

Алгоритмы детектирования разметки и дефектов дорожного покрытия

Сергей Судаков, Александр Семашко, Ольга Барина, Антон Конушин, Владислав Киншаков, Андрей Крылов

Московский Государственный Университет,
Факультет Вычислительной Математики и Кибернетики,
Москва, Россия

Аннотация

В работе рассмотрены алгоритмы детектирования разметки и дефектов дорожного покрытия. Данные алгоритмы разработаны и встраиваются в систему видеопаспортизации дорог (СВПД) – программно-аппаратный комплекс сбора и анализа данных об автомобильных дорогах. Обнаружение разметки и дефектов происходит на ректифицированных изображениях – «развертках» дорожного покрытия, полученных путем объединения данных с видеосъемки дороги. В работе предлагается новый алгоритм для детектирования разметки на основе машинного обучения. Основной идеей алгоритма является пересегментация изображения и классификация полученных регионов с помощью каскада классификаторов, каждый этап которого применяется к регионам определенного масштаба. В работе также предлагается новый алгоритм выделения контуров дефекта на основе метода активных контуров. Ряд экспериментов, проведенных на наборе изображений дорожного покрытия, демонстрирует преимущество предложенных алгоритмов над существующими аналогами.

Ключевые слова: сегментация изображений, машинное обучение, каскад, активные контуры, системы видеопаспортизации, дорожная разметка, дефекты дорожного покрытия.

1. ВВЕДЕНИЕ

Для оценки состояния дорожно-транспортной сети, планирования ремонтных работ широко используются передвижные дорожные лаборатории. Подобные лаборатории, например [1], оснащаются несколькими видеокамерами, гироскопом, инерциальной системой позиционирования, приемником GPS, лазерным трехмерным сканером и другими датчиками, как показано на Рис.1. С помощью дорожной лаборатории осуществляется видеосъемка всей протяженности обследуемой дороги. Дальнейшая обработка полученных видеоданных в настоящее время производится практически полностью вручную. Оператор вручную отмечает на видео все необходимые для анализа объекты, такие как линии разметки, кромку дороги, дефекты дорожного покрытия (ямы, трещины) и заплатки, сделанные ранее для ремонта дороги. Эта процедура очень трудоемка, поэтому актуальной становится задача автоматизации обнаружения и выделения границ данных объектов в видеосъемках дороги.

В данной работе мы рассматриваем два вида объектов анализа – дорожную разметку и площадные артефакты дорожного покрытия (ямы, заплатки).

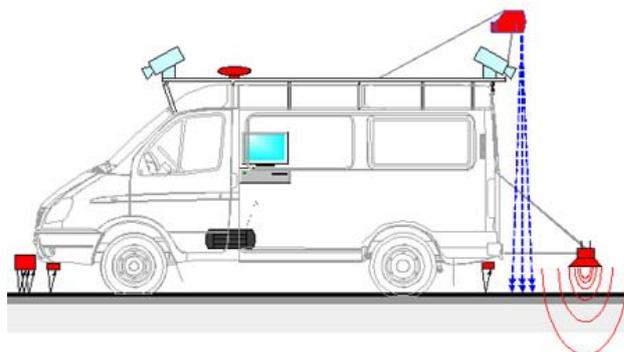


Рисунок 1 Схема дорожной лаборатории. Спереди и сзади автомобиля установлены видеокамеры.

Задачи обнаружения дорожной разметки можно разделить на две основные категории: собственно обнаружение разметки и отслеживание разметки в видео. Здесь под обнаружением разметки имеется в виду проблема точного поиска контуров разметки без каких-либо данных о её расположении на изображении (текущем кадре видеопоследовательности). Отслеживание разметки – проблема её покadroвого обнаружения на основе модели, полученной ранее. Кроме того, в этой задаче требуется найти только примерное расположение и ориентацию разметки, а не её точный контур. При отслеживании разметки в видео использование информации о расположении разметки на предыдущих кадрах позволяет существенно сократить область поиска разметки. В то время как алгоритмы обнаружения разметки должны найти её контуры без знания модели разметки и расположения дороги на изображении. Алгоритмы обнаружения должны работать на реальных изображениях, то есть изображениях с тенями, машинами, непостоянной поверхностью дороги, различными типами разметки, а также просто на зашумленных изображениях.

Существует много различных методов распознавания разметки. Одним из популярных методов является поиск краев на изображении, их анализ и поиск среди них прямых с помощью преобразования Хафа [2]. Однако преобразование Хафа часто оказывается слишком чувствительным к шуму, хотя и неплохо справляется с затенением на дороге.

