

УДК 004.932.2

С.В. Воронов, И.В. Воронов, В.А. Шрамов

ОБНАРУЖЕНИЕ ОБЪЕКТОВ НА ИЗОБРАЖЕНИЯХ С ПРИМЕНЕНИЕМ ГИСТОГРАММ ОРИЕНТАЦИЙ ГРАДИЕНТОВ¹

Воронов Сергей Васильевич, кандидат технических наук, окончил радиотехнический факультет Ульяновского государственного технического университета, доцент кафедры «Радиотехника» УлГТУ. Имеет статьи и монографии в областях обработки и анализа сигналов, изображений и их последовательностей, а также в области компьютерного зрения. [e-mail: valmedia@yandex.ru].

Воронов Илья Васильевич, окончил радиотехнический факультет УлГТУ, аспирант УлГТУ. Имеет статьи в области обработки и рекуррентного оценивания параметров цифровых изображений и их последовательностей. [e-mail: ilvo1987@gmail.com].

Шрамов Вадим Андреевич, окончил радиотехнический факультет УлГТУ, аспирант УлГТУ. Инженер-исследователь ФНПЦ АО «НПО «Марс». [e-mail: vadim_shramov@mail.ru].

Аннотация

Автоматизированное обнаружение объектов различных классов на изображениях и кадрах видеопоследовательностей является одной из основных задач компьютерного зрения. Наиболее широко используемый на сегодняшний день подход к решению данной задачи заключается в извлечении из локальных областей изображений объектов некоторых признаков и дальнейшем обучении на основе полученных векторов признаков алгоритмов классификации. При этом наибольший интерес с точки зрения соотношения эффективности и требуемых вычислительных ресурсов представляют признаки, получаемые на основе гистограмм ориентаций градиентов. Данная работа посвящена модификации способа извлечения локальных признаков на основе гистограмм ориентаций градиентов, которая заключается в извлечении признаков вдоль граней, что позволяет учитывать их пространственное расположение. Также для увеличения дискриминационных свойств векторов признаков предложено дополнительно использовать информацию о структуре, которая основана на использовании «центра тяжести» локальных областей. Полученные экспериментальные результаты позволяют говорить о том, что предложенные изменения по сравнению с традиционным способом извлечения признаков позволяют повысить как точность обнаружения объектов разных классов, так и скорость сходимости алгоритмов классификации.

Ключевые слова: обнаружение объекта, гистограмма ориентаций градиентов, локальные признаки, AdaBoost, вектор признаков, классификация.

DETECTION OF OBJECTS ON IMAGES WITH THE USE OF HISTOGRAMS OF ORIENTATED GRADIENTS

Sergei Vasilevich Voronov, Candidate of Engineering; graduated from the Faculty of Radioengineering of Ulyanovsk State Technical University; Associate Professor at the Department of Radioengineering; an author of articles and monographs in the field of digital signal and image processing and computer vision. e-mail: valmedia@yandex.ru.

Ilia Vasilevich Voronov, Postgraduate Student at Ulyanovsk State Technical University; graduated from the Faculty of Radioengineering of Ulyanovsk State Technical University; an author of articles in the field of digital signal and image processing. e-mail: ilvo1987@gmail.com.

Vadim Andreevich Shramov, Postgraduate Student at Ulyanovsk State Technical University; graduated from the Faculty of Radioengineering of Ulyanovsk State Technical University; Research Engineer at FRPC JSC "RPA "Mars". e-mail: vadim_shramov@mail.ru.

Abstract

Automated detection of objects of different classes on images and frames of video sequences is one of the main tasks of computer vision. The most widely used approach to solving this problem today is extracting certain features from the local image areas and further learning of classification algorithms on the basis of the extracted vectors. At the same time, the most interesting because of the good ratio of efficiency and the required computational resources are the features obtained using

¹ Работа выполнена при финансовой поддержке РФФИ, проект № 16-41-732084.

histograms of orientated gradients. This paper is devoted to the modification of the method of extraction of local features on the basis of histograms of orientated gradients, which consists in extracting features along the edges. It allows taking into account their spatial arrangement. Moreover, to increase the descriptive properties of feature vectors, it was suggested to use information on the structure that is based on the use of the "center of gravity" of local areas. Experimental results show that the proposed changes in comparison with the traditional method of extracting features allow to increase both the accuracy of detection of objects of different classes and the speed of convergence of classification algorithms.

