

Распознавание дорожных знаков в сложных метеоусловиях

Г. Е. Эдель^{1,2}, В. В. Капустин¹, М. Е. Сукотнова¹

¹ Томский гос. ун-в. систем управления и радиоэлектроники (ТУСУР)

² Томский научно-исследовательский и проектный институт нефти и газа

Аннотация: Рассмотрена проблема обнаружения и распознавания дорожных знаков в сложных метеоусловиях. Предложен алгоритм, основанный на комбинации моделей нейронных сетей и обладающий высокой точностью и устойчивостью при распознавании изображений, полученных в сложных метеоусловиях. Эффективность алгоритма проверена на наборе изображений, перекрываемых дождем и снегом. Результаты экспериментов показали существенное повышение эффективности предложенного алгоритма по сравнению с алгоритмом, не учитывающим влияние погоды.

Ключевые слова: автоматическое распознавание, компьютерное зрение, повышение точности, предобработка изображений, нейронные сети, динамические метеоусловия, обнаружение дорожных знаков.

Для цитирования: Эдель Г. Е., Капустин В. В., Сукотнова М. Е. Распознавание дорожных знаков в сложных метеоусловиях // Вестник СибГУТИ. 2025. Т. 19, № 3. С. 19–29. <https://doi.org/10.55648/1998-6920-2025-19-3-19-29>.



Контент доступен под лицензией
Creative Commons Attribution 4.0
License

© Эдель Г. Е., Капустин В. В., Сукотнова М. Е., 2025

Статья поступила в редакцию 28.08.2024;
переработанный вариант – 26.01.2025;
принята к публикации 13.03.2025.

1. Введение

Целью данного исследования является разработка и оценка алгоритма распознавания дорожных знаков, способного работать в неблагоприятных погодных условиях, таких как дождь и снег. Основной задачей является повышение точности и устойчивости системы к искажениям, вызванным неблагоприятными погодными условиями, с использованием современных методов машинного обучения и нейронных сетей. Важность данного исследования продиктована необходимостью повышения безопасности дорожного движения, так как неблагоприятные погодные условия могут значительно ухудшать видимость и распознавание дорожной информации. Учитывая стремительное развитие технологий автономного вождения и систем помощи водителю, важно обеспечить надежную работу этих систем даже в условиях плохой погоды.

Существуют различные методы распознавания дорожных знаков, уже внедрённые и используемые на практике. Технологические гиганты, такие компании, как Mobileye, Bosch и Tesla, разработали алгоритмы и методы, защищенные патентами, которые являются частью их интеллектуальной собственности. Тем не менее, научные исследования и публикации продолжают описывать методы и подходы, применяемые в системах распознавания дорожных знаков в неблагоприятных погодных условиях.

Система ADAS (система помощи водителю) Mobileye, используемая в автомобилях таких производителей, как Audi, BMW и Nissan, использует камеры и алгоритмы компьютерного зрения для обнаружения и классификации дорожных знаков в режиме реального време-

ни. Для борьбы с осадками система применяет методы предварительной обработки изображений, такие как фильтрация и улучшение контраста, чтобы сделать знаки более видимыми в плохую погоду. Система Bosch использует камеры и алгоритмы машинного обучения для распознавания дорожных знаков. Она борется с неблагоприятными погодными условиями с помощью методов увеличения данных, включая синтетические изображения с различными погодными условиями в обучающий набор данных, что повышает устойчивость модели. Система компании Tesla также использует распознавание дорожных знаков с помощью камер и алгоритмов глубокого обучения. Она использует против осадков методы предварительной обработки изображений, такие как фильтрация шума и улучшение контраста, а также методы увеличения данных, это улучшает устойчивость модели к неблагоприятным погодным условиям.

Однако, несмотря на значительный прогресс в распознавании дорожных знаков, существующие системы до сих пор сталкиваются с трудностями в условиях сильных осадков, таких как дождь и снег. Поэтому разработка эффективных алгоритмов распознавания дорожных знаков, способных работать в сложных метеоусловиях, становится ключевой задачей для улучшения безопасности дорожного движения. Исследования в данной области способны привести к сокращению количества дорожно-транспортных происшествий и повышению общей безопасности транспортной инфраструктуры.

