

Комбинированный алгоритм локализации номеров железнодорожных цистерн

И.В. Копылов

ivv.kopylov@gmail.com

Кафедра математического и программного обеспечения ЭВМ (МПОЭВМ),
Череповецкий государственный университет, Череповец, Россия

Предложен новый подход к локализации номеров железнодорожных цистерн. Представлено гибридное решение, основанное на объединении алгоритма выделения границ контрастных объектов и алгоритма обнаружения номера с помощью обученного детектора, используя принцип скользящего окна. Первый этап возвращает набор зон на изображении, в которых предположительно может находиться номер вагона. На втором этапе происходит уточнение зоны, в которой находится номер.

Ключевые слова: локализация номеров, машинное обучение, скользящее окно, выделение границ контрастных объектов.

A combined algorithm for plate localization of railroad tank cars

I. V. Kopylov

Department of Mathematical Insure and Software of Computing Machines,
Cherepovets State University, Cherepovets, Russia

This paper shows a new approach to plate localization of railway tanks. Presented hybrid solution based on a combination of extraction algorithm boundaries contrast objects and plate detection algorithm by trained detector, using the principle of the sliding window. The first stage returns a set of areas in the image, which can be expected to be a plate of the tank car. The second step is the specification of a zone containing the plate.

Key words: plates localization, machine learning, sliding window, extraction boundaries contrast objects.

1. Введение

Задача локализации номеров цистерн в железнодорожном составе является актуальной для систем диагностирования подвижного состава, а также систем, предназначенных для автоматизации процессов коммерческого учета сырья и продукции, отгружаемых железнодорожным транспортом.

В данной статье предложен гибридный подход для локализации номеров вагонов, состоящий из двух этапов. На первом этапе выполняется выделение вертикальных перепадов яркости на изображении с дальнейшей обработкой полученной матрицы перепадов:

- выделение вертикальных перепадов с помощью фильтра Собеля [1], получение изображения границ G ;
- вычисление модулей перепадов яркости $|G|$ полученного изображения вертикальных перепадов G ;
- линейное контрастирование $|G|$ с удалением малоинформативных «хвостов» гистограммы;
- разбиение контрастированного изображения $|G|$ на столбцы с заданной шириной;
- выявление локальных минимумов проекции модуля градиента в столбцах;
- выбор потенциальных зон в каждом столбце;
- удаление пересекающихся зон;
- выбор лучших зон среди оставшихся после удаления пересекающихся областей;

- подавление областей, центрирование и формирование выхода с координатами зон с предполагаемым номером вагона.

На втором этапе используется обученный детектор (бинарный классификатор) номера. В найденных зонах производится попытка обнаружить номер с помощью детектора, используя принцип скользящего окна [2]. Каждое окно анализируется бинарным классификатором, который принимает решение - попадает часть номера в анализируемую область или нет. В результате выигрывает та зона, в которой было обнаружено большее количество положительных откликов детектора.

Алгоритм машинного обучения, используемый для обучения детектора, основан теории случайных функций [3,7]. В качестве признаков, которыми описываются зоны анализа детектора, были выбраны пирамидальные признаки [5].

В рамках эксперимента были подготовлены небольшая выборка для обучения детектора, состоящая из 500 положительных примеров (части номеров вагонов) и 500 шумовых примеров, а также тестовая выборка, состоящая из 4600 положительных примеров и 30000 шумовых. Обученный детектор показал следующие результаты на тестовой выборке: 89.93% правильного обнаружения номера, 4.44% ложного срабатывания на шумовой выборке.

Для проведения теста локализации номеров была составлена выборка из 78 изображений вагонов.

Эксперименты показали следующие результаты: на 76 вагонах номер был обнаружен, на 71 вагоне номер находился в первой из предложенных зон. Составленные выборки представлены в открытый доступ [8].

2. Локализация номера цистерны алгоритмом выделения границ

Для предварительной локализации зон с предполагаемым номером используется свертка исходного полутонового изображения I цистерны (рис. 1) с фильтром H , $I * H$. Результатом данной операции является изображение границ объектов G , над которым выполняется ряд операций, приводящих к нахождению зон с вероятным номером в них.




