

УДК 004.891

DOI: [10.26102/2310-6018/2026.58.7.002](https://doi.org/10.26102/2310-6018/2026.58.7.002)

Миварная экспертная система выявления сложных условий наблюдения и выбора способов коррекции изображения для однокамерной системы технического зрения автономного робота-курьера

А.А. Милевич¹, Д.А. Овчинников¹, О.О. Варламов^{1,2}

¹Московский государственный технический университет им. Н.Э. Баумана, Москва, Российская Федерация

²Научно-исследовательский институт вычислительных комплексов им. М.А. Карцева, Москва, Российская Федерация

Резюме. В статье рассматривается задача интеллектуальной поддержки принятия решений в системе технического зрения мобильного автономного робота-курьера, использующего одну видеокамеру и функционирующего при ограниченных бортовых вычислительных ресурсах без обращения к облачным вычислениям. Актуальность работы обусловлена тем, что в реальных условиях эксплуатации качество визуального восприятия сцены ухудшается при недостаточной освещенности, переэкспонировании, наличии осадков, тумана, бликов, шумов матрицы, размытия изображения, частичной окклюзии и загрязнения объектива. Предлагается миварная экспертная система, формализующая предметную область в виде параметров, отношений, правил и ограничений. Пользователь задает 13 входных параметров: десять нормализованных признаков изображения и три контекстных признака – место наблюдения, время суток и время года. На выходе система формирует два семантически интерпретируемых результата: текущее сложное условие и рекомендуемое действие по улучшению изображения. Особенностью модели является атомарная структура отношений: в одном отношении используется не более одного условного оператора, а сложная логика строится как цепочка простых правил. Дополнительно в модель введены шесть служебных контекстных признаков, позволяющих учитывать плотность городской среды, ночную освещенность и сезонные эффекты при выборе ветви вывода. В качестве модуля распознавания объектов используется предобученная система YOLO, а МЭС выступает вычислительно экономичным и объяснимым слоем интерпретации сложных условий наблюдения, что делает предложенный подход пригодным для локального применения на борту автономного робота-курьера. Полученные результаты подтверждают возможность построения объяснимой, модульной и расширяемой экспертной системы для поддержки работы однокамерного автономного робота-курьера в сложных условиях наблюдения.

Ключевые слова: миварная экспертная система, автономный робот-курьер, система технического зрения, однокамерное наблюдение, сложные условия наблюдения, ограниченные вычислительные ресурсы, объяснимый искусственный интеллект, экспертные правила, КЭСМИ.

Для цитирования: Милевич А.А., Овчинников Д.А., Варламов О.О. Миварная экспертная система выявления сложных условий наблюдения и выбора способов коррекции изображения для однокамерной системы технического зрения автономного робота-курьера. *Моделирование, оптимизация и информационные технологии*. 2026;14(7). URL: <https://moitvvt.ru/ru/journal/article?id=2390> DOI: 10.26102/2310-6018/2026.58.7.002

Mivar expert system for identifying challenging observation conditions and selecting image correction methods for a single-camera vision system of an autonomous delivery robot

A.A. Milevich^{1✉}, D.A. Ovchinnikov¹, O.O. Varlamov^{1,2}

¹*Bauman Moscow State Technical University, Moscow, the Russian Federation*

²*Kartsev Research Institute of Computing Complexes, Moscow, the Russian Federation*

Abstract. The paper addresses the problem of intelligent decision support for the vision subsystem of a mobile autonomous delivery robot equipped with a single camera and operating under limited onboard computational resources without relying on cloud computing. The relevance of the study is determined by the degradation of image perception under insufficient illumination, overexposure, precipitation, haze, glare, digital noise, blur, partial occlusion, and lens contamination. A mivar expert system is proposed to formalize the domain knowledge in terms of parameters, relations, rules, and constraints. The user specifies 13 input parameters: ten normalized image features and three contextual attributes – location, time of day, and season. The system produces two semantically interpretable outputs: the current challenging observation condition and the recommended image enhancement action. A key feature of the model is its atomic relation structure: each relation contains no more than one conditional operator, while complex logic is represented as a chain of simple rules. Additional contextual service features are introduced to account for dense urban environment, nighttime city illumination, and seasonal effects when selecting the inference branch. A pretrained YOLO detector is used as the object recognition module, while the MES serves as an explainable and computationally efficient layer for interpreting challenging observation conditions. This combination makes the proposed approach suitable for local onboard deployment in an autonomous delivery robot. The obtained results confirm the feasibility of an explainable, modular, and extensible expert system for supporting a single-camera autonomous delivery robot under adverse observation conditions.

Keywords: mivar expert system, autonomous delivery robot, vision system, single-camera observation, challenging observation conditions, limited computational resources, explainable artificial intelligence, production rules, KESMI.

For citation: Milevich A.A., Ovchinnikov D.A., Varlamov O.O. Mivar expert system for identifying challenging observation conditions and selecting image correction methods for a single-camera vision system of an autonomous delivery robot. *Modeling, Optimization and Information Technology*. 2026;14(7). (In Russ.). URL: <https://moitvivr.ru/ru/journal/article?id=2390> DOI: 10.26102/2310-6018/2026.58.7.002

Введение

Развитие автономных мобильных платформ приводит к росту интереса к системам доставки в городской среде [1, 2]. Для автономного робота-курьера качество восприятия сцены определяет не только надежность распознавания объектов, но и корректность выбора траектории, безопасного маневра и приоритезации элементов окружения [3, 4]. При использовании одной камеры как основного сенсора задача особенно усложняется, поскольку деградация изображения напрямую влияет на качество всех последующих этапов восприятия и принятия решений.

В настоящей работе рассматривается именно автономный робот-курьер, для которого критично выполнение вычислений на борту без обращения к облачным сервисам. Такой режим эксплуатации обусловлен требованиями к устойчивости связи, задержке принятия решений, энергетической эффективности и предсказуемости работы в городской среде. Поэтому архитектура системы сознательно ориентирована на локальную обработку: миварная экспертная система используется как объяснимый и вычислительно экономичный модуль интерпретации сцены, а предобученная модель

YOLO – как готовый детектор объектов, не требующий ресурсоемкого дообучения в контуре эксплуатации [5, 6].

Для открытых городских сценариев наиболее характерны следующие деградации: недостаточная освещенность, переэкспонирование, дождь и капли на объективе, туман и дымка, размытие, цифровой шум, засветка, частичная окклюзия и загрязнение объектива [7, 8]. В литературе широко рассматриваются вопросы ухудшения качества восприятия в автономных и робототехнических системах под действием неблагоприятных погодных факторов и искажений изображения, а также методы их компенсации [9, 10]. Вместе с тем для инженерных систем поддержки принятия решений остается востребованным не только факт обнаружения деградации, но и объяснимое описание того, почему был сделан именно такой вывод и какой путь логического вывода к нему привел [11, 12].

Миварный подход представляет интерес именно в этой постановке, поскольку позволяет сочетать продукционные правила, формальную структуру отношений и интерпретируемую маршрутизацию вывода [13, 14]. Для задач технического зрения автономного робота-курьера такой подход удобен тем, что инженер может явно задать связи между визуальными признаками, контекстом наблюдения и итоговыми рекомендациями по улучшению изображения [15, 16]. Это особенно важно при исследовательской и диссертационной работе, где необходимо не только получить корректный результат, но и показать механизм его получения.

