

# Классификация теней с помощью деревьев решений в задаче мониторинга транспортного потока

Илья Попов, Александр Бовырин  
Компания Интелливижн,  
Нижний Новгород, Россия,  
{ilyap, alexb} @ intelli-vision.com

## Abstract

This work aimed to shadow classification problem. Due to increasing traffic jams number automatic road traffic monitoring is becoming important application of computer vision. It is known that shadows of vehicles can dramatically decrease accuracy of monitoring. We developed shadow recognition algorithm which significantly decrease influence of shadows. This algorithm is based on extraction of specialized set of features and CART method usage for further classification. This shadow detection method has low computational load and this has been developed to be ported to DSP architectures.

## Аннотация


Данная работа посвящена проблеме распознавания теней автомобилей при анализе транспортного потока. Автоматический учёт проезжающих автомобилей по видео данным является важным приложением компьютерного зрения. Известно, что тени от транспортных средств негативно влияют на корректность полученной статистики. В статье предложен алгоритм распознавания теней, который позволяет значительно уменьшить влияние теней на работу системы. Этот алгоритм основан на оригинальном наборе признаков и применении метода CART для дальнейшей классификации. Особенностью алгоритма является то, что он не требует больших вычислительных ресурсов и может быть реализован на DSP-архитектурах.

**Ключевые слова:** классификация теней, анализ транспортного потока, деревья решений.

## 1. ВВЕДЕНИЕ

В настоящее время системы автоматического мониторинга загруженности дорог особенно актуальны в связи с всё увеличивающимся транспортным потоком. Было предложено много работ по автоматическому подсчёту транспортных средств (ТС) на полосе движения, оценки их средней скорости и их классификации [1], [2]. Большинство авторов [2]-[4] отмечают, что одной из основных проблем влияющих на точность анализа является наличие теней от проезжающих автомобилей на соседних полосах движения, которые и по форме и по движению похожи на автомобили и они, таким образом, генерируют ложные срабатывания детектора автомобилей, приводя к серьёзным ошибкам в общую статистику.

На изображении 1 представлен типичный случай тени на соседней полосе движения.



Изображение 1:  
типичный случай тени на соседней полосе движения.

Во многих работах проблема теней решается с помощью классификации каждого пикселя на изображении, учитывая факт, что в теневой области оттенок цвета пикселя фона не сильно меняется, а интенсивность уменьшается. Обзор таких методов можно найти в работе [4]. Однако попиксельная классификация недостаточно хорошо работает на чёрно-белых камерах видеонаблюдения и часто “вырезает” большие тёмные области на ТС, что может привести к ошибкам детектирования.

В работе [3] задача распознавания теней решалась с помощью использования набора вейвлетов и применения обученной нейронной сети в качестве классификатора.

Следует отметить, что нейронные сети не позволяют прямо оценить, какие переменные наиболее важны для распознавания и таким образом для решения задачи требуется вычислять все признаки.

Авторы работы [10] предложили использовать ребра изображения как вспомогательную информацию для точного отсека тени от ТС. Однако применяемые в этой работе методики (детектор рёбер Кани, преобразование Хафа) требуют значительных вычислительных ресурсов.

Поскольку использование систем автоматического мониторинга транспортного потока чаще всего подразумевает их портирование на архитектуру DSP [5], то важно экономить вычислительные ресурсы и вычислять только те признаки, которые наиболее значимы для распознавания.

Для этих целей в данной работе предложено использовать метод CART (classification and regression tree) предложенный

в [6]. CART позволяет оценить важность признаков участвующих в распознавании.

В работе также предложен оригинальный набор признаков, по которым производится построение дерева решений и дальнейшее распознавание.

В данной работе не представлены описания используемых нами методов обучения фона, методов извлечения движущихся объектов на видео и методов слежения за ТС. Примеры таких методов можно найти в [7], [1].

## 2. ИЗВЛЕЧЕНИЕ ВЕКТОРА ПРИЗНАКОВ

В рамках поставленной задачи было введено понятие полосы движения – четырехугольная область, заданная на интересующей пользователя части дороги (см. изображение 1).

Для обеспечения возможности детекции и распознавания объектов для каждой полосы была реализована модель фона (BG). Эта модель в дальнейшем использовалась для выделения области (FG), в которой находится появившийся объект – транспортное средство (ТС), тень, пешеход и т.п.