Ещё одним из методов является использование градиента для нахождения краев дороги и линий разметки [3]. Исходя из величины и ориентации градиента, отбираются пиксели, предположительно лежащие на краю дороги, и подбирается

наиболее подходящая модель для линий разметки. Хотя этот алгоритм хорошо работает на "чистых" дорогах, у него нет никакой защиты от обнаружения посторонних объектов на дороге. Другой способ использования градиента предлагается авторами статьи [4]. На основе градиентного поля для каждого пикселя вычисляется предложенная авторами характеристика «гребневости» (ridgeness), которая принимает большие значения, если пиксель изображения лежит на гребне яркости. После этого пиксели с достаточно большим значением «гребневости» объявляются пикселями разметки. Метод хорошо обнаруживает разметку, однако чувствителен к шуму, который имеет большое значение «гребневости».

Другим подходом к проблеме распознавания разметки является применение так называемых управляемых фильтров [5]. Для обнаружения разметки используется тот факт, что пиксели разметки дают большой отклик управляемого фильтра, ориентированного вдоль линий разметки, и малый отклик перпендикулярно этому направлению. Однако при таком подходе наряду с разметкой выделяются другие яркие прямые на изображении, так что результат требует дополнительной обработки.

Большинство существующих методов обнаружения дорожной разметки создавались для систем автоматического управления автомобилем, и их основной целью является не собственно обнаружение разметки, а создание модели этой разметки. Для этого достаточно найти ключевые точки разметки и вычислить модель, наилучшим образом описывающую эти точки.

Нашей задачей является анализ качества разметки, причем необходимо найти её точные контуры, а не примерное расположение. Предлагаемый алгоритм предназначен для анализа ректифицированных изображений («разверток») дорожного покрытия, а не исходных видеосъемок. В отличие от существующих подходов, предложенный алгоритм основан на сегментации изображения с последующей классификацией полученных сегментов, основанной на машинном обучении. Это позволяет использовать набор различных признаков полученных сегментов для обнаружения разметки, что повышает точность обнаружения по сравнению с существующими методами.

Для выделения площадных артефактов дорожного покрытия могут использоваться обычные методы интерактивной сегментации изображений, такие как [6] и [6]. В настоящее время большое количество исследований посвящено построению трехмерной модели дефекта с использованием стерео-съемки специальным образом подсвеченной дороги (см., например, [7]); в т.ч. с проецированием на дорогу калибровочных меток, а также по данным лазерных или ультразвуковых сканеров).

Для выделения площадных объектов разработан алгоритм, основанный на методе «активных контуров» [9]. Алгоритм также предназначен для обработки ректифицированных изображений дороги, и позволяет выделить контур

производного площадного дефекта по одной точке, отмеченной оператором внутри области объекта.

Во второй части статьи описывается процедура построения ректифицированных изображений дороги из исходной видеосъемки. В третьей части рассказывается о предложенном алгоритме, используемом в нашей системе для получения и классификации сегментов изображения-развертки. В четвертой части описываются эксперименты с несколькими алгоритмами обнаружения разметки, и предоставляется оценка качества работы нашего алгоритма, а также результаты сравнения с более простыми методами, основанными на классификации регионов. Пятая часть посвящена описанию алгоритма выделения площадных артефактов дорожного покрытия.

2. ПРЕДОБРАБОТКА ВИДЕОПОСЛЕДОВАТЕЛЬНОСТИ

Использование исходных видеосъемок в качестве исходных данных для выделения объектов дорожной разметки и дефектов обладает рядом недостатков. Во-первых, изображения всех артефактов дорожного покрытия претерпевают перспективные искажения, что затрудняет их распознавание. Например, заплатки прямоугольной формы приобретают форму трапеции. Во-вторых, протяженные объекты большой длины не видны целиком ни на одном кадре исходной видеопоследовательности. В-третьих, на каждом кадре видеопоследовательности разные области дороги представляются с разным пространственным разрешением.