Key words: object detection, HOG, local features, AdaBoost, feature vector, classification.

ВВЕДЕНИЕ

Автоматизированное обнаружение объектов различных классов на изображениях и кадрах видеопоследовательностей является одной из основных задач компьютерного зрения. Решение данной задачи требуется во множестве информационных систем нового поколения: видеонаблюдении, медицине, интернете, навигационных системах и т. д. При этом одна из основных проблем в этой области состоит в том, что внешний вид объекта может сильно меняться из-за многих факторов, таких как различная освещенность, изменение точки обзора, позы, присутствие шума и т. д., что приводит к высоким требованиям надежности разрабатываемых алгоритмов. Появление более дешевого и вычислительно эффективного оборудования способствовало значительному развитию данного направления и появлению различных методов, решающих указанную задачу [1]. Среди них широко используемая парадигма заключается в обучении классификатора по локальным признакам с использованием композиций алгоритмов (бустинг) [1–4]. Например, в работе [1] был предложен эффективный алгоритм детектирования лица с использованием алгоритма AdaBoost для обучения каскадного классификатора на основе хаароподобной функции. В [2] предложен подход на основе проецирования ковариационной матрицы к римановым многообразиям и последующего использования алгоритма LogitBoost для обучения детектора пешеходов.

Разработка новых и модификация существующих локальных признаков, которые могут эффективно отражать уникальные внутренние характеристики внешнего вида объекта, являются основными способами повышения эффективности алгоритмов обнаружения объектов. В общем, существуют два типа широко используемых локальных признаков: контурные и статистические. Контурные признаки обычно строятся вдоль границ для описания локальной структурной информации. В работе [5] была предложена функция кромки (edgelet feature), которая представляет собой короткий отрезок края или кривой с разным весом на каждый пиксель. В [6] рассмотрены адаптивные контурные признаки. Эти признаки состоят из цепочки из нескольких «гранул» в ориентированном гранулярном пространстве и обладают хорошим описательным свойством, которое позволяет выделять уникальные особенности объектов, что обеспечивает хорошие результаты в задачах обнаружения и сегментации людей [6]. Статистические признаки основаны на извлечении из локальных областей некоторой статистической информа-

ции (например, гистограммы, ковариационной матрицы, статистических моментов и т. д.), которая обладает сильной дискриминационной способностью, позволяющей успешно идентифицировать локальные области (по сути служащие некоторыми шаблонами) на различных изображениях.

Статистические признаки приобрели большую популярность на сегодняшний день. Среди наиболее известных признаков данной группы можно выделить: логарифмические фильтры Габора [7], выделение на основе вейвлет-преобразования [8], применение метода главных компонент [5], локальные бинарные шаблоны [9], дескрипторы SIFT [10], SURF [11] и гистограммы ориентаций градиентов [12]. При этом с точки зрения соотношения точности и требуемого объема вычислительных затрат наибольший интерес представляют гистограммы ориентаций градиентов.

При построении вектора признаков локальных областей на основе гистограмм ориентаций градиентов игнорируется важная структурная информация в каждой ячейке. Если две ячейки содержат одно и то же ребро, но в разных положениях, результирующие векторы признаков будут одинаковыми. Данная работа направлена на решение данной проблемы с целью увеличения дискриминационной способности гистограмм ориентаций градиентов и повышения точности детектирования объектов различных классов.

ГИСТОГРАММА ОРИЕНТАЦИЙ ГРАДИЕНТОВ

Основная идея построения признаков на основе гистограмм ориентаций градиентов заключается в том, что локальный внешний вид объекта и его форма на изображении могут быть описаны с помощью распределения градиентов яркостей или направлений граней [12]. Для вычисления данных признаков изображение разделяется на маленькие связанные области, называемые ячейками, и для каждой ячейки строится оценка гистограммы направлений градиентов пикселей, находящихся внутри ячейки. Для каждого пикселя ячейки вычисляется оценка градиента, которая используется во взвешенном голосовании для составления гистограммы ориентаций всей ячейки. Гистограмма разбивается на каналы, которые равномерно распределены в диапазоне от 0 до 180 градусов. При этом число этих каналов можно регулировать.

