

# Сравнение алгоритмов классификации радарных изображений при различных методах предобработки на примере базы MSTAR

А.А. Бородинов<sup>1</sup>, В.В. Мясников<sup>1,2</sup>

<sup>1</sup>Самарский национальный исследовательский университет имени академика С.П. Королева, Московское шоссе 34А, Самара, Россия, 443086

<sup>2</sup>Институт систем обработки изображений РАН – филиал ФНИЦ «Кристаллография и фотоника» РАН, Молодогвардейская 151, Самара, Россия, 443001

**Аннотация.** Данная работа направлена на сравнение алгоритмов классификации и методов машинного обучения при различных методах предварительной обработки радарных изображений. Предварительная обработка включает фильтрацию спекл-шума и нормализацию ориентации объекта на изображении. В сравнении рассматривались следующие алгоритмы классификации: дерево решений, метод опорных векторов, метод ближайших соседей, алгоритмы машинного обучения random forest и AdaBoost, в роли слабого классификатора использовалось дерево решений. Также были рассмотрены сверточная нейронная сеть (Convolutional Neural Network) и остаточная нейронная сеть (Residual Neural Network). Для уменьшения размерности был применен метод главных компонент. Исследование проводилось на объектах из базы радиолокационных изображений MSTAR. В статье представлены результаты проведенных исследований.

## 1. Введение

Радиолокационные космические снимки, полученные при помощи радаров с синтезированной апертурой (Synthetic Aperture Radar), получили свое распространение из-за независимости от погодных явлений и естественной освещенности. Распознавание образов на радарных снимках применяется в различных сферах, таких как сельское хозяйство, лесное хозяйство, геология, экология, а также в работе МЧС. Радар с синтезированной апертурой представляет обычно собой воздушную или космическую радарную систему, которая использует траекторию полета платформы для симуляции чрезвычайно большой антенны, что позволяет создавать изображения дистанционного зондирования земли с высоким разрешением.

Определенную сложность при обработке полученных изображений представляет собой спекл-шум, который присутствует на радиолокационных изображениях. Для улучшения точности классификации снимков также проводится нормализация ориентации объекта. В большинстве случаев угол поворота цели неизвестен. В данной работе рассматриваются три часто используемых в научных статьях метода для нахождения угла поворота: метод, основанный на использовании моментов изображения; метод, основанный на преобразовании Хафа, в котором происходит поиск длинных прямых линий на изображении, которые принимаются за границы объекта; метод, основанный на нахождении прямоугольника с минимальной площадью, описывающего объект.

В работе сравниваются классические алгоритмы классификации радарных изображений при различных методах их предварительной обработки и методы, основанные на применении сверточных нейронных сетей [8]. Все эксперименты проведены с использованием общедоступной базы радиолокационных снимков военной техники MSTAR.

Статья организована следующим образом. Во втором параграфе приведена постановка задачи классификации. В третьем параграфе описаны методы предварительной обработки изображений и приведено сравнение точности нахождения угла поворота. В четвертой главе описан метод снижения размерности признакового пространства. В пятой главе описаны исследуемые алгоритмы классификации. В шестой главе представлены результаты экспериментальных исследований. В заключении содержатся выводы и планы дальнейших исследований. В завершении работы указаны благодарности и список использованной литературы.

## 2. Постановка задачи классификации

Задачу распознавания объекта на изображении можно разделить на две основные подзадачи:

- поиск объекта на изображении и выделение областей интереса;
- распознавание и классификация найденного объекта или области интереса. [1]

Первая подзадача направлена на поиск объектов для классификации. Часто информация о местоположении, размерах, ориентации, наличии и количестве целей изначально отсутствует. В таком случае необходимо определить неизвестные параметры, требуемые для дальнейшего выделения объекта или локальной области интереса.

Вторая подзадача применяется для всего изображения целиком и позволяет принять решение к какому из нескольких классов обрабатываемое изображение относится. Решающая функция для каждого вектора признаков соотносит объект в соответствующий класс. В данной статье рассмотрена только задача классификации.

