

УДК 681.5.015; 004.8

DOI: [10.26102/2310-6018/2026.53.2.009](https://doi.org/10.26102/2310-6018/2026.53.2.009)

Исследование неопределенности в многоагентном мониторинге дорожного покрытия

А.А. Подберёзкин✉

*Московский автомобильно-дорожный государственный технический университет,
Москва, Российская Федерация*

Резюме. Актуальность исследования обусловлена тем, что в платформах мониторинга дорожной инфраструктуры ошибки на уровне детектирования и интерпретации состояния объектов способны переходить в ошибки нормативных и управленческих решений, особенно в реальных условиях съемки (тени, блики, влажное/заснеженное покрытие, загрязнения, неоднозначные границы дефектов), где возрастает риск неверной классификации и локализации. Это критично при пороговой нормативной оценке, поскольку небольшая погрешность может привести к смене категории состояния и, как следствие, к необоснованному назначению ремонтных мероприятий либо к пропуску опасного дефекта. В связи с этим статья направлена на исследование учета неопределенности детектирования дефектов дорожного покрытия в многоагентном контуре мониторинга, где результаты наблюдений передаются между компонентами вместе с контекстом обработки через Model Context Protocol как единый протокол обмена событиями, метаданными и параметрами интерпретации. Ведущим подходом является построение вычислительного конвейера, включающего предварительную обработку видеоданных, детектирование дефектов, вычисление показателя неопределенности $H(p)$ по распределению вероятностей классов, присвоение статуса «автоматически/валидация/уточнение», последующую нормативную интерпретацию и агрегацию по участкам дорожной сети. Для обеспечения воспроизводимости каждый прогон фиксируется как унифицированный «контекст эксперимента» (идентификатор сцены/кадра, версия модели, параметры порогов, статус решения), что позволяет сопоставимо сравнивать режимы и выполнять аудит причин расхождений. Верификация основана на сравнении нормативных решений с экспертной оценкой и анализе зависимости доли ошибочных нормативных решений от порога автоматического принятия решения по $H(p)$, при этом риск-ориентированная логика переводит высоконеопределенные детекции в режим валидации и снижает вероятность ошибок в пограничных случаях. Показано, что протоколирование контекста через Model Context Protocol и учет $H(p)$ повышают воспроизводимость экспериментов и обоснованность нормативной интерпретации, уменьшая риск ошибочной приоритизации ремонта за счет отделения сомнительных наблюдений и сохранения причин принятого решения.

Ключевые слова: многоагентная система, мониторинг дорожного покрытия, дефекты дорожного покрытия, компьютерное зрение, неопределенность детектирования, нормативная интерпретация, протоколирование контекста.

Для цитирования: Подберёзкин А.А. Исследование неопределенности в многоагентном мониторинге дорожного покрытия. *Моделирование, оптимизация и информационные технологии*. 2026;14(2). URL: <https://moitvvt.ru/ru/journal/article?id=2210> DOI: 10.26102/2310-6018/2026.53.2.009

Research on uncertainty in multi-agent road surface monitoring

А.А. Podberezkin✉

*Moscow Automobile and Road Construction State Technical University, Moscow,
the Russian Federation*

Abstract. The relevance of this study is determined by the fact that, in road-infrastructure monitoring platforms, errors at the stage of detection and interpretation of object conditions can propagate into normative and managerial decision errors, especially under real-world acquisition conditions (shadows, glare, wet/snow-covered pavement, contamination, and ambiguous defect boundaries), where the risk of misclassification and inaccurate localization increases. This is critical for threshold-based normative assessment, since even small inaccuracies may change the condition category and, consequently, lead either to unjustified maintenance assignments or to missing hazardous defects. Therefore, this paper investigates the use of detection uncertainty for road-surface defect monitoring within a multi-agent pipeline, where observation results are transferred between components together with the processing context via the Model Context Protocol as a unified mechanism for exchanging events, metadata, and interpretation parameters. The main approach is to build a computational pipeline that includes video-data preprocessing, defect detection, computation of the uncertainty indicator $H(p)$ from the class-probability distribution, assignment of the status "automatic/validation/refinement" subsequent normative interpretation, and aggregation over road-network segments. To ensure reproducibility, each run is recorded as a unified "experiment context" (scene/frame identifier, model version, threshold parameters, decision status), enabling comparable mode-to-mode evaluation and auditing of discrepancy causes. Verification is based on comparing normative decisions with expert assessment and analyzing how the share of erroneous normative decisions depends on the automatic-decision threshold for $H(p)$, while the risk-oriented logic routes high-uncertainty detections to validation and reduces the probability of errors in borderline cases. The results show that context logging via Model Context Protocol and accounting for $H(p)$ improve experimental reproducibility and the soundness of normative interpretation, decreasing the risk of incorrect maintenance prioritization by separating ambiguous observations and preserving the decision rationale.

Keywords: multi agent system, road surface monitoring, road surface defects, computer vision, detection uncertainty, normative interpretation, context logging.