В рамках работы было рассмотрено более 20 признаков, из которых в процессе отбора с использованием деревьев принятия решений рассмотренных ниже в финальной версии алгоритма оставлено 10 наиболее значимых. Большинство из них в качестве исходных данных используют информацию об области FG. Отбор признаков проводился, как по критерию качества классификации тени, так и по критерию трудоемкости вычислений. Причем, трудоемкость вычислений отчасти имела преобладающую роль в связи с тем, что алгоритм распознавания теней должен был работать в составе основного программного комплекса на одном вычислительном устройстве одновременно для нескольких потоков видеоданных в условиях значительных ограничений по объему доступной памяти и производительности процессора (например, процессоры серии TI DSP C62xx, 8MB RAM, 300 MHz).

Из наиболее интересных среди значимых признаков можно выделить:

1) Число угловых точек [8] внутри области тени. Поскольку изображение ТС контрастнее покрытия дорожной полосы, то обычно число угловых точек внутри теневой области значительно меньше, чем в области ТС.

$$nFPCount = \sum_{p \in FG} 1,$$

где FG - множество внутренних пикселей маски объекта, p – угловая точка с координатами (x, y).

2) Площадь не фоновых пикселей обнаруженных на полосе движения;

$$S = \sum_{c=1}^w \sum_{r=1}^h M(c,r), \text{ где } M(c,r) - \text{ маска FG, содержащая}$$

значение 1 в области объекта, иначе – 0, w – число столбцов в изображении, h – число строк в изображении.

3) Средняя магнитуда градиентов в области объекта. Тень дает минимум новых градиентов, причем в основном на ее краях;

$$nEdgesXY = \frac{\sum_{p \in FG} \sqrt{(I_x^2(p_i) + I_y^2(p_i))}}{S},$$

где  $I_x$  и  $I_y$  - значения градиентов в точке  $p_i$ , S – площадь объекта определенная, как признак (2)

4) Среднеквадратическое отклонение значений интенсивности в области объекта.

$$nStd = \sqrt{\frac{\sum_{p_i \in FG} (I(p_i) - I_{avg})^2}{S - 1}},$$

где  $I_{avg}$  – среднее значение интенсивности для множества пикселей определенных FG, S – определена признаком (2). Тень должна иметь меньшее значение nStd, чем ТС.

5) Энтропия значений интенсивности в области объекта определяется как:

$$E = - \sum_{i=0}^{255} w_i \log(w_i), w_i = \frac{Hist(i)}{S},$$

где Hist[i],  $i = 0..255$  – вектор значений хранящий гистограмму распределения значений интенсивности в области FG, S – определена признаком (2). В теневой области признак должен иметь малое значение.

6) Процент числа пикселей от общего числа пикселей объекта, у которых значение интенсивности уменьшилось по сравнению с данными модели фона;

$$nOffDown = \frac{\sum_{c=1}^w \sum_{r=1}^h M(c,r) \cdot f(c,r)}{S},$$

$$f(c,r) = \begin{cases} 1, & p_{c,r} < b_{c,r} \\ 0, & p_{c,r} \geq b_{c,r} \end{cases}$$

где  $p_{c,r} \in P$  – исходное изображение,  $b_{c,r} \in BG$  – изображение модели BG, параметры w, h, M(c,r), S – определены в признаке (2).

7) Средняя интенсивность изображения фона в области, где маска FG содержит ненулевые значения.

В области тени средняя интенсивность должна быть меньшей, чем в той же области на изображении фона.

$$nBGAvgInt = \frac{\sum_{p \in FG} BG(p)}{S}$$

где BG – изображение фона, S – значение площади не фоновых пикселей, p – точка определяющая координаты пикселей, где маска FG принимает ненулевые значения.

8) Средняя интенсивность пикселей изображения фона.

$$nBGOnlyAvgInt = \frac{\sum_{p \in BG} BG(p)}{N},$$

где BG – изображение фона, p – точка принадлежащая полосе, N – число пикселей на анализируемой полосе движения.

Правила классификации теней могут меняться, когда интенсивность пикселей фона мала. Например, видеоданные соответствуют позднему вечеру, ночи и т.п.