Комбинация гистограмм ячеек в конечном итоге и представляет вектор признаков. Конечный вектор признаков нормализуется по контрасту на основе оценки




Рис. 1. Пример выделения гистограммы ориентаций градиентов

некоторой меры интенсивности градиентов по большей области изображения, которую называют блоком [12]. Затем полученное значение используется для нормализации всех ячеек внутри блока. Эта нормализация приводит к лучшей инвариантности к изменениям в освещении или затенении [12]. Пример выделения гистограммы ориентаций градиентов показан на рисунке 1.

МОДЕРНИЗАЦИЯ ОЦЕНКИ ГИСТОГРАММЫ ОРИЕНТАЦИЙ ГРАДИЕНТОВ




Рис. 2. Выделение признаков вдоль граней

Как уже было отмечено, при вычислении вектора признаков локальной области на основе гистограммы ориентаций градиентов происходит потеря информации о местоположении граней.

Предположим, что мы вычисляем гистограммы ориентаций градиентов в ряде ячеек вдоль некоторой грани, которая может быть получена, например, с помощью детектора Канни [13], как показано на рисунке 2. Сама грань может представлять собой линии и дуги различной длины, позиции и направления.

Выделим 4 пикселя (точки), которые являются центрами ячеек (серые прямоугольники) и распределены равномерно на используемой грани. Эти ячейки могут накладываться друг на друга или находиться раздельно. Чтобы уменьшить размер области, которую могут покрывать выбранные ячейки, целесообразно добавить ограничение на расстояние d между двумя соседними центральными пикселями d и размером ячейки (w, h):

$$0,75 \cdot \max(w, h) < d \cdot \min(w, h).$$

Поскольку ячейки расположены вдоль граней, данный способ вычисления гистограммы ориентаций гради-

ентов не только извлекает статистическую информацию в локальной области, но также отражает положение и направление граней. Таким образом, при данном способе вычисления каждый контейнер вектора градиента представляет собой взвешенную сумму всех пикселей с одинаковой ориентацией градиента в ячейке. Его можно легко извлечь, используя алгоритм интегрального изображения [1]. Интегральное изображение представляет собой алгоритм для эффективной генерации суммы значений в прямоугольном подмножестве. Для входного изображения I значение в точке (x, y) в соответствующем интегральном изображении I' является суммой всех пикселей выше и слева от (x, y) в I . Тогда для получения суммы всех пикселей в прямоугольнике (A, B, C, D) в I можно использовать выражение:

$$S = I'(A) + I'(D) - I'(B) - I'(C).$$

При таком подходе вычисляется несколько градиентных изображений разных градиентных ориентаций и генерируются интегральные изображения. Затем полученные интегральные изображения можно использовать для вычисления суммы ячеек вдоль выбранной грани, чтобы получить конечный вектор признаков.

Помимо использования расположения ячеек, мы можем использовать и некоторую информацию о структуре распределения градиентов в ячейке при извлечении признаков, чтобы еще больше увеличить дискриминационную способность полученных признаков. Для начала разделим каждую ячейку на 8 регионов в соответствии с направлением каждого пикселя ячейки относительно центра ячейки, как показано на рисунке 3. Далее для каждой области рассчитываются «центры тяжести», а также расстояние между центром тяжести и центром ячейки. Полученное расстояние используется для генерации вектора структуры. Как видно на рисунке 3, ячейка разделена на 8 областей, которые пронумерованы от 0 до 7, а вектор r_1 (рис. 4.) иллюстрирует евклидово расстояние между «центром тяжести» области 1 и центром ячейки, которое будет использоваться при вычислении вектора структуры. Координату центра ячеек обозначим через (x_c, y_c) , тогда i -я ячейка структурного вектора \bar{s}_g может быть найдена как




Рис. 3. Разделение ячейки по направлениям




Рис. 4. Вектор расстояния до «центра тяжести»

$$\bar{s}_g = \frac{\sum_{(x,y) \in R_i} r_i \cdot \text{grad}(x,y)}{\sum_{(x,y) \in R_i} \text{grad}(x,y)}$$

где R_j – одна из 8 областей каждой ячейки, grad – величина градиента.