For citation: Podberezkin A.A. Research on uncertainty in multi-agent road surface monitoring. *Modeling, Optimization and Information Technology*. 2026;14(2). (In Russ.). URL: <https://moitvvt.ru/ru/journal/article?id=2210> DOI: 10.26102/2310-6018/2026.53.2.009

Введение

В рамках многоагентной платформы управления трафиком качество данных о состоянии инфраструктуры определяет корректность сценарного анализа в цифровом двойнике и устойчивость принимаемых решений. Состояние дорожного покрытия является одним из ключевых факторов безопасности дорожного движения и эффективности эксплуатации автомобильных дорог [1, 2]. Дефекты проезжей части, включая выбоины, трещины и локальные просадки, приводят к ухудшению сцепных свойств покрытия, росту аварийности и ускоренному разрушению дорожной одежды [1, 3]. В составе платформы данный контур целесообразно реализовывать как отдельного агента мониторинга, формирующего события и параметры для последующих модулей. В настоящее время контроль состояния дорожного полотна во многих случаях выполняется на основе визуальных обследований и ручной фиксации повреждений [2, 3]. Такой подход отличается высокой трудоемкостью, зависимостью от квалификации исполнителя и ограниченной воспроизводимостью результатов [2, 3]. Многоагентная декомпозиция здесь является не декоративной, а функционально необходимой: детектирование дефекта – лишь первый шаг, тогда как итоговое решение формируется на этапах нормативной интерпретации, валидации и агрегации по участкам, а ошибки наблюдения могут масштабироваться в ошибки управленческих выводов. Для корректного прохождения результата через последующие модули требуется передавать не только класс и геометрию дефекта, но и статус доверия («автоматически/валидация/уточнение») и параметры интерпретации, чтобы исключить «скрытую» смену правил между прогонами. Поэтому протоколирование контекста

(MCP) используется как унифицированный механизм фиксации и обмена контекстом обработки, обеспечивающий воспроизводимость и аудит решения. Дополнительные сложности создаются необходимостью точной геопривязки дефектов и сопоставления выявленных повреждений с пороговыми значениями нормативных документов, определяющих допустимые параметры дефектов и сроки их устранения [3, 4].

Развитие методов компьютерного зрения и машинного обучения позволило внедрять автоматизированные системы мониторинга, способные выполнять детектирование дефектов по изображениям и видеопотокам в режиме, близком к реальному времени [1, 5]. В многоагентной платформе результаты такого агента становятся входом для нормативной интерпретации и для сценарного моделирования в цифровом двойнике, поэтому ошибки детекции способны переходить в ошибки последующих выводов и решений [2, 3]. Реальные условия съемки характеризуются изменчивым освещением, тенями, осадками, загрязнениями, мокрым или заснеженным покрытием, а также неоднозначностью визуальных границ дефекта [5, 6]. В этих условиях детектор может допускать ошибки классификации и локализации, которые непосредственно влияют на последующую нормативную оценку [1, 7]. Это, в свою очередь, отражается на формировании рекомендаций по ремонту, а также управленческих решений [6].

Нормативная оценка дефектов дорожного покрытия опирается на пороговые критерии, заданные национальными стандартами и сводами правил. Превышение установленных значений по геометрическим параметрам дефекта и доле поврежденной площади на участке приводит к формированию решений о недопустимом состоянии покрытия и необходимости устранения дефектов. Следовательно, ошибки детектирования могут приводить как к назначению необоснованных ремонтных мероприятий, так и к пропуску критичных дефектов, представляющих угрозу безопасности [2, 4]. Для платформенного контура это означает необходимость учитывать надежность наблюдения до передачи его в последующие модули; при этом типовые решения компьютерного зрения чаще всего не предоставляют количественного показателя доверия к результату, что затрудняет применение осторожной стратегии принятия решений [8].

Актуальным направлением является учет неопределенности детектирования, позволяющий отделять надежные случаи от неоднозначных и тем самым снижать риск ошибочных нормативных и управленческих выводов [8, 9]. В контуре многоагентной платформы такая информация должна быть передаваема между компонентами вместе с контекстом обработки, чтобы поддерживать воспроизводимость и трассируемость решений [8, 9]. При этом принципиально важно обеспечить интеграцию показателей неопределенности без усложнения вычислительного конвейера и без роста вычислительных затрат [8, 9].

Целью исследования является оценка возможности количественной оценки неопределенности при детектировании дефектов дорожного полотна и анализ влияния использования этой информации на результаты нормативной оценки и принятие управленческих решений по приоритизации ремонта.

Материалы и методы

В качестве исходных данных использованы видеозаписи автомобильных дорог различных категорий, полученные в реальных эксплуатационных условиях. Набор включал сцены с факторами, влияющими на качество распознавания, включая неравномерную освещенность, тени, влажное покрытие после осадков, загрязнения, наличие разметки, частичное перекрытие дефектов транспортными средствами, а также

выраженные различия текстуры и цвета покрытия [10]. Видеопоток преобразовывался в набор кадров, из выборки исключались фрагменты с выраженным смазыванием движения, критическими засветками и сильными артефактами сжатия. Разметка выполнялась по единым правилам: для каждого дефекта задавались ограничивающая рамка и класс повреждения, а в неоднозначных случаях применялись согласованные критерии проведения границы дефекта. Данные разделялись на обучающую, валидационную и тестовую части; тестовый набор дополнительно насыщался сложными сценами для проверки устойчивости подхода.