Рис. 1: Исходное изображение цистерны.

2.1. Вычисление перепадов яркости и линейное контрастирование

Выполняется выделение вертикальных перепадов яркости на изображении I с помощью фильтра Собеля с маской:

$$H = \begin{pmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{pmatrix}$$

В результате получается изображение границ $G = I * H$. Для дальнейшего анализа рассматриваются только абсолютные значения перепадов яркостей (рис. 2) в G , т.е. $|G|$ [1].

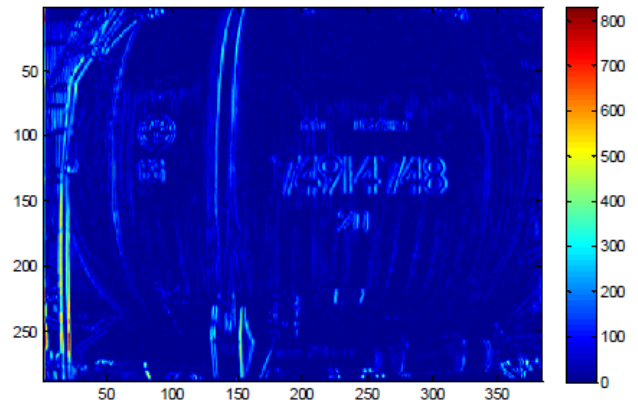


Рис. 2: Модуль вертикальных перепадов $|G|$.

Далее производится линейное контрастирование $|G|$. Для этого строится гистограмма по значениям из $|G|$, задаются доли самых больших и самых малых значений $|G|$ - $minGTh$, $maxGTh$. Минимальное значение контрастированного $|G|$ (обозначим как \bar{G}) станет равным 0, максимальное 255.

2.2. Локальные минимумы проекции модуля градиента в столбцах

Полученное после контрастирования изображение \bar{G} разбивается по горизонтали на n частей и в каждой из них рассчитывается средняя яркость элементов строки. Затем определяются локальные минимумы средней яркости. Количество частей, на которые необходимо разбить изображение определяется исходя из максимальной ширины номера $maxPlWidth$ и параметра k , указывающего, на сколько частей необходимо разбить номер максимальной ширины. $maxPlWidth$ и k являются настраиваемыми параметрами алгоритма.




Рис. 3: Средняя интенсивность строк в каждой из зон. Профиль столбца 6.

При анализе средних яркостей b строк в каждом из столбцов, локальным минимумом считается строка i , если для нее выполняется одно из условий:

$$b(i) \leq b(i-1) \quad \text{and} \quad b(i) < b(i+1)$$

or

$$b(i) < b(i-1) \quad \text{and} \quad b(i) \leq b(i+1)$$

$(i, b(i))$ - локальный минимум.




Рис. 4: Средняя интенсивность строк для столбца 6. Красными точками отмечены локальные минимумы.

2.3. Выбор потенциальных зон в каждом столбце

В каждом столбце анализируются всевозможные пары локальных минимумов с разницей координат от $minPlateHeight$ до $maxPlateHeight$, где $minPlateHeight$ - минимальная высота номера, $maxPlateHeight$ - максимальная высота номера. Через точки, соответствующие паре локальных минимумов, проводится прямая и выполняется оценка площади s (рис.5) между кривой средней яркости b и этой прямой. Площадь нормируется. Выбираются только те пары точек, у которых соответствующая нормированная площадь (вес) превышает порог $minS$.




Рис. 5: Визуализация вычисляемых площадей.

Результатом выполнения этого этапа является набор потенциальных зон в каждом столбце. Для столбца 6 рассматриваемого примера было выделено 6 потенциальных зон (параметры $minPlateHeight = 15$, $maxPlateHeight = 32$).




Рис. 6: Результат выделения потенциальных зон.