Рисунок 2 Построение развертки дороги. (а) Один из исходных кадров видеосъемки дороги с дорожной лабораторией (б) Полученная развертка дороги

Для преодоления этих недостатков в данной работе в качестве исходных данных используются ректифицированные изображения дороги, полученные из исходных видеопоследовательностей. Ректифицированным изображением называется изображение, полученное с помощью ортографической проекции объекта. Поскольку поверхность дороги близка к плоскости, ректифицированное изображение может быть получено с помощью перспективного преобразования плоскости **Error! Reference source not found.**, примененного к области дороги на исходном изображении. Ввиду того, что только малая часть дороги видна на каждом отдельном кадре видеосъемки, по каждому кадру строится ректифицированные изображения участков дороги, которые затем объединяются в одно

большое изображение, называемое «разверткой дороги», как показано на Рис. 2. Поскольку пространственное разрешение изображения дороги быстро уменьшается с увеличением расстояния от камеры, но скорость видеосъемки достаточно высока, то по каждому кадру строится ректифицированное изображение узкой полоски дороги длиной не более 1 метра.

Для вычисления перспективного преобразования и объединения ректифицированных изображений участков дороги должны быть известны положение и ориентация камеры относительно поверхности дороги и траектория движения камеры. Положение камеры относительно дороги известно изначально вследствие жесткого закрепления камеры на дорожной лаборатории. Траектория движения камеры вычисляется с помощью использования инерциальной системы навигации совместно с GPS.

3. ОПИСАНИЕ АЛГОРИТМА ОБНАРУЖЕНИЯ РАЗМЕТКИ

В нашей работе для обнаружения дорожной разметки предлагается использовать машинное обучение. Основная идея этого подхода была взята из работ [10] и [12]. Обнаружение разметки формулируется как задача классификации суперпикселей изображения, или сегментов. Мы используем такой подход по двум причинам: во-первых, только сегменты могут предоставить пространственную информацию, такую как ориентация сегмента, удлинение, площадь, очень существенную для классификации; во-вторых, это сильно ускоряет работу системы.

В отличие от приведенных выше работ, предлагаемый в работе подход основан на использовании каскада пересегментаций. Сама идея каскадов заимствована из работы [13]. Самая общая схема работы каскада такова (Рис.3): имеется каскад классификаторов, каждый следующий из которых "сложнее" предыдущего ("сложность" классификатора определяется в зависимости от специфики данных или приложения). Массив входных данных проходит через эти классификаторы по очереди; каждый классификатор отсеивает те данные, которые точно не принадлежат искомому классу, оставшиеся данные передаются следующему, более "сложному" классификатору, для уточнения и т.д. Каждый классификатор натренирован так, чтобы максимизировать число верных обнаружений на каждом слое каскада (на каждой итерации прохода данных через каскад). Это позволяет "сложным" классификаторам сфокусироваться только на спорных районах, что увеличивает скорость работы системы в целом.

Применительно к нашей системе, схема работы каскадов следующая. С каждым классификатором связаны параметры пересегментации, на которой этот классификатор был натренирован. Классификатор является более "сложным", если его пересегментация более подробная, имеет меньший масштаб суперпикселей.

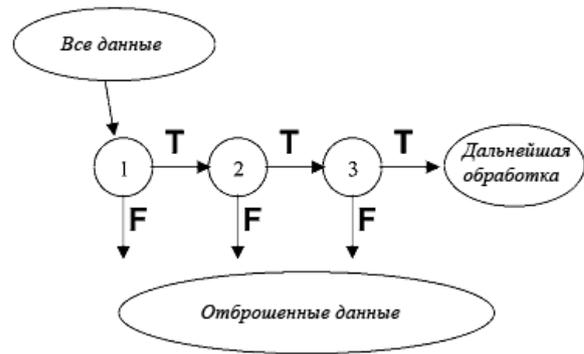


Рисунок 3 Общая схема работы каскада классификаторов

На входе каскаду подается изображение-развертка дорожного покрытия. Оно сегментируется с параметрами первого классификатора, после чего полученные сегменты классифицируются так, чтобы процент верных обнаружений был близок к 100%, то есть классификатор отбросил лишь те сегменты, для которых он уверен, что в них разметки нет. Затем отброшенные сегменты закрашиваются на исходном изображении черным цветом, что дает ускорение работы последующей пересегментации. Далее это изображение переходит на новый слой, где оно снова сегментируется, но уже с меньшим масштабом, и повторяется описанная процедура. Так происходит до последнего слоя, на котором классификатор уже натренирован не на верное обнаружение всей разметки, в ущерб минимизации ложных обнаружений, а на стандартную классификацию изображения. Пересегментация, соответствующая последнему слою каскада, достаточно подробная для учета разнообразных деталей на изображении, и большая часть дорожного покрытия и посторонних объектов закрашена. Это к тому же сближает количество сегментов разметки и дороги, решая, проблему несбалансированности классов, существенно ухудшающую качество работы любой системы, призванной найти малый класс при большом размере нецелевого класса.