Целью исследования является разработка и экспериментальная проверка миварной экспертной системы, которая по 13 входным параметрам формирует два пользовательских результата: текущее сложное условие и рекомендуемое действие по улучшению изображения [17, 18]. Для достижения цели решаются задачи формализации предметной области, построения атомарных правил, организации ветвящегося выбора маршрута, включения контекстных факторов места наблюдения, времени суток и времени года в логику вывода, а также оценки работы модели в среде КЭСМИ.

В контексте данной работы под пониманием образов понимается не только обнаружение объекта на изображении, но и интерпретация условий, в которых этот объект наблюдается. Иными словами, система должна отвечать не только на вопрос о том, что изображено в кадре, но и на вопрос о том, какие факторы ухудшают восприятие сцены и каким образом следует компенсировать их влияние.

Для неспециалиста различие между распознаванием и пониманием образов можно сформулировать следующим образом. Распознавание отвечает на вопрос: «Это автомобиль, человек или дорожный знак?». Понимание образа отвечает на более широкий вопрос: «Почему объект виден хуже обычного, что именно мешает его обнаружению и какое действие следует предпринять для повышения надежности восприятия?». В рассматриваемой задаче такими факторами являются туман, дождь, капли на объективе, частичное перекрытие поля зрения, засветка, недостаточная освещенность, шум матрицы и загрязнение оптики.

Следовательно, понимание образов в рамках предложенного подхода трактуется как объяснимая интерпретация визуальной сцены с учетом контекста наблюдения и качества изображения [19, 20]. Именно поэтому архитектура включает не только детектор объектов, но и миварную экспертную систему, определяющую сложное условие наблюдения и формирующую рекомендацию по улучшению изображения либо по выбору режима обработки сцены.

Именно поэтому в работе акцент сделан на сочетании предобученного детектора объектов и миварной экспертной системы. Нейросетевой модуль обеспечивает базовое извлечение визуальных признаков, тогда как МЭС связывает эти признаки с контекстом наблюдения и переводит их в понятные человеку выводы о характере деградации сцены

и необходимых действиях по коррекции изображения. Такой подход особенно удобен при разработке и верификации бортовых систем технического зрения, где важны вычислительная экономичность, объяснимость и модульность.

Практическая значимость рассматриваемой задачи определяется тем, что автономный робот-курьер должен принимать решения в реальном времени на основе ограниченного набора сенсоров и при этом обеспечивать предсказуемое поведение в городской среде [21, 22]. В такой постановке особую ценность приобретают методы, которые не только выдают итоговый результат, но и позволяют инженеру проследить путь его формирования, проверить корректность порогов и при необходимости локально скорректировать отдельные правила без перестройки всей системы.

Материалы и методы

Пусть $X = \{x_1, \dots, x_{13}\}$ – множество входов системы [23, 24]. К ним относятся десять нормализованных признаков изображения: средняя яркость кадра, контрастность, нормированная экспозиция, уровень размытия, уровень засветки и бликов, индекс дождя и капель, индекс тумана и дымки, уровень шумов матрицы, степень загрязнения объектива, степень окклюзии поля зрения. Контекстные входы представлены строковыми параметрами: место наблюдения, время суток наблюдения и время года наблюдения.

$$X = \{x_1, x_2, \dots, x_{13}\}. \quad (1)$$

Множество пользовательских выходов $Y = \{y_1, y_2\}$ включает два текстовых результата: y_1 – текущее сложное условие; y_2 – рекомендуемое действие по улучшению изображения. Формально задача может быть представлена отображением $F: X \rightarrow Y$. В инженерном смысле это означает, что система должна ответить на два вопроса: что именно мешает камере корректно наблюдать сцену и какое действие следует выполнить для улучшения изображения.

$$Y = \{y_1, y_2\}, \quad (2)$$

$$F: X \rightarrow Y. \quad (3)$$

Формально разработанную систему можно представить в виде последовательности отображений $X \rightarrow Z_1 \rightarrow Z_2 \rightarrow Q \rightarrow S \rightarrow Y$, где X – множество пользовательских входов, Z_1 – множество первичных бинарных признаков, Z_2 – множество служебных контекстных признаков, Q – множество количественных оценок сложных условий, S – множество бинарных сложных условий, а Y – множество конечных текстовых выводов.

$$X \rightarrow Z_1 \rightarrow Z_2 \rightarrow Q \rightarrow S \rightarrow Y. \quad (4)$$

Множество X включает 13 входных параметров: десять нормализованных характеристик изображения и три контекстных строковых признака, задающих время суток, время года и место наблюдения. Множество Y состоит из двух пользовательских выходов: текущего сложного условия и рекомендуемого действия по улучшению изображения.

Множество Z_1 формируется по результатам пороговой и категориальной обработки входов и включает признаки низкой яркости, высокой экспозиции, сильного размытия, сильной засветки, дождя или капель, тумана или дымки, высокого шума матрицы, загрязнения объектива, сильной окклюзии, а также признаки дня, ночи, зимнего и летнего сезона и принадлежности к конкретному населенному пункту [25, 26].

Множество Z_2 содержит шесть служебных контекстных признаков, введенных для уточнения распознавания в наиболее чувствительных ветвях: признак очень плотной городской среды, признак высокого ночного городского освещения, признак зимнего усиления тумана, признак зимнего риска загрязнения объектива, признак низкого контраста и признак критически низкого контраста. Эти признаки вычисляются только внутри модели и не требуют дополнительных действий со стороны пользователя.

Множество Q включает оценки сложных условий. Каждая оценка представляет собой агрегированный показатель, вычисляемый из базовых и служебных признаков. На следующем этапе формируется множество S , элементы которого интерпретируются как бинарные признаки наличия следующих состояний: недостаточная освещенность, переэкспонирование, дождь или капли, туман или дымка, размытие, шум матрицы, засветка и блики, окклюзия поля зрения, загрязнение объектива.

Пусть $R = \{R_1, R_2, \dots, R_m\}$ – множество отношений модели, а $P = \{P_1, P_2, \dots, P_k\}$ – множество правил. Каждое отношение реализует элементарное преобразование и содержит не более одного условного оператора. В текущей реализации используются четыре базовых класса отношений: пороговые отношения вида $a > \theta \rightarrow z$, строковые отношения вида $s = v \rightarrow z$, отношения суммирования вида $a + b \rightarrow q$ и отношения фиксации состояния вида $q \geq \theta \rightarrow s$.

$$R = \{R_1, R_2, \dots, R_m\}, \quad P = \{P_1, P_2, \dots, P_k\}. \quad (5)$$

Правило в миварной системе задается как применение отношения к конкретным параметрам модели: $P_i = \langle X_i, R_i, Y_i \rangle$, где X_i – набор входных параметров правила, R_i – используемое отношение, Y_i – результирующий параметр. Благодаря такой структуре сложная логика распознавания строится как каскад простых, интерпретируемых шагов. Это позволяет КЭСМИ формировать граф решения, в котором виден путь от исходных входов к финальному пользовательскому выводу.

$$P_i = \langle X_i, R_i, Y_i \rangle. \quad (6)$$

Содержательно функционирование модели организовано как многоуровневая маршрутизация. На первом уровне формируются первичные признаки, на втором – служебные контекстные признаки, на третьем вычисляются оценки сложных условий, на четвертом определяется семейство ветви вывода, на пятом активируется конкретный маршрут, а на шестом строятся текстовые результаты. Тем самым МЭС выступает не набором разрозненных эвристик, а формализованной и объяснимой системой принятия решений. Сводка входных и выходных параметров системы представлена в Таблице 1.