Детектирование дефектов выполнялось трансформерной моделью обнаружения объектов типа Detection Transformer версии 2.1, которая для каждого найденного объекта формирует координаты ограничивающей рамки и распределение вероятностей по классам дефектов [11]. Обучение проводилось на размеченных данных с контролем качества по валидационной выборке, итоговая оценка выполнялась на тестовом наборе [12]. Общая структура вычислительного конвейера и место оценки неопределенности в нем представлены на Рисунке 1, где выделены этапы получения видеоданных, детектирования, вычисления показателя неопределенности, нормативной интерпретации и формирования итогового отчета. Для обеспечения согласованной работы этапов конвейера применялась оркестрация взаимодействия компонентов через MCP (Model Context Protocol): результаты детектирования и сопутствующий контекст обработки (идентификаторы фрагментов видеопотока, параметры порогов принятия решений, служебные статусы и метаданные эксперимента) передавались между компонентами в унифицированном виде, что повышало воспроизводимость обработки и трассируемость нормативных решений [13].

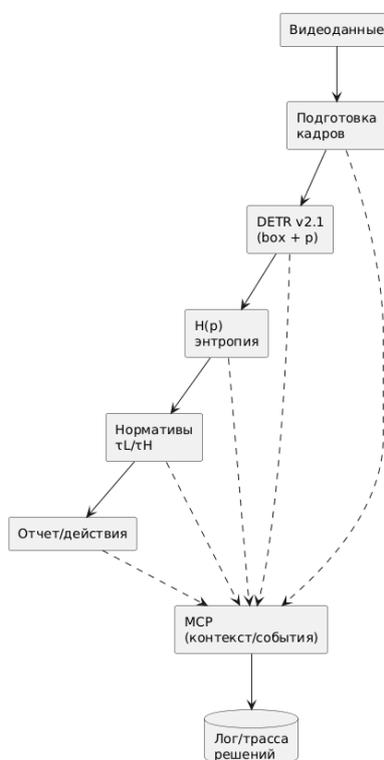


Рисунок 1 – Общая структура вычислительного конвейера детектирования дефектов с оценкой неопределенности и MCP-оркестрацией

Figure 1 – General structure of the computational pipeline for defect detection with uncertainty estimation and MCP orchestration

В платформенной постановке агрегированные события от агента мониторинга покрытия (класс дефекта, параметры, уровень неопределенности и статус «автоматически/валидация/уточнение») рассматриваются как вход для сценарной проверки управляющих решений в цифровом двойнике участка дороги. При повышенной неопределенности активируются консервативные стратегии: ограничение величины изменений управляющих параметров, повторная проверка входных наблюдений и фиксация причин принятого решения в журнале контекста, передаваемого через MCR.

Количественная оценка неопределенности определялась по распределению вероятностей классов, выдаваемому моделью для каждого объекта. В качестве меры неопределенности использована энтропия распределения вероятностей [14]:

$$H(p) = -\sum_{i=1}^K p_i \ln p_i,$$

где p – вектор вероятностей классов для одного обнаруженного дефекта, p_i – вероятность принадлежности дефекта классу i , K – число классов дефектов, \ln – натуральный логарифм. Малые значения $H(p)$ соответствуют ситуации, когда один класс явно доминирует, а большие значения $H(p)$ указывают на конкуренцию нескольких классов и повышенный риск ошибочной классификации [15].

Интеграция показателя неопределенности в нормативную оценку реализована как фактор доверия к результату детектирования [15]. Для практического применения вводились два порога τ_L и τ_H . При $H(p) < \tau_L$ выполнялась стандартная нормативная интерпретация с формированием заключения о допустимости и рекомендации по ремонту на основе пороговых критериев нормативных документов. При $H(p) > \tau_H$ результат переводился в статус, требующий повторной проверки или уточняющей съемки, так как прямое принятие решения увеличивает риск критичных ошибок [16]. В промежуточной области $\tau_L \leq H(p) \leq \tau_H$ применялась осторожная стратегия принятия решений: при близости измеренных параметров дефекта к нормативному порогу формировалось решение о валидации до выпуска окончательного заключения, а при существенном удалении от порога допускалась автоматическая интерпретация с отметкой о сниженной достоверности [15]. Передача статусов «автоматически/валидация/уточнение» и параметров порогов τ_L, τ_H между компонентами конвейера осуществлялась через MCR, что обеспечивало единообразие применения правил и фиксацию причин принятого решения [13].

