

УДК 004.89

## ПОСТРОЕНИЕ КАРТЫ РАСПРЕДЕЛЕНИЯ АНОМАЛИЙ ИСПОЛНЕНИЯ ЛОГИСТИЧЕСКИХ ПРОЕКТОВ В УСЛОВИЯХ НЕОПРЕДЕЛЁННОСТИ

**Беляков Станислав Леонидович**, д.т.н., профессор, Южный федеральный университет (ЮФУ), Таганрог, Россия, E-mail: sbelyakov@sfnedu.ru

**Израилов Лев Алексеевич**, аспирант, Южный федеральный университет (ЮФУ), Таганрог, Россия, E-mail: izrailev@sfnedu.ru

### АННОТАЦИЯ

Для успешной реализации логистической операции необходимо прогнозировать возможность возникновения непредвиденных ситуаций. Они способны вызвать нежелательные издержки. Требуется принятие решений, способствующих преодолению ситуаций. Однако такие решения нередко приходится принимать в условиях неполноты и неопределённости доступной информации. Изменчивость окружающей среды требует постоянной актуализации информации о факторах, влияющих на реализацию логистических операций. Получить полное представление обо всех этих факторах практически невозможно, поэтому при принятии решений важную роль играют опыт и знания. Впрочем, применимость знаний о решении отдельно взятой ситуации ограничивается факторами, которые были наблюдаемы в момент реализации. С целью преодоления данного недостатка в статье предлагается разработка модели переноса полезного знания из прецедентов в новую ситуацию на примере задачи определения зон влияния аномалий логистического проекта. Для реализации модели используется метод рассуждений на основе прецедентов (Case-Based Reasoning). Он позволяет решить новую задачу, применяя или адаптируя ранее используемое решение. Логистические проекты описываются геоинформационными моделями.

**Ключевые слова:** интеллектуальные геоинформационные системы, геоинформационные системы, прецедентный анализ, принятие решений в условиях неопределённости.

## BUILDING A DISTRIBUTION MAP OF ANOMALIES IN THE EXECUTION OF LOGISTICS PROJECTS UNDER CONDITIONS OF UNCERTAINTY

**Stanislav L. Belyakov**, Doctor of Technical Sciences, Professor, Southern Federal University (SFU), Taganrog, Russia, E-mail: sbelyakov@sfnedu.ru

**Lev A. Izrailev**, PhD student, Southern Federal University (SFU), Taganrog, Russia, E-mail: izrailev@sfnedu.ru

### ANNOTATION

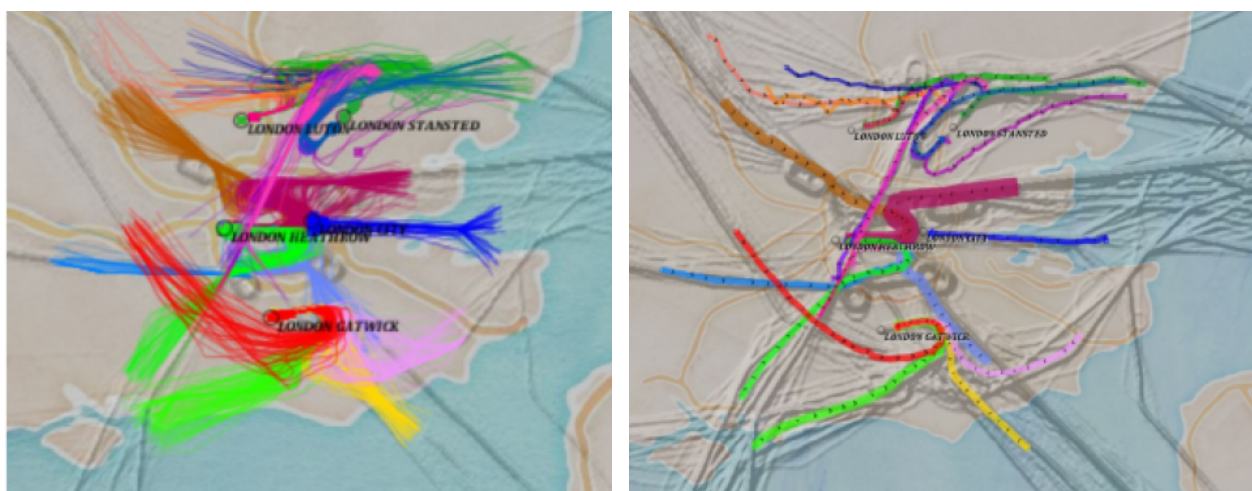
For the successful implementation of a logistics operation, it is necessary to predict the possibility of unforeseen situations. They can cause undesirable costs. It requires making decisions that help to overcome situations. However, such decisions often have to be made in conditions of incompleteness and uncertainty of the available information. The variability of the environment requires constant updating of information about the factors affecting the implementation of logistics operations. It is almost impossible to get a complete picture of all these factors, so experience and knowledge play an important role in making decisions. However, the applicability of knowledge about solving a particular situation is limited by the factors that were observed at the time of implementation. In order to overcome this disadvantage, the article proposes the development of a model for transferring useful knowledge from precedents to a new situation using the example of the problem of determining the zones of influence of anomalies in a logistics project. The use-Case-Based Reasoning method is used to implement the model. It allows you to solve a new problem by applying or adapting a previously used solution. Logistics projects are described by geoinformation models.