В связи с необходимостью обработки большого количества изображений для обучения и тестирования, а также низкой производительностью некоторых алгоритмов, возникает потребность в снижении размерности признакового пространства. Существуют различные методы, применяемые для решения данной задачи. К таким методам можно отнести наиболее популярные: метод главных компонент, факторный анализ, метод независимых компонент, самоорганизующиеся карты Кохонена и другие. В данной работе применен метод главных компонент.

## 3. Предварительная обработка изображений

Предварительная обработка изображений состоит из двух этапов. На первом этапе происходит фильтрация спекл-шума фильтром Ли и пороговой обработкой. На втором этапе применяется один из методов нормализации ориентации объекта на изображении.

Метод, основанный на моментах изображения, позволяет получить необходимый угол поворота при помощи следующей формулы, где

$$\begin{aligned} \mu_{11}' &= \mu_{11}/\mu_{00} = M_{11}/M_{00} - xy, \\ \mu_{20}' &= \mu_{20}/\mu_{00} = M_{20}/M_{00} - x^2, \\ \mu_{02}' &= \mu_{02}/\mu_{00} = M_{02}/M_{00} - y^2: \\ \varphi &= \frac{1}{2} \arctg \frac{2\mu_{11}'}{\mu_{20}' + \mu_{02}'} + v \frac{\pi}{2} \quad (v = 0, 1, \dots) \end{aligned} \quad (1)$$

В методе, основанном на нахождении минимальной площади прямоугольника, описывающего объект на изображении, угол поворота вычисляется как угол между горизонталью и одной из сторон прямоугольника. Предполагается, что прямоугольник опишет объект на изображении таким образом, что самая длинная грань объекта будет описана длинной стороной прямоугольника. Для выделения границ объекта используется алгоритм Кэнни. На рисунке 1 представлена схема алгоритма предварительной обработки.


Объекты из базы MSTAR, описанные прямоугольником минимальной площади показаны на рисунке 2.

Метод, основанный на преобразовании Хафа, предполагает нахождение длинных прямых линий на изображении, которые могут являться границами объекта. Угол поворота вычисляется для линии, соответствующей самой длинной, прямой и непрерывающейся грани объекта. Как и

предыдущий, данный метод подходит для нормализации ориентации объекта с прямыми границами. Для выделения границ можно воспользоваться алгоритмом Кэнни или оператор Собеля. На рисунке 3 представлена схема алгоритма предварительной обработки с описанным методом.



**Рисунок 1.** Алгоритм предварительной обработки с использованием метода, основанного на нахождении прямоугольника минимальной площади.



**Рисунок 2.** Слева представлен пример ошибочного нахождения прямоугольника, справа показано корректное выделение объекта.



**Рисунок 3.** Алгоритм предварительной обработки с использованием метода, основанного на нахождении прямоугольника минимальной площади.

Пример работы описанного метода представлен на рисунке 4.



**Рисунок 4.** Первые два изображения демонстрируют неверное нахождение грани объекта, третье и четвертое демонстрируют корректную работу метода.

В таблице 1 представлено процентное соотношение количества изображений, отклоненных от истинного угла поворота на указанный угол, к общему числу изображений.

Полученные после нормализации ориентации объекта изображения обрезаются.

**4. Метод главных компонент**

Метод главных компонент (PCA - Principal Components Analysis) является одним из наиболее используемых способов уменьшения размерности признакового пространства с потерей

наименьшего количества информации. Данный метод сводится к вычислению собственных значений ковариационной матрицы анализируемого изображения. [2] Алгоритмы вычисления ковариационной матрицы работают в построчном режиме чтения изображения, что позволяет достичь высокой производительности и невысокие требования к объему оперативной памяти. [3]

**Таблица 1.** Сравнение результатов использовавшихся методов нормализации ориентации объекта.

Отклонение от истинного угла поворота	Моменты изображения, %	Прямоугольник с мин. площадью, %	Преобразование Хафа, %
>30	4,276	9,922	6,079
20 – 30	8,697	10,678	6,399
10 – 20	37,056	25,778	9,862
5 – 10	25,916	20,367	14,251
2 - 5	14,049	18,621	30,163
1 - 2	4,945	7,390	15,707
<1	5,061	7,244	17,539