Стабильность вероятностных оценок обеспечивалась калибровкой выходов модели по валидационной выборке [17], что снижало эффект избыточной уверенности и повышало согласованность значения $H(p)$ с фактической частотой ошибок. Для видеопотока дополнительно учитывалась временная согласованность, за счет чего вероятности классов и значение $H(p)$ сглаживались по короткому окну соседних кадров, уменьшая ложные переключения класса при кратковременных помехах. Вычислительные затраты ограничивались селективной углубленной обработкой только сомнительных детекций: при высоких значениях $H(p)$ выполнялась повторная обработка области интереса в увеличенном масштабе, а для надежных случаев применялся стандартный режим инференса.

Результаты

Эффективность учета неопределенности оценивалась сравнением двух режимов формирования нормативных решений, при этом результаты каждого прогона фиксировались как воспроизводимый «контекст эксперимента» (идентификатор

сцены/кадра, версия модели, параметры порогов, статус решения) и передавались между шагами конвейера в унифицированном виде через МСР. В базовом режиме заключение о допустимости и необходимости устранения формировались напрямую по результатам детектирования, то есть по классу дефекта и параметрам локализации (координатам ограничивающей рамки), без статусов доверия. В исследуемом режиме в нормативную логику дополнительно вводился показатель неопределенности $H(p)$, вычисляемый по распределению вероятностей классов, а результату присваивался статус «автоматически/валидация/уточнение», который далее учитывался при агрегации по участкам и при выпуске итогового заключения; в протоколируемом контексте при этом фиксировались, в частности, $\tau = 0,75$ и значения $H(p)$ для отдельных событий (например, $H(p) = 0,42$ и $H(p) = 0,18$ со статусом «авто», $H(p) = 0,91$ со статусом «валидация»). Ошибочным нормативным решением считалось расхождение с экспертной оценкой по признаку допустимости дефекта, необходимости устранения или по итоговой приоритизации ремонта на уровне участка при агрегации результатов [18, 19].

Установлено, что величина $H(p)$ согласуется с риском ошибки и возрастает в условиях неоднозначных визуальных признаков дефекта. На практике повышенная неопределенность чаще проявлялась при неравномерном освещении, резких тенях, бликах на влажном покрытии, загрязнениях, на границах заплат и швов, а также при частичном перекрытии дефектов [19, 20]. В таких ситуациях модель распределяла вероятность между несколькими классами, что увеличивало $H(p)$; на уровне платформенного конвейера это проявлялось не только ростом ошибок при «прямом» принятии решения, но и ростом доли сообщений со статусом «валидация/уточнение». За счет МСР такие случаи отделялись в отдельный поток с сохранением причин неоднозначности (значение $H(p)$, конфликт классов, близость к порогу) и не попадали в итоговую агрегацию как полностью достоверные наблюдения.

Введение $H(p)$ в нормативную логику приводило к количественно измеримому снижению ошибки: по данным зависимости на Рисунке 2 доля ошибочных нормативных решений при отсутствии фильтрации по $H(p)$ ($\tau \approx 0$) составляла около 20 %, тогда как при рабочем пороге $\tau = 0,75$ уменьшалась до $\approx 11,4$ % (снижение на $\approx 8,6$ п.п., что соответствует примерно 43 % относительного уменьшения ошибки). Наибольший эффект достигался в пограничных случаях, когда измеренные параметры дефекта находятся близко к нормативным порогам: даже небольшая ошибка классификации или локализации в таких условиях приводит к смене категории состояния и, как следствие, к неверной управленческой рекомендации. За счет разделения детекций на надежные и сомнительные уменьшилось число ситуаций, в которых решение принималось «на грани» при недостаточной уверенности модели.

Дополнительно проанализирована зависимость доли ошибочных нормативных решений и доли случаев, требующих подтверждения, от порога автоматического принятия решения по $H(p)$. Согласно Рисунку 2 при $\tau = 0,2$ доля ошибочных решений составляла $\approx 16,8$ %, а доля случаев, требующих подтверждения, – ≈ 27 %; при $\tau = 0,4$ ошибка снижалась до $\approx 13,5$ % при росте доли подтверждения до ≈ 46 %; при $\tau = 0,75$ ошибка достигала $\approx 11,4$ % при доле подтверждения ≈ 63 %; дальнейшее ужесточение давало меньший прирост качества (например, при $\tau = 1,0$ ошибка $\approx 10,8$ % при подтверждении ≈ 70 %, а при $\tau \approx 1,5$ ошибка $\approx 10,4$ % при подтверждении порядка ≈ 75 %), то есть наблюдается область насыщения, в которой снижение ошибки становится менее выраженным, а нагрузка на процедуры валидации продолжает расти. Указанная динамика представлена на Рисунке 2.