**Keywords:** intelligent geoinformation systems, geoinformation systems, precedent analysis, decision-making in conditions of uncertainty.

## Введение

Состояние неопределённости остается одной из ключевых проблем принятия решений в логистическом проекте. В транспортных системах логистическим проектом называют совокупность процессов, связанных с планированием и оптимизацией перевозок грузов, проектированием цепей поставок, проектированием и оптимизацией работы склада и т. д. [26]. Состояние неопределенности представляют собой ситуации, в которых отсутствует полная информация о факторах, влияющих на результат выполнения логистических операций, в результате чего возникает опасность возникновения ущерба от неверно принятых решений.

Изменчивость окружающей среды становится важной проблемой в области управления логистикой. Управление логистикой определяется качеством принимаемых решений в таких условиях, когда доступная информация представляет собой ограниченный набор известных факторов, влияющих на реализацию проекта [5]. Получить полное представление обо всех этих факторах практически невозможно, поэтому при принятии решений важную роль играют знания и опыт, полученный при реализации предыдущих проектов. Однако применимость опыта решения отдельно взятой ситуации ограничивается факторами, которые были наблюдаемы в момент реализации. Поэтому эффективнее стремиться к обобщению множества однотипных случаев для возможности определения всех возможных состояний, при которых применимо то или иное решение. Иными словами, следует определить допустимые преобразования ситуации, которые не изменяют ее суть.



**Рис. 1** – Обобщение траекторий движущихся объектов [20]

Рассмотрим следующий пример. На рисунке 1 (а) представлено множество траекторий движения летательных аппаратов в течении дня. На рисунке 1 (б) данные траектории были обобщены с помощью инструментов кластеризации. Представление множества отдельных траекторий в виде области допустимых траекторий полета (допустимых преобразований), значительно упрощает восприятие и позволяет выделить основные направления движения. В случае отсутствия информации о необходимой траектории движения маршрут движения может быть выбран в пределах области допустимых преобразований.

Накопленный опыт реализации проектов позволяет оценивать риски, связанные с возникновением непредвиденных ситуаций в новом проекте по аналогии с уже известными случаями. Множество таких ситуаций в данной работе будут рассматриваться как аномалии логистического проекта.

Таким образом, в статье рассматривается возможность принятия решений в области логистического проекта в условиях неопределенности на основе его картографического представления. Основной целью является разработка модели переноса полезного знания из прецедентов в новую ситуацию на примере задачи определения зон влияния аномалий логистического проекта. Использование данной модели позволит определять зоны проявления аномалий при отсутствии информации о факторах и причинах их возникновения.

## 1. Обзор известных решений

Проблема принятия решений в условиях неопределённости в логистическом проекте исследуется довольно давно. Одним из направлений исследований является теория управления рисками. В рамках данной теории определяются основные решения и последствия их принятия в условиях неопределённости [3]. Они могут быть определены в том числе путем обобщения статистических данных [12]. Однако из-за непредсказуемости некоторых факторов, влияющих на последствия решений, такие решения составляют риск, который считается нежелательным и требует принятия превентивных мер, что негативно сказывается на эффективности проекта.

Говоря о рисках, отдельно стоит выделить направление аварийной логистики [7, 16]. Ее основная цель – максимально сократить время и свести к минимуму потери в результате аварийных ситуаций за счет эффективного распределения логистических процессов. Часто такие ситуации обладают неопределённостью данных, вследствие чего принятия решений в значительной степени выполняются экспертным методом и зависят от накопленного опыта решений похожих ситуаций [14]. В то же время субъективность эксперта способствует принятию необоснованных решений.

С целью преодоления субъективности разрабатываются информационные системы, использующие методы машинного обучения для прогнозирования и поддержки принятия решений [9, 19]. Подходы к машинному обучению выходят за рамки традиционных ограничений благодаря возможностям распознавания образов, которые обнаруживают сложные взаимосвязи в многомерных данных, постоянно адаптируясь к меняющимся условиям без ручного вмешательства эксперта [11].

В контексте логистики стоит упомянуть муравьиные алгоритмы [15]. Муравьиные алгоритмы моделируют процесс принятия решения на основе коллективного поведения. Каждый «муравей» в алгоритме представляет собой отдельное решение, которое постепенно улучшается в процессе поиска. Это позволяет исследовать множество возможных вариантов и находить нереализованные возможности для оптимизации. Кроме того, при наличии новых данных алгоритм способен адаптироваться к изменениям в условиях. Проведённые исследования [17, 18] демонстрируют эффективность алгоритма. Между тем, неустойчивость качества решения при изменении параметров следов «феромонов» и ограниченности эвристической информации составляет существенный недостаток для ситуаций неопределённости.

Другим направлением является использование имитационных моделей [4]. Имитационные модели иногда рассматриваются как «цифровые двойники» логистической системы. Такие модели позволяют моделировать систему максимально приближённую к реальности и анализировать реализацию проекта в разных условиях. Однако применение таких моделей в условиях недостатка и неопределённости информации затруднительно. Из-за невозможности учесть некоторые факторы, снижается надёжность результатов. Также возникает проблема актуализации модели вследствие изменения параметров реального объекта.

