

Сергей В. Дуга¹, Андрей И. Труфанов²

¹Экспертно-криминалистический отдел, Следственное управление Следственного комитета
Российской Федерации по Иркутской области,
Клары Цеткин ул., 9а, Иркутск, 664039, Россия.

²Иркутский национальный исследовательский технический университет,
Лермонтова ул., 83, Иркутск, 664074, Россия

¹e-mail: siber@list.ru, <http://orcid.org/0000-0002-5894-9855>

²e-mail: troufan@gmail.com, <http://orcid.org/0000-0002-6967-3495>

СЕТЬ ЗНАНИЙ КАК КОНЦЕПЦИЯ СИСТЕМ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЯ
В ПРЕДВАРИТЕЛЬНОМ СЛЕДСТВИИ

DOI: <http://dx.doi.org/10.26583/bit.2020.3.05>

Аннотация. В настоящее время интеллектуальный анализ данных является важным инструментом для расследования преступлений. В статье предлагается извлечение криминалистически значимых сведений из неструктурированных данных, с использованием методов сетевого анализа (анализа графов). Рассмотрены частные определения термина «Knowledge Graph» (граф знаний), дано обобщающее авторское определение понятия «сети знаний». Раскрыта позиция сети знаний в общем контексте науки о сетях. На реальных примерах показано, каким образом сетевые (графовые) модели данных могут эффективно использоваться в предметной области предварительного следствия. Обсуждаются уровни реализации (сбор, хранение, анализ и визуализация) и основные преимущества концепции. Результаты сетевого интеллектуального анализа данных могут быть использованы для выявления закономерностей, извлечения неопределенных (неочевидных) данных, что в свою очередь будет способствовать раскрытию преступления.

Ключевые слова: информатизация расследования, сеть знаний, графовая модель данных, комплексные сети, сетевой анализ.

Для цитирования: ДУГА, Сергей В.; ТРУФАНОВ, Андрей И. СЕТЬ ЗНАНИЙ КАК КОНЦЕПЦИЯ СИСТЕМ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЯ В ПРЕДВАРИТЕЛЬНОМ СЛЕДСТВИИ. *Безопасность информационных технологий*, [S.l.], в. 27, п. 3, р. 54–65, 2020. ISSN 2074-7136. Доступно на: <<https://bit.mephi.ru/index.php/bit/article/view/1292>>. Дата доступа: 01 sep. 2020. DOI: <http://dx.doi.org/10.26583/bit.2020.3.05>.

Sergey V. Duga¹, Andrey I. Trufanov²

¹Investigation Department, Investigative Committee of the Russian Federation Irkutsk Region,
K. Tsetkin str., 9a, Irkutsk, 664039, Russia

²Irkutsk National Research Technical University,
Lermontova str., 83, Irkutsk, 664074, Russia

¹e-mail: siber@list.ru, <http://orcid.org/0000-0002-5894-9855>

²e-mail: troufan@gmail.com, <http://orcid.org/0000-0002-6967-3495>

The knowledge graph concept of decision support system in preliminary investigation

DOI: <http://dx.doi.org/10.26583/bit.2020.3.05>

Abstract. Particular definitions of the concept of "Knowledge Graph" (knowledge network) are considered, and a generalizing author's definition of the concept of "knowledge networks" is given. The position of the knowledge network in the general context of network science is revealed. Real-world examples show how network (graph) data models can be effectively used in the subject area of preliminary investigation. The levels of implementation and the main advantages of the concept are discussed.

Keywords: informatization of investigations, knowledge graph, graph data model, complex networks, network analysis.

For citation: DUGA, Sergey V.; TRUFANOV, Andrey I. The knowledge graph concept of decision support system in preliminary investigation. IT Security (Russia), [S.l.], v. 27, n. 3, p. 54–65, 2020. ISSN 2074-7136. Available at: <<https://bit.mephi.ru/index.php/bit/article/view/1292>>. Date accessed: 01 sep. 2020. DOI: <http://dx.doi.org/10.26583/bit.2020.3.05>.