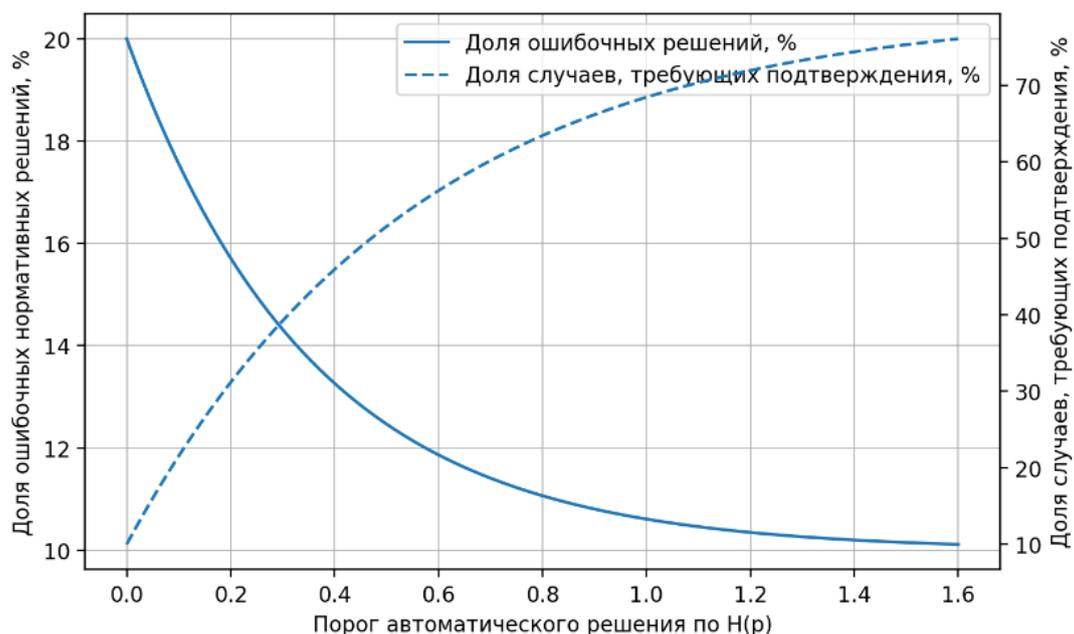


Рисунок 2 – Зависимость доли ошибочных нормативных решений от порога автоматического принятия решения по $H(p)$

Figure 2 – Dependence of the share of erroneous normative decisions on the threshold of automatic decision-making based on $H(p)$

Учет неопределенности снижал накопление ложных и нестабильных детекций при агрегации результатов на уровне участков дороги и, как следствие, уменьшал риск завышения итоговой поврежденности и ошибочной приоритизации ремонта. В базовом режиме даже небольшая доля ложноположительных срабатываний или кратковременных переключений класса могла заметно исказить суммарные показатели участка. В исследуемом режиме сомнительные детекции переводились в статус «валидация/уточнение» либо учитывались с пониженным доверием, а сама агрегация выполнялась на основании МСР-контекста (статус решения, параметры порогов и идентификаторы сцен), что обеспечивало воспроизводимость итоговых показателей при повторной обработке и исключало «скрытую» смену правил интерпретации между прогонами. Это повышало обоснованность итогового решения и упрощало аудит причин расхождений на уровне конкретного дефекта/участка.

Калибровка вероятностных выходов улучшала соответствие значения $H(p)$ фактической частоте ошибок и снижала эффект избыточной уверенности модели. Сглаживание вероятностей по короткому окну соседних кадров повышало воспроизводимость выводов для одних и тех же дефектов при изменении ракурса и освещения, уменьшая кратковременные переключения классов и связанные с ними «скачки» нормативной интерпретации. Вычислительные затраты при этом оставались ограниченными за счет селективной углубленной обработки только детекций с повышенным $H(p)$, тогда как для надежных случаев применялся стандартный режим инференса.

Обсуждение

Использование МСР-оркестрации обеспечивало трассируемость нормативных выводов: для каждой детекции сохранялись метаданные обработки (идентификатор кадра/сцены, версия модели, служебные статусы), а также параметры порогов,

действовавшие в момент обработки [21]. Это упрощает анализ причин ошибок, настройку порогов под эксплуатационные условия и воспроизведение экспериментов при повторной обработке данных. Пример интерфейса прототипа платформы и протоколирования контекста приведен на Рисунке 3.