Таблица 1 – Входные и выходные параметры миварной экспертной системы

Table 1 – Input and output parameters of the mivar expert system

Группа	Параметр	Тип	Назначение
Визуальные входы	Средняя яркость кадра, контрастность, экспозиция, размытие, засветка, дождь, туман, шум, загрязнение, окклюзия	double	Описание текущего качества изображения
Контекстные входы	Место наблюдения, время суток, время года	string	Учет городской среды и сезонных факторов
Пользовательские выходы	Текущее сложное условие, рекомендуемое действие	string	Семантический результат для оператора/исследователя

В модели используются только атомарные отношения. Каждое отношение реализует одну простую операцию и содержит не более одного условного оператора. Применяются отношения проверки строкового значения, пороговые отношения для числовых признаков, отношения суммирования, отношения фиксации сложного условия, отношения маршрутизации по семейству ветвей и отношения семантической интерпретации.

$$R_{thr}(a, \theta) \rightarrow z, \quad z = \begin{cases} 1, & a > \theta, \\ 0, & \text{иначе.} \end{cases} \quad (7)$$

$$R_{str}(s, v) \rightarrow z, \quad z = \begin{cases} 1, & s = v, \\ 0, & \text{иначе.} \end{cases} \quad (8)$$

$$R_{sum}(a, b) \rightarrow q, \quad q = a + b \quad (9)$$

$$R_{fix}(q, \theta) \rightarrow s, \quad s = \begin{cases} 1, & q \geq \theta, \\ 0, & \text{иначе.} \end{cases} \quad (10)$$

Правило в системе задается как применение отношения к конкретным параметрам: $P_i = \langle X_i, R_i, Y_i \rangle$, где X_i – набор входов правила, R_i – отношение, Y_i – формируемый выход. На содержательном уровне правила интерпретируются как продукционные конструкции вида «Если – то» либо как цепочки «Вход; Действие; Выход». Ключевые правила выделяют признаки деградации изображения, вычисляют оценки сложных условий, фиксируют активные состояния и переводят внутренний результат в пользовательский текст.

Логика маршрутизации организована в виде четырех семейств ветвей: атмосферной, световой, оптической и нейтральной. Внутри активного семейства выбирается конкретный маршрут: дождь, туман, недостаточная освещенность, переэкспонирование, засветка, размытие, шум матрицы, окклюзия, загрязнение объектива или норма. Важной особенностью является семантическая схема «активная ветка → текст ветки → копирование в итог», благодаря которой неактивные ветви не формируют текстовых промежуточных результатов и реже попадают в граф решения.

В базовой части модели формируются первичные признаки: признак дня и ночи, признаки сезона, а также бинарные признаки выраженности визуальных деградаций. Далее вычисляются оценки сложных условий. После фиксации состояний срабатывают правила выбора семейства ветви и правила активации конкретного маршрута. На завершающем этапе строятся тексты текущего сложного условия и рекомендуемого действия по улучшению изображения.

В текущей версии модели КЭСМИ отдельно заведены шесть внутренних признаков, которые не вводятся пользователем вручную. Они вычисляются после обработки исходных параметров и используются только для уточнения отдельных ветвей вывода. К таким признакам относятся плотная городская среда, высокий уровень ночного городского освещения, зимнее усиление тумана, зимний риск загрязнения объектива, низкий контраст и критически низкий контраст.

Эти признаки не выбирают сложное условие самостоятельно. Они добавляют или уменьшают вклад уже активной ветви. Например, для тумана учитывается сочетание индекса тумана, низкого контраста и зимнего сезона. Для недостаточной освещенности, наоборот, ночное время усиливает ветвь, но высокий уровень городской подсветки может уменьшить ее вес.

Разработанная миварная экспертная система имеет многослойную архитектуру продукционного вывода. На внешнем уровне пользователь задает только 13 исходных параметров: десять нормализованных характеристик изображения и три строковых

параметра контекста – время суток наблюдения, время года наблюдения и место наблюдения. Внутренние признаки, служебные номера маршрутов и служебные флаги вычисляются автоматически и не требуют ручного задания.

Первый слой модели формирует контекстные признаки: день или ночь, зимний или летний сезон, а также принадлежность к одному из рассматриваемых населенных пунктов. Второй слой строит первичные признаки деградаций изображения: низкую яркость, высокую экспозицию, сильное размытие, сильную засветку, наличие дождя или капель, наличие тумана или дымки, высокий шум матрицы, загрязнение объектива и сильную окклюзию поля зрения. Эти признаки играют роль атомарных логических детекторов.

Третий слой включает шесть служебных контекстных признаков, введенных для повышения чувствительности модели к особенностям городской среды и сезонным условиям. К ним относятся признаки очень плотной городской среды, высокого ночного городского освещения, зимнего усиления тумана, зимнего риска загрязнения объектива, низкого контраста и критически низкого контраста. В отличие от прямых визуальных признаков такие параметры не определяют сложное условие самостоятельно, а модифицируют силу ветвей вывода.

Четвертый слой отвечает за вычисление интегральных оценок сложных условий [27, 28]. Для каждой ветви строится отдельная оценка: недостаточной освещенности, переэкспонирования, дождя и капель, тумана и дымки, размытия, шумов матрицы, засветки и бликов, окклюзии и загрязнения объектива. В перестроенных ветвях контекстные служебные признаки используются как дополнительные слагаемые или ослабляющие факторы. Например, туман усиливается низким контрастом и зимним фактором, а недостаточная освещенность усиливается ночным временем и низкой яркостью, но ослабляется высоким уровнем городского освещения.

Пятый слой реализует маршрутизацию логического вывода. В модели выделены четыре семейства ветвей: атмосферное, световое, оптическое и нейтральное. После определения активного семейства система выбирает один из десяти конечных маршрутов сложных условий. Такая организация позволяет КЭСМИ строить различные графы решения для разных сценариев, а не один и тот же линейный путь с изменяющимися значениями узлов.

На последнем шаге модель записывает результат выбранного маршрута в два поля вывода: «Текущее сложное условие» и «Рекомендуемое действие по улучшению изображения». Для каждого маршрута выбора сложных условий в базе знаний создан отдельный набор правил, который формирует текст результата. Такой способ был выбран для того, чтобы в графе КЭСМИ можно было увидеть не только выбранную ветвь, но и правило, сформировавшее итоговую рекомендацию.

При отладке правила рассматривались по четырем группам: правила первичных признаков, правила контекстных признаков, правила расчета оценок и правила формирования текстового результата. Это упростило проверку модели КЭСМИ: при ошибке можно было менять не всю базу знаний, а конкретную группу правил. Перечень сложных условий и соответствующих им рекомендуемых действий приведен в Таблице 2.

