Система определения туманных дорожных сцен, основанная на ансамбле классификаторов

П.А. Курников[1], Д.Л. Шоломов[2], А.В. Панченко[3]

[1] Национальный исследовательский технологический университет "МИСиС", г. Москва, Россия
[2] Федеральное государственное учреждение "Федеральный исследовательский центр "Информатика и управление" Российской академии наук", г. Москва, Россия
[3] Московский физико-технический институт (государственный университет), г. Москва, Россия

Аннотация. В системах ADAS (advanced driving assistance system) чрезвычайно важно уметь выявлять погодные условия, при которых видимость водителя ограничена. В настоящей работе рассмотрена система реального времени по определению дорожных сцен, содержащих туман, в видеопотоке с монокулярной камеры. Система использует ансамбль (комитет) из нескольких базовых классификаторов. Под базовым классификатором подразумевается алгоритм, основанный на компьютерном зрении и позволяющий разделять дорожные сцены на несколько классов погодных условий, таких как дождь, снег, туман. Каждый из базовых классификаторов системы оперирует уникальным признаковым пространством, что делает систему существенно более устойчивой. Система является частью ADAS комплекса и используется для рекомендации выбора скоростного режима в условиях ограниченной видимости. В работе представлены результаты проведенных экспериментов.

Ключевые слова: детектор тумана, распознавание погодных условий, ADAS системы, деревья решений, метод комитетов, гистограмма яркости, оператор Лапласа, дискретное преобразование Фурье, JPEG компрессия.

DOI 10.14357/20718632180206

Введение

Детектирование дорожных сцен, содержащих туман, является одной из приоритетных задач в разработке ADAS комплексов [1]. Предлагаемая в работе система позволяет существенно обезопасить водителя от аварий. Распознавание тумана – задача нетривиальная, поскольку степень тумана и его характер могут сильно варьироваться, дорожные сцены для магистралей и городской среды сильно отличаются по составу и расположению дорожных объектов, кроме того, на характеристики изображения сцены существенно влияет освещенность. В ходе исследования данной проблемы было изучено несколько работ по схожей тематике. В работе [2] применен комбинированный *state of the art* подход на основе работ [3, 4], базирующихся, в свою очередь, на определении расстояний до тумана. В работе производится сегментация дорожного полотна и области неба на компоненты. В системах подобного рода предъявляются повышенные требования к каждой из ее низкоуровневых частей, таких как определение точки схода, сегментация дорожной сцены, оценка дальности видимости и т.д. Падение точности на нижних уровнях мультипликативно отражается на верхних уровнях и, как следствие, влияет на финальное качество системы, то есть система будет устойчива и

универсальна только в случае высокой точности каждой из ее составных частей. Но следует отметить, что в реальных системах этого условия добиться практически невозможно. Например, на сценах без дорожной разметки, с плохим дорожным полотном и при ограниченной видимости сложно применить метод Хафа для поиска линий, необходимых для определения точки схода. Существует целый ряд других факторов, не позволяющих добиться высоких результатов в каждом из модулей. В работе [5] используется подход на основе вычисления признаков с помощью показателя *power spectrum*, определяемого как квадрат магнитуды преобразования Фурье от производных изображения. Этот подход был частично применен в одном из классификаторов в данной работе. Стоит заметить, что использование лишь этого классификатора как самостоятельного решения по детектированию тумана не представляется возможным из-за невысокой точности классификации и неустойчивости к вариативности дорожных сцен (крутые повороты, наличие близких автомобилей, сцены в ракурсе, тоннели и прочие факторы). Существует ряд работ, основанных на применении специального стереоскопического оборудования [6, 7].

В данной работе было предложено, опираясь на предыдущие результаты, реализовать систему детектирования туманов по принципу метода комитетов простых (слабых) классификаторов [8, 9], где простыми классификаторами являются независимые модули, работающие в принципиально различных признаковых пространствах. В данном случае, финальное качество системы возрастает при добавлении в нее нового независимого классификатора, точность которого составляет $\frac{1}{2}+\varepsilon$ на бинарном отклике. Другими словами, классификаторы дополняют друг друга, тем самым взаимно нивелируя слабые стороны. При этом добавление нового классификатора представляется несложной процедурой машинного обучения.