2.4. Удаление пересекающихся зон и выбор лучших среди оставшихся

Выделенная в каждом столбце зона проверяется на пересечение с другими зонами столбца, и если существует зона, которая пересекается с рассматриваемой и имеет большую площадь, то рассматриваемая зона удаляется (рис. 7).

Среди оставшихся зон выбирается заданное количество ($N_{kandidat}$) лучших в каждом столбце. Эти зоны по построению не могут пересекаться.




Рис. 7: В каждом столбце удалены пересекающиеся зоны и выделено по 3 зоны с максимальным весом среди оставшихся. Цвет прямоугольника соответствует порядковому номеру зоны: 1 - красный (зона с максимальным весом), 2 - зеленый, 3 - синий (зона с минимальным весом).

2.5. Формирование зон с номером

На данном этапе сравниваются выделенные зоны с зонами в соседних столбцах. Анализируется два соседних столбца слева и два соседних столбца справа. Если рассматриваемая зона пересекается по вертикали с зоной в одном из соседних столбцов и ее вес меньше соседа, то эта зона подавляется. Далее идет центрирование оставшихся обла-

стей, т.е. выбор предполагаемой средней зоны номера, при котором наибольший вес имеют оставшиеся зоны после процедуры подавления. У подавленных зон вес уменьшается. Опираясь на средние зоны, строятся зоны с предполагаемым номером цистерны в них (рис. 8). Высота зоны с номером равна высоте центрированной зоны столбца, ширина равна $maxPlWidth$.




Рис. 8: Результат локализации алгоритмом выделения границ.

3. Уточнение зоны с номером

На данном этапе используется обученный детектор (бинарный классификатор) номера. В найденных зонах изображения I производится попытка обнаружить номер с помощью детектора, используя принцип скользящего окна. Каждое окно анализируется бинарным классификатором, который принимает решение - попадает часть номера в анализируемую область или нет. В результате выигрывает та зона, в которой было обнаружено большее количество положительных откликов детектора.

Алгоритм машинного обучения, используемый для обучения детектора, основан на теории случайных функций. В качестве признаков, которыми описываются зоны анализа детектора, были выбраны пирамидальные признаки [5].

3.1. Выбор признаков для изображения части номера

Рассмотрим этапы формирования признакового пространства для бинарного классификатора, более компактно описывающих изображения частей номеров цистерн [5]. Последовательность этапов формирования признаков выглядит следующим образом:

- Для представления изображения части номера цистерны выбран иерархический способ его

разбиения. Данный способ заключается в формировании пирамиды прямоугольных участков изображения A_0, A_1, \dots, A_n , интенсивности которых $I_{A_0}, I_{A_1}, \dots, I_{A_n}$. В итоге получается пирамида интенсивностей участков изображения, которая и является новым его представлением (рис. 9).

- Вид признаков, полученных из новой модели изображения, представляет собой всевозможные пары линейных комбинаций интенсивностей $I_{A_0}, I_{A_1}, \dots, I_{A_n}$:

$$f(I_{A_i}, I_{A_j}) = a_0 I_{A_i} + a_1 I_{A_j} \quad (1)$$

где $a_0 = 1/128$, $a_1 = -1/128$, а значения функции $f(I_{A_i}, I_{A_j}) \in (-2, 2)$.

- После преобразования изображения и получения признакового пространства выбирается подмножество наиболее информативных признаков, упрощающее задачу машинного обучения. Способ отбора значимых признаков основан на полном их переборе. В данном подходе используется критерий уменьшения признакового пространства с помощью линейного дискриминанта Фишера [6], определение значимости каждого признака с помощью критерия Джини [4]. Отбор производится жадным алгоритмом.




Рис. 9: Вид представления пирамиды участков изображения. L_0 – слой, которому соответствует само изображение, т.е. участок A_0 с интенсивностью I_{A_0} .

3.2. Обучение детектора номера цистерны

Для обучения детектора использовался алгоритм, основанный на теории случайных функций. Данный метод машинного обучения гарантирует получение оптимального результата с точки зрения рассматриваемого математического аппарата теории случайных функций. По эффективности не уступает иным популярным методам машинного обучения [3,7].