Процесс тренировки такого каскада требует существенного внимания. В качестве классификаторов мы используем Gentle AdaBoost [14] с деревом глубины 3 в качестве базового классификатора, как один из лучших на сегодня классификаторов [15]. Однако, тренировка AdaBoost сфокусирована на минимизации общей ошибки, а не максимизации верных обнаружений, пусть и с серьезным увеличением числа ложных обнаружений. Простым выходом из положения является изменение порога для выходов AdaBoost. Обычно выходы выше 0 относятся к объектам одного класса, ниже - другого. Понижая порог, мы увеличиваем число ложных срабатываний, увеличивая при этом количество верных обнаружений. Таким образом, для тренировки каскада необходимо выбрать два важных параметра: количество слоев каскада и порог для AdaBoost на каждом слое. Хотя оптимальный выбор этих параметров представляет большую трудность [16], существует простая схема для их получения, дающая неплохие результаты.

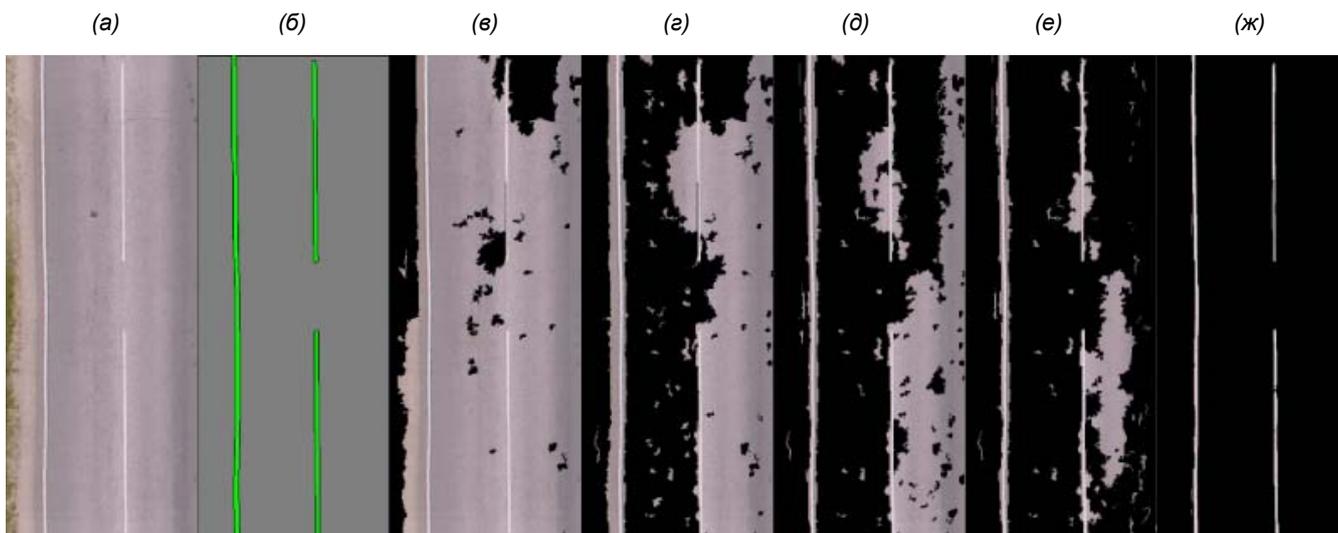


Рисунок 4 Пример работы каскадного метода обнаружения дорожной разметки. Изображения слева направо: (а) - Исходное изображение-разетка, (б) - вручную размеченное изображение, (в) - результат работы 1-го слоя каскада, (г) - результат работы 3-го слоя каскада, (д) - результат работы 5-го слоя каскада, (е) - результат работы 7-го слоя каскада, (ж) - окончательный результат работы алгоритма. Каскад насчитывал 8 слоев.