1. Архитектура системы

На Рис. 1 представлена архитектура системы детектирования туманных сцен, основанной на методе комитетов. Рассмотрим процесс работы системы подробнее.

На первом шаге на вход каждому из множества классификаторов последовательно подаются изображения из видеопотока. Для каждого

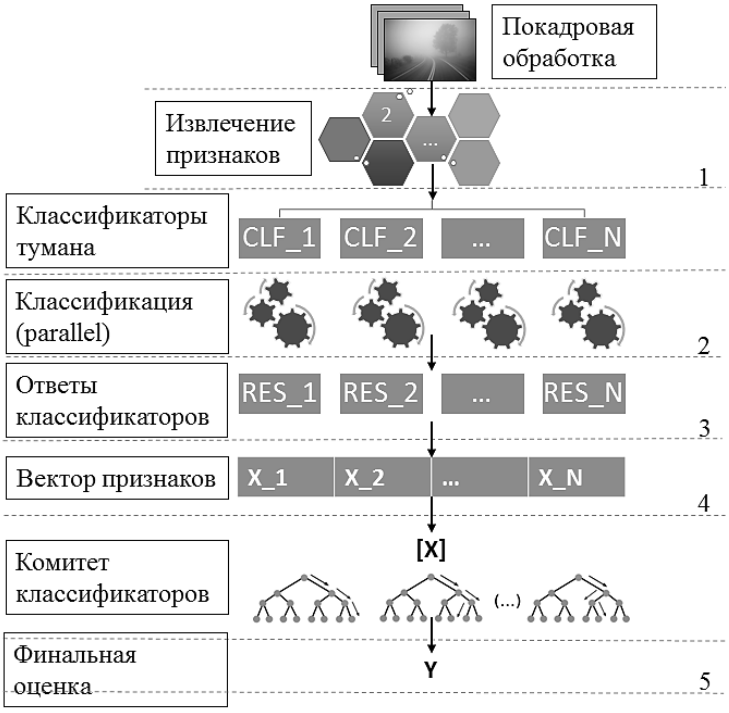

Рис. 1. Архитектура детектора туманных сцен

классификатора на изображении извлекаются определенные признаки. Далее, параллельно, каждый из классификаторов дает вероятностную оценку принадлежности исходной сцены к классу тумана. На третьем шаге из полученных оценок формируется вектор-элемент нового признакового пространства финального (сильного) классификатора. На завершающем этапе этот вектор оценок подается на вход обученному классификатору Random Forest [10, 11], который выдает уже финальную оценку. Помимо этого, для сравнения в работе был исследован подход, в котором на последнем шаге вместо комитета классификаторов, основанного на деревьях решений, использовалась схема их взвешенного голосования.

В систему вошли следующие базовые (слабые) классификаторы.

1. *HRF-классификатор (Histogram Random Forest),* использующий гистограмму яркостей изображения в качестве признакового пространства для классификатора на основе деревьев решений.

2. *JPG-классификатор (Jpeg compression),* использующий степень сжатия областей изображения с последующей классификацией методом *k ближайших соседей*.

3. *LPL-классификатор (Laplas transform)*, базирующийся на преобразовании Лапласа.

4. *DFT-классификатор (Discrete Fourier Transform),* в основе которого лежит преобразование Фурье.

Рассмотрим подробнее метод комитетов, а также каждый из классификаторов в отдельности.

2. Принцип комитетов

Метод комитетов представляет собой алгоритмическую композицию моделей, позволяющую добиваться более высокой точности всей системы в целом. Принцип метода комитетов основан на использовании «слабых классификаторов» [8, 9]. Формализованная постановка выглядит следующим образом.

Рассмотрим задачу классификации на K классов:

$$Y = \{1, 2, ..., K\} \qquad (1)$$

Пусть имеется M классификаторов

$$f_m : X \to Y,\ m = 1, 2, ..., M, \qquad (2)$$

где f_m – слабый классификатор, точность которого составляет $\frac{1}{2} + \varepsilon$.

