

Научная статья  
УДК 629.33-52

## Метод автоматизации обработки результатов испытаний эффективности действия систем ADAS (DCAS)

Ренат Флюорович Алтдинов<sup>1</sup>, Сергей Робертович Кристальный<sup>2</sup>

<sup>1,2</sup> Московский автомобильно-дорожный государственный технический университет (МАДИ), Москва, Россия

<sup>1</sup> renat.altdinoff@yandex.ru

<sup>2</sup> sportauto@rambler.ru

**Аннотация.** Предлагается инновационный метод автоматизированной обработки результатов испытаний эффективности действия интеллектуальных систем помощи водителю (Advanced Driver-Assistance System – ADAS, Driver Control Assistance Systems – DCAS). Разработаны два подхода к определению момента срабатывания целевого визуального сигнала: подход на основе анализа изменения яркости в заданных областях кадра и метод с использованием сверточных нейронных сетей. Приведены примеры технической реализации указанных подходов. Выполнено сравнение подходов по точности, скорости обработки и устойчивости к воздействию внешних условий. Продемонстрирована работоспособность предложенного метода на примере обработки результатов испытаний эффективности действия системы предупреждения о столкновении спереди. Установлено, что подход с использованием нейронных сетей обеспечивает большую точность детекции целевого изображения, чем подход на основе анализа изменения яркости в заданных областях кадра.

**Ключевые слова:** опережающая система экстренного торможения (ОСЭТ), классификация изображения, обработка видеоданных, сверточные нейронные сети, испытательный заезд, синхронизация параметрических записей

**Для цитирования:** Алтдинов Р. Ф., Кристальный С. Р. Метод автоматизации обработки результатов испытаний эффективности действия систем ADAS (DCAS) // Автомобиль. Дорога. Инфраструктура. 2026. № 2 (48).

Original article

## The method for automating the processing of test results for the effectiveness of ADAS (DCAS) systems

Renat F. Altdinov<sup>1</sup>, Sergey R. Kristalny<sup>2</sup>

<sup>1,2</sup> Moscow Automobile and Road Construction State Technical University (MADI), Moscow, Russia

<sup>1</sup> renat.altdinoff@yandex.ru

<sup>2</sup> sportauto@rambler.ru

---

© Алтдинов Р. Ф., Кристальный С. Р., 2026

**Abstract.** An innovative method of automated processing of test results of the effectiveness of intelligent driver assistance systems (Advanced Driver-Assistance System – ADAS, Driver Control Assistance Systems – DCAS) is proposed. Two approaches have been developed to determine the moment when the target visual signal is triggered: an approach based on the analysis of brightness changes in specified areas of the frame and a method using convolutional neural networks. Examples of the technical implementation of these approaches are given. A comparison of approaches in terms of accuracy, processing speed, and resistance to environmental conditions has been performed. The efficiency of the proposed method is demonstrated by the example of processing the test results of the effectiveness of the front collision warning system. It has been found that the neural network approach provides greater accuracy in detecting the target image than the approach based on the analysis of brightness changes in specified areas of the frame.

**Keywords:** advanced emergency braking system (OSET), image classification, video data processing, convolutional neural networks, test run, synchronization of parametric recordings

**For citation:** Altdinov R.F., Kristalny S.R. The method for automating the processing of test results for the effectiveness of ADAS (DCAS) systems. *Avtomobil'. Doroga. Infrastruktura*. 2026. № 2 (48).

### Введение

Все большее количество производителей автомобилей предлагают в качестве опции на своих моделях системы помощи водителю: системы удержания в полосе движения, системы автоматического экстренного торможения (ОСЭТ), которые в литературе [1] также обозначается как САЭТ – системы адаптивного круиз-контроля и другие [1].

Несмотря на развитие методов виртуальных испытаний, независимые дорожные (полигонные) испытания остаются одним из основных инструментов оценки эффективности действия таких систем. В ходе испытаний регистрируются параметрические данные и производится видеосъемка салона автомобиля и внешней обстановки для последующего определения точного времени наступления интересующих событий.