Разработать алгоритм, метод, систему или же обучить нейронную сеть, используя материалы, полученные в условиях, близким к идеальным, мало для разработки стабильной системы распознавания. Поэтому разработчиками нередко вносятся те или иные алгоритмы предобработки, которые способны упростить системный анализ полезных данных из обучающей выборки, выровнять гистограммы, удалить появившееся артефакты, повысить качество цветопередачи, а также восстановить возможными методами перекрытые объекты интереса и так далее [1–3].

Сформировать наиболее удачную для распознавания базу данных, которая включает в себя фиксацию объекта интереса в различных условиях сцены – первый и наиболее важный этап разработки подобных алгоритмов, способных верно распознавать и классифицировать любой входящий в систему объект, что является актуальной задачей компьютерного зрения. Обычно архитектура нейронных сетей не ограничивает разработчика в количестве материалов, находящихся в базе данных, однако стабильных результатов в работе нейронной сети можно достичь лишь при её обучении на достаточной выборке изображений (от 500 до 1000 фотографий для каждого класса). В зависимости от принципа работы нейронной сети базы данных для обучения составляются по-разному, однако верный сбор информации для обучения – ключевой шаг в получении стабильного алгоритма. Необходимо, чтобы база данных включала в себя максимальное количество возможных изменений объекта интереса в кадре. Под изменениями понимаются такие параметры объекта интереса, как его детализация, повороты, изменение освещённости [3–6].

2. Разработка алгоритма для распознавания дорожных знаков

Для автоматического обнаружения и распознавания дорожных знаков в кадре был выбран метод, включающий применение свёрточной нейронной сети на основе архитектуры VGG-16 и выделение объектов по цветам. Входящие фото- и видеоданные конвертируются из цветового пространства RGB в HSV, что позволяет снизить вычислительную сложность и повысить быстродействие алгоритма. Архитектура VGG-16 включает в себя несколько свёрточных и полносвязных слоев, что позволяет эффективно выделять и классифицировать объекты на изображениях. Входное изображение проходит через серию сверточных слоев, каждый из которых применяет фильтры для выделения различных признаков. В VGG-16 используются фильтры размером 3x3 с шагом 1 и нулевым паддингом, что позволяет сохранять размер изображения на каждом уровне. После каждой группы сверточных слоев применяется пулинг (обычно max-pooling) с размером окна 2x2 и шагом 2. Это позволяет уменьшить раз-

мер изображения и сократить количество параметров, сохраняя при этом важные признаки. Далее следуют три полносвязных слоя. Первый и второй полносвязные слои содержат по 4096 нейронов, а третий – 1000 нейронов. В VGG-16 используется функция активации ReLU (Rectified Linear Unit) после каждого сверточного и полносвязного слоя, что позволяет модели обучаться нелинейным зависимостям. Для улучшения обобщающей способности модели и предотвращения переобучения используются методы нормализации и регуляризации, такие как dropout [5–7].

Нейронная сеть обучена на 100 классах дорожных знаков, каждый из которых пронумерован от 0 до 100. Выборка объектов интереса была сформирована на основе изображений дорожных знаков, взятых из открытой базы данных российских дорожных знаков. Таким образом, конечная база данных включает в себя более 70 тысяч изображений различных знаков. На рисунке 1 представлен график распределения изображений в обучающей выборке.

Поскольку представленные в базе данных дорожные знаки были собраны в одну папку, необходимо было рассортировать их по классам. Данная операция была выполнена автоматически с помощью файла формата .csv, в котором были прописаны названия файлов и классы, к которым они принадлежат. Таким образом, автоматически были созданы 100 директорий для каждого из классов дорожных знаков.