Требуется построить сильный классификатор $f(x)$ на основе слабых классификаторов $f_1(x), ..., f_M(x)$ с лучшими характеристиками по точности и полноте.

Набор обученных классификаторов можно объединить в алгоритмическую композицию по определенным правилам, например:

- простым голосованием:

$$f(x) = \arg\max_{k=1,...,K} \sum_{m=1}^{M} I(f_m(x) = k), \qquad (3)$$

- взвешенной комбинацией классификаторов:

$$f(x) = \arg\max_{k=1,...,K} \sum_{m=1}^{M} a_m \cdot I(f_m(x) = k), \qquad (4)$$

$$a_m \geq 0,\ \sum_{m=1}^{M} a_m = 1.$$

В основу ансамбля классификаторов могут быть положены и деревья решений. В данной статье в качестве композиции классификаторов использовались два подхода – алгоритм машинного обучения на основе модели Random Forest [10, 12] и взвешенная комбинация базовых классификаторов (4). Комитет классификаторов строился над четырьмя типами слабых классификаторов (раздел 4). В результате были получены следующие схемы.

1. Схема *RF-HJLD (Random Forest* над *HRF JPG LPL DFT)* – основана на модели машинного обучения Random Forest. Ответы слабых классификаторов образуют признаковое пространство, на этих данных обучается модель верхнего уровня.

2. Схема *WV-HJLD (Weighted voting* над *HRF JPG LPL DFT)* – взвешенная комбинация базовых классификаторов. Веса классификаторов в свою очередь оптимизируются с помощью метода градиентного спуска над признаковым пространством ответов слабых классификаторов.

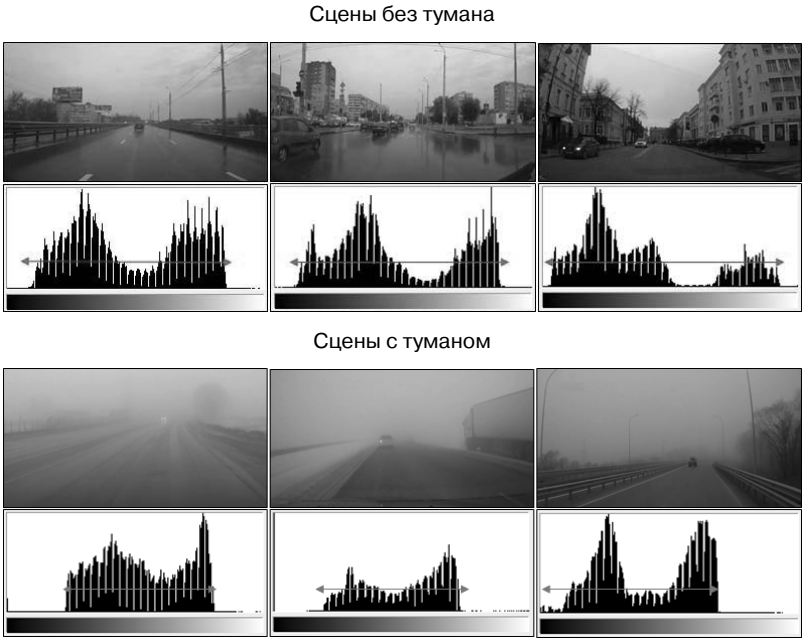

Рис. 2. Сравнительная таблица диапазона гистограмм яркости изображения в сценах с туманом и без тумана

3. Обзор базовых классификаторов

3.1. Классификатор HRF

При анализе характеристик интенсивности изображений с туманом, было замечено, что цветовой охват изображения на туманных сценах имеет более узкий диапазон в сравнении с изображениями без тумана. Например, на Рис. 2 для сцен без тумана ширина диапазона яркости составляет не менее 77%, в то время как на сценах с туманов ширина диапазона составляет не более 62%.

Было предложено использовать гистограмму яркостей серого изображения как признак. По стенду, содержащему размеченные исходные классы изображений, формируется соответствующее признаковое пространство. В качестве классификатора использован алгоритм машинного обучения Random Forest, основанный на деревьях решений. В работе была намеренно использована загрубленная шкала яркости, состоящая из 32 значений, чтобы минимизировать вероятность переобучения.