Введение

В последнее время отечественное научное сообщество все больше внимания уделяет применению искусственных нейронных сетей в расследовании преступлений. В частности, в каждой из работ [1–5] делается попытка по-своему раскрыть понятие «искусственный интеллект» в контексте противодействия преступности, его применение по предупреждению преступности.

В целом, в своих попытках авторы надеются, что внедрение подобных систем может не только использоваться в качестве предупредительно-профилактических мер, но и улучшить качество предварительного следствия, сократить его сроки, и, как следствие, повысить имидж и доверие граждан к правоохранительным органам.

В работе [6], авторы определяют три направления расследования преступлений, в которых могут применяться системы искусственного интеллекта – «распознавание (визуальных образов и связей между объектами криминалистического познания), предсказание и классификация». Для достижения результатов, авторами предлагается «сформировать набор данных прикладной области, после чего обучить искусственную нейронную сеть с помощью алгоритмов машинного обучения».

В работе [7], автор предлагает объединение всех баз данных и учётов, ведущихся в МВД России, а также разработку на основе искусственного интеллекта системы ввода полной информации о правонарушениях и преступлениях путём сканирования материалов уголовных дел, материалов об административных правонарушениях. Автор предполагает, что внедрение подобной системы способно значительно повысить качество расследования преступлений.

В то же время нельзя не отметить, что применение систем искусственного интеллекта не должно подменять собой человека, но должно быть направлено на оказание содействия в его повседневной деятельности. Более того, со стороны государства необходимо правовое регулирование, выработка государственной политики в отношении искусственного интеллекта.

Нами предлагается создание системы поддержки принятия решения в предварительном следствии [8], в которой, за счет объединения методов машинного обучения и теории комплексных сетей, реализован мощный аналитический инструмент. Внедрение системы будет содействовать следователям в повседневной деятельности, предоставит возможность анализа получаемых сведений как в рамках расследуемого уголовного дела, так и в контексте других уголовных дел. В результате накопленных системой сведений предполагается формировать т.н. «сеть знаний». Аналог этого понятия в англоязычной терминологии «Knowledge Graph», буквально «граф знаний». Однако на наш взгляд, «сеть знаний» в русской транскрипции в наилучшей степени отражает свойства рассматриваемой сущности и связанные с ней явления и процессы.

Термин «Knowledge Graph» (сеть знаний) стал набирать популярность с 2012 года, после публикации корпорацией «Google» о своей семантической технологии «Google’s Knowledge Graph», расширяющую известную поисковую систему, в частности, позволяющую устранить смысловую неоднозначность поискового запроса [9].

Важно, что интерес к данной тематике прослеживается с середины семидесятых годов прошлого века. В [10] дается определение «Knowledge Graph» (сеть знаний) как «математической структуры с вершинами - единицами знаний, соединенных ребрами,

которые представляют отношения». Хотя в последующие годы и было опубликовано большое количество работ [11–18], самым различным образом формулирующих частные определения «Knowledge Graph» (сеть знаний), в т.ч. и Википедия [19], на сегодняшний день общепринятого формального определения этого понятия не существует.

В своем исследовании мы предлагаем и используем следующее определение «сети знаний»: это крупномасштабная сеть, описывающая сущности реального мира (с указанием семантического типа и свойств), а также отношения между ними (также наделенными свойствами), охватывающая определенную предметную область. Таким образом, сеть знаний организует информацию в структурированном виде путем явного описания отношений между сущностями.

Формально сеть знаний можно описать как $G = \{E, R, F\}$, где E – набор узлов, R – набор связей, F – факты. Факт обозначается триплетом $(h, r, t) \in F$. Каждый триплет связывает две сущности h (субъект) и t (объект) через отношение r (предикат), а также дополнительную информацию, связанную с триплетом, представленную как ключ-значение (k, v) [20].