Рис. 1. Распределение изображений в обучающей выборке

Каждый класс, на котором обучалась система, содержал в себе изображения размером 48×48 пикселей необходимого знака при различных освещении, углах поворота, размерах и так далее. Размер изображений обучающей выборки объясняется необходимостью присутствия на изображении только объекта интереса (в данном случае, дорожного знака). Набор данных был разделен на обучающую и тестовую выборки, при соотношении 80% на 20% соответственно. Чтобы обучить нейронную сеть на базе данных, состоящей из 100 классов и более 70000 изображений, потребовалось более 6 часов. Количество эпох было выбрано равным 100. Выбор количества эпох был обоснован эмпирическим исследованием, которое включало анализ зависимости точности и потерь от числа эпох. В ходе экспериментов было установлено, что при 100 эпохах достигается стабильность алгоритма и минимизация потерь. Технические характеристики компьютера, на котором осуществлялось обучение: процессор AMD Ryzen 5 5600G, 6 ядер, оперативная память 64 Гб, видеокарта 3060ti. В качестве исходных данных нейросети выступает созданный классифицирующий файл формата .csv, к которому обращается модель в процессе обучения. Данный файл содержит номер класса (метки) и его наименование. На рисунке 2 представлены зависимости полученной точности и потерь от числа эпох. Из зависимостей, представленных на рисунке, заметно, что стабильность алгоритма достигается в результате обучения её на 100 эпохах.




Рис. 2. Полученные зависимости числа точности (а) и значений потерь (б) от количества эпох

Проверка работоспособности алгоритма, а также его первый запуск производились на тестовых изображениях. В ходе выполнения данной проверки все результаты распознавания оказались верными – алгоритм верно распознавал входящий в систему класс. На рисунке 3 представлены некоторые примеры работы алгоритма.



Рис. 3. Тестирование алгоритма на тестовых изображениях

Как видно из полученных результатов, разработанный алгоритм верно и с достаточно высокой точностью распознал представленные знаки.

В ходе исследования эффективности распознавания на реальных видеозаписях алгоритм показал отличные результаты в условиях хорошей видимости: обнаружение и верная классификация дорожных знаков.

Для более точного представления ситуации на дороге необходимо, чтобы алгоритм верно определял знак вне зависимости от угла съёмки. В результате тестов точность распознавания при различных ракурсах съёмки изменяется незначительно. Средние значения точности для съёмки, сделанной под различными углами поворота дорожного знака в плоскости, отличается не более, чем на 10%.

Когда дорожный знак находится на достаточно большом расстоянии от камеры видеорегистратора, количество пикселей, приходящееся на область знака в кадре, мало, что приводит к плохой детализации и наоборот. Тесты показали, что алгоритм способен обнаружить знаки как при высокой детализации, так и при низкой. Однако, в случае низкой детализации (менее 20×20 пикселей), алгоритму не всегда удавалось не только верно распознать дорожный знак, но и найти его в кадре.

3. Разработка алгоритма для снижения влияния динамических эффектов, вызванных сложными метеоусловиями

В качестве метеоэффектов, влияющих на работу алгоритма, были выбраны дождь и снег, перекрывающие пиксели на изображении и тем самым препятствующие стабильному распознаванию нейронной сетью дорожных знаков.

Для удаления визуальных эффектов от метеоусловий использовались нейронные сети, работа которых основана на свёртке изображений и использовании шаблонов, на которых обучалась нейронная сеть. Для реализации алгоритма повышения качества фото- и видеодан-

ных при компенсации визуальных эффектов от погодных явлений, а именно – дождя, был выбран метод с использованием нейронной сети SAPNet (реализация нейронной сети, удаляющей полосы дождя, производилась на изображениях с имитацией дождя [7–9]).

SAPNet использует несколько свёрточных блоков, каждый из которых отвечает за ту или иную операцию. Так, например, полномасштабный свёрточный блок отвечает за расширение поля анализа для выделения полос дождя разного масштаба. Архитектура данной нейронной сети основывается на архитектуре VGG-16 [10]. Данная нейронная сеть выделяет полосы дождя, обучаясь на имеющейся базе данных негативных изображений. Негативные изображения в задачах распознавания – это изображения, которые не содержат объект интереса, в данном случае, дождь. Для формирования обучающей выборки было использовано несколько баз данных – Rain100H и открытая база данных российских знаков (директория с негативными изображениями). Таким образом, имеющаяся база данных состояла из ста тысяч изображений, в которой зафиксированы различные объекты, перекрытые дождем (люди, дороги, здания, дорожные знаки и так далее). В разработанном алгоритме используется билатеральный фильтр: на итоговых кадрах происходит выделение контуров, что приводит к увеличению качества полученных кадров [8–11]. Несомненно, добиться полного удаления (чистого изображения) капель дождя из кадра невозможно, однако частичное перекрытие знаков дождём, которое может повлиять на результаты обнаружения и распознавания, устраняется.