3.2. Классификатор LPL

Классификатор базируется на преобразовании Лапласа и использует следующие признаки.

Среднее квадратичное отклонение яркости в окрестности S точки i:

$$stdev_S(i) = \sqrt{\frac{\sum_{j \in S} (src(j) - mean(i))^2}{N}} \qquad (5)$$

и число пикселей изображения I, в которых результат применения оператора Лапласа к серому изображению превосходит некоторое пороговое значение T:

$$sum_{lapl}(I) = \sum_{i \in I} lapl(i) > T\,. \qquad (6)$$

Пара данных признаков вычисляется для разных областей изображения. Выделение областей интересов производится с использованием калибровки камеры и процедуры ректификации [13]. При классификации изображения вектор пар признаков сравнивается с вектором пороговых значений, полученным при обучении дерева решений.

3.3. Классификатор JPG

В данном классификаторе используются свойства сжатия нескольких областей JPEG изображений. Результаты сжатия областей

изображения накапливаются в результирующий вектор. Сжатие проводится по полному изображению и по зонам интереса (*ROI*), определяемым с помощью калибровки камеры [14]. Вектор степеней сжатия областей при этом сравнивается с вектором пороговых значений, полученным в процессе обучения данной модели на обучающей выборке. Классификация проводится методом *k ближайших соседей*.

3.4. Классификатор DFT

На первом этапе происходит вычисление магнитуды изображения от преобразования Фурье. Данный подход частично можно встретить в работе [5]. Для фильтрации шумов признаки выделяются на более контрастном изображении, при этом результат преобразования Фурье возводится в некоторую степень (в работе использован степенной показатель 4). Далее рассчитывается центральный момент второго порядка. Имея данный показатель, с помощью метода *k ближайших соседей* вычисляется оценка принадлежности изображения к классу тумана.

4. Результаты

Для тестирования и замера точности системы определения тумана и характеристик каждой из ее компонент были сформированы обучающий и тестовый стенды, содержащие изображения дорожных сцен, снятых на видеорегистратор (Табл. 1). Задача заключалась в классификации изображения по двум основным классам (*fog – no_fog*). Разделение стендов на классы проводилось вручную и базировалось на 50% потере контраста на дорожном полотне при оценке расстояния до тумана. Сцены с видимостью менее 100 метров размечались как класс *явный туман (fog)*. Сцены с видимостью более 300 метров размечались как *не туман (no_fog)*. В работе не ставилось целью детектирование спорных сцен, видимость на которых лежит в диапазоне от 100 до 300 метров. Однако введение 3-его класса в систему не представляется сложной процедурой.

Выборки максимально декоррелированы, поскольку разбивались по различным географическим локациям и погодным условиям. Ниже представлены результаты базовых классификаторов, а также результаты двух комитетных моделей. Модели тестировались на одном наборе данных (Табл. 2).

Как видно из результатов, ни один из базовых классификаторов не обладает высокой точностью, которая не превосходит *90%*.

Результаты тестирования комитетов представлены в сравнительной Табл. 3.

По таблице виден существенный прирост точности при использовании обоих комитетов. Несмотря на то, что точность классификации на тестовых данных оказалась меньше, средний прирост в точности составил порядка 6% по сравнению с любой одиночной моделью.

Табл. 1. Объем обучающей и тестовой выборок

Train dataset		**Test dataset**	
fog	**no_fog**	**fog**	**no_fog**
10500	10100	7800	8150

Табл. 2. Результаты базовых классификаторов на тестовой выборке

Классификатор	**fog (TPR)**	**no_fog (TNR)**	**total (ACC)**
HRF	90,85	87,55	89,87
JPG	93,08	84,47	89,58
LPL	89,78	87,82	86,48
DFT	92,51	83,31	88,77

Рис. 3. Сравнительная гистограмма результатов комитетных моделей

	Классификатор	**Training** *(20600 samples)*	**Test** *(15950 samples)*
TPR	**WV-HJLD**	99,47	96,27
TNR		93,51	94,52
TPR	**RF-HJLD**	99,94	96,88
TNR		96,73	94,84

Данный показатель выглядит позитивно. Стоит заметить, что комитет *RF-HJLD* с применением ансамбля решающих деревьев Random Forest показал себя несколько лучше, чем комитет *WV-HJLD* с обычным взвешенным голосованием (Рис. 3).