Сущности реального мира разнообразны и взаимосвязаны. Инструменты науки о сетях [21], включающие теорию графов, теорию вероятностей и линейную алгебру, являются эффективным средством при изучении реальных, сложных систем, таких как технологические, социальные, информационные и др. Сложные сущности практически любой предметной области могут быть представлены сетевыми структурами. Сети являются простым и мощным способом представления моделей связей и взаимодействий между частями системы.

Понятно, что связи в сети могут быть направленными или ненаправленными. Некоторые системы имеют направленные связи, например, электронное письмо, направленное от одного человека к другому. Иные сетевые системы имеют ненаправленные связи, такие как линии электросети, по которым электрический ток может течь в обоих направлениях [22].

Кроме того, узлы и связи в сети могут содержать какую-либо дополнительную информацию (свойства), например, тип, имя, вес связи и т.д., для большей детализации системы.

В табл. 1 приведены некоторые примеры представления различных систем в виде сети.

Таблица 1.

Сеть	Узлы	Связи
WWW	Веб-страницы	Ссылки
Звонки	Абонент	Звонок
Сеть цитирования	Статьи	Цитаты
Научное сотрудничество	Ученые	Соавторство

Сетевые (графовые) модели являются подходящим инструментом при анализе самых разных наборов данных, в частности [23–26].

Хотя термин «Knowledge Graph» чаще всего ассоциируется с «Google», сети знаний используются не только поисковыми системами. В табл. 2 приведены примеры использования сетей знаний в крупнейших ИТ-компаниях [27].

Таблица 2.

Компания	Размер графа	Стадия разработки
Microsoft	~ 2 миллиарда вершин	Активно используется в продуктах
Google	1 миллиард вершин	Активно используется в продуктах
Facebook	~ 50 миллиардов вершин	Активно используется в продуктах
eBay	Ожидается около 100 миллионов вершин	Ранние стадии разработки и внедрения
IBM	> 100 миллионов вершин	Активно используется в продуктах

Более того, сегодня сети знаний применяются и в правительственных организациях. Так, при помощи графовой модели, Министерство обороны США отслеживает и анализирует расходы на техническое обслуживание оборудования (от вертолетов и бронированных машин до стрелкового оружия и радиоприемников) [28]. Техническое обслуживание и поддержка этого оборудования требует закупки миллионов запасных частей в год. После внедрения графовой базы данных, Министерство обороны США имеет гораздо более гибкое и надежное представление о требованиях к деталям и стоимости этих частей для всех систем, компонентов и подкомпонентов.

В НАСА сеть знаний [29] составлена из документов, являющихся источником информации для графа. НАСА использует обработку естественного языка для сканирования документов на предмет данных, включаемых в сеть знаний.

Эти данные включают в себя сотни миллионов документов, отчетов, проектных данных, извлеченных уроков, научных исследований, медицинского анализа и многое другое, хранящиеся в общенациональной базе данных.

При регистрации сложной технической проблемы, техническому специалисту отображаются самые похожие проблемы, обработанные ранее, алгоритм ее решения, и все связанные с ней документы. Благодаря этому решение проблемы значительно ускоряется. Отметим, что в наибольшей степени сети знаний отвечает модель в интерпретации комбинированных стволовых сетей [30], способных органично включить и описать разноплановые узлы, связи и факты.

Фактически, концепция сетей знаний осваивается немногочисленными отечественными исследователями [31], зачастую, в неявной и далекой от практики форме [32–33].

1. Предметная область

Сети и их инструмент – графы могут быть использованы для эффективного анализа данных. Намерение, следующее за настоящим обзором, состоит в использовании графовой базы данных для хранения криминалистически значимых сведений, их анализа и визуализации.

При производстве по уголовному делу, следователь анализирует не только отдельные сущности (субъекты, события и т.д.), но и связи между ними.

Данные о преступлении (или преступлениях) могут быть представлены комплексной (сложной) сетью, поскольку они содержат различные отношения между сущностями реального мира, такими как люди, сведения о звонках, сведения о переписке, места, организации и т.д. Такое представление существенно облегчит проверку доказательств по уголовному делу, а именно «сопоставление их с другими доказательствами, имеющимися в уголовном деле, а также установления их источников» (УПК РФ Статья 87).