Работа нейронной сети для удаления изображения снега использует ту же архитектуру, что и нейронная сеть SAPNet, VGG-16 с ядром свёртки 3×3 . Однако для данной нейронной сети используется оценка глубины, из-за чего база данных, на которых обучается нейронная сеть, представляет собой «шаблоны» снега, взятые из открытой базы данных Snow100K dataset, которая включает в себя 100000 масок снега [12]. Подобные маски необходимы, чтобы сформировать сеть оценки глубины. Информация, полученная из сети оценки глубины, затем объединяется с признаками, которые были извлечены из входных изображений, для получения чистого выходного изображения.

Таким образом, начальным этапом построения алгоритма распознавания дорожных знаков по фото- и видеоизображениям, полученным в сложных метеоусловиях, является создание нескольких блоков моделей:

- 1) модели нейронной сети для распознавания дорожных знаков;
- 2) модели с использованием билатерального фильтра для удаления дождя на основе нейронной сети SAPNet;
- 3) модели, использующей семантическую сегментацию и оценку глубины. Это и есть модуль обучения, который, к тому же, последовательно обучается на нескольких базах данных.

Алгоритм модуля распознавания обращается к модулю обучения, поскольку данные, входящие в блок обнаружения, из блока обучения попадают на вход данного блока. В модуле обучения происходят процессы постобработки кадров базы данных, на которых, в последствии, обучается конечная нейронная сеть, включающая в себя несколько моделей обучения – для обнаружения знаков в кадре, удаления полос дождя и снега соответственно. Далее поступающие в систему кадры обрабатываются с помощью встроенного алгоритма удаления тумана и подаются в обученную модель для верного соотнесения входящих знаков к тому или иному классу. Если знак не был классифицирован вовсе, алгоритм возвращается к обращению алгоритма к базе данных, пока знак не будет распознан, либо, не достигнув результата, выдает ответ [0] – не обнаружен дорожный знак в базе данных. После процесса распознавания на результирующем изображении выводится обработанный кадр с выделенными знаками, которые промаркированы классом с его названием. На этом работа алгоритма заканчивается. На рисунке 4 представлена блок-схема модулей обучения и распознавания алгоритма автоматического распознавания дорожных знаков по фото- и видеоизображениям, полученным в сложных метеоусловиях.