В условиях усложнения структуры логистических проектов, возникает интерес к созданию больших языковых моделей (LLM, Large Language Models) для использования в задачах управления. Такие модели могут анализировать статистические данные, а также динамичные внешние факторы. Например, используя LLM, менеджеры логистических проектов могут получить рекомендации по оптимизации маршрутов доставки или распределению ресурсов [13]. Впрочем, нерешёнными остаются проблемы переобучения и «галлюцинирования» таких моделей. Степень надёжности ответов находится под большим вопросом.

В работе [22] отмечаются следующие недостатки использования LLM:

1. Неоднозначность пользовательских запросов. Пользователь рассуждает на интуитивном уровне, из-за чего часто опускает контекстуальные детали. Например, запрос «Покажи мне зоны затопления» без конкретных данных об осадках, топографии или временных рамок способен вызывать путаницу в ответах.
2. Поверхностные знания предметной области. Нерешённой остается проблема актуализации языковой модели. Запросы, требующие глубокого осмысления и новых знаний предметной области, могут привести к неполным или неверным результатам.

Таким образом, анализ литературы позволил сформулировать следующие недостатки существующих решений:

- Некоторые исследования чрезмерно фокусируются на машинном автоматизированном процессе принятия решений, игнорируя потенциал гибких суждений и опыта людей, принимающих решения в сложных ситуациях (в том числе в сценариях аварийной логистики).
- Существующие системы сосредоточены на стратегическом управлении и планировании. Им не хватает способности адаптироваться к изменениям в предметной области. В условиях изменчивых сценариев логистики и при недостатке информации, система не может своевременно предоставлять предложения для принятия решений.
- При проектировании систем поддержки принятия решений не всегда уделяется внимание представлению информации в интерфейсе интуитивно понятным образом, что затрудняет быстрое получение ключевой информации пользователем и влияет на эффективность принятия решений.
- Чтобы иметь возможность определить необходимый порядок действий, требуется создание сложных моделей, которые учитывают все возможные варианты развития ситуаций. Для их создания требуется сбор и накопление больших объемов данных, которые со временем устаревают из-за изменений в предметной области.

Преодоление данных недостатков возможно с помощью создания самообучающихся систем на основе опыта. Одним из методов реализации таких систем является прецедентный анализ.

Прецедентный анализ (CBR-анализ) используется для решения задач, используя ранее полученные прецеденты. В отличие от традиционных методов, которые требуют строгих правил и моделей, прецедентный анализ предлагает гибкость и адаптивность, а также возможность накапливать опыт принятия решений за счет применения CBR-цикла. Благодаря этому системы рассуждений на основе прецедентов нашли свое применение в задачах принятия решений для трудно формализуемых объектов управления, а также в сложных и динамичных предметных областях [1, 2]. Например, в работе [3] предлагается разработка системы поддержки принятия решений на основе рассуждения по прецедентам по оценке безопасности участка транспортной системы города. Однако данная система рассматривает пространственные характеристики, что создает проблему учета пространственного контекста.

Сочетание пространственной визуализации и интеллектуального метода анализа данных рассматривается в рамках создания методов геовизуальной аналитики и геоинформационных систем (ГИС). Такие системы отличаются высокой степенью интерактивности и множеством типов визуального представления пространственных данных, что можно считать важным преимуществом для принятия решений в условиях неопределенности. В работе [8] отмечается потенциал использования ГИС в исследованиях логистических проектов. Прежде всего, он играет важную роль в сборе данных, которые могут быть использованы в ходе текущего анализа, а также в последующие годы при сравнении с другими проектами.

Возможность «увидеть ситуацию», а не только оценить ее качественные и количественные характеристики, позволяет определить их сходства с учетом топологических особенностей [10]. Например, при планировании нового логистического проекта можно использовать геовизуальные методы для отображения на карте ранее реализованных проектов и принятых решений в новых условиях [6]. В свете этого интерес вызывают работы, посвященные применению рассуждений на основе географических знаний [21]. При этом, в работе отмечается, что доступные сегодня геоданные страдают неполнотой данных, что еще раз подчеркивают актуальность разработки моделей рассуждений в условиях неопределённости.



## 2. Форма представления знаний о аномалиях в логистическом проекте

Область реализации логистического проекта (ЛП) представляет собой пространство, в котором протекают процессы, связанные с выполнением основных его функций. Область ЛП условно можно задать тремя типами объектов: центры ЛП, маршруты ЛП и прецеденты ЛП. Центры ЛП – это физические или виртуальные локализации, которые являются узловыми точками в системе логистики. Маршруты ЛП представляют собой заранее определенные пути, по которым осуществляются перевозки от одного центра ЛП к другому.

Определим понятие аномалия, как возникновение в случайный момент времени непредвиденной ситуации, когда ожидания от совершения одного из процессов не выполняются. Например, процесс движения из точки А в В оказывается невозможен или длительность его выполнения значительно выше прогнозируемого. Тем не менее, не всегда аномалия в ЛП может характеризоваться аварийной ситуацией. Непредвиденные изменения условий могут не создавать угрозу безопасности, однако могут оказать негативное влияние на проект [25]. Например, увеличить временные издержки.