Классификация обнаруженного объекта на классы: тень/не тень само по себе является нетривиальной задачей. В данном случае задача дополнительно осложнялось требованием минимизации ошибок распознавания ТС как тени, так как в данном случае алгоритм переставал детектировать ТС, что значительно ухудшало точностные характеристики программного комплекса в целом. В качестве основного подхода примененного на начальном этапе решения данной задачи была сформирована база данных значений признаков с целью определения их статистических характеристик, таких как дисперсия, средние и медианные значения. Данный подход дал положительные результаты только на начальном этапе разработки алгоритма, когда в наличии было не более 2-3 часов видео с примерами теней. Когда объем тестовых видеоданных превысил 40 часов статистические данные о распределении признаков теней и ТС стали иметь значительное пересечение, что привело к проблемам с фильтрацией теней и ложным распознаванием ТС, как тени. Таким образом, независимый учет признаков по отдельности не смог обеспечить качественного решения задачи.

### 3. ИСПОЛЬЗОВАНИЕ ДЕРЕВЬЕВ РЕШЕНИЙ

Для построения решающих правил принятия решения о классификации объекта на тень или ТС мы использовали алгоритм построения дерева решений CART (Classification And Regression Tree) предложенный в работе [6].

Результатом работы CART является бинарное дерево решений. Каждая вершина этого дерева представляет собой правило классификации ассоциированное с одной переменной, которое наилучшим образом разделяет тренировочное подмножество данных на два класса.

Существуют различные критерии выбора наилучшей переменной при формировании вершины дерева.

Нами было опробовано два критерия:

1. Энтропийный критерий

$$I_E(i) = - \sum_{j=1}^m f(i, j) \log_2 f(i, j)$$

2. Gini-критерий

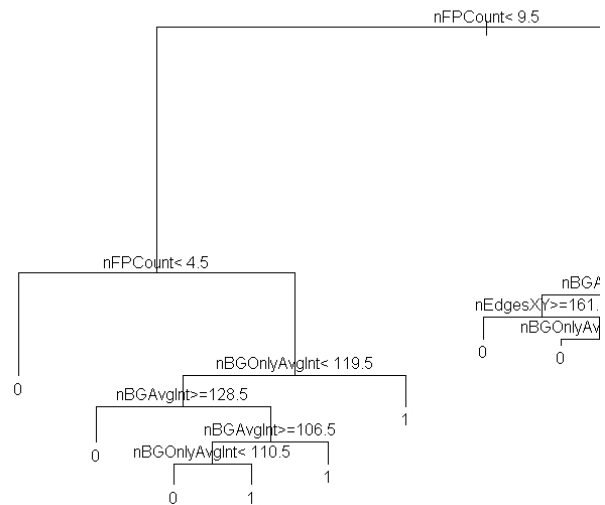
$$I_G(i) = 1 - \sum_{j=1}^m f(i, j)^2$$

где m – число классов (в нашем случае m=2), f(i, j) - частота класса j в вершине i.

В ходе построения дерева решений последовательно выбираются переменные минимизирующие один из этих критериев в производных вершинах. Например, если есть переменная i, которая идеально разбивает множество на классы, то  $I_G = 0$  в производных вершинах.

Эксперименты показали, что для нашей задачи наилучший результат даёт тренировка дерева с помощью энтропийного критерия. При этом было замечено, что увеличение глубины дерева решений, начиная с шести, мало влияет на качество распознавания (например, использование дерева с глубиной семь показало уменьшение ошибки распознавания менее чем на один процент), поэтому глубина финального дерева была выбрана равной 6.

В рамках формата данной статьи затруднительно привести изображение всего дерева решений, поэтому мы приводим лишь фрагмент.



Изображение 2: фрагмент дерева решений (метка 0 соответствует классу “тень”, 1 – “ТС”).

Значительным достоинством применения CART является то, что в качестве результата работы формируется «прозрачное» для восприятия и анализа дерево решений, построенное с использованием заранее подготовленного обучающего множества, причем решающее задачу с заданными точностными характеристиками. В качестве набора данных для обучения использовались признаки, полученные по примерно 8 часам видеоданных.

В ходе построения дерева решений оказалось, что некоторые вычислительно тяжёлые признаки такие как, например, энтропия расположены далеко от корня дерева и мало влияют на результат распознавания. Поэтому эти признаки могут быть опущены при использовании метода на DSP архитектурах без значимого ухудшения результатов распознавания.