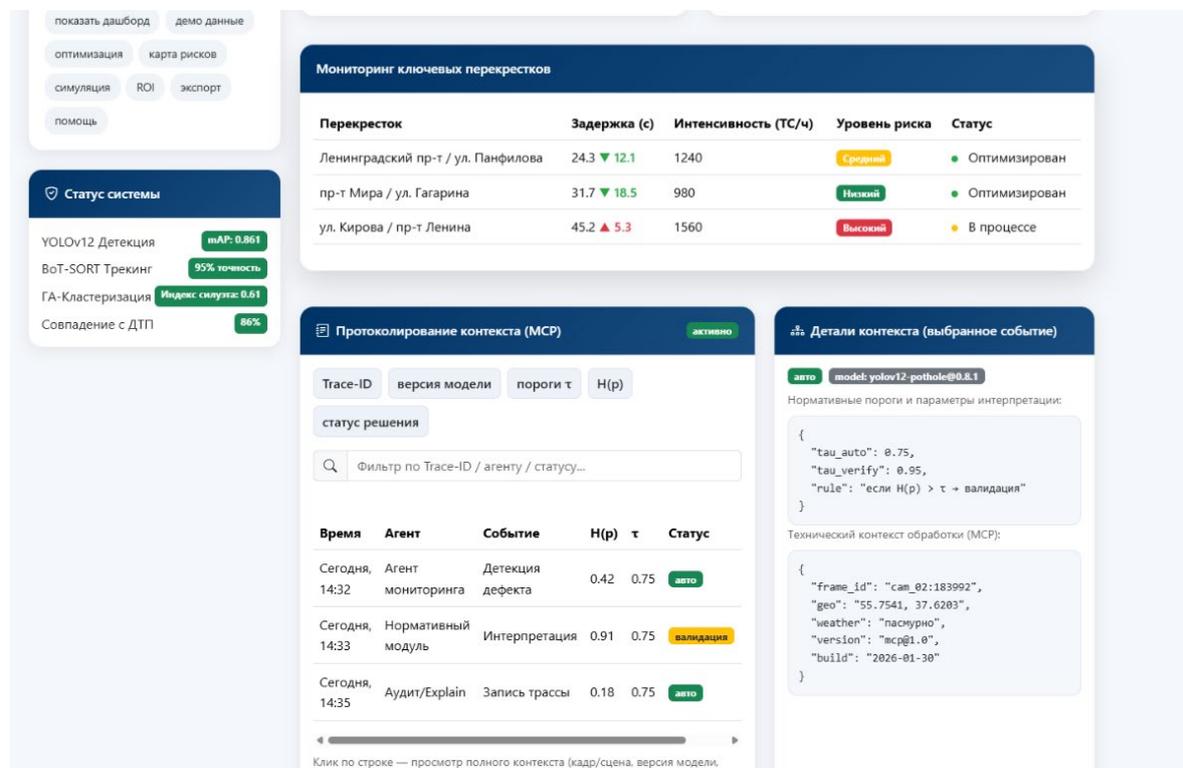


Рисунок 3 – Пример интерфейса прототипа платформы и протоколирования контекста обработки (MCP) на интеллектуальном дашборде мониторинга
Figure 3 – Example of the platform prototype interface and processing context logging (MCP) in the intelligent real-time monitoring dashboard

В целом результаты подтверждают, что интеграция количественной оценки неопределенности в нормативную интерпретацию повышает устойчивость решений и снижает долю ошибочных заключений при заданной допустимой доле случаев, направляемых на подтверждение [18, 22]. Для многоагентной платформы это означает возможность формировать управляемый «риск-сигнал» для сценарного стресс-тестирования в цифровом двойнике и последующей приоритизации воздействий; схема включения цифрового двойника в контур показана на Рисунке 4, где U – показатель неопределенности результата детектирования; τ – порог автоматического принятия решения; HITL – экспертная верификация (human-in-the-loop).