Возникновение аномалии, как и любой иной ситуации, является следствием совокупности факторов. Факторы привязаны к месту проявления (пространству) и могут быть связаны с природными, экономическими, социальными и технологическими условиями.

Знание о аномалиях представляет собой набор отношений и взаимосвязей между факторами окружающей среды, топологией местности и иных внешних условий. Представление аномалий в виде картографического объекта в отличие от простого словесного описания, позволяет отобразить в интуитивно понятной форме территории возникновения непредвиденных ситуаций и наделять соответствующими характеристиками прочие объекты в зависимости от того, как они соотносятся в пространстве.

Непрерывная область проявления аномалии составляет зону аномалий. Ситуации проявления аномалий представляют собой прецеденты. В качестве прецедентов рассматриваются конкретные проблемные ситуации, возникающие в процессе реализации логистических задач. Это могут быть примеры успешного решения логистической проблемы или описания неудачных случаев. Заложенный в прецеденты принцип «параметры ситуации – действие – обратная связь» позволяет в будущем заранее прогнозировать, к каким последствиям в похожих условиях ситуации, приведут те или иные принятые решения.

Модель прецедента представляется следующим образом:

$$CASE = (x_1, x_2, \dots, x_n, R)$$

где  $x_1, \dots, x_n$  – параметры ситуации, описывающей данный прецедент ( $x_1 \in X_1, x_2 \in X_2, \dots, x_n \in X_n$ ),  $R$  – решение,  $n$  – количество параметров прецедента, а  $X_1, \dots, X_n$  – области допустимых значений параметров прецедента.

Параметры ситуации позволяют определить свойства текущей ситуации, чтобы сравнить его с другими прецедентами. В случае нахождения близкого прецедента, решение может быть повторно применено, либо без изменений, либо с применением процедуры адаптации. Новый решенный прецедент становится частью базы прецедентов. Описанный выше процесс составляет CBR-цикл. В результате его выполнения система реализует принцип самообучения, накапливая опыт в виде базы прецедентов.

В пространстве прецедент может быть представлен как область (линейный, полигональный), либо как точечный объект. Сравнение прецедентов может быть выполнено с помощью метрик близости. Выбор метрики близости зависит от параметров прецедента и предметной области.

Согласно гипотезе компактности, схожие прецеденты чаще лежат в одном классе, чем в разных, а, следовательно, и их решения применимы для всего класса подобных ситуаций. Поэтому при сравнении прецедентов следует учитывать не только фактические параметры текущей ситуации, но и любые другие неучтенные факторы, которые могут оказаться важными. В частности, следует рассматривать пространственный контекст. С его помощью становится возможным отделить одну группу прецедентов от другой.

Для сравнения пространственных ситуаций разумно применить геоинформационные системы [24]. Они могут быть применены в том числе и в условиях неопределённости. Например, в ситуациях аварийного реагирования, когда поступающая информация ограничена лишь пространственными характеристиками, использование прецедентного

анализа совместно с ГИС может значительно повысить эффективность и обоснованность принимаемых решений [23].

ГИС обладают необходимым инструментарием для накопления и анализа прецедентов в пространстве, а также способны визуализировать допустимые преобразования свойств ситуации. При поиске решения они позволяют учесть не только топологические особенности первоначальной зоны, но и «смысловую близость». Смысловая близость прецедентов может быть определена через пространственное расположение и набор отношений с другими объектами. Близкие ситуации в пространстве обладают общим контекстом. При этом расположение необязательно должно быть идентичным. Как было сказано ранее, допустимые преобразования ситуации позволяют определить границы, в пределах которых прецеденты сохраняют ее суть.

### 3. Построение модели пространственного анализа аномалий

Рассмотрим поэтапно процесс переноса полезного знания из реализованных проектов в новую ситуацию на примере задачи определения зон влияния аномалий ЛП (Рис. 2).




Рис. 2 – Модель рассуждений

Первым этапом является извлечение информации о известных зонах аномалий. Сведения о них могут быть получены из ранее реализованных ЛП в той же области.

Второй этап – картографическое представление ЛП. Должна быть определена область выполнения и пространственное расположение элементов ЛП, а также информация о известных зонах аномалий.

Третий этап – пространственный анализ прецедентов. Необходимо определить тип пространственных отношений между прецедентами и известными зонами аномалий. Например, находится прецедент в границах или за ее пределами известной аномальной зоны.

В случае если прецедент находится «внутри» аномальной зоны, то выполняется извлечение и последующее обобщение прецедентов. Все найденные прецеденты в одной зоне принадлежат к соответствующему классу аномалий и формируют набор прецедентов аномальной зоны.

На четвертом этапе запускается CBR-цикл, в ходе которого прецеденты, которые находятся за пределами зон аномалий сравниваются с набором прецедентов зоны аномалий. Чтобы оценить принадлежность ситуации к зоне аномалий определим все прецеденты, которые принадлежат области реализованного ЛП и известной зоне аномалий. Например, в зоне аномалий один прецедент произошел с параметром «день», другой «ночь». Значит при поиске прецедентов следует рассматривать прецеденты, которые произошли ночью и днем. В то же время, учитывая фактор возможной ковариации параметров, если один прецедент произошел «ночь, дождь», а другой «день, ясно», то не следует рассматривать близким сочетание параметров «день, дождь», так как соотношение двух величин могут быть линейно зависимыми.