4. Экспериментальная часть

В рамках эксперимента были подготовлены небольшая выборка для обучения детектора, состоящая из 500 положительных примеров (части номеров вагонов) и 500 шумовых примеров, а также тестовая выборка, состоящая из 4600 положительных примеров и 30000 шумовых.

Каждое изображение представлялось в виде пирамиды с 5 уровнями. Всего возможных признаков (1) в данном представлении равно 820. Из них были отобраны 36 признаков. Т.е. каждому изображению из обучающей выборки соответствовал числовой вектор длиной 36. Обученный детектор показал следующие результаты на тестовой выборке: 89.93% правильного обнаружения номера, 4.44% ложного срабатывания на шумовой выборке.

Для проведения теста локализации номеров была составлена выборка из 78 изображений вагонов. Эксперименты показали следующие результаты: на 76 вагонах номер был обнаружен, на 71 вагоне номер находился в первой из предложенных зон (рис. 11). Составленные выборки представлены в открытом доступе [8].

Так, например, для рассматриваемого примера изображения с цистерной, которое использовалось в качестве иллюстраций в статье, распределение положительных откликов детектора на 8 зонах получилось следующим (рис. 10):




Рис. 10: В первой зоне детектор положительно сработал 21 раз, в результате чего алгоритм отдал предпочтение этой зоне.




Рис. 11: Пример изображения первой зоны.

5. Заключение

Предложенный комбинированный алгоритм показал неплохие результаты на тестовых данных: 97% - номер будет в одной из найденных зон, 91% - номер будет содержаться в первой из найденных зон. Данный подход может показать лучшие результаты, если предоставить детектору номера больше дан-

ных для обучения, протестировать различные методы машинного обучения и иные способы признакового описания изображений частей номера цистерн.

Литература

- [1] *W. Kong, P. Chang, Z. Bi.* Real-time Sobel edge detector. // The 6th PSU-UNS International Conference on Engineering and Technology (ICET-2013), Novi Sad, May 15-17, 2013. University of Novi Sad, Faculty of Technical Sciences. pp.1-2.
- [2] *P. Viola, M. Jones.* Robust Real-Time Face Detection. // International Journal of Computer Vision 57(2), 2004, pp.137-154.
- [3] *Бахвалов Ю.Н., Малыгин Л.Л., Черкас П.С.* Метод машинного обучения на основе алгоритма многомерной интерполяции и аппроксимации случайных функций. // Череповец, Вестник Череповецкого государственного университета. 2012. Т. 2. № 39-2. С.7-10.
- [4] www.basegroup.ru/library/analysis/tree/math_cart_part1 – Критерий Джини.
- [5] *Копылов И.В., Малыгин Л.Л.* Построение модели изображения и ее применение в задачах детектирования объектов. // Череповец, Вестник Череповецкого государственного университета, Технические науки, №8, 2014.
- [6] *Дж.Ту, Р. Гонсалес.* Принципы распознавания образов. // Пер. с англ. – М.: Мир, 1974 –411 с. стр.281.
- [7] *Ширабакина Т.А., Бахвалов Ю.Н., Зуев А.Н.* Метод распознавания образов на основе теории случайных функций. // Известия высших учебных заведений. Приборостроение. СПГИ точной механики и оптики. 2005 г. Т.48, №2, С.5-8.
- [8] https://yadi.sk/d/_2yaEW59gx3gG – Расположение выборок для обучения и тестирования.

Сведения об авторе

Копылов Иван Владимирович.

Аспирант.

Дискретная математика и математическая кибернетика.

Кафедра математического и программного обеспечения ЭВМ.

Череповецкий Государственный Университет.

Kopylov Ivan Vladimirovich.

Postgraduate student.

01.01.09 Discrete mathematics and mathematical cybernetics.

Department of Mathematical Insure and Software of Computing Machines.

Cherepovets State University.

Телефон: +79114448038

E-mail: ivv.kopylov@gmail.com