Таблица 2 – Сложные условия и рекомендуемые действия
Table 2 – Challenging conditions and recommended actions

Номер сложного условия	Текущее сложное условие	Рекомендуемое действие
0	Сложные условия не выявлены	Дополнительная коррекция изображения не требуется
1	Недостаточное освещение сцены	Осветлить изображение и повысить различимость деталей
2	Слишком яркое изображение с пересветом	Снизить яркость и уменьшить пересвет
3	На изображении видны дождь или капли	Подавить дождь и убрать капли с изображения
4	Видимость снижена из-за тумана или дымки	Уменьшить эффект тумана и повысить видимость
5	Изображение получилось размытым	Применить алгоритм устранения размытия
6	На изображении выраженный цифровой шум	Подавить цифровой шум
7	В кадре присутствуют сильные блики или засветка	Ослабить блики и засветку
8	Обзор камеры частично перекрыт	Перейти в осторожный режим анализа и использовать несколько кадров
9	Объектив камеры загрязнен	Очистить объектив и предупредить оператора

Реализация выполнена в формате XML-модели для среды КЭСМИ. В актуальной версии используются 13 пользовательских входов, 2 пользовательских выхода, 6 контекстных служебных признаков, 5 перестроенных ветвей, 96 правил, 60 отношений и 13 ограничений. Ограничения контролируют диапазоны числовых входов и допустимые значения строковых параметров. Поддерживаются Москва и крупнейшие города Московской области, а также Иннополис как отдельный тестовый сценарий малой плотности городской среды.

Выбор связки «МЭС + предобученная YOLO» продиктован ограниченностью доступных вычислительных ресурсов. В отличие от архитектур, предполагающих передачу данных в облако или использование тяжёлых каскадов нейросетевой обработки, предложенный подход допускает локальное выполнение на вычислительной платформе автономного робота. Это снижает зависимость от сетевой инфраструктуры, уменьшает задержки и делает систему более пригодной для реального применения в условиях нестабильной связи.

Подготовлены наборы XML-сценариев с предустановленными значениями параметров для нормальных условий, недостаточной освещенности, переэкспонирования, дождя, тумана, размытия, шумов, засветки, окклюзии и загрязнения объектива [29, 30]. Ветвь дождя и капель соотносится с задачами удаления дождя [31]. Такой подход обеспечивает воспроизводимость экспериментов и позволяет сравнивать графы решения без ручного повторного ввода параметров.

После формализации предметной области и построения XML-модели в КЭСМИ следующим шагом стала экспериментальная проверка того, насколько вывод МЭС может быть полезен не только как самостоятельный семантический результат, но и как управляющий сигнал для модуля распознавания объектов.

Для проверки практической полезности разработанной миварной экспертной системы был проведен эксперимент по интеграции МЭС с детектором объектов. В качестве детектора использовалась предобученная модель YOLOv12s.pt [32, 33]. Использование именно предобученного детектора соответствует целевой архитектуре автономного робота-курьера с ограниченными бортовыми ресурсами: в рабочем контуре применяется уже обученная модель, а МЭС выполняет вычислительно лёгкую логическую интерпретацию сложных условий и выбор согласованного режима обработки изображения [34].

Проверялась гипотеза о том, что предварительное знание о сложных условиях наблюдения позволяет улучшить распознавание объектов в сцене по сравнению с прямым запуском детектора на исходном изображении [35]. Для иллюстрации были выбраны два сценария, отражающие разные классы деградаций визуальной информации: частичное перекрытие объекта и сильный туман. Первый сценарий соответствует геометрическому ограничению обзора, второй – атмосферной деградации, снижающей контраст и дальность видимости.

Результаты

В качестве искомых параметров в КЭСМИ были выбраны только два поля вывода: «Текущее сложное условие» и «Рекомендуемое действие по улучшению изображения». Для каждого XML-сценария задавались 13 входных значений, после чего фиксировались выбранное семейство ветви, конечный маршрут и сформированный текст рекомендации.

В нормальном сценарии специальные ветви не активировались, и система возвращала результат «Сложные условия не выявлены». В сценарии дождя с высоким индексом капель выбиралась атмосферная ветвь и маршрут «дождь/капли». В сценарии тумана при низком контрасте и зимнем сезоне активировался маршрут «туман/дымка». Для сценария окклюзии решающим становился высокий показатель перекрытия поля зрения, а для загрязнения объектива – сочетание признака загрязнения, низкого контраста и зимнего риска.

Контекстные признаки использовались как поправки к ветвям, а не как самостоятельные причины выбора сложного условия. Например, ночной городской контекст уменьшал вес ветви недостаточной освещенности, если место наблюдения относилось к Москве или крупному городу Московской области. Зимний сезон, наоборот, усиливал ветви тумана и загрязнения объектива только при наличии соответствующих визуальных признаков.

Количественные характеристики итоговой XML-модели приведены в Таблице 3. Эти значения получены по версии базы знаний, загруженной в КЭСМИ для экспериментальной проверки.

Таблица 3 – Количественные характеристики реализованной модели
Table 3 – Quantitative characteristics of the implemented model

Показатель	Значение
Пользовательские входы	13
Пользовательские выходы	2
Контекстные служебные признаки	6
Перестроенные ветви	5
Правила	96
Отношения	60
Ограничения	13

После запуска сценариев дополнительно просматривались графы решения КЭСМИ. При проверке анализировалось, какой входной параметр первым активировал ветвь, какие служебные признаки добавились к маршруту и каким правилом был записан итоговый текст рекомендации. Это позволяло корректировать систему. Например, если модель выбирала неверный маршрут, то корректировались порог или связь в конкретном отношении.

В первом сценарии использовалось исходное изображение со сценой частичного перекрытия автомобиля элементом стеклоочистителя. При базовом запуске детектора на исходной сцене результат базового распознавания показал уверенность YOLO 0,70 для класса CAR. После учета сложного условия «частичное перекрытие объекта» и запуска детектора в режиме, согласованном с выводом МЭС, уверенность возросла до 0,90. Абсолютный прирост confidence составил 0,20, что соответствует относительному увеличению примерно на 28,6 % по сравнению с базовым вариантом.

Во втором сценарии использовалось исходное изображение с выраженным туманом. В базовом режиме автомобиль был обнаружен с уверенностью 0,84. После предварительного учета сложного условия «сильный туман» и запуска детектора в режиме, информированном о данном условии, уверенность повысилась до 0,99. Абсолютный прирост составил 0,15, а относительный – около 17,9 %.

Среднее значение confidence по двум сценариям увеличилось с 0,77 до 0,945, то есть на 0,175 в абсолютном выражении. Полученные результаты показывают, что предварительное определение сложного условия наблюдения и использование рекомендации МЭС способны повышать уверенность детектора при распознавании объектов в сложных сценах. Следует отметить, что данный эксперимент носит пилотный характер и служит proof-of-concept для дальнейших исследований на расширенном наборе изображений. Количественные результаты эксперимента представлены в Таблице 4.

Таблица 4 – Результаты эксперимента по интеграции МЭС и детектора объектов
Table 4 – Results of the experiment on integrating the MES with the object detector

Сценарий	Сложное условие	Уверенность без учёта МЭС	Уверенность с учётом МЭС	Абсолютный прирост
Частичное перекрытие объекта	Частичное перекрытие объекта	0,70	0,90	+0,20
Сильный туман	Сильный туман	0,84	0,99	+0,15

Для иллюстрации первого сценария на Рисунке 1 приведено сопоставление исходного изображения, результата прямого распознавания и результата распознавания после учета вывода миварной экспертной системы. Такое представление позволяет на одной иллюстрации увидеть исходную деградацию сцены, реакцию базового детектора и эффект от использования рекомендации МЭС.