ПРИМЕНЕНИЕ АЛГОРИТМА ADABOOST СОВМЕСТНО С ГИСТОГРАММОЙ ОРИЕНТАЦИЙ ГРАДИЕНТОВ

В алгоритме обучения AdaBoost [14] вектор признаков некоторой локальной области изображения может рассматриваться как функция, отображающая пространство изображений в диапазон действительных чисел $f: x \rightarrow [f_{min}, f_{max}]$. Также AdaBoost основан на применении ансамблей слабых классификаторов. Слабый классификатор представляет собой функцию преобразования вектора признаков x в вещественное доверительное пространство классификации [14]. Для задачи бинарной классификации предположим, что данные для обучения представлены в виде $(x_1, y_1), \dots, (x_n, y_n)$, где x_i является элементом обучающей выборки, а $y_i \in \{-1, 1\}$ является меткой класса соответствующего элемента. Для начала разделим выборочное пространство на N_s равноразмерных поддиапазонов T_j , тогда слабый классификатор определяется как кусочная функция

$$h(x) = \frac{1}{2} \ln \left(\frac{W_+^j + \varepsilon}{W_-^j + \varepsilon} \right), \tag{1}$$

где ε – коэффициент сглаживания,

W_{\pm}^j – распределение вероятностей значения признака для позитивных/негативных элементов выборки, реализованное в виде гистограмм:

$$W_{\pm}^j = P(x \in X_j, y \in \{-1, 1\}), j = 1, \dots, N_s.$$

Лучший слабый классификатор выбирается в соответствии с ошибкой классификации Z кусочной функции в соответствии с уравнением [14]:

$$Z = 2 \cdot \sum_j \sqrt{W_+^j \cdot W_-^j}. \tag{2}$$

На каждой итерации функции кандидата вектора признаков оцениваются на всех положительных и отрицательных выборках. Чтобы обучить лучшие слабые классификаторы, наиболее интуитивно понятным способом является просмотр всего набора признаков, что является

малоэффективным с точки зрения требуемого объема вычислительных затрат. Поэтому можно воспользоваться следующим методом, чтобы снизить вычислительные затраты [14]. Для оценки качества из всего набора признаков выбирается случайная подвыборка размера $\log(0,05)/\log(0,95) = 59$, что гарантирует нахождение лучших 5% признаков с вероятностью 95%. Далее для каждого блока-кандидата выделяются векторы признаков, которые в последующем применяются для обучения линейной гиперплоскости классификации w^* с использованием метода наименьших квадратов. Затем конечное значение признака, используемое для построения вероятностного распределения, вычисляется по формуле [14]:

$$f(x) = w^* \cdot x + b \tag{3}$$

где b – величина смещения. Более подробно алгоритм представлен на рисунке 5.

ЭКСПЕРИМЕНТАЛЬНЫЕ РЕЗУЛЬТАТЫ

Эксперименты на наборе данных INRIA для детектирования пешеходов

Для оценки эффективности предложенного модифицированного способа расчета признаков на основе гистограмм ориентаций градиентов был использован набор данных изображений пешеходов INRIA [12], который содержит 1774 изображения, содержащих людей, а также 1671 изображение, на которых люди отсутствуют. Тестировались различные размеры ячеек от 8×8 до 32×32 , которые использовались с целью обучения каскадного классификатора скользящего окна размером 64×128 .

Параметры:
 N – число элементов обучающей выборки;
 M – число признаков для сравнения на каждой итерации;
 E – максимальное число слабых классификаторов.
 Входные данные: обучающая выборка $set\{(x_i, y_i)\}$.