Традиционная обработка результатов выполняется вручную. Оператор покадрово просматривает видеозапись и фиксирует временные метки событий, после чего вычисляет искомые моменты с учетом известной задержки между регистрацией сигнала синхронизации и целевым событием.

Более подробно метод описан в [1]. Этот процесс трудоёмок и подвержен субъективным ошибкам. Пример приборной панели с интересующими областями, выделенными красной рамкой, представлен на рисунке 1. Примеры целевых визуальных сигналов в укрупненном формате представлены на рисунке 2.



Рис. 1. Приборная панель в ходе испытательного заезда




Рис. 2. Визуальные сигналы целевых событий:

- а) визуальный сигнал синхронизации в момент срабатывания;
- б) визуальный сигнал синхронизации в момент отсутствия целевого сигнала;
- в) визуальный сигнал о возможном столкновении в момент срабатывания;
- г) визуальный сигнал о столкновении в момент отсутствия целевого сигнала

**Цель** данного исследования – разработать метод автоматизированного подхода к анализу результатов испытательных заездов, позволяющий сократить время постобработки и снизить влияние человеческого фактора.

В рамках реализации метода автоматизированного анализа результатов испытаний были разработаны два подхода.

### Подход на основе анализа изменения яркости

Метод основан на анализе изменения средней яркости в заданных областях интереса (ROI – Region of Interest) на видеокадрах. При включении или выключении лампы происходит резкий скачок яркости между соседними кадрами, превышающий заданный порог. Этот скачок фиксируется как момент события.

Алгоритм детекции по изменению яркости (рисунке 3) позволяет пользователю интерактивно выбрать ROI для сигналов синхронизации и предупреждения, после чего покадрово вычисляет среднюю яркость, фиксирует скачок и определяет моменты включения / выключения.

```
% Покадровое вычисление средней яркости
for i = 1:totalFrames
    frame = read(video, i);

    % Вычисление средней яркости в выбранных ROI
    brightness1(i) = mean(rgb2gray(ircrop(frame, lamp1_rect))(:)) / 255;
    brightness2(i) = mean(rgb2gray(ircrop(frame, lamp2_rect))(:)) / 255;

    % Поиск скачка яркости (начиная со 2-го кадра)
    if i > 1
        % Детекция выключения (падение яркости)
        drop = brightness1(i-1) - brightness1(i);
        if drop > brightnessThreshold1 && isnan(timeOff)
            timeOff = (i - 1) / fps;
        end

        % Детекция включения (рост яркости)
        jump = brightness2(i) - brightness2(i-1);
        if jump > brightnessThreshold2 && isnan(timeOn)
            timeOn = (i - 1) / fps;
        end
    end
end
```

Рис. 3. Алгоритм детекции по изменению яркости

Графики яркости и скачков для обоих сигналов приведены на рисунке 4.

