

Сравнение алгоритмов классификации в задаче распознавания объектов на радарных изображениях базы MSTAR

А.А. Бородинов^а, В.В. Мясников^а

^а Самарский национальный исследовательский университет имени академика С.П. Королева, 443086, Московское шоссе, 34, Самара, Россия

Аннотация

Настоящая работа посвящена сравнению качества работы ряда известных алгоритмов классификации в задаче распознавания локальных объектов на радарных изображениях. В сравнении используются следующие алгоритмы классификации: дерево решений; байесовский классификатор для нормального распределения; метод ближайшего соседа; метод опорных векторов (SVM). В качестве предварительной обработки изображений, полученных радаром с синтезированной апертурой, используются нормализация ориентации распознаваемого объекта и метод главных компонент. Исследование проводится на объектах из базы радиолокационных снимков MSTAR. В работе представлены результаты проведенных исследований.

Ключевые слова: классификация изображений; радар с синтезированной апертурой; классификация; дерево решений; C4.5; CART; SVM; MSTAR.

1. Введение

Радиолокационные космические снимки, полученные при помощи радаров с синтезированной апертурой, получили свое распространение из-за независимости от погодных явлений, а также способности получать снимки объектов вне зависимости от их освещенности. Определенную сложность при обработке полученных изображений представляет собой спекл-шум, который присутствует на радиолокационных изображениях. Распознавание образов на радиолокационных снимках применяется в различных сферах, таких как сельское хозяйство, лесное хозяйство, анализ рельефа, мониторинг разливов нефти и распознавание техники. Исследования различных алгоритмов классификации радиолокационных изображений проводились и ранее, однако часто в них сравниваются полученные данные с данными из других статей. Такой подход может привести к неточным результатам анализа полученных результатов. Также большинство статей используют для сравнения только наиболее популярные алгоритмы классификации, такие как SVM, AdaBoost и нейронные сети. В данной работе в исследовании приняли классификаторы, редко используемые в работах по данной теме: деревья решений, метод ближайших соседей, наивный байесовский классификатор. Цель данной работы - восполнить указанный пробел. Все тесты проведены с использованием общедоступной базы радиолокационных снимков военной техники MSTAR.

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. Целевая задача классификации является построение решающей функции. Решающая функция для каждого вектора признаков соотносит 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. Метод главных компонент (PCA)

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]

4. Оценка результатов классификации

Для оценки результатов классификации используется метод скользящего контроля. Скользящий контроль (кросс-валидация, кросс-проверка (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 [4] 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:

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

где Ω_0 обучающая выборка, Ω_T тестовая выборка, Ω 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:

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

где μ является методом обучения.

5. Алгоритмы классификации РИ

5.1. Байесовский классификатор гауссовский случай

Метод классификации, основанный на наивном байесовском классификаторе, является алгоритмом обучения с учителем, в котором применяется теорема Байеса со строгим (наивным) предположением о независимости между каждыми парами признаков [5]. Предположение о независимости позволяет избавиться от сложной схемы оценки параметров классификатора. Это позволяет применять алгоритм на больших выборках. Также классификация оказывается достаточно точной: недостаточной для высокоточных систем классификации, однако удовлетворительной для грубой оценки и сравнения с другими алгоритмами. Исходя из теоремы Байеса:

$$P(y|x_1, \dots, x_n) = \frac{P(y)P(y|x_1, \dots, x_n)}{P(x_1, \dots, x_n)}$$

и предположении независимости, получаем:

$$P(x_i|y, x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n) = P(x_i|y),$$

что можно переписать:

$$P(y|x_1, \dots, x_n) = \frac{P(y) \prod_{i=1}^n P(x_i|y)}{P(x_1, \dots, x_n)},$$

и получить в результате классификатор – функцию \hat{y} :

$$\hat{y} = \arg \max_y P(y) \prod_{i=1}^n P(x_i|y).$$

и использовать оценку апостериорного максимума для оценки $P(y)$ и $P(x_i|y)$.

Различные наивные байесовские классификаторы различаются, в основном, допущениями, которые они делают относительно $P(x_i|y)$.

В данной работе используемые плотности – гауссовский случай, в основе которого лежит использование плотности распределения вероятностей вида:

$$P(x_i|y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} e^{-\frac{(x_i-\mu_y)^2}{2\sigma_y^2}},$$

Где μ_y и σ_y^2 являются математическим ожиданием и корреляционной матрицей.