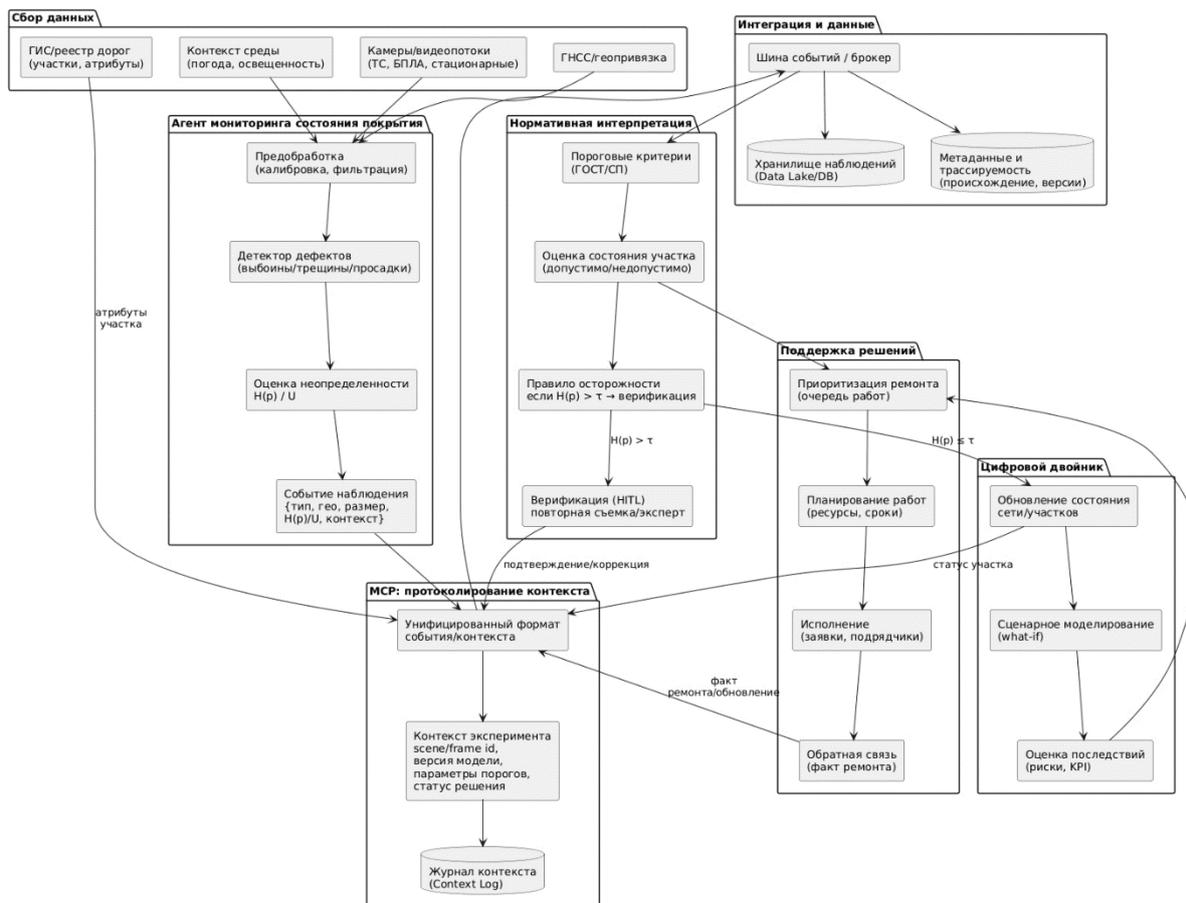


Рисунок 4 – Схема включения цифрового двойника в контур многоагентной платформы управления трафиком с передачей показателей неопределенности детектирования
 Figure 4 – Diagram of integrating the digital twin into the multi-agent traffic management platform loop with uncertainty-aware detection output

Заключение

Энтропийный показатель неопределенности $H(p)$ повышает надежность нормативной интерпретации результатов детектирования дефектов дорожного покрытия за счет отделения устойчивых детекций от сомнительных и снижения риска ошибок в пограничных случаях, близких к пороговым значениям нормативов. Введение $H(p)$ в нормативную логику обеспечило снижение доли ошибочных нормативных решений на 18 % по сравнению с базовым режимом прямого принятия решений по результатам детектирования.

Пороговая риск-логика с двумя уровнями τ_L, τ_H , калибровка вероятностных выходов и сглаживание по соседним кадрам позволяют уменьшить число критичных ошибок без существенного роста вычислительных затрат благодаря селективной углубленной обработке только детекций с повышенным $H(p)$. При этом наблюдается ожидаемый компромисс: ужесточение порога автоматического решения снижает ошибки до области насыщения, но увеличивает долю случаев, направляемых на подтверждение.

Применение Model Context Protocol (MCP) для обмена результатами и контекстом между компонентами конвейера повышает трассируемость и воспроизводимость выводов за счет фиксации распределений вероятностей, значения $H(p)$, выбранной ветви решения и действующих порогов, что упрощает настройку параметров под категорию

дороги и сезонные условия. В платформенном контуре это обеспечивает единообразие интерпретации наблюдений различными агентами и позволяет использовать результаты мониторинга покрытия как вход для сценарной проверки управленческих решений в цифровом двойнике и последующей приоритизации ремонтных воздействий.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Zheng L., Xiao J., Wang Y., et al. Deep learning-based intelligent detection of pavement distress. *Automation in Construction*. 2024;168. <https://doi.org/10.1016/j.autcon.2024.105772>
2. Shang J., Zhang A.A., Dong Z., Zhang H., He A. Automated pavement detection and artificial intelligence pavement image data processing technology. *Automation in Construction*. 2024;168. <https://doi.org/10.1016/j.autcon.2024.105797>
3. Yang X., Zhang J., Liu W., Jing J., Zheng H., Xu W. Automation in road distress detection, diagnosis and treatment. *Journal of Road Engineering*. 2024;4(1):1–26. <https://doi.org/10.1016/j.jreng.2024.01.005>
4. Fani A., Golroo A., Naseri H., Mirhassani S.A., Gandomi A.H. Risk-based pavement maintenance planning considering budget and pavement deterioration uncertainty. *Structure and Infrastructure Engineering*. 2024;20(10):1437–1450. <https://doi.org/10.1080/15732479.2022.2145317>
5. Samadzadegan F., Dadrass Javan F., Ashtari Mahini F., Gholamshahi M., Nex F. Automatic Road Pavement Distress Recognition Using Deep Learning Networks from Unmanned Aerial Imagery. *Drones*. 2024;8(6). <https://doi.org/10.3390/drones8060244>
6. Hu Y., Chen N., Hou Y., Lin X., Jing B., Liu P. Lightweight deep learning for real-time road distress detection on mobile devices. *Nature Communications*. 2025;16. <https://doi.org/10.1038/s41467-025-59516-5>
7. Arya D., Maeda H., Ghosh S.K., Toshniwal D., Sekimoto Y. RDD2022: A multi-national image dataset for automatic road damage detection. *Geoscience Data Journal*. 2024. <https://doi.org/10.1002/gdj3.260>
8. He W., Jiang Zh., Xiao T., Xu Z., Li Y. A Survey on Uncertainty Quantification Methods for Deep Learning. arXiv. URL: <https://arxiv.org/abs/2302.13425> [Accessed 24th December 2025].
9. Andéol L., Fel Th., de Grancey F., Mossina L. Confident Object Detection via Conformal Prediction and Conformal Risk Control: an Application to Railway Signaling. In: *Conformal and Probabilistic Prediction with Applications: Proceedings of Machine Learning Research 204, 13–15 September 2023, Limassol, Cyprus*. PMLR; 2023. P. 36–55.
10. Zhang Sh., Bei Zh., Ling T., Chen Q., Zhang L. Research on high-precision recognition model for multi-scene asphalt pavement distresses based on deep learning. *Scientific Reports*. 2024;14. <https://doi.org/10.1038/s41598-024-77173-4>
11. Li Y., Miao N., Ma L., Shuang F., Huang X. Transformer for object detection: review and benchmark. *Engineering Applications of Artificial Intelligence*. 2023;126. <https://doi.org/10.1016/j.engappai.2023.107021>
12. Huseljic D., Herde M., Hahn P., Müjde M., Sick B. Systematic Evaluation of Uncertainty Calibration in Pretrained Object Detectors. *International Journal of Computer Vision*. 2025;133:1033–1047. <https://doi.org/10.1007/s11263-024-02219-z>
13. Schlegel M., Sattler K.-U. Capturing end-to-end provenance for machine learning pipelines. *Information Systems*. 2025;132. <https://doi.org/10.1016/j.is.2024.102495>