Алгоритм настройки каскада классификаторов

- Выбираем минимальный приемлемый уровень верных обнаружений на одном слое - d
- Выбираем целевое значение уровня ложных обнаружений после прохождения каскада F_{target}
- Выбираем начальные параметры пересегментации
- $F_0 = 1.0, D_0 = 1.0, i = 0$
- **Пока** $F_i > F_{target}$
 - $i = i + 1$
 - Сегментируем тренировочный набор изображений, получаем P - набор данных для сегментов разметки, N - набор данных для посторонних сегментов
 - Используя P и N , тренируем классификатор AdaBoost
 - Для данной сегментации и натренированного классификатора делаем оценку на контрольном наборе, вычисляем F_i, D_i
 - Снижаем порог AdaBoost, пока D_i станет не меньше d (это же влияет и на F_i)
 - Уменьшаем масштаб пересегментации
- Сегментируем тренировочный набор изображений с финальными параметрами пересегментации
- Тренируем последний слой каскада с порогом, равным 0 ;

Остается лишь выбрать минимальный приемлемый уровень верных обнаружений и целевое значение уровня ложных срабатываний. Они выбираются эмпирически из следующего принципа.

$$D = \prod_{i=1}^n d_i$$

Здесь D – результирующий уровень верных обнаружений всего каскадного классификатора, а d_i – соответствующие уровни каждого слоя. Следовательно, чтобы получить 90% верных обнаружений, каскаду из десяти слоев достаточно иметь на каждом слое иметь уровень верных срабатываний, равный 0.99 (так как 0.9 примерно равно 0.99^{10}). Целевое значение уровня ложных обнаружений выбирается из такого же соотношения, но учитывая, что уровни ложных обнаружений мы не знаем наперед, и они находятся примерно между 0.7-0.8 на первой итерации и целевым F_{target} , плавно уменьшаясь.

4. ЭКСПЕРИМЕНТЫ

В качестве тестовой базы использовался набор из 120 изображений - разверток дорожного покрытия, полученных с помощью метода, описанного во второй части (Рис.4 (а)). Каждое такое изображение имеет размер в среднем 450×1000 пикселей. Для получения оценок качества работы системы и подсчета ошибок была вручную проведена разметка этих изображений так, чтобы одним цветом указывались участки, относящиеся к разметке, а другим - относящиеся к дороге и посторонним объектам (Рисунок 2 (б)). Набор был поделен на три равных части: набор для обучения классификаторов в каждом слое каскада, набор для контроля числа верных и ложных обнаружений при тренировке каскада и набор для оценки качества работы каскада, после его получения. В каждый из наборов вошли изображения с различными качеством освещения, уровнем шума и качеством разметки.

Для тренировки каскадного классификатора был использован алгоритм, описанный в предыдущей части, где минимальный

уровень верных обнаружений был выбран, как 0.99, а целевой уровень ложных срабатываний – 0.15. Натренированный каскад состоял из 9 слоев. Оценки количества верных и ложных обнаружений были получены с помощью подсчета верно и неверно определенных пикселей на изображении. В итоге каскад классификаторов на тестовом наборе дал 92% верных обнаружений и 0.07% ложных обнаружений.

Для сравнения были реализованы ещё два более простых алгоритма обнаружения дорожной разметки. Первый алгоритм включает в себя одну пересегментацию и классификацию полученных сегментов с помощью машинного обучения. Второй алгоритм состоит из нескольких пересегментаций различного масштаба. Для каждой пересегментации с помощью классификации AdaBoost с деревом глубины 3 в качестве базового классификатора и преобразования Платта [17] вычисляются вероятности принадлежности пикселей изображения классу разметки, затем вычисляется средняя вероятность, которая определяет класс пикселя. Этот метод позволяет обходить дефекты одной сегментации, когда слишком мелкий масштаб суперпикселей влечет за собой чувствительность к шуму, а слишком большой масштаб суперпикселей приводит к потере многих деталей. Все алгоритмы используют для сегментации изображения метод, предложенный в [18]. Итоговые результаты сравнения показаны в Таблице 1.

	Уровень верных обнаружений	Уровень ложных обнаружений
Каскадная классификация	92%	0.07%
Классификация одной сегментации	89.5%	0.09%
Классификация нескольких сегментаций	88%	0.04%

Таблица 1. Качество обнаружения разметки разными методами,

Как видно из таблицы 1, при удачно подобранной сегментации, простая классификация дает больший уровень верных обнаружений, чем классификация с несколькими пересегментациями. Однако последняя дает в два раза меньший уровень ложных обнаружений. Этот уровень не может достичь и каскадный алгоритм, который оказался лучшим по уровню верных обнаружений.

5. АЛГОРИТМ ВЫДЕЛЕНИЯ КОНТУРА ДЕФЕКТА

Для поиска контуров дефектов покрытия (таких, как выбоины и заплатки) реализован интерактивный алгоритм, в основе которого лежит использование метода активных контуров (“змея”-snake) [9]. В качестве поля внешних сил используется GVF (потока вектора градиента) [19], которое

строится по карте границ $E = -|\nabla(I * G_\sigma(x, y))|$, где I – значение интенсивности изображения дороги, G_σ – функция Гаусса. Полученный контур затем уточняется с помощью алгоритма, основанного на вычислении минимального разреза графа [20].