1. Инициализация весов и выхода классификатора $w_i = 1/N, F(x_i) = 0$.
2. Цикл для $t = 1, 2, \dots, E$.
 - 2.1. Обновление весов w_i , используя t -й выход слабого классификатора $w_i = w_i \cdot e^{-y_i \cdot h_i(x)}$.
 - 2.2. Цикл для $m = 1, 2, \dots, M$.
 - 2.2.1. Выделение вектора признаков.
 - 2.2.2. Обучение гиперплоскости классификации w^* и вычисление $f(x)$ в (3).
 - 2.2.3. Построение предсказанных распределений вероятностей W_+ и W_- .
 - 2.2.4. Выделение наилучших признаков по минимуму Z из (2).
 - 2.3. Обновление слабых классификаторов $h_i(x)$ в соответствии с уравнением (1).
 - 2.4. Обновление сильного классификатора $F_{t+1}(x) = F_t(x) + h_i(x)$.
3. Результирующий классификатор $F(x) = \text{sign} \left[\sum_{j=1}^E h_j(x) \right]$.

Рис. 5. Алгоритм обучения классификатора

На рисунке 6 представлены графики зависимости вероятности пропуска объекта P_{MO} от среднего числа ложно позитивных объектов в окне FP_{avg} . Здесь кривая 1 соответствует результатам, полученным с применением классического подхода с выделением вектора признаков на основе гистограммы ориентаций градиентов, кривая 2 – предложенное модифицированное выделение признаков с применением нормализации вдоль граней, кривая 3 – добавление информации о структуре к модифицированному вектору признаков. В качестве алгоритма обучения в каждом случае использовался AdaBoost с одинаковым числом слабых классификаторов. Из рисунка 6 видно, что применение модифицированного метода выделения признаков показывает лучшие результаты по сравнению с традиционным. Таким образом, добавление информации о структуре к вектору признаков немного увеличивает точность. Так, например, при обеспечении точности обнаружения 98% величина среднего числа ложных обнаружений для классического метода составляет 5%, для модифицированного – 1,3%, а для модифицированного метода при добавлении информации о структуре – 0,8%.

На рисунке 7 представлены результаты зависимости вероятности пропуска объекта P_{MO} от среднего числа ложных обнаружений на изображении FP_I . Полученные результаты носят аналогичный характер.

Далее было проведено сравнение скорости сходимости процесса обучения на том же наборе данных INRIA. Полученные результаты представлены на рисунке 8. Здесь приведена зависимость среднего числа ложных обнаружений в окне FP_{avg} от номера итерации t (числа слабых классификаторов алгоритма AdaBoost) для разных методов. Результаты показывают, что применение модифицированного способа выделения признаков позволяет алгоритму обучения сходиться быстрее, со скоростью примерно в два раза быстрее, чем при использовании традиционного способа. При добавлении информации о структуре скорость сходимости дополнительно увеличивается.

Эксперименты на наборе данных UIUC для детектирования автомобилей

Были проведены эксперименты по оценке эффективности предложенных методов в задаче обнаружения автомобилей. В эксперименте были использованы изображения автомобилей из набора данных UIUC [15]. Этот набор данных содержит тестовую выборку, состоящую из 170 изображений с 200 автомобилями, разномасштабную тестовую выборку, состоящую из 108 изображений, на которых присутствует 139 автомобилей, и обучающий набор из 550 изображений по одному автомобилю на каждом снимке. Изображения автомобилей из обучающей выборки приводились к одному размеру 64×32 пикселя. Для дополне-




Рис. 6. Вероятность пропуска объекта от среднего числа ложно позитивных объектов в окне




Рис. 7. Вероятность пропуска объекта от среднего числа ложных обнаружений на изображении




Рис. 8. Среднее число ложных обнаружений в окне от номера итерации

ния выборки негативными примерами было использовано 5000 случайных изображений из сети Интернет, на которых отсутствовали автомобили.

Полученные результаты точности приведены в таблице 1. Аналогично набору данных INRIA, представленные результаты позволяют утверждать, что предложенные

изменения дают возможность получить более высокие характеристики точности обнаружения по сравнению с традиционным методом.