Если в границах зоны аномалий существует близкий прецедент, то его соответствующий класс назначается для прецедента. В случае если требуется отделить прецеденты с низкой степенью соответствия, при расчетах может быть использовано пороговое значение, ниже которого прецеденты не считаются близкими.

Пятый этап – расчет расстояния до ближайшего прецедента. Если расстояние больше смыслового буфера, то прецедент рассматривается как единичный случай и зоны аномалий для него не строятся. Если расстояние меньше смыслового буфера, то считаем, что прецеденты формируют общую зону аномалий. Новая зона рассматривается как синтезированная и сохраняется основные характеристики исходной. Ее форма и топологические свойства строятся в зависимости от соответствующих свойств исходной зоны аномалии и от количества найденных прецедентов.

В результате создаются следующие наборы данных:

1. Прецеденты известной аномальной зоны;
2. Синтезированные зоны аномалий;
3. Результат сравнения прецедентов.

Допустим существует ЛП. В области проекта  $W^*$  расположено множество логистических центров  $S^*$  и множество маршрутов движения  $R$  между ними. Также предполагаем наличие зон аномалий  $A^*$ , на основании наличия данных о прецедентах  $C$ . Выбор маршрута движения зависит от количества пересекаемых этим маршрутом зон аномалий и степенью их опасности. Информация о зонах аномалий в проекте  $M^*$  первоначально неизвестна. Таким образом, ЛП можно описать моделью

$$M^* = (W^*, S^*, R^*, A^*)$$

Известны два реализованных логистических проекта  $M_a$  и  $M_b$

$$M_a = (W_a, S_a, R_a, A_a), \quad \text{где } W_a \in W^*$$

$$M_b = (W_b, S_b, R_b, A_b), \quad \text{где } W_b \in W^*$$

Для проектов известны все зоны аномалий  $A_{a,b}$  в пределах их границ. Чтобы определить зоны аномалий  $A^*$  воспользуемся анализом известных зон из реализованных проектов  $M_a$  и  $M_b$  и прецедентов аномалий  $C^*$ , свойства которых заданы множеством параметров  $P$ . Модель зоны аномалий для области текущего проекта

$$A^* = (P, C^*), \text{ где } C^* \in W^*$$

Определим  $P$  при которых аномалия возникает. Для этого проверим прецеденты на соответствие области проектов  $M_a$  и  $M_b$

$$C_W^* = \{C_1^*, C_2^*, \dots, C_n^*\}, \text{ где } C_W^* \subset C^*$$

$$C_W^* \in W_a, C^* \in W_b$$

В результате получаем прецеденты, которые являются подмножеством известной зоны аномалий:

$$P_1 = [\{x_1 \ x_2 \ \dots\}, \{x_1 \ x_2 \ \dots\}, \dots \{x_1 \ x_2 \ \dots\}]$$

$$P_2 = [\{x_1 \ x_2 \ \dots\}, \{x_1 \ x_2 \ \dots\}, \dots \{x_1 \ x_2 \ \dots\}]$$

...

$$P_n = [\{x_1 \ x_2 \ \dots\}, \{x_1 \ x_2 \ \dots\}, \dots \{x_1 \ x_2 \ \dots\}]$$

Чтобы определить к какой аномалии принадлежат прецеденты проекта  $M^*$ , воспользуемся принятой метрикой близости  $N(P_n, C^*)$ . Затем, для определения пространственных характеристик построим границы новой зоны аномалий. Если для прецедента отсутствует по смыслу близкий прецедент, принимаем его статистически не значимым. Для таких прецедентов границы зоны аномалий не строятся.

**Эксперимент.** В ходе исследования проведен эксперимент, направленный на оценку эффективности предложенной модели на примере задачи определения зон аномалий исполнения логистического проекта в условиях неопределенности. Под условиями неопределённости рассматривался сценарий, при котором информация ограничена известными зонами аномалий из реализованных проектов и прецедентами проявления аномалий.

Для проверки модели использовалось программное обеспечение QGIS версии 3.42 и язык программирования Python.

Предположим, что имеется текущий ЛПП, в котором расположено 7 логистических центров, между которым построены маршруты (Рис. 3).




Рис. 3 – Схема проекта




Исходя из информации по реализованным проектам нам известны 5 различных типов зон аномалий, а также 61 прецедент, связанный с ними. Считаем, что других типов зон аномалий в области текущего проекта нет. Прецеденты заданы в виде точечных объектов. Параметры прецедента заданы 6 случайными параметрами с помощью функции  $\text{rand}(\min, \max)$ :

$\text{par 1} = \text{rand}(0, 10);$                        $\text{par 4} = \text{rand}(0, 10);$   
 $\text{par 2} = \text{rand}(0, 10);$                        $\text{par 5} = \text{rand}(0, 5);$   
 $\text{par 3} = \text{rand}(0, 10);$                        $\text{par 6} = \text{rand}(0, 5)$

Аналогичным образом, каждому прецеденту выбирается одно из решений  $\text{Solution} = \text{rand}(\min 1, \max 5)$ .