В данной работе рассматривается задача автоматического выделения контура объекта, имея на входе только координаты какой-либо точки, лежащей гарантированно внутри искомого контура. Поиск контура состоит из следующих этапов:

- построение инициализатора (начального приближения) для активного контура;
- определение области, в которой будет производиться поиск;
- вычисление карты границ, и поля внешних сил GVF;
- получение результата метода активных контуров;
- коррекция результата методом минимального разреза графа.

5.1 Построение инициализатора и определение области поиска

Рассматривается задача построения инициализирующего контура, состоящая в том, чтобы найти контур, достаточно близкий к контуру реального, искомого объекта, и целиком лежащий внутри него, используя только данные о внутренней области конструируемого контура. Это возможно, если известны свойства внутренней области искомого объекта – текстура, возможный диапазон цветов, и т.д.

Мы строим инициализатор, предполагая, что область внутри искомого контура однородна по цвету. Как критерий для определения, является ли инициализатор допустимым, рассматривается дисперсия интенсивности в его внутренней области.

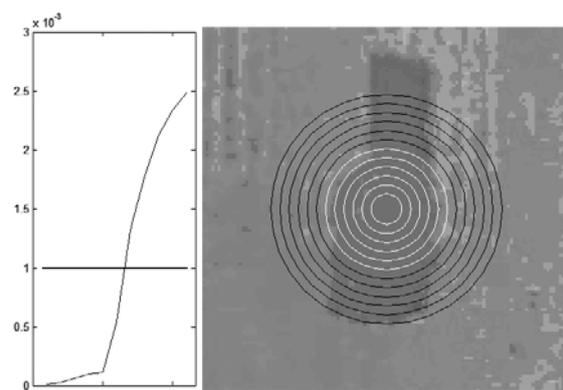


Рисунок 5 Дисперсия интенсивности внутри контура.

На Рис. 5 показан рост дисперсии интенсивности внутри круга при увеличении его радиуса. Легко видеть резкий рост дисперсии при выходе за границы дефекта. Показан простейший вариант отсечения – по порогу; контуры,

являющиеся допустимыми инициализаторами, нарисованы белым цветом.

Инициализирующий контур ищется в виде эллипса с центром в точке, заданной пользователем. На первом шаге максимизируется малая ось эллипса, т.е. определяется максимальный радиус окружности, удовлетворяющей требованиям. Затем определяется максимум длины большой оси эллипса и угол поворота, при котором этот максимум достигается. На Рис. 6 приведено несколько примеров получаемых инициализаторов.

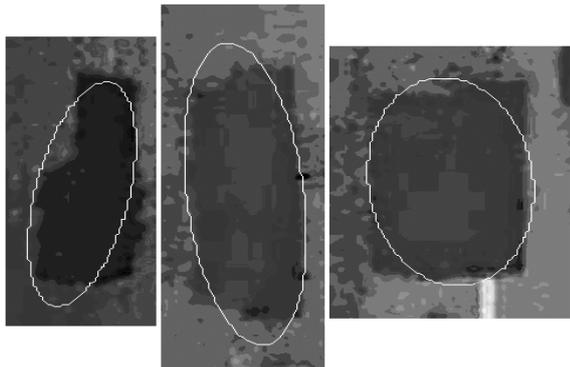


Рисунок 6: Примеры инициализаторов метода активных контуров.

В качестве ограничивающего прямоугольника берется минимальный прямоугольник со сторонами расположенными вдоль и поперек направления дороги, содержащий полученный эллипс. Этот прямоугольник масштабируется с заданным коэффициентом увеличения, выбранного так, чтобы внутри полученного расширенного прямоугольника с большой вероятностью содержался искомый контур.

5.2 Применение «змей» и коррекция

В связи с отсутствием априорной информации о свойствах контура искомого объекта (таких, как протяженность, гладкость и пр.), параметры внутренней энергии модели выбираются такими, чтобы внутренние силы модели были малы по сравнению с внешними, и не оказывали заметного влияния на результат.

