemy [Information Technologies and Computing Systems], 2019, no. 3, pp. 3-15. DOI: 10.14357/20718632190301 (in Russian).
6. Bailey, Ken (1994). "Numerical Taxonomy and Cluster Analysis". Typologies and Taxonomies. p. 34. ISBN 9780803952591.
7. Kornilov M., Fedorenko V. Use of the Cluster Analysis to compare the Digital Images Traces of the Firing Pin// Proceedings of Saratov University 2014. Vol. 14. Ser. Economic. Management. Law, iss.1. P.2., pp 187-190.
8. Fedorenko V.A., Kornilov M.V. Automatic Comparison of Firing Pin Marks Against Descriptors Independent of Image Orientation // AFTE 2018, pp. 169-175.

9. Gonzalez R., Woods R. Tsifrovaia obrabotka izobrazhenii [Digital Image Processing]. Moscow, JSC "Tecnosphaera", 2019. 1104 p. (in Russian).
10. Furman Ia. A. Vvedenie v konturnyi analiz i ego prilozheniia k obrabotke izobrazhenii i signalov [Contour Analysis Introduction and its Image and Signal Processing Applications]. Moscow, Physics and mathematics publishers, 2003. 592 p. (in Russian).
11. S.B.A. Kamaruddin, N.A.M. Ghani, C.-Y. Liong, A.A. Jemain, Firearm Classification using Neural Networks on Ring of Firing Pin Impression Images, Adv. Distrib. Comput. Artif. Intell. J. 1 (2012) 27–35. <https://doi.org/10.14201/ADCAIJ20121312734>
12. O. Giudice, L. Guarnera, A.B. Paratore, G.M. Farinella, S. Battiato, Siamese Ballistics Neural Network, in: 2019 IEEE Int. Conf. Image Process., IEEE, 2019: pp. 4045–4049. <https://doi.org/10.1109/ICIP.2019.8803619>
13. Rashid T. Sozdaem neironnuiu set' [Make your own neural network]. St. Petersburg, Alfa-Book LLC, 2017. 272 p. (in Russian).
14. Nikolenko S. I., Kadurin A. A., Arkhangel'skaia E. O. Glubokoe obuchenie. Pogruzhenie v mir neironnykh setei [Deep Learning. Dipping into the world of neural networks]. St. Petersburg, Petersburg, 2018. 480 p. (in Russian).
2. David A. Forsyth, Jean Ponce "Computer Vision. A Modern Approach" 2018, p. 960.

**Fedorenko V. A.** Candidat 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 K. 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 P. V.** Ph.D., Division of Identification and Forensic Science, National Police HQ, Haim Bar-Lev road, Jerusalem, 91906, Israel, e-mail: pavel.giverts@gmail.com