Также следует отметить, что оба подхода хорошо распараллеливаются, это позволяет добиться высоких показателей по скорости работы детектора. Примеры работы детектора представлены ниже в Табл. 4 и Табл. 5.

Как видно из результатов классификации, сцены с хорошей контрастностью и отсутствием туманов выдают более низкий показатель *Fog probability*. Причем сцены содержат различные погодные условия и освещенность. На сценах с туманом ряд слабых классификаторов содержит ошибки в классификации (*Fog_probability* < 0.5), однако результирующие комитеты на основе корректных результатов остальных классификаторов выдают правильный ответ, что делает данный подход устойчивым средством для определения дорожных сцен с туманом.

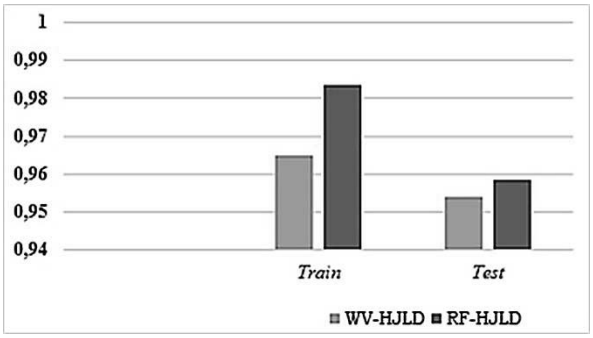

Рис. 3. Сравнительная гистограмма результатов комитетных моделей

Заключение

В работе продемонстрированы преимущества метода комитетов для определения туманных дорожных сцен над подходами, работаю-

Табл. 4. Результаты работы слабых классификаторов и комитетов на сценах с туманом

True class	***FOG***				
Images					
	Fog probability				
HRF	0,41	0,11	0,36	0,99	0,99
JPG	0,93	0,99	0,99	0,99	0,99
LPL	0,51	0,64	0,99	0.05	0,70
DFT	0,99	0,95	0,99	0,99	0,97
WV-HJLD	**0,69**	**0,60**	**0,74**	**0,90**	**0,96**
RF-HJLD	**0,85**	**0,92**	**0,80**	**0,99**	**0,99**

Табл. 5. Результаты работы слабых классификаторов и комитетов на сценах без тумана

True class	***NO FOG***				
Images					
	Fog probability				
HRF	0,36	0,12	0,48	0,15	0,39
JPG	0,04	0,01	0,27	0,02	0,34
LPL	0,01	0,01	0,01	0,01	0,01
DFT	0,05	0,11	0,13	0,01	0,10
WV-HJLD	**0,17**	**0,06**	**0,33**	**0,07**	**0,30**
RF-HJLD	**0,01**	**0,01**	**0,01**	**0,01**	**0,01**

щими с одним признаковым пространством. Результаты оценки на основе *35000* изображений продемонстрировали высокий потенциал предложенного метода. При использовании данного подхода суммарная точность на тестовой выборке составила *96,5%*. К сожалению, данные результаты были получены на относительно хорошо разделяемых классах, на которых практически отсутствовали неявные сцены с диапазоном видимости от *100* до *300* метров, поэтому в дальнейшем для такого рода сцен планируется ввести дополнительный класс *слабый туман (low fog)*. На следующем этапе исследований для достижения большей устойчивости детектора будет использован механизм межкадрового сглаживания. Кроме того, отдельное внимание планируется уделить задаче детектирования ночных сцен, дообучив на них существующие комитеты.