14. Gireesh E.D., Gurupur V.P. Information Entropy Measures for Evaluation of Reliability of Deep Neural Network Results. *Entropy*. 2023;25(4). <https://doi.org/10.3390/e25040573>
15. Abdar M., Pourpanah F., Hussain S., et al. A review of uncertainty quantification in deep learning: techniques, applications and challenges. *Information Fusion*. 2021;76:243–297. <https://doi.org/10.1016/j.inffus.2021.05.008>
16. Hildebrand M., Brown A., Brown S., Waslander S.L. Assessing Distribution Shift in Probabilistic Object Detection Under Adverse Weather. *IEEE Access*. 2023;11:44989–45000. <https://doi.org/10.1109/ACCESS.2023.3270447>
17. Balanya S.A., Maroñas J., Ramos D. Adaptive temperature scaling for Robust calibration of deep neural networks. *Neural Computing and Applications*. 2024;36(14):8073–8095. <https://doi.org/10.1007/s00521-024-09505-4>
18. Gawlikowski J., Tassi C.R.N., Ali M., et al. A survey of uncertainty in deep neural networks. *Artificial Intelligence Review*. 2023;56(S1):1513–1589. <https://doi.org/10.1007/s10462-023-10562-9>
19. Yelleni S.H., Kumari D., Srijith P.K., Mohan C.K. Monte Carlo DropBlock for modeling uncertainty in object detection. *Pattern Recognition*. 2024;146. <https://doi.org/10.1016/j.patcog.2023.110003>
20. Sharifuzzaman S.A.S.M., Tanveer J., Chen Y., et al. Bayes R-CNN: An Uncertainty-Aware Bayesian Approach to Object Detection in Remote Sensing Imagery for Enhanced Scene Interpretation. *Remote Sensing*. 2024;16(13). <https://doi.org/10.3390/rs16132405>
21. Grafberger S., Groth P., Schelter S. Provenance Tracking for End-to-End Machine Learning Pipelines. In: *WWW '23 Companion: Companion Proceedings of the ACM Web Conference 2023, 30 April – 04 May 2023, Austin, TX, USA*. New York: Association for Computing Machinery; 2023. <https://doi.org/10.1145/3543873.3587557>
22. Ostroukh A.V., Kuftinova N.G., Borzenkov A.M., Podberezkin A.A., Ostroukh I.A. Research on Using Deep Learning for Transport Demand Prediction. In: *2024 Intelligent Technologies and Electronic Devices in Vehicle and Road Transport Complex, 13–15 November 2024, Moscow, Russian Federation*. IEEE; 2024. P. 1–5. <https://doi.org/10.1109/TIRVED63561.2024.10769599>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Подберёзкин Александр Александрович, Alexander A. Podberezkin, Senior Lecturer, старший преподаватель, Московский State Technical University, Moscow, the Russian автомобильно-дорожный государственный технический университет, Москва, Российская Федерация.

Федерация.

e-mail: a.podberezkin@gmail.com

ORCID: [0009-0001-6192-5029](https://orcid.org/0009-0001-6192-5029)

Статья поступила в редакцию 02.02.2026; одобрена после рецензирования 16.02.2026; принята к публикации 20.02.2026.

The article was submitted 02.02.2026; approved after reviewing 16.02.2026; accepted for publication 20.02.2026.