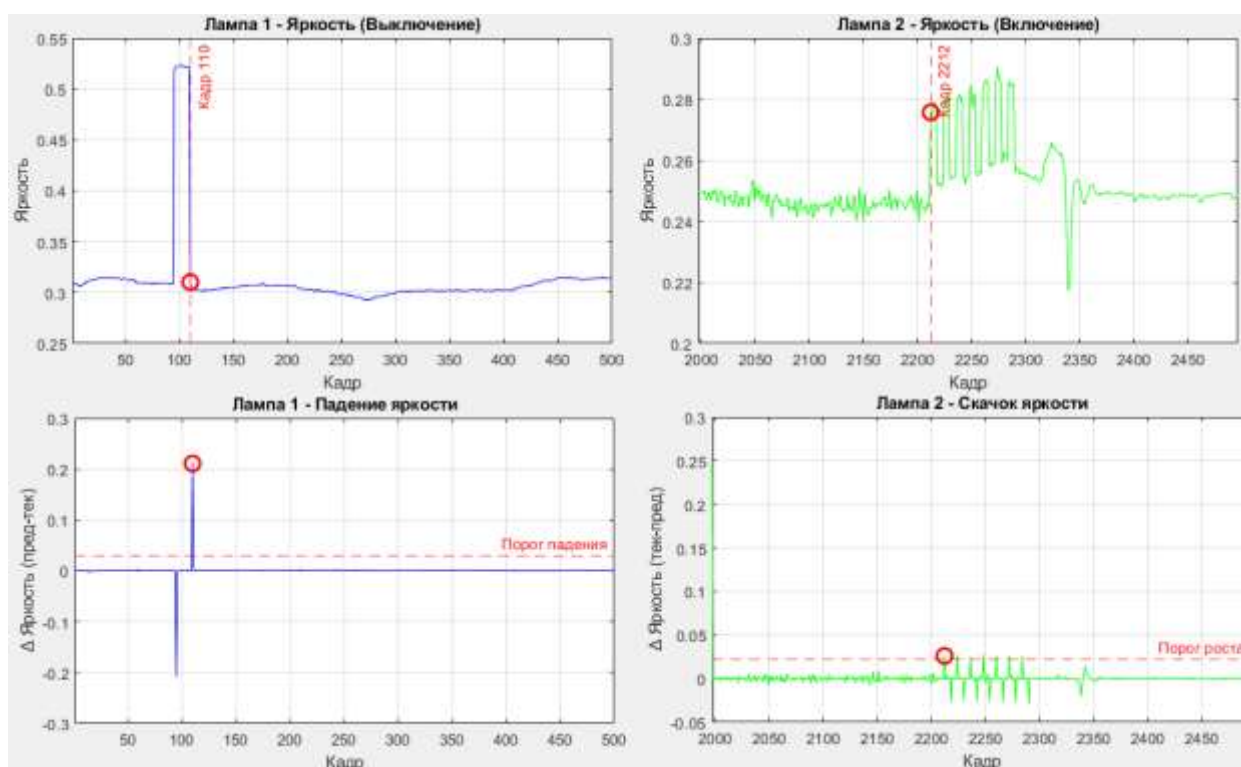


Рис. 4. Графики яркости и скачков для двух визуальных сигналов

### Подход на основе анализа данных сверточных сетей

Сверточные нейронные сети (CNN – convolutional neural network) обучаются и самостоятельно выделяют признаки соответствующего визуального сигнала.

Первый этап – подготовка данных и обучение нейронной сети для решения задачи классификации. Обучающая выборка сформирована из кадров видеозаписи с ручной разметкой классов «on»/«off». Архитектура CNN (таблица 1) выбрана из компромисса между точностью и вычислительной сложностью: три свёрточных блока с фильтрами 8→16→32 (размер кадра 224×224). Пакетная нормализация и Dropout-регуляризация обеспечили сходимость обучения на ограниченной выборке.

Использован оптимизатор SGDM (начальная скорость 0,001, 15 эпох, объем выборки на итерацию оптимизации – 32). На графике процесса обучения (рисунок 5) видна точность (accuracy), стремящаяся к 100%.

Архитектура CNN

Тип слоя	Параметры	Назначение
Входной слой	224×224×3	принимает RGB-изображение
Свёрточный слой	3×3, 8 фильтров	выделение простых признаков
Batch Normalization	—	ускорение обучения
ReLU	—	нелинейность
Max Pooling	2×2, stride=2	уменьшение размерности
Свёрточный слой	3×3, 16 фильтров	выделение сложных признаков
Batch Normalization	—	ускорение обучения
ReLU	—	нелинейность
Max Pooling	2×2, stride=2	уменьшение размерности
Свёрточный слой	3×3, 32 фильтра	выделение высокоуровневых признаков
Batch Normalization	—	ускорение обучения
ReLU	—	нелинейность
Полносвязный слой	64 нейрона	классификация
Dropout	0.5	борьба с переобучением
Выходной слой	2 нейрона (softmax)	вероятности классов