Сопоставление рисунков показывает, что частичное перекрытие области наблюдения приводит к снижению уверенности обнаружения автомобиля, тогда как предварительное определение соответствующего сложного условия и переход к согласованному режиму обработки позволяют повысить устойчивость распознавания. Тем самым Рисунок 1 служит визуальным подтверждением тезиса о полезности экспертного слоя интерпретации перед запуском детектора.



Рисунок 1 – Сценарий частичного перекрытия объекта: *a* – исходное изображение; *б* – результат распознавания YOLO без учета сложного условия; *в* – результат распознавания с учетом сложного условия, предварительно определенного МЭС
Figure 1 – Partial object occlusion scenario: *a* – original image; *b* – YOLO detection result without using the challenging condition; *c* – detection result using the challenging condition preliminarily identified by the MES

Второй сценарий, представленный на Рисунке 2, посвящен атмосферной деградации изображения в виде выраженного тумана. Здесь также используется тройное сопоставление: исходная сцена, базовый результат YOLO и результат после применения режима, выбранного на основе вывода МЭС.




Рисунок 2 – Сценарий сильного тумана: *a* – исходное изображение; *б* – результат распознавания YOLO без учета сложного условия; *в* – результат распознавания с учетом сложного условия, предварительно определенного МЭС
Figure 2 – Dense fog scenario: *a* – original image; *b* – YOLO detection result without using the challenging condition; *c* – detection result using the challenging condition preliminarily identified by the MES

На Рисунке 2 видно, что основным фактором ухудшения восприятия становится падение контраста и дальности видимости. Именно поэтому ветвь тумана и дымки в МЭС опирается не только на индекс тумана, но и на служебные признаки, связанные с сезоном и контрастностью кадра. Иллюстрация помогает связать формальные правила модели с наблюдаемым качеством изображения.

Для двух тестовых сценариев были сохранены графы решения КЭСМИ. Первый граф относился к сцене частичного перекрытия объекта, второй – к сцене сильного тумана. При их анализе проверялись, какие входные признаки запустили ветвь вывода, какие служебные признаки вошли в маршрут и каким правилом был сформирован итоговый текст рекомендации.

В сценарии окклюзии, который изображен на Рисунке 3, основной вклад дает признак перекрытия поля зрения. В сценарии тумана маршрут формируется не только по индексу тумана, но и с учетом низкого контраста и сезонного признака. Поэтому графы используются не как декоративные иллюстрации, а как способ проверить, что итоговое решение действительно получено из заданных правил.

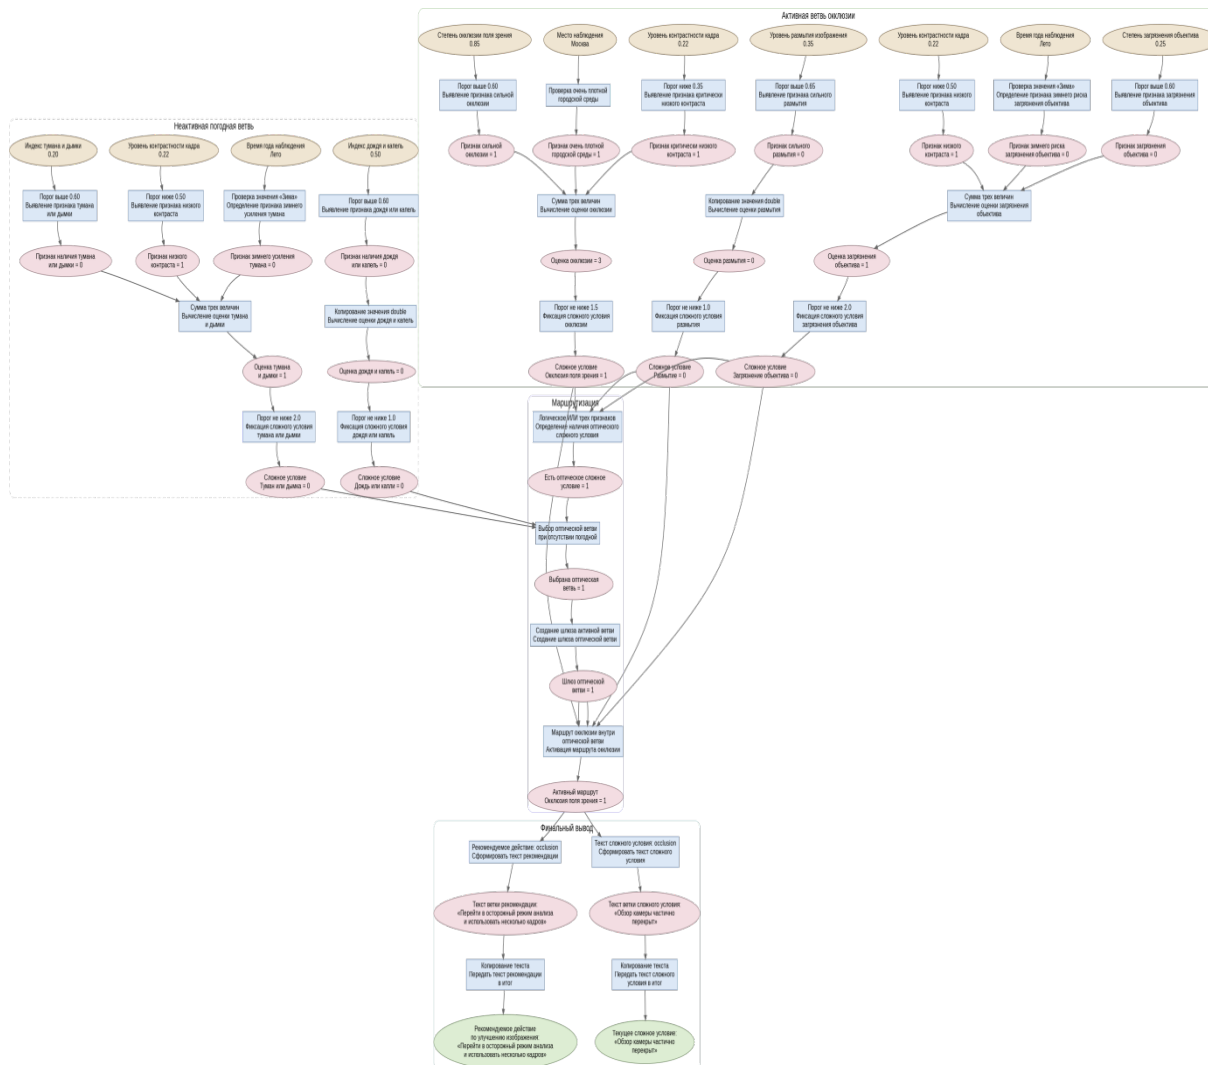


Рисунок 3 – Граф решения КЭСМИ для сценария частичного перекрытия объекта
Figure 3 – KESMI solution graph for the partial object occlusion scenario

Аналогичный граф решения для сценария сильного тумана представлен на Рисунке 4. Он позволяет проследить, каким образом в модели взаимодействуют визуальные признаки и контекстные модификаторы, усиливающие атмосферную ветвь вывода.