В результате, таблица примет следующий вид (Рис. 4):

Q Прецеденты — объектов всего: 61, отфильтровано: 61, выбрано: 0



	id	par1	par2	par3	par4	par5	par6	Solution	Anomaly	DegreeAttr
1	1	10	3	1	8	3	3	1	NULL	NULL
2	2	0	3	8	8	3	2	1	NULL	NULL
3	3	1	3	1	2	0	3	1	NULL	NULL
4	4	6	4	5	0	3	1	1	NULL	NULL
5	5	5	7	9	1	4	0	1	NULL	NULL
6	6	10	2	4	3	1	1	1	NULL	NULL
7	7	4	1	1	2	0	4	1	NULL	NULL
8	8	6	4	3	8	3	4	1	NULL	NULL
9	9	0	1	8	10	2	0	1	NULL	NULL
10	10	9	1	3	2	0	1	2	NULL	NULL
11	11	8	3	1	9	5	4	2	NULL	NULL
12	12	7	7	9	4	0	1	2	NULL	NULL
13	13	7	3	4	1	0	0	2	NULL	NULL
14	14	5	7	6	0	3	1	2	NULL	NULL
15	15	5	9	9	10	3	0	2	NULL	NULL
16	16	5	4	5	5	3	3	2	NULL	NULL
17	17	5	2	5	3	1	5	2	NULL	NULL
18	18	4	6	4	9	5	2	2	NULL	NULL
19	19	6	0	3	2	5	4	2	NULL	NULL
20	20	9	1	9	9	0	0	2	NULL	NULL

Рис. 4 – Первые 20 прецедентов

В границах, реализованных ЛП расположены центры А, F, D, В, С. Маршруты AF, FD, FC, DC, проходят через границы аномалий.

Задача – построить тематическую карту зон аномалий для области текущего ЛП на основе информации о реализованных проектах.

Проверим прецеденты на соответствие области известных реализованных проектов. В результате был получен следующий набор прецедентов аномалий и значения их параметров:

Anomaly 1 = [(2, 10, 9, 9, 5, 0), (1, 6, 2, 0, 4, 4), (3, 10, 8, 7, 4, 4), (10, 3, 1, 8, 3, 3)];

Anomaly 2 = [(2, 5, 3, 8, 0, 0), (5, 7, 6, 0, 3, 1), (4, 6, 4, 9, 5, 2)], (8, 5, 2, 1, 1, 2), (4, 10, 9, 3, 4, 4)];

Anomaly 3 = [(1, 6, 2, 0, 4, 4), (2, 4, 2, 9, 0, 3), (6, 8, 4, 5, 1, 5), (10, 9, 0, 10, 5, 0), (5, 3, 5, 4, 5, 1)];

Anomaly 4 = [(2, 8, 8, 1, 5, 5), (10, 2, 4, 3, 1, 1), (6, 4, 3, 8, 3, 4), (3, 0, 4, 8, 5, 3), (0, 5, 5, 1, 3, 1), (5, 2, 5, 3, 1, 5), (0, 1, 8, 10, 2, 0)];

Anomaly 5 = [(6, 4, 5, 0, 3, 1), (6, 0, 3, 3, 0, 0), (5, 10, 2, 0, 2, 0), (8, 0, 0, 9, 5, 2)]

В данном эксперименте, в качестве метрики близости была использована мера сходства по Хэммингу, как наиболее приемлемая:

$$S(C, T) = \frac{n_{CT}}{n}$$


где  $n_{CT}$  – число совпадающих признаков (параметров) у прецедента С и ситуации Т,  $n$  – общее количество признаков.

Определяем к какой зоне ближе всего будет расположен прецедент. Для этого сравниваем прецеденты с набором прецедентов зоны аномалий (Рис. 5).

Прецеденты — объектов всего: 61, отфильтровано: 61, выбрано: 0

	id	par1	par2	par3	par4	par5	par6	Solution	Anomaly	DegreeAttr	CaseAnomal
1	1	10	3	1	8	3	3	1	Anomaly1	1,000	истина
2	2	0	3	8	8	3	2	1	Anomaly1	0,5	ложь
3	3	1	3	1	2	0	3	1	Anomaly1	0,5	ложь
4	4	6	4	5	0	3	1	1	Anomaly3	1,000	истина
5	5	5	7	9	1	4	0	1	Anomaly1	0,333	ложь
6	6	10	2	4	3	1	1	1	Anomaly5	1,000	истина
7	7	4	1	1	2	0	4	1	Anomaly2	0,333	ложь
8	8	6	4	3	8	3	4	1	Anomaly5	1,000	истина
9	9	0	1	8	10	2	0	1	Anomaly5	1,000	истина
10	10	9	1	3	2	0	1	2	Anomaly2	0,333	ложь
11	11	8	3	1	9	5	4	2	Anomaly3	0,5	ложь
12	12	7	7	9	4	0	1	2	Anomaly2	0,333	ложь
13	13	7	3	4	1	0	0	2	Anomaly2	0,333	ложь
14	14	5	7	6	0	3	1	2	Anomaly2	1,000	истина
15	15	5	9	9	10	3	0	2	Anomaly4	0,5	ложь
16	16	5	4	5	5	3	3	2	Anomaly3	0,5	ложь
17	17	5	2	5	3	1	5	2	Anomaly5	1,000	истина
18	18	4	6	4	9	5	2	2	Anomaly2	1,000	истина
19	19	6	0	3	2	5	4	2	Anomaly5	0,5	ложь
20	20	9	1	9	9	0	0	2	Anomaly1	0,5	ложь

Рис. 5 – Результаты сравнения прецедентов



**Рис. 6** – Синтезированные и известные зоны аномалии

Построим границы аномальной зоны с помощью операции «буфер» (Рис. 6).