Рис. 5. График процесса обучения (accuracy – точность; loss – потери; iteration - повторения)

Следующий этап – обработка видео с применением свёрточных нейронных сетей. Алгоритм детекции загружает обученные модели, обрабатывает видео покадрово и фиксирует моменты рассматриваемых визуальных сигналов. Алгоритм представлен на рисунке 6.

```
while hasFrame(vid)
    frameCount = frameCount + 1;
    frame = readFrame(vid);
    % Обработка лампы 1 (синхронизация)
    if frameCount >= frames1_start && frameCount <= frames1_end
        label1 = classifyFrame(frame, net1, roi1, inputSize);
        % Фиксация времени включения
        if strcmp(finalLabel1, 'on')
            timestamp = (frameCount - 1) / fps;

            if isempty(lamp1_firstTime)
                lamp1_firstTime = timestamp; % Первое срабатывание
            end
            lamp1_lastTime = timestamp;      % Последнее срабатывание
        end
    end
    % Обработка лампы 2 (предупреждение) - аналогично
    if frameCount >= frames2_start && frameCount <= frames2_end
        label2 = classifyFrame(frame, net2, roi2, inputSize);
        % ... (логика аналогична лампе 1)

        if strcmp(finalLabel2, 'on') && isempty(lamp2_firstTime)
            lamp2_firstTime = (frameCount - 1) / fps;
        end
    end
end
end
```

Рис. 6. Алгоритм детекции

### Описание полигонных испытаний

Для проверки эффективности действия системы предупреждения о столкновении спереди (входит в состав САЭТ) проведено испытание, подробно описанное в [1]. В рамках настоящего исследования рассматривается обработка результатов испытательного заезда, выполняемого по сценарию «прямое торможение системой без участия водителя» (тип 2б по классификации [1]). Сценарий «прямое торможение системой» соответствует требованиям международного стандарта ISO 22839:2013<sup>1</sup> для подтверждения функций снижения тяжести последствий столкновения. Условия проведения заезда представлены в таблице 2.

<sup>1</sup> ISO 22839:2013. Intelligent transport systems – Forward vehicle collision mitigation systems – Operation, performance, and verification requirements. – Geneva: ISO, 2013. – 52 p.

Таблица 2

Условия испытательного заезда

Параметр	Значение
Сценарий испытания	Прямое торможение системой (тип 2б)
«Цель»	Мягкая стена (картон с отражающим покрытием)
Скорость объекта испытаний, км/ч	40
Дорожное покрытие	Сухой асфальтобетон
Боковое смещение цели Elat, %	0
Действия водителя	Торможение не применяется

В качестве объекта испытаний был использован серийный автомобиль Infiniti QX 60 Hi-tech, оснащенный системой FCW (Forward Collision Warning) – системой предупреждения о столкновении спереди [3]. Более подробное описание объекта испытаний приведено в [1]. Основные технические характеристики объекта испытаний приведены в таблице 3.

Таблица 3

Основные технические характеристики автомобиля Infiniti QX 60 Hi-tech

Параметр	Значение
Колесная формула/ведущие колеса	4×4 / все
Тип кузова	Цельнометаллический, несущий, хэтчбек
Габаритные размеры (длина/ширина/высота), мм	5093 / 1960 / 1742
Снаряженная масса, кг	2082
Двигатель	VQ35DE V6, бензиновый
Максимальная мощность, кВт (мин <sup>-1</sup> )	193 (6400)
Коробка передач	CVT XTRONIC, автоматическая бесступенчатая

Для решения сформулированных выше задач на автомобиль была установлена следующая измерительная и регистрирующая аппаратура: 1) аккумуляторная батарея автомобиля; 2) блок питания и индикации датчика CPFTA; 3) сигнальная лампа внутренней световой индикации; 4) GPS-антенна GARMIN; 5) сигнальная лампа внешней световой индикации; 6) GPS/ГЛОНАСС-антенна JAVAD; 7) компактная мобильная система сбора и обработки данных CS 1016 FAMOS Online; 8) MSW процессор; 9) блок распределения питания Small 12V PowerDistributorBox; 10) датчик ускорений и угловых скоростей TANS; 11) ноутбук с программным обеспечением IMC;

12) динамометрическое измерительное рулевое колесо MSW; 13) датчик усилия нажатия на педаль тормоза CPFTA; 14) бортовая система видеофиксации; 15) выносной датчик угловой скорости колеса WPT; 16) CDS-GPS-процессор.