## 5. Алгоритмы классификации

### 5.1. *KNeighbors*

Алгоритм  $k$  ближайших соседей относится к метрическим алгоритмам классификации с обучающей выборкой  $\Omega_0$ . Такие алгоритмы относят объект  $u$  к тому классу  $y \in Y$ , для которого суммарный вес ближайших объектов из обучающей выборки максимален:

$$a(u, \Omega_0) = \arg \max_{y \in Y} \Gamma_y(u, \Omega_0), \quad \Gamma_y(u, \Omega_0) = \sum_{i=1}^K [y_u^{(i)} = y] \omega(i, u). \quad (2)$$

Где весовая функция  $\omega(i, u)$  оценивает степень важности  $i$ -го соседа для классификации объекта  $u$ . Функция  $\Gamma_y(u, \Omega_0)$  является оценкой близости объекта  $u$  к классу  $y$ . Функция степени важности выбирается неотрицательной и не возрастающей по  $i$ . Критерии выбора обусловлены тем, что чем меньше расстояние между исследуемыми объектами выборки  $u$  и  $x_u^{(i)}$ , тем больше вероятности верной классификации. В алгоритме  $k$  ближайших соседей, объект  $u$  относят к такому классу, которому принадлежит больше элементов, среди  $k$  ближайших соседей  $x_u^{(i)}$ ,  $i = \overline{1, k}$ :

$$\omega(i, u) = [i \leq k] \omega_i, \quad a(u, \Omega_0, k) = \arg \max_{y \in Y} \sum_{i=1}^k [y_u^{(i)} = y] \omega_i. \quad (3)$$

В работе использовалась метрика Минковского. Данная метрика определяется через следующую формулу:

$$r(x, y) = (\sum_{i=1}^n |x_i - y_i|^p)^{1/p}. \quad (4)$$

К недостаткам метрических алгоритмов можно отнести хранение всей обучающей выборки.

### 5.2. *Decision Tree (C4.5, CART)*

Под деревом решений понимается структура иерархического типа, в ветках которой определяют разбиение пространства признаков, а листьями являются элементарные функции классификации. Существует различные методы построения деревьев. В данной работе будут рассмотрены алгоритмы C4.5 [4] и CART [5].

C4.5, получая на вход выборку  $\Omega_0$ , строит исходное дерево, основываясь на следующих правилах. Если все объекты в выборке принадлежат одному классу или выборка мала, то дерево представляет из себя лист, промаркированный наиболее встречающимся классом в выборке. Иначе, выбирается критерий разбиения, делящий выборку на две или более выборки. Затем критерий выбирается для полученных разбиений. Данная процедура рекурсивно применяется

для каждой полученной выборки. Одним из используемых критериев, который используется в работе, является минимизация значения энтропии получаемых разбиений выборки. Полученное исходное дерево затем обрезают, чтобы избежать переобучения. По полученному дереву строится решающая функция для классификации объектов.

В алгоритме CART рекурсивно строится бинарное дерево решений. Дерево создается до максимального размера без использования правила останова, а затем обрезается. Алгоритм строит не одно, а последовательность вложенных обрезанных деревьев. Выбор наилучшего разбиения происходит на основе скользящего контроля. Критерий разбиения основан на индексе Джини.

### 5.3. SVM

Метод опорных векторов является одним из самых надежных методов среди всех известных алгоритмов и чаще всех применяется для сравнения с новыми алгоритмами. Разделяющая классы функция представляет собой разделяющую гиперплоскость. Алгоритм максимизирует кратчайшее расстояние между точками, ближайшими к точкам на гиперплоскости [6]. В работе в качестве разделяющей гиперплоскости применяется линейная разделяющая функция и радиальная базисная функция.

### 5.4. AdaBoost

Популярный алгоритм усиления ансамбля классификаторов AdaBoost был предложен Фрейндом и Шапиром [7]. Основная идея алгоритма заключается в обучении ансамбля слабых классификаторов. Затем производится объединение полученных предсказаний путем взвешенного голосования большинства. Изначально весовые коэффициенты равны. На очередной итерации алгоритм изменяет веса. Для каждой последующей итерации веса выборок меняются индивидуально. Вес данных, которые были классифицированы неверно, увеличивается. Таким образом алгоритм концентрирует обучение на сложно классифицируемых данных. В роли слабых классификаторов, используемых в ансамбле при проведении экспериментов, применяются деревья решений.