Следует отметить ещё один аспект, почему из множества алгоритмов классификации (машина опорных векторов, бустинг, нейронные сети,... [9]) был выбран именно алгоритм CART. Дело в том, что при классификации с помощью дерева решений нет необходимости вычислять все выбранные

признаки, поскольку часто путь от корня до листа дерева содержит меньшее число признаков.

#### 4. РЕЗУЛЬТАТЫ

Тренировка дерева была осуществлена на тренировочной базе состоящей из 1194573 векторов признаков соответствующих случаю тени на полосе движения и 2082016 примерам соответствующих наличию транспортных средств на полосе.

Тестирование метода осуществлялось на тестовой базе состоящей из 4300462 позитивных примеров (тени) и 7911660 негативных примеров (ТС). Тестовая база не включала примеры из тренировочной базы.

Применение описанного выше метода распознавания теней дало следующие результаты:

- 79% правильно распознанных теней.
- 0.8% ТС были распознаны как тень

Важно, что процент ТС распознанных как тень не велик, поскольку в реальных условиях применения системы лучше классифицировать тень как машину, чем пропустить машину. Для того чтобы получить требуемые точностные характеристики распознавания можно варьировать параметры функции потерь при построении дерева (потери при ошибке классификации ТС должны быть больше, чем потери при неправильной классификации тени).

Отметим, что с целью дальнейшего уменьшения ошибок классификации проводилась временная фильтрация результатов классификаций.

#### 5. ЗАКЛЮЧЕНИЕ

Применение предложенного набора признаков и метода CART для распознавания теней ТС на соседних полосах движения показало существенное уменьшения случаев ложных срабатываний детектора автомобилей на тестовом наборе данных. С помощью этого метода удалось достичь уровня ложных срабатываний равного 0.8%, что является приемлемым уровнем для применения в коммерческих системах автоматического мониторинга трафика.

Следует отметить, что классификация с помощью CART и предложенного набора признаков не требует больших вычислительных ресурсов и может быть реализована на DSP, что практически значимо для систем подобного рода [5].

#### 6. ЛИТЕРАТУРА

- [1] R. Cucchiara, C. Grana, M. Piccardi, and A. Prati, "Statistical and knowledge-based moving object detection in traffic scene", in Proceedings of IEEE Int'l Conference on Intelligent Transportation Systems, Oct. 2000, pp. 27-32.
- [2] Yoneyama, A., Yeh, C.H., Kuo, C.C.J., "Robust Vehicle and Traffic Information Extraction for Highway Surveillance", JASP(2005), No. 14, 2005, pp. 2305-2321.
- [3] Chao, T, Lau, B, Park, Y "Vehicle Detection and Classification in Shadowy Traffic Images Using Wavelets and Neural Networks", Transportation Sensors and Controls: Collision Avoidance, Traffic Management, 1996, SPIE Proc. Vol 2902, pp 136-147.

[4] A. Prati, I. Mikic, C. Grana, and M. M. Trivedi, "Shadow detection algorithm for traffic flow analysis: a comparative study," in Proc. IEEE Conference on Intelligent Transportation System (ITSC '01), pp. 340–345, Oakland, Calif, USA, August 2001.

[5] Michael Bramberger, Roman P. Pflugfelder, Arnold Maier, Bernhard Rinner, Bernhard Strobl, Helmut Schwabach "A Smart Camera for Traffic Surveillance", In Proceedings of the First Workshop on Intelligent Solutions in Embedded Systems, 2003

[6] L. Breiman, J. H. Friedman, R. A. Olshen, and C. J. Stone, *Classification and Regression trees*. Wadsworth Inc., 1984.

[7] C. Stauffer and W. E. L. Grimson, "Adaptive background mixture models for real-time tracking," in Proc. IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR '99), vol. 2, pp. 246–252, Fort Collins, Colo, USA, June 1999.

[8] C. Harris and M.J. Stephens. A combined corner and edge detector. In Alvey Vision Conference, pages 147–152, 1988.

[9] Richard O. Duda, Peter E. Hart, and David G. Stork (2001). *Pattern Classification*. Wiley.

[10] Angie W. K. So, Kwan-Yee Kenneth Wong, Ronald H. Y. Chung, Francis Y. L. Chin: Shadow detection for vehicles by locating the object-shadow boundary. Signal and Image Processing, Proceedings of the IASTED International Conference, 2005.