Питание оборудования осуществлялось от бортовой сети автомобиля через блок распределения питания Small 12V Power Distributor Box фирмы KISTLER (Германия).

Синхронизация параметрической записи и видеоматериалов обеспечивалась системой светодиодных ламп внутренней и внешней индикации.

Подробное описание измерительной и регистрирующей аппаратуры, а также схема установки приведена в [1].

### **Сравнение подходов к реализации автоматизированной обработки испытаний**

Сравнение разработанных подходов (подход на основе оценки яркости и подход на основе анализа данных сверточных сетей) по ключевым критериям приведено в таблице 4.

Таблица 4

Сравнение подходов обработки

Критерий	Подход на основе оценки яркости	Подход на основе анализа данных сверточных сетей
Точность детекции	Зависит от порога	100% на валидации
Устойчивость к изменению освещения	Требует переподбора порога при изменении освещенности >20%	Сохраняет точность >0,95 при изменении освещенности до 30%
Устойчивость к вибрациям камеры	Смещение ROI приводит к ошибкам	Не требует фиксированной ROI
Скорость обработки	≈ 1000 кадров/с	≈ 200 – 500 кадров/с (на CPU)
Необходимость обучения	Нет	Да
Необходимость ручной настройки	Да (ROI, пороги)	Нет (после обучения)
Объективность результатов	Зависит от выбора порога оператором	Не зависит от оператора (после обучения)

Скорость обработки легкой сверточной сети на центральном процессоре (CPU) составляет 200–500 кадров/с, что достаточно для офлайн-обработки результатов испытаний (постобработка). Для работы в реальном времени при частоте видеосъемки 60 кадров/с запас производительности составляет 3-8 раз, что создает потенциальную возможность реализации метода в реальном времени. Однако для окончательного вывода требуется дополнительное исследование.

### Сравнительная оценка эффективности автоматизированных подходов и ручной обработки результатов испытаний

В данном разделе представлены результаты сравнения трех подходов к обработке данных испытательного заезда: традиционный подход на основе ручной обработки, подход на основе автоматизированной обработки, базирующийся на анализе изменения яркости, и подход на основе автоматизированной обработки, базирующийся на применении сверточной нейронной сети (CNN). Сравнение выполнено по двум параметрам: точности определения времени до столкновения (ТТС – Time to Collision [4]) и среднего времени, затраченного на обработку данных заезда.

Расчет времени до столкновения (ТТС) вычисляется по формуле [4]:

$$TTC = \frac{d}{v}, \quad (1)$$

где  $d$  – текущее расстояние (Distance) до препятствия, м;

$v$  – относительная скорость (Relative Velocity) сближения, м/с.

Результаты обработки испытательного заезда тремя способами представлены в таблице 5.

Таблица 5

#### Сравнение эффективности обработки испытательных заездов

Способ обработки	Скорость, км/ч	Расстояние, м	ТТС, с	Время обработки
Ручная	39,65	20,38	1,85	30 – 40 мин.
Подход на основе оценки яркости	39,65	20,38	1,85	7 – 12 мин.
Подход на основе анализа данных сверточных сетей	39,67	20,44	1,86	0,5 – 1,0 мин.

### Выводы

В качестве результатов проведенного исследования можно считать следующее.

1. Разработаны два подхода к реализации метода автоматизированной обработки результатов испытаний: подход, основанный на анализе изменения яркости, и подход, основанный на использовании свёрточных нейронных сетей.