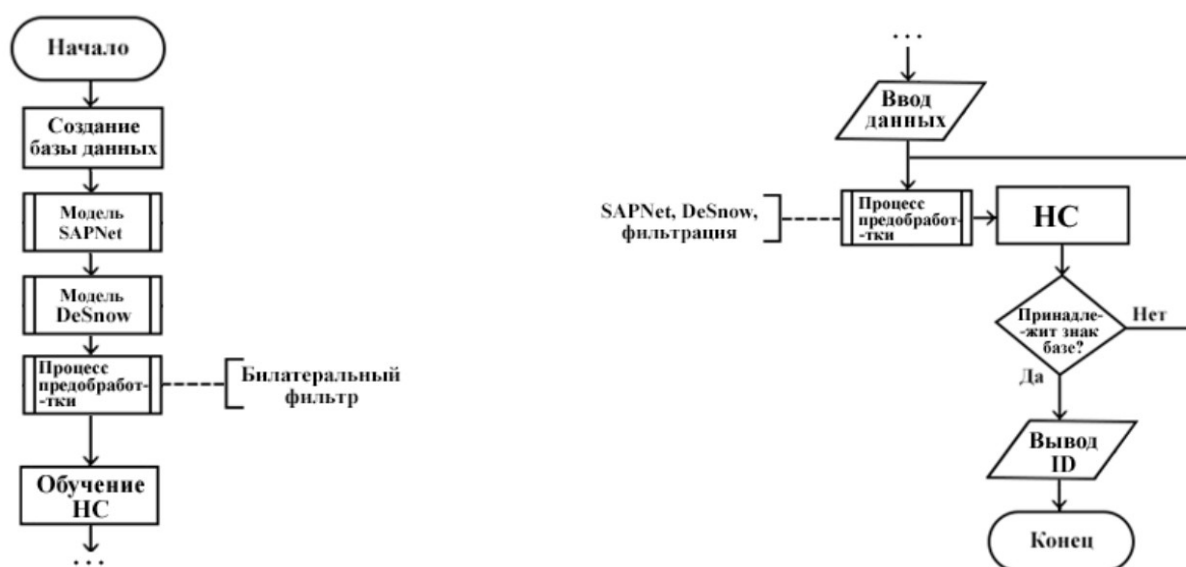


Рис. 4. Блок-схема модуля обучения и распознавания алгоритма автоматического распознавания дорожных знаков по фото- и видеоизображениям, полученным в сложных метеоусловиях

4. Исследование эффективности разработанного алгоритма для распознавания дорожных знаков в сложных метеоусловиях

Первым критерием точности работы алгоритма является ракурс съёмки при повороте знака в плоскости. Пример работы нейронной сети для данного критерия точности без удаления дождя и снега из кадра и с применением алгоритма удаления представлен на рисунке 5. Алгоритм был протестирован на 100 изображениях различных классов при разрешении 1280×720 пикселей с наложением эффекта дождя и снега.

Как можно заметить, данная нейронная сеть справилась с поставленной задачей удаления капель дождя и снега из кадра – полосы и снежинки не перекрывают знак и дальнейшее обнаружение объекта интереса уже не является проблемой.



Рис. 5. Пример работы алгоритма удаления изображений дождя и снега при повороте знака в плоскости на 30° : исходное изображение – а, в; обработанное изображение – б, г

На рисунке 5 а видно, что алгоритм без предобработки не смог обнаружить знак в исходном кадре. При удалении с помощью разработанного алгоритма изображений дождя и снега с кадров удалось добиться стабильной работы по распознаванию дорожных знаков. При расположении знака под углом к направлению движения видеокамеры, превышающим 30° , разработанный алгоритм показал стабильное обнаружение.

Эмпирическая оценка вероятности правильного решения при различении дорожных знаков на кадрах с изображением дождя и снега и при расположении дорожного знака под углом $10...30^\circ$ составило $0,6...0,8$ для алгоритма без предобработки, а для разработанного алгоритма – $0,95...0,99$, что говорит об эффективной работе предложенного алгоритма.

Следующий критерий точности – пространственное разрешение области знака в кадре (детализация знака в кадре). В сложных условиях видимости, но при довольно большом числе элементов разложения, приходящихся на объект интереса, алгоритм чаще всего справляется с поставленной задачей. Удаление таких нежелательных явлений, как дождь и снег, повышают точность и стабильность обнаружения. Эффективность алгоритма становится ещё более очевидной при низкой детализации объектов интереса, что проиллюстрировано на рисунке 6.




Рис. 6. Пример работы алгоритма удаления изображений дождя и снега при низкой детализации области знака в кадре (30×30 пикселей):

исходное изображение (дождь, снег) – а, в; обработанное изображение – б, г

Сложные метеоусловия и низкая детализация в кадре существенно сказываются на точности обнаружения дорожных знаков и её стабильности. На необработанных кадрах объекты не были распознаны вовсе, либо были, но точность такого обнаружения сильно менялась от кадра к кадру. После удаления дождя и снега все дорожные знаки были обнаружены.

Последний критерий работы алгоритма – быстродействие. При исследовании разработанного алгоритма разрешении по кадру распознавания 640×480 пикселей быстродействие составило 65 мс, а при 1280×720 пикселей – 100 мс, т. е. время распознавания дорожных знаков с устранением эффектов сложных метеоусловий в первом случае увеличилось на 50 мс, а во втором – на 80 мс относительно значений быстродействия, полученных при работе нейронной сети без предобработки, что объясняется увеличением вычислительной сложности алгоритма и может быть скорректировано оптимизацией или распараллеливанием вычислений.