5.2. KNeighbors

Алгоритм k ближайших соседей относится к метрическим алгоритмам классификации с обучающей выборкой Ω_0 . Такие алгоритмы относят объект u к тому классу $y \in Y$, для которого суммарный вес ближайших объектов из обучающей выборки максимален:

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

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 $x_u^{(i)}$, $i = \overline{1, k}$:

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

В качестве метрики чаще всего выбирается евклидова метрика из-за ее простоты и понятности. В работе исследуются три метрики: евклидова, Минковского и манхэттенское расстояние.

Евклидово расстояние между двумя точками x, y определяется в евклидовом n -мерном пространстве как :

$$r(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}.$$

Манхэттенское расстояние определяется как сумма модулей разностей координат:

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

Еще одной метрикой на евклидовом пространстве, которая исследуется в работе является метрика Минковского. Ее можно рассматривать как обобщение евклидова и манхэттенского расстояний. При параметре $p = 2$, расстояние Минковского обобщается в евклидово расстояние, а при $p = \infty$ - в расстояние Чебышева. Данная метрика определяется через следующую формулу:

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

К недостаткам метрических алгоритмов можно отнести хранение всей обучающей выборки.

5.3. 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 [6] и CART [7].

C4.5, получая на вход выборку Ω_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.

5.4. 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 [8]. В работе в качестве разделяющей функции применяется линейная разделяющая функция и радиальная базисная функция.

6. Экспериментальные исследования

Все экспериментальные исследования проводились на ПК Intel Core i5-4460, 16 Гб ОЗУ. Все алгоритмы классификации были написаны на языке программирования Python 3.6. Также использовались фреймворки и библиотеки scikit-learn, openCV, numpy. В качестве объектов классификации выступали образцы военной техники из публичной базы данных радиолокационных изображений MSTAR, представленной на рисунке 1.

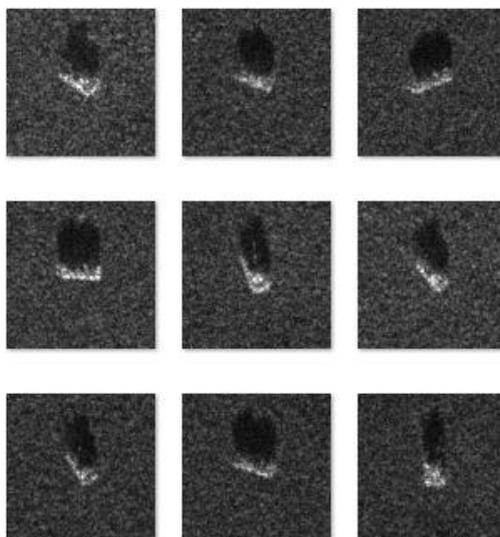


Рис. 1. Изображения объектов MSTAR.

Для распознавания использовались магнитудные значения изображений БМП-2, БТР-60, БТР-70 и Т-72. В качестве предобработки изображений была проведена нормализация ориентации объектов на центрированных изображениях и их обрезка с размера 128×128 до 60×60 пикселей. Полученные изображения представлены на рисунке 2.

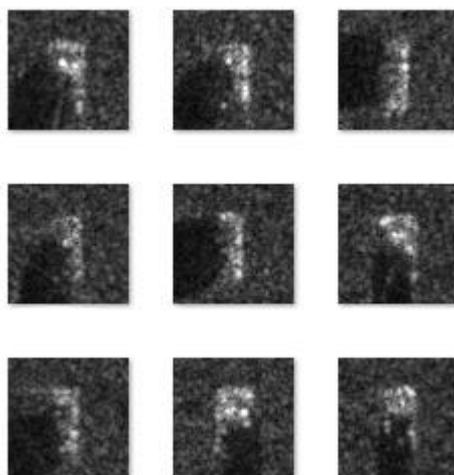


Рис. 2. Обработанные изображения MSTAR.

Угол съемки целей составляет 15 и 17 градусов. Исходная выборка состоит из 3438 изображений различных классов объектов. Количество изображений каждого класса представлено в таблице 1.

Таблица 1. Количество объектов классификации

Объект/Угол	15°	16°
БМП-2	587	698
БТР-60	195	256
БТР-70	196	233
Т-72	582	691

Для всех изображений из общей выборки было проведено снижение размерности. Список исследуемых классификаторов приведен в таблице 2.