2. Апробацией данных на полигонных испытаниях подтверждена работоспособность подходов. Разработанные подходы и ручная обработка дали близкие значения ТТС (1,85–1,86 с). Подход на основе анализа данных сверточных сетей обеспечивает погрешность не более одного кадра ( $\approx 0,017$  с) при многократном сокращении времени обработки – до 1 мин против 30–40 мин при ручной обработке.

3. Определены рекомендуемые границы применимости разработанных подходов. Подход на основе оценки яркости эффективен только при стабильных условиях съёмки и фиксированном положении камеры. Подход на основе CNN менее чувствителен к условиям съёмки, но требует предварительного обучения на размеченной вручную выборке.

### Список источников

1. Новые методы испытаний систем автоматического экстренного торможения и опыт их применения / А. М. Иванов, С. Р. Кристальный, Н. В. Попов [и др.] // Труды НГТУ им. Р.Е. Алексеева. – 2018. – № 2(121). – С. 146-155. – DOI 10.46960/1816-210X\_2018\_2\_146. – EDN XSELUT.
2. Исследование процесса экстренного торможения с применением системы АБС и без неё / А. Е. Гончарук, Е. С. Красавин, В. Д. Сморгчов, С. С. Шадрин // Автомобиль. Дорога. Инфраструктура. – 2021. – № 4(30). – EDN LSPNOQ.
3. Актуальные вопросы совершенствования технического зрения при использовании на автомобилях / А. Г. Тыняный, С. Р. Кристальный, П. А. Красавин [и др.] // Автомобиль. Дорога. Инфраструктура. – 2026. – № 1(47). – EDN HCEEEXC.
4. Safety effectiveness of forward collision warning systems in the vehicle fleet: A driving simulation study / O. Olufowobi, J. Ivan, K. Wang, N. Eluru // Accident Analysis & Prevention. – 2025. – Vol. 218. – P. 108078. – DOI 10.1016/j.aap.2025.108078. – EDN EEOXZU.

5. Goodfellow, I. Deep Learning / I. Goodfellow, Y. Bengio, A. Courville. – Cambridge, MA: MIT Press, 2016. – 800 p. – ISBN 0262035618.

### References

1. Ivanov A.M., Kristalny S.R., Popov N.V., Toporkov M.A., Isakova M.I. *Trudy NGTU im. R.Ye. Alekseyeva*, 2018, no. 2(121), pp. 146-155, doi 10.46960/1816-210X\_2018\_2\_146.
2. Goncharuk A.Ye., Krasavin Ye.S., Smorchkov V.D., Shadrin S.S. *Avtomobil'. Doroga. Infrastruktura*, 2021, no. 4(30).
3. Tynyany A.G., Kristalny S.R., Krasavin P.A., Toporkov M.A., Andreev A.N. *Avtomobil'. Doroga. Infrastruktura*, 2026, no. 1(47).
4. Olufowobi O., Ivan J., Wang K., Eluru N. Safety effectiveness of forward collision warning systems in the vehicle fleet: A driving simulation study, *Accident Analysis & Prevention*, 2025, vol. 218, p. 108078, doi 10.1016/j.aap.2025.108078.
5. Goodfellow I., Bengio Y., Courville A. *Deep Learning*, Cambridge, MA, MIT Press, 2016, 800 p., ISBN 0262035618.

Рецензент: В.В. Гаевский, д-р техн. наук, доцент, МАДИ

### *Информация об авторах*

**Алтдинов Р. Ф.** – магистрант, МАДИ, Москва;

**Кристалный С. Р.** – канд. техн. наук, доцент, МАДИ, Москва.

### *Information about the authors*

**Altdinov R. F.** – undergraduate, MADI, Moscow;

**Kristalny S. R.** – Candidate of Sciences (Technical), associate professor, MADI, Moscow.

*Статья поступила в редакцию 13.05.2026; одобрена после рецензирования 10.06.2026; принята к публикации 30.06.2026.*

*The article was submitted 13.05.2026; approved after reviewing 10.06.2026; accepted for publication 30.06.2026.*