5. Заключение

Разработанный алгоритм для обнаружения дорожных знаков в неблагоприятных погодных условиях, таких как дождь или снег, основан на комбинации моделей нейронных сетей и обладает высокой точностью и устойчивостью при распознавании изображений, полученных в сложных метеоусловиях. Используемая для решения этой задачи нейронная сеть, прошла обучение на наборе данных, содержащем изображения дорожных знаков в разных условиях освещения и видимости. Для повышения точности и стабильности распознавания дорожных знаков в условиях осадков была применена предобработка изображений, состоящая из коррекции цвета, контраста и яркости, а также из удаления шумов и артефактов. Предложенный алгоритм был протестирован на наборе данных, включающем изображения дорожных знаков в условиях дождя и снега. Результаты тестирования показали, что предобработка изображений позволяет существенно повысить точность обнаружения в среднем более чем на 25%, а также существенно повысить надежность классификации дорожных знаков в сложных метеоусловиях по сравнению с алгоритмом, работающим без предобработки. Эффективность алгоритма с предобработкой особенно заметна при обнаружении знаков с низкой детализацией 30×30 пикселей. Вероятность верного распознавания дорожных знаков стабильно превышает 0,9, тогда как без предобработки они не были обнаружены вовсе. В дальнейшем данный алгоритм может быть применен совместно с активно-импульсной телевизионной измерительной системой, что повысит эффективность обнаружения объектов в сложных условиях видения [13–15]. Таким образом, предложенный алгоритм может быть полезен как для систем автоматического управления транспортными средствами, так и для автономных мобильных роботов, особенно в условиях неблагоприятной погоды.

Литература

12. *Mathias M., Timofte R., Benenson R., Van Gool L.* Traffic sign recognition – How far are we from the solution? // The 2013 international joint conference on Neural networks (IJCNN IEEE), 4-9 August 2013 Fairmont Hotel Dallas, Texas, USA. P. 1–8.
13. *Сагдуллаев Ю. С.* Отображение и фиксация выделенной телеметрической информации в телевизионных изображениях космических // Вопросы радиоэлектроники, Серия техника телевидения, 2018. Вып. 3, - С 101–07.
14. *Фахми Ш. С., Еуд М. М., Костикова Е. В.* [и др.] Метод и алгоритмы обнаружения и распознавания дорожных знаков // Вопросы радиоэлектроники, Серия техника телевидения, 2018. Вып. 3. С. 95–00.
15. *Levinson J., Askelad J., Becker J., Dolson J.* Towards fully autonomous driving: Systems and algorithms // IEEE intelligent vehicles symposium (IV) IEEE, 5-9 June 2011 Baden-Baden, Germany. P. 163–168.
16. *Timofte R., Zimmermann K., Van Gool L.* Multi-view traffic sign detection, recognition, and 3D localization, Machine vision and applications // IEEE Workshop on Applications of Computer Vision, 7-8 December, 2009, Snowbird, UT, USA. P. 633–647.
17. *Sermanet P., LeCun Y.* Traffic sign recognition with multi-scale convolutional networks // The 2011 international joint conference on neural networks IEEE, 31 July – 5 August, 2011 Doubletree Hotel San Jose, California, USA. P. 2809–2813.
18. *Houben S., Stallkamp J., Salmen J., Schlipsing M., Igel C.* Detection of traffic signs in real-world images: The German Traffic Sign Detection Benchmark // The 2013 international joint conference on neural networks IJCNN IEEE, 4-9 August 2013 Fairmont Hotel Dallas, Texas, USA. P. 1–8.
19. *Q. Guo, J. Sun, F. Juefei-Xu* [et al] Efficientderain: Learning pixel-wise dilation filtering for high-efficiency single-image deraining // Conference: Thirty-Fifth AAAI Conference on Artificial Intelligence (AAAI 2021). P. 1–9.

20. Fu H., Huang J., Delu Z. [et al] Removing rain from single images via a deep detail network // In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017. P. 3855–3863.
21. Mu Y., Ruiwen N., Chang Z. [et al] Model of VGG-16 for Remote Sensing Image Classification // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing PP, June 2021. P. 6916–6922.
22. Qi Y., Zhang P., The Tracker with Online Training Based on the TLD Algorithm // Proceedings of the 2nd International Conference on Information Technology and Intelligent Transportation Systems (ITITS 2017), 10 June 2017, Xi'an, China. P. 76–81.
23. Official website with dataset [Электронный ресурс]. URL: <https://paperswithcode.com/dataset/snow100k> (дата обращения: 20.05.2024).
24. Kapustin V. V., Zahlebin A. S., Movchan A. K. [et al] Experimental assessment of the distance measurement accuracy using the active-pulse television measuring system and a digital terrain model // Computer Optics 2022; 46(6). P. 948–954.
25. Movchan A. K., Kapustin V. V., Kuryachiy M. I., Movchan E. S. Multi-Area Method of a Depth Map Building with Gain Modulation in Active-Pulse Television Measuring Systems // In 2022 International Siberian Conference on Control and Communications (SIBCON) P. 1–6.
26. Капустин В. В., Мовчан А. К. Многозонные методы формирования карт глубин с использованием активно-импульсных телевизионных измерительных систем // Вопросы радиоэлектроники, Серия техника телевидения, 2023. Вып. 2. С. 44–54.