### 5.5. Random forest

Random Forest представляет собой множество решающих деревьев. Решение о классификации принимается путем голосования большинства. Каждое решающее дерево строится независимо от других. Для каждого дерева выбирается подвыборка обучающей выборки. Для расщепления дерева выбирается наилучший признак. Обычно дерево строится до исчерпания выборки. В листьях дерева должны содержаться представители лишь одного класса.

### 5.6. Convolutional Neural Network

Сверточная нейронная сеть (CNN) состоит из одного или нескольких сверточных слоев и последующими одним или несколькими полносвязными слоями. CNN часто используют для распознавания объектов, изображений, а также для обнаружения и сегментации объектов. Использование графических процессоров позволило значительно ускорить обучение нейронной сети и уменьшить время проведения экспериментальных исследований. Алгоритмы классификации, построенные на основе сверточных нейронных сетей, позволяют добиться лучших результатов в распознавании изображений и устойчивости к повороту и сдвигу объекта на снимке.

### 5.7. Residual Neural Network

Остаточная нейронная сеть представляет собой развитие сверточных нейронных сетей. Остаточные сети позволяют конструировать гораздо более глубокие сети, чем обычные сверточные сети. В статье [8] описывается использование ансамбля из шести остаточных нейронных сетей, каждая из которых имела до 152 слоев.

Остаточная нейронная сеть состоит из остаточных блоков, включающих в себя пару слоев, где вход первого слоя добавляется к выходу второго слоя. На рисунке 5 представлен остаточный блок.




Рисунок 5. Остаточный блок в остаточной нейронной сети.

Остаточную функцию можно записать выражением  $\mathcal{F}(x) = \mathcal{H}(x) - x$ . Где первоначальная целевая функция будет равна  $\mathcal{H}(x) = \mathcal{F}(x) + x$ .

В данной статье используется остаточная нейронная сеть из 32 слоев.

## 6. Оценка результатов классификации

Для оценки результатов классификации используется метод скользящего контроля. Скользящий контроль (cross-validation, CV) представляет собой статистический метод для оценки обобщения качества классификации. Он является более надежным и тщательным способом оценивания, по сравнению с обычным последовательным разбиением набора данных на обучающую и тестовую выборки. При скользящем контроле данные неоднократно делятся на обучающий и тестовый наборы и подаются на вход классификатора.

В работе применяется модифицированный метод скользящего контроля с многократным разбиением по блокам [9] при котором весь объем данных разбивается на заданное количество равных (с точностью до 1) частей  $N$ . Число итераций обучения в данном алгоритме соответствует количеству блоков  $N$ . Также происходит стратификация классов и выборки, позволяя уменьшить дисперсию оценок скользящего контроля. Это приводит к уменьшению доверительного интервала и получению более точного значения качества классификации. Применении стратификации классов дает возможность разбивать каждый класс в заданном соотношении. На каждой итерации алгоритма случайным образом выбираются  $K$  частей в качестве обучающей выборки и  $L$  частей в качестве тестируемой выборки. Данное разбиение можно описать следующим образом:

$$N \geq K + L, \Omega_0 \cup \Omega_T = \Omega', \Omega' \subseteq \Omega, \Omega_0 \cap \Omega_T = \emptyset, \Omega_0 = \bigcup_{i=0}^{K-1} \Omega_{0i}, \Omega_T = \bigcup_{j=0}^{L-1} \Omega_{Tj}, \quad (5)$$

где  $\Omega_0$  обучающая выборка,  $\Omega_T$  тестовая выборка,  $\Omega$  исходная выборка.

Для каждого полученного разбиения производится настройка классификатора на обучающей выборке и рассчитываются значение качества классификатора на тестовой выборке.