По сравнению с графом частичного перекрытия здесь более заметна роль служебных признаков, связанных с пониженным контрастом и сезонным фактором. Таким образом, Рисунок 4 дополняет численные результаты и показывает, что МЭС не только выдает итоговый текстовый результат, но и обеспечивает интерпретируемую внутреннюю логику вывода.

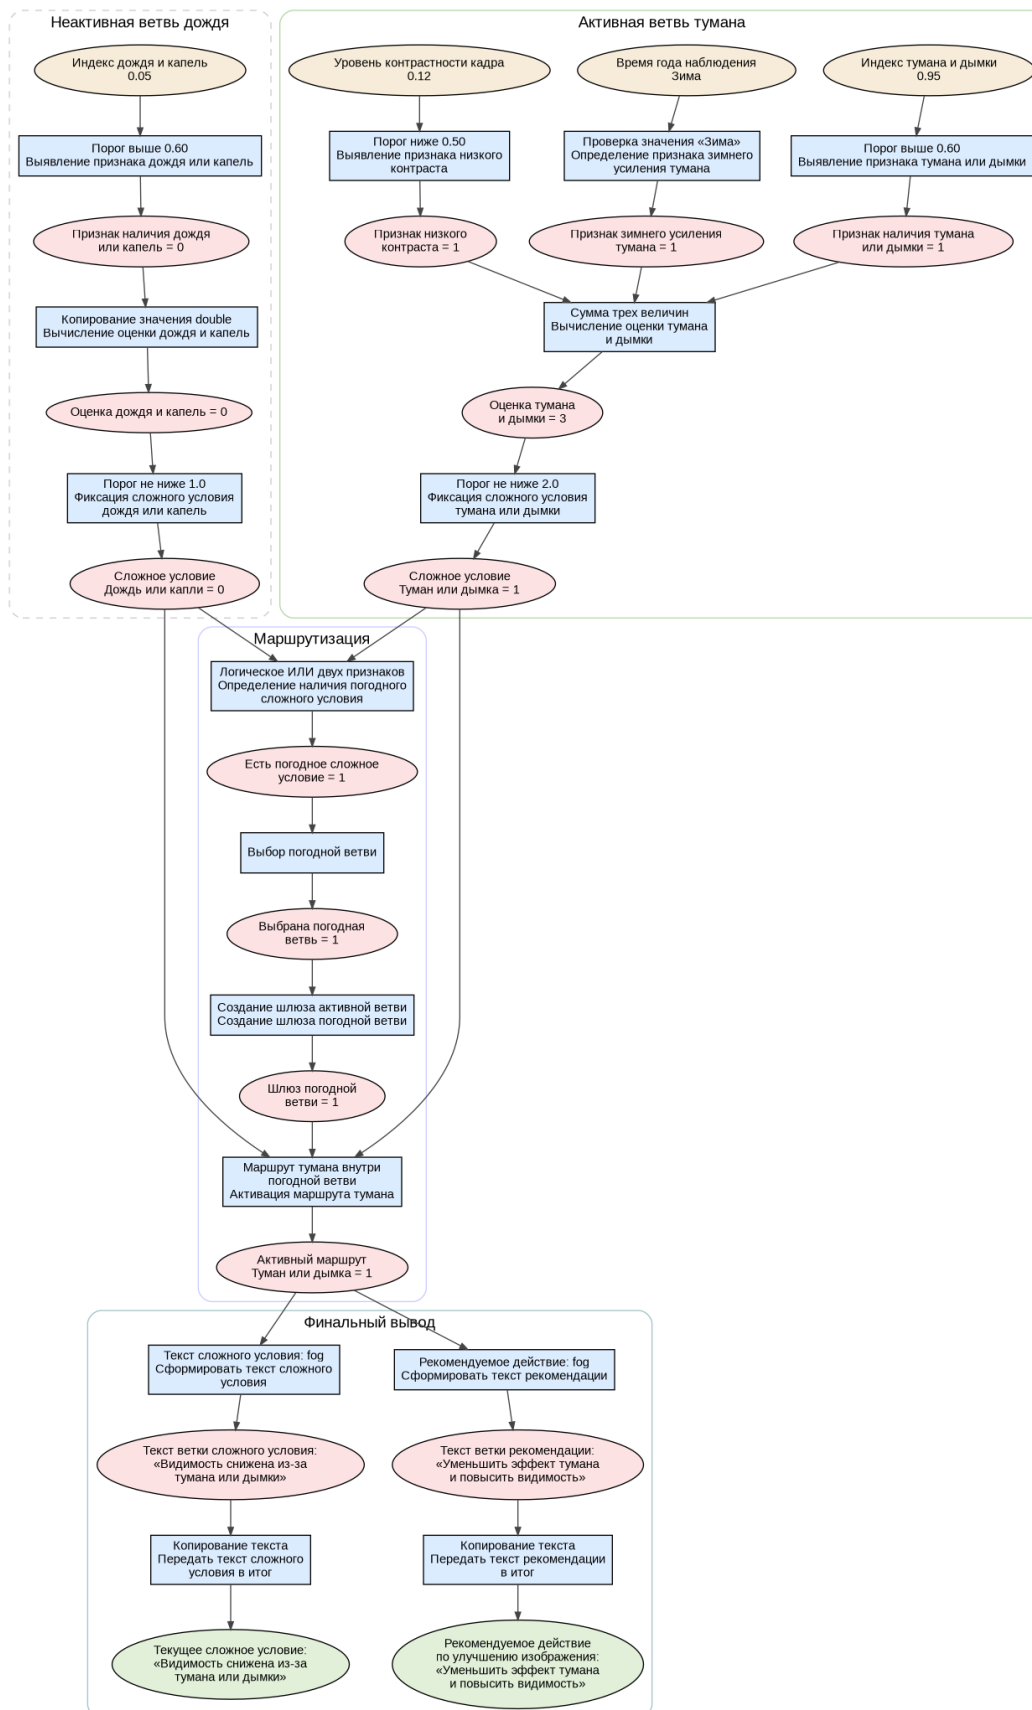


Рисунок 4 – Граф решения КЭСМИ для сценария сильного тумана
Figure 4 – KESMI solution graph for the dense fog scenario

Обсуждение

Предложенная модель сочетает преимущества экспертного, маршрутизируемого и человеко-ориентированного подходов. В отличие от линейной схемы полного перебора, где вычисляются почти все оценки, а затем выбирается итоговый номер сложного условия, ветвящаяся организация позволяет раньше выделять семейство ветви и сокращать число реально активируемых участков графа.

Результаты проверки показывают, что МЭС целесообразно рассматривать как логический слой над детектором объектов, а не как замену нейросетевого распознавания. Детектор формирует первичные признаки сцены, а МЭС определяет, какое сложное условие влияет на качество наблюдения и какой режим обработки следует выбрать.

Главное преимущество такой схемы проявилось при просмотре графов КЭСМИ. Для каждого сценария можно проследить, какой входной параметр активировал ветвь, какие служебные признаки изменили маршрут и каким правилом сформирован пользовательский результат. Это удобно при отладке, поскольку ошибка локализуется в конкретном отношении или пороге.