В качестве метрики смысловой близости прецедентов используем Евклидову метрику:

$$d = \sqrt{\sum_{k=1}^n (p_k - q_k)^2}$$

Порог смысловой близости определим, как наименьшее расстояние, в пределах которого прецеденты могут считаться близкими. Порог смысловой близости соответствует размеру буфера.

Таким образом, в пределах области текущего ЛП были построены 5 синтезированных зон аномалий. Через них проходят маршруты FD, EC, AG, GB. Новые синтезированные зоны могут быть использованы для поиска зон аномалий в других проектах.

Результаты выявления зон аномалий текущего ЛП также могут быть уточнены за счет новых данных о прецедентах (Рис. 7). Благодаря дополнительным прецедентам в Anomaly 4, были синтезированы две новые зоны аномалий. Также, в проект могут быть дополнительно интегрирована информация о зонах аномалий из прочих ЛП.



**Рис. 7** – Зоны аномалий после добавления дополнительных прецедентов

Дальнейший анализ может быть посвящен выбору оптимального маршрута с учетом свойств ситуации на момент движения и прецедентами, составляющими зону аномалий.

Полученные результаты демонстрируют возможность использования модели для переноса информации из реализованных проектов с целью определения зон аномалий. Синтезированные аномалии становятся частью соответствующей базы данных и могут быть использованы для поиска аномалий в других проектах. При добавлении новых сведений результат может быть уточнен, что обеспечивает гибкость и адаптивность анализа. Таким образом, цель эксперимента достигнута.

## Заключение

В работе проведено исследование по использованию картографического представления логистического проекта для построения тематической карты покрытия зонами аномалий. Разработана модель переноса информации о зоне проявления аномалий из одной области проекта в другую на основе обобщения известных прецедентов.

Предложенная модель предлагает ряд преимуществ:

1. Наглядная визуализация. Результат анализа зон поддается интуитивному манипулированию и может быть представлен различными методами визуализации (Тепловая карта, 3D-визуализация).
2. Возможность перенести знание в другое пространство. Для переноса используются известные прецеденты, расположенные в пределах области проекта. Их роль состоит в оценки близости текущей ситуации к определенному классу.
3. Построение самообучающейся системы. В ходе процессов анализа и переноса знаний, в системе накапливается информация о прецедентах. Проведенный эксперимент демонстрирует изменение результатов переноса знания при добавлении новых прецедентов и сведений о ранее реализованных проектах.
4. Ручное манипулирование информацией в области реализации проекта. Предложенная модель допускает участие пользователя (эксперта) для уточнения результатов анализа и добавление новых сведений. Он может выбрать другую метрику близости, изменить

параметры для расчета смысловой близости прецедентов. Также он может внедрить иную функцию визуализации в зависимости от поставленной задачи.

В отличие от существующих решений новая модель в полной мере рассматривает фактор пространственного распределения прецедентов. На основе отношений прецедента в пространстве определяются параметры для проведения рассуждений при построении зон. Рассуждения выполняются на основе дедуктивного вывода от известного общего знания о классе ситуаций к частным случаям. Такой тип рассуждений обеспечивает необходимый уровень достоверности решений в условиях неполноты и неопределённости информации.

Дальнейшие исследования будут посвящены расширению модели переноса знаний в условиях отсутствия точных границ.