Функционал качества алгоритма на выборке имеет следующий вид:

$$CV(\mu, \Omega') = \frac{1}{N} \sum_{p=1}^N \frac{1}{N} \sum_{q=1}^N Q(\mu(\Omega' \setminus \Omega_{0pq}), \Omega_{0pq}), \quad (6)$$

где  $\mu$  является методом обучения.

## 7. Экспериментальные исследования

Все экспериментальные исследования проводились на ПК Intel Core i5-6600, 16 Гб ОЗУ, NVIDIA GeForce GTX 970. Все алгоритмы классификации были написаны на языке программирования Python 3.6. Также использовались фреймворки и библиотеки scikit-learn, scikit-image, openCV, numpy, tflearn, tensorflow. В качестве объектов классификации выступали образцы военной техники из публичной базы данных радиолокационных изображений MSTAR.

Для распознавания использовались магнитудные значения изображений БМП-2, БТР-60, БТР-70 и Т-72. Перед классификацией была проведена описанная в 3 параграфе предварительная обработка и обрезка изображений до размера 60×60 пикселей. Классификация нейронными сетями проводилась без предварительной обработки изображений.

Угол съемки целей составляет 15 и 17 градусов. Исходная выборка состоит из 3438 изображений. Для всех изображений из общей выборки было проведено снижение размерности. Список исследуемых классификаторов приведен в таблице 2.

**Таблица 2.** Исследуемые классификаторы.

KNeighbor	Метод ближайших соседей
CART	Дерево решений на основе алгоритма CART
C4.5	Дерево решений на основе алгоритма C4.5
SVM	Метод опорных векторов для радиальной базисной функции
AdaBoost	Алгоритм ускорения AdaBoost
Random forest	Случайный лес
CNN	Сверточная нейронная сеть
ResNet	Остаточная нейронная сеть

Значение качества классификации будем рассчитывать, как среднее относительное число верно классифицированных объектов из тестовой выборки  $\Omega_T$ . Для метода скользящего контроля зададим число разбиений и число итераций  $N = 10$ ,  $K = 6$  и  $L = 4$ , разбив общую выборку в соотношении 6:4. Метод главных компонент позволит сократить размерность, сохранив значимую часть информации радиолокационного изображения, необходимую для классификации объектов. Результаты классификации представлены в таблице 3.

**Таблица 3.** Результаты классификации.

	Моменты изображения	Прямоугольни к с мин. площадью	Преобразовани е Хафа	Известно е значение угла поворота	Без предварительно й обработки
KNeighbors	0.93837	0.91904	0.89862	0.97689	-
CART	0.72500	0.74856	0.70908	0.82137	-
C4.5	0.75218	0.75196	0.71672	0.84055	-
SVM	0.93263	0.93299	0.90887	0.97071	-
AdaBoost	0.90029	0.87232	0.87769	0.94365	-
Random forest	0.90320	0.89113	0.86926	0.94851	-
CNN	-	-	-	-	0.97516
ResNet	-	-	-	-	0.96535

Алгоритмы AdaBoost и Random forest значительно превзошли результаты CART и C4.5. Возможно, дальнейший подбор параметров поможет достичь значений, которые показали метод ближайших соседей и метод опорных векторов. Хотя метод, основанный на преобразовании Хафа, показал наименьшее среднее значение отклонения полученного угла от известного значения, точность классификация с данным методом предварительной обработки уступила

точности классификации при использовании двух других методов по причине высокого значения среднеквадратичного отклонения.

Алгоритмы классификации, основанные на применении сверточных нейронных сетей, превзошли остальные исследуемые алгоритмы классификации в случае использования методов нормализации ориентации объекта. Метод ближайших соседей и метод опорных векторов при известном угле поворота цели показывают похожую точность классификации. В связи с тем, что в практических задачах классификации редко известен угол поворота объекта, применение алгоритмов классификации, основанных на сверточных нейронных сетях, позволит добиться лучших результатов даже без предварительной обработки изображений.

## 8. Заключение

В работе проведено сравнение алгоритмов классификации в задаче распознавания объектов на радарных изображениях. Были представлены и исследованы различные методы предварительной обработки изображений и нормализации ориентации объектов. Проведенные экспериментальные исследования показали зависимость точности классификации от значения среднеквадратичного отклонения угла поворота изображения. Показано, что применение алгоритмов классификации, основанных на сверточных нейронных сетях, позволяет получить наилучшую точность классификации даже без предварительной обработки изображений.