Ограничением текущей версии является экспертный выбор порогов. Для демонстрационной XML-модели этого достаточно, но для практического применения потребуется проверка на расширенном наборе кадров с разными уровнями освещенности, тумана, дождя, размывтия и окклюзии. После необходимо оценить, насколько выбранные рекомендации МЭС влияют на качество последующего распознавания объектов.

На двух рассмотренных примерах – частичном перекрытии объекта и сильном тумане – такая предварительная адаптация привела к росту уверенности YOLO при обнаружении автомобиля. Данный эксперимент служит для демонстрации принципиальной применимости МЭС как надстройки над системой распознавания объектов.

Заключение

Разработана миварная экспертная система выявления сложных условий наблюдения и выбора способов коррекции изображения для однокамерной системы технического зрения автономного робота-курьера. Система использует 13 пользовательских входов и формирует два конечных семантических результата: текущее сложное условие и рекомендуемое действие по улучшению изображения. Предлагаемый подход ориентирован на автономный режим работы без использования облачных вычислений и потому сочетает вычислительно экономичную миварную экспертную систему с предобученным детектором YOLO.

Предметная область формализована в виде параметров, отношений, правил и ограничений. Ключевой особенностью модели является атомарная структура отношений и ветвящаяся организация вывода, позволяющая визуализировать путь решения в среде КЭСМИ. В модель введены шесть дополнительных служебных признаков, обеспечивающих учет плотности городской среды, ночного освещения, сезонных факторов и уровня контрастности.

Показано, что использование контекстных признаков улучшает логическую согласованность распознавания в пяти наиболее чувствительных ветвях: недостаточная освещенность, туман, засветка, окклюзия и загрязнение объектива. Предлагаемый подход может служить основой для дальнейшего расширения экспертной базы знаний, количественного анализа графов вывода и интеграции МЭС с низкоуровневыми алгоритмами восстановления изображения и модулями распознавания объектов.

В дальнейшем представляется целесообразным перейти от таких примеров к более широкой экспериментальной базе, включающей серии кадров с различными погодными, световыми и оптическими искажениями, а также количественно оценить вклад МЭС в устойчивость обнаружения объектов и в стабильность работы общей архитектуры автономного робота-курьера.

Практический смысл полученных результатов состоит в том, что предложенная архитектура допускает поэтапное расширение без разрушения уже работающей базы знаний. Это важно для бортовых систем автономных платформ, где новая логика должна добавляться постепенно и верифицироваться на отдельных сценариях, а не внедряться в виде непрозрачного монолитного модуля.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Shadrin S.S., Varlamov O.O., Ivanov A.M. Experimental autonomous road vehicle with logical artificial intelligence. *Journal of Advanced Transportation*. 2017;2017:2492765. <https://doi.org/10.1155/2017/2492765>
2. Varlamov O.O. "Brains" for Robots: Application of the Mivar Expert Systems for Implementation of Autonomous Intelligent Robots. *Big Data Research*. 2021;25:100241. <https://doi.org/10.1016/j.bdr.2021.100241>
3. Varlamov O., Aladin D. A New Generation of Rules-based Approach: Mivar-based Intelligent Planning of Robot Actions (MIPRA) and Brains for Autonomous Robots. *Machine Intelligence Research*. 2024;21(5):919–940. <https://doi.org/10.1007/s11633-023-1473-1>
4. Гун Ш. Миварная система принятия решений для распределения и перевозки грузов командой складских роботов. *Системы управления и информационные технологии*. 2025;(2):23–29.
Gong S. Mivar Decision-Making System for Distribution and Transportation of Cargo by a Team of Warehouse Robots. *Management Systems and Information Technology*. 2025;(2):23–29. (In Russ.).
5. Redmon J., Divvala S., Girshick R., et al. You Only Look Once: Unified, Real-Time Object Detection. In: *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 27–30 June 2016, Las Vegas, NV, USA*. IEEE; 2016. P. 779–788. <https://doi.org/10.1109/CVPR.2016.91>
6. Wang Ch.-Y., Bochkovskiy A., Liao H.-Y.M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. In: *Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 17–24 June 2023, Vancouver, BC, Canada*. IEEE; 2023. P. 7464–7475. <https://doi.org/10.1109/CVPR52729.2023.00721>
7. Michaelis C., Mitzkus B., Geirhos R., et al. *Benchmarking Robustness in Object Detection: Autonomous Driving when Winter is Coming*. arXiv. URL: <https://doi.org/10.48550/arXiv.1907.07484> [Accessed 15th May 2026].
8. Bijelic M., Gruber T., Mannan F., et al. Seeing Through Fog Without Seeing Fog: Deep Multimodal Sensor Fusion in Unseen Adverse Weather. In: *Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 13–19 June 2020, Seattle, WA, USA*. IEEE; 2020. P. 11679–11689. <https://doi.org/10.1109/CVPR42600.2020.01170>
9. Sakaridis Ch., Dai D., Van Gool L. Semantic Foggy Scene Understanding with Synthetic Data. *International Journal of Computer Vision*. 2018;126(9):973–992. <https://doi.org/10.1007/s11263-018-1072-8>

10. He K., Sun J., Tang X. Single Image Haze Removal Using Dark Channel Prior. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2011;33(12):2341–2353. <https://doi.org/10.1109/TPAMI.2010.168>
11. Fu X., Huang J., Zeng D., et al. Removing Rain from Single Images via a Deep Detail Network. In: *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 21–26 July 2017, Honolulu, HI, USA*. IEEE; 2017. P. 1715–1723. <https://doi.org/10.1109/CVPR.2017.186>
12. Guo X. LIME: A Method for Low-light Image Enhancement. In: *Proceedings of the 24th ACM International Conference on Multimedia, 15–19 October 2016, Amsterdam, The Netherlands*. New York: ACM; 2016. P. 87–91. <https://doi.org/10.1145/2964284.2967188>
13. Shen Q., Gong Sh., Kotsenko A.A., et al. Algorithm for Dynamic Robot Trajectory Planning Based on Semantic Object Detection Using a Mivar Expert System. In: *Proceedings of the 2025 7th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE), 08–10 April 2025, Moscow, Russia*. IEEE; 2025. <https://doi.org/10.1109/REEPE63962.2025.10971158>
14. Dou L., Varlamov O.O., Kotsenko A.A. A Multimodal Target Detection Method Based on the MES and the Improved BEV Perception Algorithm. In: *Proceedings of the 2025 7th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE), 08–10 April 2025, Moscow, Russia*. IEEE; 2025. <https://doi.org/10.1109/REEPE63962.2025.10970859>
15. Aladin D.V., Varlamov O.O., Adamova L.E., et al. Control of vehicles and robots: creating of knowledge bases for mivar decision making systems robots and vehicles. In: *IOP Conference Series: Materials Science and Engineering: Proceedings of the International Conference of Young Scientists and Students "Topical Problems of Mechanical Engineering" (ToPME-2019): Volume 747, 04–06 December 2019, Moscow, Russia*. IOP Publishing; 2020. No. 012099. <https://doi.org/10.1088/1757-899X/747/1/012099>
16. Chuvikov D.A., Aladin D.V., Adamova L.E., et al. A new method for creating Mivar knowledge bases in tabular-matrix form for ground intelligent vehicle control systems. In: *Journal of Physics: Conference Series: Proceedings of the International Conference on Actual Issues of Mechanical Engineering (AIME 2021): Volume 2061, 15–16 June 2021, Novorossiysk, Russia*. IOP Publishing; 2021. No. 012123. <https://doi.org/10.1088/1742-6596/2061/1/012123>
17. Аладин Д.В. Метод автоматической генерации миварных баз знаний для решения управленческих задач в пространстве состояний. *Проблемы искусственного интеллекта*. 2025;(3):88–99. <https://doi.org/10.24412/2413-7383-2025-3-38-88-99>
Aladin D.V. Mivar knowledge base automatic generation method for solving management tasks in state space. *Problems of Artificial Intelligence*. 2025;(3):88–99. (In Russ.). <https://doi.org/10.24412/2413-7383-2025-3-38-88-99>
18. Доу Л. Модель принятия решений для обнаружения пожаров на основе распознавания образов и миварной экспертной системы. *Системы управления и информационные технологии*. 2025;(3):59–65.
Dou L. Decision-making model for fire detection based on pattern recognition and mivar expert system. *Management Systems and Information Technology*. 2025;(3):59–65. (In Russ.).
19. Selvaraju R.R., Cogswell M., Das A., et al. Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. In: *Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV), 22–29 October 2017, Venice, Italy*. IEEE; 2017. P. 618–626. <https://doi.org/10.1109/ICCV.2017.74>