Таблица 1
Результаты точности обнаружения в наборе данных UIUC

Используемый дескриптор	Точность на одно-масштабной выборке, %	Точность на разно-масштабной выборке, %
Оригинальный	97,5	93,1
Модифицированный	99,2	97,6
Модифицированный с добавлением информации о структуре	99,6	98,3

ЗАКЛЮЧЕНИЕ

В данной работе был предложен новый метод выделения признаков на основе гистограммы ориентаций градиентов, в котором блоки для расчета вектора признаков локальных областей размещаются вдоль граней, чтобы отражать информацию о форме объектов. Кроме того, в дополнении к этому предложен метод выделения информации о структуре, дополняющий вектор признаков. Экспериментальные результаты, проведенные на примере задач обнаружения людей и автомобилей с использованием наборов данных INRIA и UIUC, показывают, что предложенные изменения позволяют повысить точность обнаружения, а также до двух раз увеличить скорость сходимости алгоритма обучения, в качестве которого в данной работе был использован AdaBoost. Так, например, при обеспечении точности обнаружения 98% величина среднего числа ложных обнаружений для классического метода составляет 5%, для модифицированного – 1,3%, а для модифицированного метода при добавлении информации о структуре – 0,8%.

СПИСОК ЛИТЕРАТУРЫ

1. Paul Viola and Michael Jones Rapid object detection using a boosted cascade of simple features // CVPR. IEEE. 2001. Vol. 1. pp. I–511.
2. Oncel Tuzel, Fatih Porikli and Peter Meer Pedestrian detection via classification on riemannian manifolds // IEEE Trans on PAMI. 2008. Vol. 30, № 10. pp. 1713–1727.
3. Yingdong Ma and Liang Deng Human detection with eoh-olbp-based multi-level features // Proceedings of the 3rd International Conference on Multimedia Technology (ICMT 2013) (Springer). 2014. pp. 193–203.
4. Charles Dubout and Francois Fleuret Object classification and detection in high dimensional feature space – 2014. – URL: https://infoscience.epfl.ch/record/196980/files/Dubout_THESIS_2013.pdf (дата обращения: 25.04.2017).

5. Bo Wu and Ramakant Nevatia Detection of multiple, partially occluded humans in a single image by bayesian combination of edgelet part detectors // IJCV. 2007. Vol. 75, № 2. pp. 247–266.

6. Wei Gao, Haizhou Ai, and Shihong Lao Adaptive contour features in oriented granular space for human detection and segmentation // CVPR. IEEE. 2009. pp. 1786–1793. – URL: <http://media.cs.tsinghua.edu.cn/~ahz/papers/cvpr09-0515.pdf> (дата обращения: 25.04.2017).

7. Arrospeide J. and L.Salgado Log-Gabor Filters for Image-Based Vehicle Verification // IEEE Transactions on Image Processing. 2013. Vol. 22 (6). pp. 2286–2295.

8. Averbuch A., V.A.Z., Rabin N. and A. Schclar Wavelet-based acoustic detection of moving vehicles // Multidimensional Systems and Signal Processing. 2009. Vol. 20 (1). pp. 55–80.

9. Santhanam A., and M.M. Rahman Kernel PCA in Detecting Moving Vehicle from its Viewpoint // Computing: Theory and Applications, 2007. ICCTA '07. International Conference on. 2007. pp. 665–670. – URL: <http://toc.proceedings.com/03889webtoc.pdf> (дата обращения: 25.04.2017).

10. Choi J.Y., Sung K.S. and Y.K.Yang Multiple Vehicles Detection and Tracking based on Scale-Invariant Feature Transform // Intelligent Transportation Systems Conference, 2007 (ITSC 2007). IEEE, 2007. – URL: <http://ieeexplore.ieee.org/abstract/document/4357684/> (дата обращения: 25.04.2017).

11. Hsieh J.W., Chen L.C. and D.Y.Chen Symmetrical SURF and Its Applications to Vehicle Detection and Vehicle Make and Model Recognition // Intelligent Transportation Systems, IEEE Transactions on. 2014. № 15 (1). pp. 6–20.

12. Navneet Dalal and Bill Triggs Histograms of oriented gradients for human detection // CVPR. IEEE. 2005. Vol. 1. pp. 886–893.