Таблица 2. Исследуемые классификаторы

GaussianNB	Наивный гауссовский байесовский классификатор
KNeighbor_1	Метод ближайших соседей, евклидова метрика
KNeighbor_2	Метод ближайших соседей, манхэттенское расстояния
KNeighbor_3	Метод ближайших соседей, расстояние Минковского
CART	Дерево решений на основе алгоритма CART
C4.5	Дерево решений на основе алгоритма C4.5
SVM_1	Метод опорных векторов для линейной разделяющей функции
SVM_2	Метод опорных векторов для радиальной базисной функции

Значение качества классификации будем рассчитывать, как среднее относительное число верно классифицированных объектов из тестовой выборки Ω_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 до 20 собственных векторов, сохранив значимую часть информации радиолокационного изображения, необходимую для классификации объектов. Подробные результаты классификации представлены в таблице 3.

Таблица 3. Результаты классификации

	БМП-2	БТР-60	БТР-70	T72	Средн.
GaussianNB	0.10895	0.62011	0.78899	0.74476	0.56570
KNeighbor_1	0.98156	0.95438	0.98680	0.97407	0.97420
KNeighbor_2	0.98586	0.95476	0.98721	0.97448	0.97558
KNeighbor_3	0.98152	0.96915	0.98481	0.97208	0.97689
CART	0.85964	0.78115	0.77543	0.86927	0.82137
C4.5	0.87424	0.75564	0.85257	0.87975	0.84055
SVM_1	0.92018	0.66914	0.89281	0.87513	0.83932
SVM_2	0.96351	0.96602	0.95939	0.99392	0.97071

Как показали исследования, наилучший результат классификации радиолокационных изображений показали метод ближайших соседей (с расстоянием Минковского) и метод опорных векторов с радиальной базисной функцией.

6. Заключение

Из результатов проведенного исследования видно, что наилучшие показатели классификации радиолокационных изображений базы MSTAR дают метод ближайших соседей, а также метод опорных векторов. В последующих исследованиях планируется применить алгоритмы бустинга, такие как AdaBoost [9], и нейронные сети. За последние несколько лет было множество публикаций с применением нейронных сетей [10] для классификации радиолокационных изображений, поэтому их исследование и сравнение результатов классификации с результатами, полученными в данной работе, вызывает большой интерес.

Литература

- [1] Методы компьютерной обработки изображений / М.В. Гашников, Н.И. Глузов, Н.Ю. Ильясова, В.В. Мясников, С.Б. Попов, В.В. Сергеев, В.А. Соيفер, А.Г. Храмов, А.В. Чернов, В.М. Чернов, М.А. Чичева, В.А. Фурсов; под ред. В.А. Соифера. – 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 (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] Воронцов, К.В. Комбинаторный подход к оценке качества обучаемых алгоритмов. — Математические вопросы кибернетики / Под ред. О. Б. Лупанов. — М.: Физматлит, 2004. — Т. 13. — С. 5–36.
- [5] Naive Bayes [Electronic resource]. — Access mode: http://scikit-learn.org/stable/modules/naive_bayes.html (23.01.2017).
- [6] C4.5: Programs for Machine Learning / J.R. Quinlan. –San Mateo: Morgan Kaufmann Publishers Inc., 1993. –302 p.
- [7] Top 10 algorithms in data mining / Wu, X., Kumar, V., Ross Quinlan, J. et al. // Knowledge and Information Systems. -2008. Vol. 14(1). DOI:10.1007/s10115-007-0114-2
- [8] Cortes, C. Support-Vector Networks / C. Cortes, V. Vapnik // Machine Learning. – 1995. – Vol. 20(3). – P. 273-297.
- [9] Sun, Y. Adaptive Boosting for SAR Automatic Target Recognition / Y. J. Sun , Z. P. Liu , S. Todorovic , and J. Li// IEEE Trans. Aerosp. Electron. Syst. .- vol. 43 , №. 1 , - P. 112 – 125
- [10] Profeta, A. Convolutional neural networks for synthetic aperture radar classification / A.Profeta, A. Rodriguez, H.S. Clouse // Algorithms for Synthetic Aperture Radar Imagery XXIII. -2016. –Vol. 9843. DOI:10.1117/12.2225934