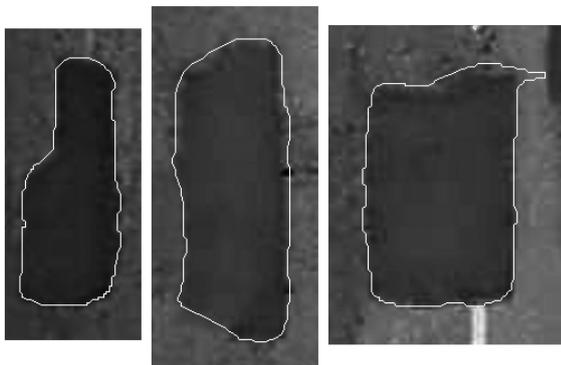


Рисунок 7: Результаты работы метода активных контуров без постобработки.

Значения поля внешних сил нормируются в каждом узле сетки, что позволяет добиться сходимости при относительно

небольшом числе итераций. Перераспределение контрольных точек производится с фиксированной частотой. На Рис.7 показаны результаты, получаемые при инициализации модели контурами из рис. 6.

На последнем шаге полученный контур корректируется с помощью алгоритма, основанного на вычислении минимального разреза графа, описанного в [20]. Это существенно улучшает результат, например, в случае сильно изрезанной нечеткой границы (Рис.8).

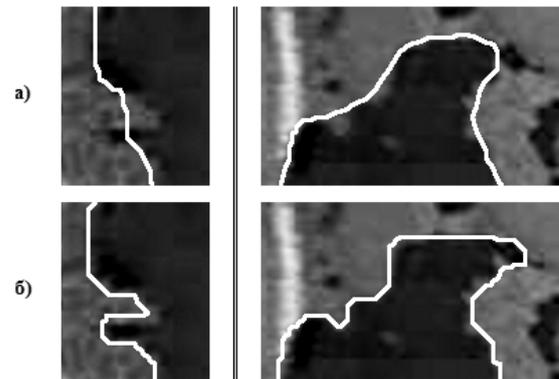


Рисунок 8: Результаты работы алгоритма – без постобработки (а) и с постобработкой методом минимального разреза графа (б).

6. ЗАКЛЮЧЕНИЕ

В данной работе были предложены новые алгоритмы обнаружения дорожной разметки и выделения контуров площадных объектов на дорожном полотне.

В отличие от большинства существующих методов нахождения дорожной разметки, предложенный метод позволяет определять точные контуры дорожной разметки, а не её примерное расположение. Основной идеей предложенного метода является пересегментация изображения с дальнейшей классификацией регионов с помощью обучения. Мы используем каскад классификаторов для разного масштаба пересегментации, натренированных с помощью разработанного алгоритма так, что каждый из них отбрасывает суперпиксели, которые почти точно не содержат разметку, и передает оставшиеся сегменты следующему слою каскада, который работает с меньшим масштабом пересегментации. Для оценки качества работы алгоритма, мы реализовали две классических схемы классификации суперпикселей. Сравнение методов показало, что хотя наш алгоритм не достигает уровня ложных обнаружений одной из этих схем, он является лучшим по уровню верных обнаружений. В будущем предполагается использование алгоритмов иерархической сегментации для повышения точности работы алгоритма, использование более широкого набора признаков для классификации, применение методов мультиклассификации для одновременного обнаружения нескольких типов объектов на дорожном полотне, а также совместное использование развертки и карты глубины, которая будет получена с помощью трехмерного лазерного сканера.

Предложенный алгоритм определения контура площадного объекта обеспечивает его получение по одной выделенной

оператором точки в области объекта за достаточно небольшое время. Проводится работа по увеличению надежности оценки размеров искомого объекта. Кроме этого, планируется улучшить алгоритм динамической репараметризации модели активного контура, что позволит получать результат за меньшее число итераций.