13. Canny. A Computational Approach to Edge Detection // IEEE Trans. on Pattern Analysis and Machine Intelligence. – 1986. № 8 (6). pp. 679–698.

14. Robert E Schapire and Yoram Singer Improved boosting algorithms using confidence-rated predictions // Machine learning. 1999. Vol. 37, № 3. pp. 297–336.

15. Shivani Agarwal, Aatif Awan and Dan Roth Learning to detect objects in images via a sparse, part-based representation // IEEE Trans on PAMI. 2004. Vol. 26, № 11. pp. 1475–1490.

REFERENCES

1. Paul Viola and Michael Jones. Rapid Object Detection Using a Boosted Cascade of Simple Features. *CVPR. IEEE*, 2001, vol. 1, pp. I–511.
2. Oncel Tuzel, Fatih Porikli and Peter Meer Pedestrian. Detection Via Classification on Riemannian Manifolds. *IEEE Trans on PAMI*, 2008, vol. 30, no. 10, pp. 1713–1727.
3. Yingdong Ma and Liang Deng Human. Detection with Eoh-Olbp-Based Multi-Level Features. *Proceedings of the 3rd International Conference on Multimedia Technology (ICMT 2013) (Springer)*. 2014, pp. 193–203.

4. Charles Dubout and Francois Fleuret. *Object Classification and Detection in High Dimensional Feature Space – 2014*. Available at: https://infoscience.epfl.ch/record/196980/files/Dubout_THESIS_2013.pdf (accessed: 25.04.2017).
5. Bo Wu and Ramakant Nevatia. Detection of Multiple, Partially Occluded Humans in a Single Image by Bayesian Combination of Edgelet Part Detectors. *IJCV*, 2007, vol. 75, no. 2, pp. 247–266.
6. Wei Gao, Haizhou Ai, and Shihong Lao. Adaptive Contour Features in Oriented Granular Space for Human Detection and Segmentation. *CVPR. IEEE*, 2009, pp. 1786–1793. Available at: <http://media.cs.tsinghua.edu.cn/~ahz/papers/cvpr09-0515.pdf> (accessed: 25.04.2017).
7. J.Arrospide and L.Salgado Log-Gabor. Filters for Image-Based Vehicle Verification. *IEEE Transactions on Image Processing*, 2013, vol. 22 (6), pp. 2286–2295.
8. Averbuch A., V.A.Z., Rabin N. and A. Schclar. Wavelet-Based Acoustic Detection of Moving Vehicles. *Multidimensional Systems and Signal Processing*, 2009, vol. 20 (1), pp. 55–80.
9. Santhanam A., and M.M. Rahman Kernel. PCA in Detecting Moving Vehicle from its Viewpoint. *Computing: Theory and Applications, 2007. ICCTA '07. International Conference on*. 2007, pp. 665–670. Available at: <http://toc.proceedings.com/03889webtoc.pdf> (accessed: 25.04.2017).
10. Choi J.Y., Sung K.S. and Y.K.Yang. Multiple Vehicles Detection and Tracking Based on Scale-Invariant Feature Transform. *Intelligent Transportation Systems Conference, 2007. ITSC 2007. IEEE, 2007*.
11. J.W.Hsieh, L.C.Chen and D.Y.Chen. Symmetrical SURF and Its Applications to Vehicle Detection and Vehicle Make and Model Recognition. *Intelligent Transportation Systems, IEEE Transactions on*, 2014, no. 15 (1), pp. 6–20.
12. Navneet Dalal and Bill Triggs Histograms of Oriented Gradients for Human Detection. *CVPR. IEEE*, 2005, vol. 1, pp. 886–893.
13. Canny. A Computational Approach to Edge Detection. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1986, no. 8 (6), pp. 679–698.
14. Robert E Schapire and Yoram Singer. Improved Boosting Algorithms Using Confidence-Rated Predictions. *Machine Learning*, 1999, vol. 37, no. 3, pp. 297–336.
15. Shivani Agarwal, Aatif Awan and Dan Roth. Learning to Detect Objects in Images Via a Sparse, Part-Based Representation. *IEEE Trans on PAMI*, 2004, vol. 26m, no. 11, pp. 1475–1490.