Эдель Герман Евгеньевич

аспирант кафедры телевидения и управления, инженер лаборатории телевидения и автоматики, Томский государственный университет систем управления и радиоэлектроники (ТУСУР, 634050, г. Томск, пр. Ленина, 40); инженер 1 категории, Томский научно-исследовательский и проектный институт нефти и газа (АО «ТомскНИПИнефть», 634027, г. Томск, пр. Мира, 72), тел. +79526833197, e-mail: german.edel99@gmail.com. ORCID ID: 0000-0001-5935-9710.

Капустин Вячеслав Валериевич

доцент, кандидат технических наук, заведующий лабораторией телевизионной автоматики (каф.ТУ). Томский государственный университет систем управления и радиоэлектроники (ТУСУР, 634050, г. Томск, пр. Ленина, 40), e-mail: peregnun@mail.ru, ORCID ID: 0000-0002-2293-0511

Сукотнова Марина Евгеньевна

магистр, инженер лаборатории телевидения и автоматики, Томский государственный университет систем управления и радиоэлектроники (ТУСУР, 634050, г. Томск, пр. Ленина, 40), e-mail: msukotnova@mail.ru, ORCID ID: 0009-0002-7703-3081.

Авторы прочитали и одобрили окончательный вариант рукописи.

Авторы заявляют об отсутствии конфликта интересов.

Вклад соавторов: Каждый автор внес равную долю участия как во все этапы проводимого теоретического исследования, так и при написании разделов данной статьи.

Recognition of road signs in difficult weather conditions

German E. Edel^{1,2}, Vyacheslav V. Kapustin¹, Marina E. Sukotnova¹

¹ Tomsk State University of Control Systems and Radioelectronics (TSUCSR)

² Tomsk Scientific Research and Design Institute of Oil and Gas

Abstract: The problem of detecting and recognizing road signs in difficult weather conditions is considered. An algorithm based on a combination of neural network models and possessing high accuracy and stability in recognizing images obtained in difficult weather conditions is proposed. The effectiveness of the algorithm was tested on a set of images overlapped by rain and snow. The experimental results showed a significant increase in the efficiency of the proposed algorithm compared to the algorithm that does not take into account the influence of the weather.

Keywords: automatic recognition, computer vision, improved accuracy, image preprocessing, neural networks, dynamic weather conditions, road sign detection.

For citation: Edel G. E., Kapustin V. V., Sukotnova M. E. Raspoznavanie dorozhnykh znakov v slozhnykh meteousloviyakh [Recognition of road signs in difficult weather conditions]. Vestnik SibGUTI, 2025, vol. 19, no. 3, pp. 19-29. <https://doi.org/10.55648/1998-6920-2025-19-3-19-29>.



Content is available under the license
Creative Commons Attribution 4.0
License

© Edel G. E., Kapustin V. V., Sukotnova M. E., 2025

The article was submitted: 28.08.2024;
revised version: 26.01.2025;
accepted for publication 13.03.2025.