Литература

1. Prun V.E., Postnikov V.V., Sadekov R.N., Sholomov D.L. “Development of Active Safety Software of Road Freight Transport, Aimed at Improving Inter-City Road Safety, Based on Stereo Vision Technologies and Road Scene Analysis” // Proceedings of the Scientific-Practical Conference "Research and Development - 2016", Springer, Cham, pp.209-218. – 2017. ISBN 978-3-319-62869-1
2. Bronte, S.; Bergasa, L.M.; Alcantarilla, P.F. “Fog Detection System Based on Computer Vision Techniques”
3. Nicolas Hautière, Jean-Philippe Tarel, Jean Lavenant, and Didier Aubert. “Automatic fog detection and estimation of visibility distance through use of an onboard camera” // Machine Vision Appl., 17(1):8–20, 2006.
4. Middleton W.E.K. “Vision through the Atmosphere” // University of Toronto Press, 1952.
5. Pavlić Mario, et al. "Image based fog detection in vehicles" // Intelligent Vehicles Symposium (IV), 2012 IEEE. IEEE, 2012.
6. Hautière N., Labayrade R., and Aubert D. “Estimation of the visibility distance by stereovision: A generic approach” // IEICE Transactions on information and systems, 89(7):2084–2091, 2006.
7. Caraffa, L. and Tarel, J.-P., “Stereo reconstruction and contrast restoration in daytime fog.” // Proceedings of Asian Conference on Computer Vision (ACCV’12), Part. IV, LNCS, Vol. 7727, Springer, Daejeon, Korea, pp. 13–25., 2013.
8. Мазуров В. Д. “Метод комитетов в задачах оптимизации и классификации” // М.: Наука, 1990. — 248 с.
9. Мазуров В. Д., Хачай М. Ю. “Комитетные конструкции” // Известия Уральского государственного университета. 1999. № 14., 1999.
10. Breiman, L. "Random Forests Machine Learning” vol.45 pp.5–32, 2001.
11. Breiman, L. “Out-of-bag estimation” // Technical report, Dept. of Statistics, University of California, Berkeley, 1996.
12. Курников П.А. “Обучение деревьев решений для валидации ответов нейронной сети” // Сб. трудов Седьмой Международной конференции «Системный анализ и информационные технологии» (САИТ 2017), стр. 256-261, Светлогорск, Россия, 2017
13. Prun V., Polevoy D., Postnikov V., "Forward rectification: spatial image normalization for a video from a forward facing vehicle camera," //Proc. SPIE 10341, Ninth International Conference on Machine Vision (ICMV 2016)
14. Prun V., Bocharov D., Koptelov I., Sholomov D., Postnikov V. “Geometric filtration of classification-based object detectors in realtime road scene recognition systems” // Eighth International Conference on Machine Vision (ICMV 2015), Vol. 9875. 98750O, 2015, doi: 10.1117/12.2228709

Курников Павел Александрович. Национальный исследовательский технологический университет ”МИСиС”, г. Москва, Россия. Аспирант. Количество печатных работ: 2. Область научных интересов: машинное обучение, методы анализа данных, компьютерное зрение. E-mail: two-names@yandex.ru

Шоломов Дмитрий Львович. Институт системного анализа Федерального государственного учреждения "Федеральный исследовательский центр "Информатика и управление" Российской академии наук" г. Москва, Россия. Старший научный сотрудник, кандидат технических наук. Количество печатных работ: более 20. Область научных интересов: цифровая обработка изображений, компьютерное зрение, искусственный интеллект. E-mail: sholomov@list.ru

Панченко Алексей Владимирович. Московский физико-технический институт (государственный университет), г. Москва, Россия. Преподаватель. Количество печатных работ: 15. Область научных интересов: робототехника, шагающие роботы, системы управления, механика. E-mail: panchenkoav@vap.ru

The system for foggy road scenes detection based on the ensemble of classifiers

P.A. Kurnikov[1], D.L. Sholomov[2], A.V. Panchenko[3]

[1] National university of science and technology ”MISiS”, Moscow, Russia
[2] Federal Research Center “Computer Science and Control” of Russian Academy of Sciences, Moscow, Russia
[3] Moscow Institute of Physics and Technology, Moscow, Russia

In ADAS (advanced driving assistance system) it is extremely important to be able to identify various weather conditions, especially conditions with low visibility. In this paper, we consider a real-time system for foggy road scenes detection in a video stream from a monocular camera. The system uses an ensemble (committee) of several basic classifiers. A basic classifier is an algorithm based on computer vision which allows you to divide road scenes into several classes of weather conditions, such as rain, snow, fog. Each of the basic classifiers of the system operates with a unique feature space, which makes the system essentially more rigid. The system is a part of the ADAS complex and is used to recommend the speed regime in conditions of reduced visibility. The article presents the results of the experiments.
Keywords: fog detection, weather conditions recognition, ADAS systems, random forest, committee method, intensity histogram, Laplace operator, discrete Fourier transform, JPEG compression.