20. Ribeiro M.T., Singh S., Guestrin C. "Why Should I Trust You?": Explaining the Predictions of Any Classifier. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 13–17 August 2016, San Francisco, CA, USA*. New York: ACM; 2016. P. 1135–1144. <https://doi.org/10.1145/2939672.2939778>
21. Lundberg S.M., Lee S.-I. A Unified Approach to Interpreting Model Predictions. In: *Advances in Neural Information Processing Systems 30: Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017), 04–09 December 2017, Long Beach, CA, USA*. 2017. P. 4765–4774.
22. Doshi-Velez F., Kim B. *Towards A Rigorous Science of Interpretable Machine Learning*. arXiv. URL: <https://doi.org/10.48550/arXiv.1702.08608> [Accessed 15th May 2026].
23. Mittal A., Moorthy A.K., Bovik A.C. No-reference image quality assessment in the spatial domain. *IEEE Transactions on Image Processing*. 2012;21(12):4695–4708. <https://doi.org/10.1109/TIP.2012.2214050>
24. Wang Zh., Bovik A.C., Sheikh H.R., et al. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*. 2004;13(4):600–612. <https://doi.org/10.1109/TIP.2003.819861>
25. Jobson D.J., Rahman Z., Woodell G.A. A Multiscale Retinex for Bridging the Gap Between Color Images and the Human Observation of Scenes. *IEEE Transactions on Image Processing*. 1997;6(7):965–976. <https://doi.org/10.1109/83.597272>
26. Guo Ch., Li Ch., Guo J., et al. Zero-Reference Deep Curve Estimation for Low-Light Image Enhancement. In: *Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 13–19 June 2020, Seattle, WA, USA*. IEEE; 2020. P. 1777–1786. <https://doi.org/10.1109/CVPR42600.2020.00185>
27. Zhang K., Zuo W., Chen Y., et al. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. *IEEE Transactions on Image Processing*. 2017;26(7):3142–3155. <https://doi.org/10.1109/TIP.2017.2662206>
28. Nah S., Kim T.H., Lee K.M. Deep Multi-scale Convolutional Neural Network for Dynamic Scene Deblurring. In: *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 21–26 July 2017, Honolulu, HI, USA*. IEEE; 2017. P. 257–265. <https://doi.org/10.1109/CVPR.2017.35>
29. Kupyn O., Budzan V., Mykhailych M., et al. DeblurGAN: Blind Motion Deblurring Using Conditional Adversarial Networks. In: *Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 18–23 June 2018, Salt Lake City, UT, USA*. IEEE; 2018. P. 8183–8192. <https://doi.org/10.1109/CVPR.2018.00854>
30. Ren W., Liu S., Zhang H., et al. Single Image Dehazing via Multi-scale Convolutional Neural Networks. In: *Computer Vision – ECCV 2016: Proceedings of the 14th European Conference on Computer Vision: Part II, 11–14 October 2016, Amsterdam, The Netherlands*. Cham: Springer; 2016. P. 154–169. https://doi.org/10.1007/978-3-319-46475-6_10
31. Zhang H., Patel V.M. Density-aware Single Image De-raining Using a Multi-stream Dense Network. In: *Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 18–23 June 2018, Salt Lake City, UT, USA*. IEEE; 2018. P. 695–704. <https://doi.org/10.1109/CVPR.2018.00079>
32. Tian Y., Ye Q., Doermann D. *YOLOv12: Attention-Centric Real-Time Object Detectors*. arXiv. URL: <https://doi.org/10.48550/arXiv.2502.12524> [Accessed 15th May 2026].
33. Liu W., Anguelov D., Erhan D., et al. SSD: Single Shot MultiBox Detector. In: *Computer Vision – ECCV 2016: Proceedings of the 14th European Conference on Computer Vision:*

- Part I, 11–14 October 2016, Amsterdam, The Netherlands*. Cham: Springer; 2016. P. 21–37. https://doi.org/10.1007/978-3-319-46448-0_2
34. Lin T.-Y., Goyal P., Girshick R., et al. Focal Loss for Dense Object Detection. In: *Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV), 22–29 October 2017, Venice, Italy*. IEEE; 2017. P. 2999–3007. <https://doi.org/10.1109/ICCV.2017.324>
35. Hendrycks D., Dietterich Th.G. Benchmarking Neural Network Robustness to Common Corruptions and Perturbations. In: *Proceedings of the 7th International Conference on Learning Representations (ICLR), 06–09 May 2019, New Orleans, LA, USA*. 2019. URL: <https://openreview.net/forum?id=HJz6tiCqYm>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Милевич Артём Андреевич, студент, **Artem A. Milevich**, Student, Bauman Moscow Московский государственный технический университет им. Н.Э. Баумана, Москва, Федерация.

e-mail: artemmilevich994@gmail.com

ORCID: [0009-0008-5004-1771](https://orcid.org/0009-0008-5004-1771)

Овчинников Данила Алексеевич, студент, **Danila A. Ovchinnikov**, Student, Bauman Московский государственный технический университет им. Н.Э. Баумана, Москва, the Russian Federation.

e-mail: daninza7@gmail.com

ORCID: [0009-0000-3002-2698](https://orcid.org/0009-0000-3002-2698)

Варламов Олег Олегович, доктор технических наук, профессор, Московский государственный технический университет им. Н.Э. Баумана; главный научный сотрудник, Научно-исследовательский институт вычислительных комплексов им. М.А. Карцева, Москва, Российская Федерация.

e-mail: ovar@narod.ru

ORCID: [0000-0002-2858-1383](https://orcid.org/0000-0002-2858-1383)

Статья поступила в редакцию 08.05.2026; одобрена после рецензирования 22.06.2026; принята к публикации 06.07.2026.

The article was submitted 08.05.2026; approved after reviewing 22.06.2026; accepted for publication 06.07.2026.