Работа выполнена при поддержке РФФИ 08-01-00883-а

7. ЛИТЕРАТУРА

- [1] НПО «Регион», <http://www.nporegion.ru>
- [2] J.McDonald "Detecting and tracking road markings using the Hough transform" *Proc. of the Irish Machine Vision and Image Processing Conference, 2001*
- [3] Weina Lu, Haifang Wang, Qingzhu Wang "A synchronous detection of the road boundary and lane marking for intelligent vehicles" *In Proc. of SPND-2007, pp.741-745, 2007*
- [4] A.Lopez, C.Canero, J.Serrat, J.Saludes, F.Lumbreras, T.Graf "Detection of Lane Marking based on Ridgeness and RANSAC" *In Proc. of the 8th International IEEE Conference on Intelligent Transportation Systems, pp.254-259, 2005*
- [5] Joel C. McCall and Mohan M. Trivedi "An Integrated, Robust Approach to Lane Marking Detection and Lane Tracking" *In Proc. IEEE Intelligent Vehicles Symposium, pp.533-537, 2004*
- [6] Y.Boykov, M.P.Jolly "Interactive Graph Cuts for Optimal Boundary and Region Segmentation of Objects in N-D Images", *In Proc. ICCV2001, pp.105-112, 2001*
- [7] Vezhnevets V., Konouchine V. "'GrowCut" - Interactive Multi-Label N-D Image Segmentation By Cellular Automata". *In Proc. Graphicon-2005, Novosibirsk Akademgorodok, Russia, 2005.*
- [8] A.E. Grace, D. Pycock, H.T. Tillotson, M.S. Snaith "Active shape from stereo for highway inspection" *Machine Vision and Applications 12: pp.7-15, Springer-Verlag 2000*
- [9] M. Kass, A. Witkin and D. Terzopoulos "Snakes: Active Contour Models" *International Journal of Computer Vision, vol. 1, pp. 321-331, 1987*
- [10] Richard Hartley, Andrew Zisserman, "Multiple view geometry in computer vision", *Cambridge University Press, New York, NY, 2001*
- [11] D.Hoiem, A.A.Efros, M.Hebert "Geometric context from a single image" *In Proc. of Tenth IEEE International Conference on Computer Vision, pp.645-661, 2005*
- [12] L.Yang, P.Meer, D.J.Foran "Multiple class segmentation using a unified framework over Mean-Shift patches" *In Proc. of IEEE Conference on Computer Vision and Pattern Recognition, pp.1-8, 2007*
- [13] P.Viola, M.J.Jones "Robust real-time face detection" *In Proc. of International Journal of Computer Vision 57(2), pp.137-154, 2004*
- [14] J. Friedman and T. Hastie and R. Tibshirani, "Additive logistic regression: A statistical view on boosting" *Stanford university technical report*
- [15] R.Caruaana, A.Niculescu-Mizil "An empirical comparison of supervised learning algorithms" *In Proc. of the 23rd International Conference on Machine Learning, pp.161-168, 2006*
- [16] S.C.Brubaker, M.D.Mullin, J.M.Rehg "Towards optimal training of cascaded detectors" *In. Proc. of European Conference on Computer Vision, pp.325-337, 2006*
- [17] A.Niculescu-Mizil, R.Caruaana "Obtaining calibrated probabilities from boosting" *In Proc. of 21st Conference on Uncertainty in Artificial Intelligence, pp.413-420, 2005*
- [18] P.F.Felzenszwalb, D.P.Huttenlocher "Efficient graph-based image segmentation" *In. Proc. of International Journal of Computer Vision, Volume 59, Number 2, September 2004*
- [19] C. Xu, J.L. Prince "Snakes, Shapes, and Gradient Vector Flow" *IEEE Trans. on Image Processing, vol. 7, no. 3, pp. 359-369, Mar. 1998*
- [20] E.V. Zaugolnova, D.V. Yurin "Algorithm for Refinement of Preliminary Segmentation of Images with Smooth, Low Contrast 2D Objects Boundaries" *In proc. Graphicon, 2006*

Об авторах

Сергей Судаков – студент ф-та ВМиК МГУ, email: svsudakov@gmail.com

Александр С. Семашко - студент ф-та ВМиК МГУ, email: alex.semashko@gmail.com

Ольга Барина – аспирант ф-та ВМиК МГУ. Email: olga.barinova@gmail.com

Антон Конушин – к.ф.-м.н., научный сотрудник лаб. Компьютерной графики и мультимедиа ф-та ВМиК МГУ. Email: ktosh@graphics.cs.msu.ru

Владислав Киншаков – к.т.н., директор НПО «Регион», Email: it@yandex.ru

Андрей С. Крылов - доцент, к.ф.-м.н., зав. лаб. математических методов обработки изображений ф-та ВМиК МГУ email: kryl@cs.msu.ru

Detection of road lane marking and artifacts of road surface

In this paper two novel methods for road lane marking and road surface artifacts detection are presented. These algorithms are developed for video-based road registration and monitoring system, which is car-mounted complex for data gathering and analysis of road surface. Detection is performed on rectified images of road surface, constructed from video sequences from driving vehicle. A new method of road lane marking detection is based on machine-learning approach. The algorithm applies oversegmentation method to images and then classify the regions using classifier cascades. Each state of cascade is applied to specific scale of oversegmented regions. Algorithm for road defects segmentation is based on active contours.

Keywords: image segmentation, machine learning, classifier cascade, active contours, road monitor systems, lane markings, road surface defects