Дальнейшим направлением исследований является разработка алгоритма классификации, основанного на сверточной нейронной сети и выбор наилучших гиперпараметров, позволяющего превзойти полученную точность классификации.

## 9. Благодарности

Работа выполнена при поддержке Федерального агентства научных организаций (соглашение № 007-ГЗ/ЧЗ363/26) и РФФИ в рамках научного проекта № 18-31-00350-мол\_а.

## 10. Литература

- [1] Гашников, М.В. Методы компьютерной обработки изображений / М.В. Гашников, Н.И. Глумов, Н.Ю. Ильясова, В.В. Мясников, С.Б. Попов, В.В. Сергеев, В.А. Сойфер, А.Г. Храмов, А.В. Чернов, В.М. Чернов, М.А. Чичева, В.А. Фурсов; под ред. В.А. Сойфера. – 2-е изд., испр. – М.: Физматлит, 2003. – 784 с.
- [2] Метод главных компонент [Электронный ресурс]. – Режим доступа: [http://www.machinelearning.ru/wiki/index.php?title=Метод\\_главных\\_компонент](http://www.machinelearning.ru/wiki/index.php?title=Метод_главных_компонент) (26.01.2017).
- [3] Кузнецов, А.В. Сравнение алгоритмов управляемой поэлементной классификации гиперспектральных изображений / А.В. Кузнецов, В.В. Мясников // Компьютерная оптика. – 2014. – Т. 38, № 3. – С. 495-502.
- [4] Quinlan, J.R. C4.5: Programs for Machine Learning / J.R. Quinlan. – San Mateo: Morgan Kaufmann Publishers Inc., 1993. – 302 p.
- [5] Wu, X. Top 10 algorithms in data mining / X. Wu, V. Kumar, J. Ross Quinlan et al. // Knowledge and Information Systems. – 2008. – Vol. 14(1). DOI: 10.1007/s10115-007-0114-2.
- [6] Cortes, C. Support-Vector Networks / C. Cortes, V. Vapnik // Machine Learning. – 1995. – Vol. 20(3). – P. 273-297.
- [7] Freund, Y. A decision-theoretic generalization of on-line learning and an application to boosting / Y. Freund, R.E. Schapire // J Comput Syst Sci. – 1997. – Vol. 55(1). – P. 119-139.
- [8] He, K. Deep residual learning for image recognition / K. He, X. Zhang, S. Ren, J. Sun // CVPR. – 2016. – P. 770-778.
- [9] Воронцов, К.В. Комбинаторный подход к оценке качества обучаемых алгоритмов / К.В. Воронцов // Математические вопросы кибернетики; под ред. О.Б. Лупанов. – М.: Физматлит, 2004. – Т. 13. – С. 5-36.



## Comparison of radar image classification algorithms for various preprocessing methods based on MSTAR data

A.A. Borodin<sup>1</sup>, V.V. Myasnikov<sup>1,2</sup>

<sup>1</sup>Samara National Research University, Moskovskoe Shosse 34A, Samara, Russia, 443086

<sup>2</sup>Image Processing Systems Institute of RAS - Branch of the FSRC "Crystallography and Photonics" RAS, Molodogvardejskaya street 151, Samara, Russia, 443001

**Abstract.** This work is aimed at comparing the classification algorithms and methods of machine learning with various methods for preprocessing radar images. Preprocessing includes speckle noise filtering and object orientation normalization on the image. In comparison, the following classification algorithms were considered: the decision tree, the support vector machine, the nearest-neighbor method, the random forest and AdaBoost machine learning algorithms, and the decision tree was used as a weak classifier. Convolutional Neural Network and Residual Neural Network were also considered. To reduce the dimension, the principal component method was applied. The study was carried out on the objects from the base of radar images MSTAR. The paper presents the results of the research.

**Keywords:** SAR, Machine learning, Digital images, Convolutional Neural Network, CNN.