DOI 10.14357/20718632180206

Reference

1. Prun V.E., Postnikov V.V., Sadekov R.N., Sholomov D.L. “Development of Active Safety Software of Road Freight Transport, Aimed at Improving Inter-City Road Safety, Based on Stereo Vision Technologies and Road Scene Analysis” // Proceedings of the Scientific-Practical Conference "Research and Development - 2016", Springer, Cham, pp.209-218. – 2017. ISBN 978-3-319-62869-1
2. Bronte, S.; Bergasa, L.M.; Alcantarilla, P.F. “Fog Detection System Based on Computer Vision Techniques”
3. Nicolas Hautière, Jean-Philippe Tarel, Jean Lavenant, and Didier Aubert. “Automatic fog detection and estimation of visibility distance through use of an onboard camera” // Machine Vision Appl., 17(1):8–20, 2006.
4. Middleton W.E.K. “Vision through the Atmosphere” // University of Toronto Press, 1952.
5. Pavlić Mario, et al. "Image based fog detection in vehicles" // Intelligent Vehicles Symposium (IV), 2012 IEEE. IEEE, 2012.
6. Hautière N., Labayrade R., and Aubert D. “Estimation of the visibility distance by stereovision: A generic approach” // IEICE Transactions on information and systems, 89(7):2084–2091, 2006.
7. Caraffa, L. and Tarel, J.-P., “Stereo reconstruction and contrast restoration in daytime fog.” // Proceedings of Asian Conference on Computer Vision (ACCV’12), Part. IV, LNCS, Vol. 7727, Springer, Daejeon, Korea, pp. 13–25., 2013.
8. Mazurov V. D. “ Committee method in the problems of optimization and classification” // M.: Nauka, 1990. — 248 p.
9. Mazurov V. D., Khachai M. Yu. “ Committee constructions” // Izvestiya of Ural State University. 1999. № 14., 1999.
10. Breiman, L. "Random Forests Machine Learning” vol.45 pp.5–32, 2001.
11. Breiman, L. “Out-of-bag estimation” // Technical report, Dept. of Statistics, University of California, Berkeley, 1996.
12. Kurnikov P.A. “Training the decision trees for neural network response validation” // Proceedings of the Seventh International conference «System analysis and information technologies » (SAIT 2017), pp. 256-261, Svetlogorsk, Russia, 2017
13. Prun V., Polevoy D., Postnikov V., "Forward rectification: spatial image normalization for a video from a forward facing vehicle camera," //Proc. SPIE 10341, Ninth International Conference on Machine Vision (ICMV 2016)
14. Prun V., Bocharov D., Koptelov I., Sholomov D., Postnikov V. “Geometric filtration of classification-based object detectors in realtime road scene recognition systems” // Eighth International Conference on Machine Vision (ICMV 2015), Vol. 9875. 98750O, 2015, doi: 10.1117/12.2228709

Kurnikov Pavel Aleksandrovich. National university of science and technology ”MISiS”, Moscow, Russia. Postgraduate student. Number of the printed works: 2. Range of scientific interests: machine learning, data science, computer vision. E-mail: two-names@yandex.ru

Sholomov Dmitry Lvovich. Federal Research Center “Computer Science and Control” of Russian Academy of Sciences, 119333, 44/2 Vavilova str., Moscow, Russia. Senior researcher, Ph.D. Number of the printed works: more than 20. Range of scientific interests: image processing, computer vision, artificial intelligence. E-mail: sholomov@list.ru

Panchenko Aleksei Vladimirovich. Moscow Institute of Physics and Technology, Moscow, Russia. Lecturer. Number of the printed works: 15. Range of scientific interests: robotics, walking robots, control systems, mechanics. E-mail: panchenkoav@vap.ru