References

1. Mathias M., Timofte R., Benenson R., Van Gool L. Traffic sign recognition – How far are we from the solution? *The 2013 international joint conference on Neural networks (IJCNN IEEE)*, 4-9 August 2013 Fairmont Hotel Dallas, Texas, USA. pp. 1-8.
2. Sagdullaev Y.S. Display and fixation of selected telemetric information in satellite television images. *Voprosy Radioelectronics, TV Technology Series*, 2018. Issue 3, pp. 101-107.
3. Fahmi Sh. S., Eid M. M., Kostikova E. V. et al. Method and algorithms for detecting and recognizing road signs. *Questions of radio electronics, TV Technique Series*, 2018. Issue 3. pp. 95-100.
4. Levinson J., Askelad J., Becker J., Dolson J. Towards fully autonomous driving: Systems and algorithms. *IEEE intelligent vehicles symposium (IV) IEEE*, 5-9 June 2011 Baden-Baden, Germany. pp. 163-168.
5. Timofte R., Zimmermann K., Van Gool L. Multi-view traffic sign detection, recognition, and 3D localization, Machine vision and applications. *IEEE Workshop on Applications of Computer Vision*, 7-8 December, 2009, Snowbird, UT, USA. pp. 633-647.
6. Sermanet P., LeCun Y., Traffic sign recognition with multi-scale convolutional networks. *The 2011 international joint conference on neural networks IEEE*, 31 July – 5 August, 2011 Double-tree Hotel San Jose, California, USA. pp. 2809-2813.
7. Houben S., Stallkamp J., Salmen J., Schlipsing M., Igel C. Detection of traffic signs in real-world images: The German Traffic Sign Detection Benchmark. *The 2013 international joint conference on neural networks IJCNN IEEE*, 4-9 August 2013 Fairmont Hotel Dallas, Texas, USA. pp. 1-8.
8. Guo Q., Sun J., Juefei-Xu F. et al. Efficientderain: Learning pixel-wise dilation filtering for high-efficiency single-imagederaining. *Conference: Thirty-Fifth AAAI Conference on Artificial Intelligence (AAAI 2021)*. pp. 1-9.
9. Fu H., Huang J., Delu Z. et al. Removing rain from single images via a deep detail network. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017. pp. 3855-3863.

10. Mu Y., Ruiwen N., Chang Z. et al. Model of VGG-16 for Remote Sensing Image Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing PP*, June 2021. pp. 6916-6922.
11. Qi Y., Zhang P., The Tracker with Online Training Based on the TLD Algorithm. *Proceedings of the 2nd International Conference on Information Technology and Intelligent Transportation Systems (ITITS 2017)*, 10 June 2017, Xi'an, China. pp. 76-81.
12. Official website with dataset, available at: <https://paperswithcode.com/dataset/snow100k> (accessed: 05.20.2024).
13. Kapustin V.V., Zahlebin A.S., Movchan A.K. et al. Experimental assessment of the distance measurement accuracy using the active-pulse television measuring system and a digital terrain model. *Computer Optics 2022*; 46(6). pp. 948-954.
14. Movchan A.K., Kapustin V.V., Kuryachiy M.I., Movchan E.S. Multi-Area Method of a Depth Map Building with Gain Modulation in Active-Pulse Television Measuring Systems. In *2022 International Siberian Conference on Control and Communications (SIBCON)* pp. 1-6.
15. Kapustin V.V., Movchan A.K. Multi-zone methods of forming depth maps using active pulse television measuring systems. *Issues of Radio Electronics, Television Technology Series*, 2023. Issue. 2. pp. 44-54.

German E. Edel

Postgraduate student of the Department of Television and Control, engineer of the Laboratory of Television and Automation, Tomsk State University of Control Systems and Radio Electronics (TUSUR, 634050, Tomsk, Lenin ave., 40). Engineer of the 1st category, Tomsk Scientific Research and Design Institute of Oil and Gas (JSC TomskNIPIneft, 72 Mira ave., 634027, Tomsk), tel. +7 9526833197, e-mail: german.edel99@gmail.com, ORCID ID: 0000-0001-5935-9710.

Vyacheslav V. Kapustin

Associate Professor, Candidate of Technical Sciences, Head of the Laboratory of Television Automation (Faculty of Technical Sciences). Tomsk State University of Control System and Radioelectronics (TUSUR, 634050, Tomsk, Lenin Ave., 40), e-mail: peregnun@mail.ru, ORCID ID: 0000-0002-2293-0511

Marina E. Sukotnova

Master, engineer of the laboratory of television and automation, Tomsk State University of Control Systems and Radioelectronics (TUSUR, 634050, Tomsk, Lenin Ave., 40), e-mail: msukotnova@mail.ru, ORCID ID: 0009-0002-7703-3081.