## Список использованной литературы

1. Мусайбеков А. Г., Хабибулин Р. Ш., Ухатов В. С. Анализ результатов поиска и сходимости прецедентов в системе поддержки управления ликвидации пожаров и чрезвычайных ситуаций // *Современные проблемы гражданской защиты*. – 2020. – № 1(34). – С. 4–15.
2. Дли М. И., Соколов А. М., Воротилова М. Ю. Построение локальных нечетких моделей для ситуационного управления сложными объектами на основе прецедентов // *Программные продукты и системы*. – 2025. – № 3.
3. Рашевский Н. М., Руденко И. Е., Соколов Д. А., Феклистов В. А., Якунин О. А. Разработка системы поддержки принятия решений на основе рассуждения по прецедентам по оценке безопасности участка транспортной системы города // *Информатика, вычислительная техника и управление (ИВД)*. – 2022. – № 7 (91).
4. Рожко А. И., Ханова А. А. Концептуальная структура системы управления транспортно-логистическим проектом на основе имитационного моделирования // *Вестник АГТУ. Серия: Управление, вычислительная техника и информатика*. – 2022. – № 1.
5. L. Marzantowicz, “The Impact of Uncertainty Factors on the Decision-Making Process of Logistics Management,” *Processes*, vol. 8, no. 5, p. 512, 2020. DOI: 10.3390/pr8050512
6. Беляков С. Л., Боженюк А. В., Белякова М. Л. Прецедентный анализ геоинформационных моделей проектов логистики // *Наука и технологии железных дорог*. – 2019. – № 2.
7. K. Guo, “Design of Human-Machine Collaborative Decision Support System in Emergency Logistics Scenarios,” *Int. J. Glob. Econ. Manag.*, vol. 7, no. 3, pp. 98–106, 2025. DOI: 10.62051/ijgem.v7n3.10.
8. I. Jażdżewska and K. Żerek, “A spatial analysis of one of the regional logistics clusters in central Poland using GIS,” *Environ. Socio-Econ. Stud.*, vol. 12, no. 2, pp. 48–61, 2024. DOI: 10.2478/environ-2024-0012.
9. K. R. Mudunuru, R. Remala, and S. K. Nagarajan, “Leveraging IoT and Data Analytics in Logistics: Optimized Routing, Safety, and Resource Planning,” *Int. J. Comput. Trends Technol.*, vol. 72, no. 7, pp. 101–107, 2024. DOI: 10.14445/22312803/IJCTT-V72I7P113.
10. A. Robinson, “Geovisual Analytics,” in *The Geographic Information Science & Technology Body of Knowledge*, J. P. Wilson, Ed., 3rd Quart. 2017. [Online]. Available: <https://doi.org/10.22224/gistbok/2017.3.6>.
11. C. Y. Krishna, “AI-Powered Supply Chain Optimization: Enhancing Demand Forecasting and Logistics,” *J. Comput. Sci. Technol. Stud.*, vol. 7, no. 4, pp. 792–801, 2025.
12. J. Mašek, L. Duricova, and J. Čamaj, “Analysing factors influencing railway accidents: A predictive approach using multinomial logistic regression and data mining,” *PLoS One*, vol. 20, no. 10, p. e0256789, 2025.
13. J. Li et al., “ChatSync: Large Language Model Enabled Spatial-Temporal Knowledge Reasoning for Production Logistics Synchronization,” *IEEE Internet Things J.*, vol. 12, no. 22, pp. 47499–47518, 2025. DOI: 10.1109/IIOT.2025.3603073.
14. U. Olmez et al., “Evaluation of logistics risk factors with BWM method; Sivas province example,” *Pesqui. Oper.*, vol. 44, p. e26745, 2024. DOI: 10.1590/0101-7438.2023.043.00286745.
15. J. Jiao, Y. Liu, and C. Xie, “The Optimization Model of E-Commerce Logistics Distribution Path Based on GIS Technology,” *Adv. Multimedia*, vol. 2022, p. 1234567, 2022. [Online]. Available: <https://doi.org/10.1155/2022/1234567>.



16. M. K. Pasupuleti, “Predictive Relief Logistics Models for Earthquakes and Floods Based on Traffic, Weather, and Supply Chain Data,” *Int. J. Acad. Ind. Res. Innov.*, vol. 5, no. 4, pp. 142–150, 2025.
17. Зорькин Д. Ю., Самофалова Л. В., Асанова Н. В. Муравьиный алгоритм на Python // *Известия ЮФУ. Технические науки*. – 2025. – № 1 (243).
18. Кошуняева Н. В., Тутыгин А. Г. Сравнительный анализ эффективности использования метаэвристических методов моделирования для решения задачи коммивояжёра // *Моделирование и анализ данных*. – 2025. – Т. 15, № 3. – С. 76–93.
19. Конев К. А. Машинное обучение для поддержки принятия решений в сфере качества на промышленном предприятии // *Экономика. Информатика*. – 2023. – № 3.
20. G. Andrienko, N. Andrienko, G. Fuchs, and J. M. Cordero Garcia, “Clustering Trajectories by Relevant Parts for Air Traffic Analysis,” *IEEE Trans. Vis. Comput. Graphics*, vol. 24, no. 1, pp. 34–44, 2018. DOI: 10.1109/TVCG.2017.2744322.
21. T. Li et al., “HGeoKG: A Hierarchical Geographic Knowledge Graph for Geographic Knowledge Reasoning,” *ISPRS Int. J. Geo-Inf.*, vol. 14, no. 1, p. 18, 2025.
22. R. Pierdicca, N. Muralikrishna, F. Tonetto, and A. Ghianda, “On the Use of LLMs for GIS-Based Spatial Analysis,” *ISPRS Int. J. Geo-Inf.*, vol. 14, no. 10, p. 401, 2025.
23. Иванова Н. В., Белов В. С., Самаркин А. И. и др. Картографический анализ экстренных вызовов на дорожно-транспортные происшествия для оптимизации работы службы скорой медицинской помощи // *Вестник Псковского государственного университета. Серия: Естественные и физико-математические науки*. – 2023. – Т. 16, № 2. – С. 114–129.
24. Беляков С. Л., Израилев Л. А. Геоинформационные модели аварийных ситуаций с пространственными обобщениями // *Известия ЮФУ. Технические науки*. – 2025. – № 1 (243). – С. 153–164. DOI: 10.18522/2311-3103-2025-1-153-164.
25. N. Y. Uzun and A. Deran, “The importance of logistics costs in e-commerce businesses,” *Mersin Univ. J. Marit. Fac.*, vol. 7, no. 1, pp. 9–25, 2025. DOI: 10.47512/meujmaf.1699397.
26. Маколова Л. В. Управление проектами в логистике: учеб. пособие. – Ростов-на-Дону: РГУПС, 2017.