В [34] предлагается модель данных для расследования преступления «POLE» (рис. 1). «POLE» означает Persons (субъекты), Objects (объекты), Locations (места) и Events (события).

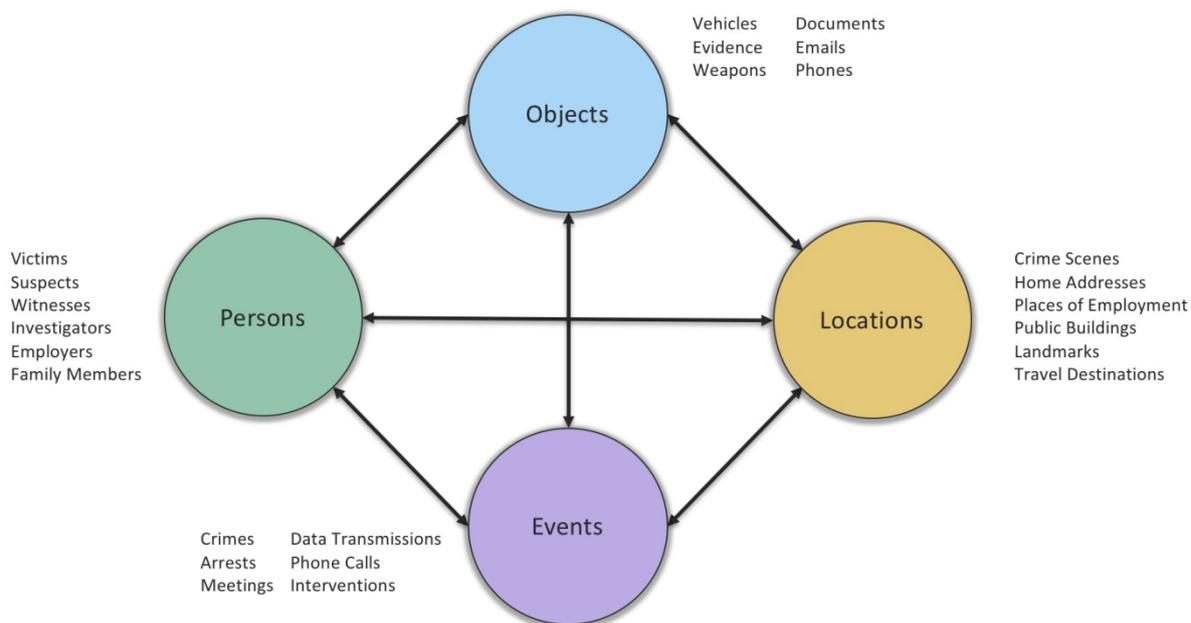


Рис. 1. Модель данных «POLE»
(Fig.1. The “POLE” data model)

В данной модели используются следующие семантические типы узлов:

1. Субъекты. В качестве субъектов могут выступать потерпевшие по уголовному делу, подозреваемые и обвиняемые в совершении преступления, свидетели преступления и т.д.

2. События – время, место, способ и другие обстоятельства совершения преступления, обстоятельства, способствовавшие совершению преступления (УПК РФ Статья 73), а также иные обстоятельства, имеющие значение для уголовного дела (встречи людей, телефонные звонки, передача данных и пр.).

3. Объектами могут быть любые предметы, которые служили орудиями, оборудованием или иными средствами совершения преступления, предметы и документы, которые могут служить средствами для обнаружения преступления и установления обстоятельств уголовного дела (УПК РФ Статья 81).

4. Места – место совершения преступления, домашний/рабочий адрес человека, адрес регистрации юридического лица и пр.

Представление модели данных «POLE» в виде графа представлено на рис. 2.

Другим примером успешного использования графовых баз данных в расследовании являются исследования «Международного консорциума журналистов-расследователей» (The International Consortium of Investigative Journalists (ICIJ)), которые выявили много интересных закономерностей, включая потенциально незаконную деятельность президента Азербайджана [35].

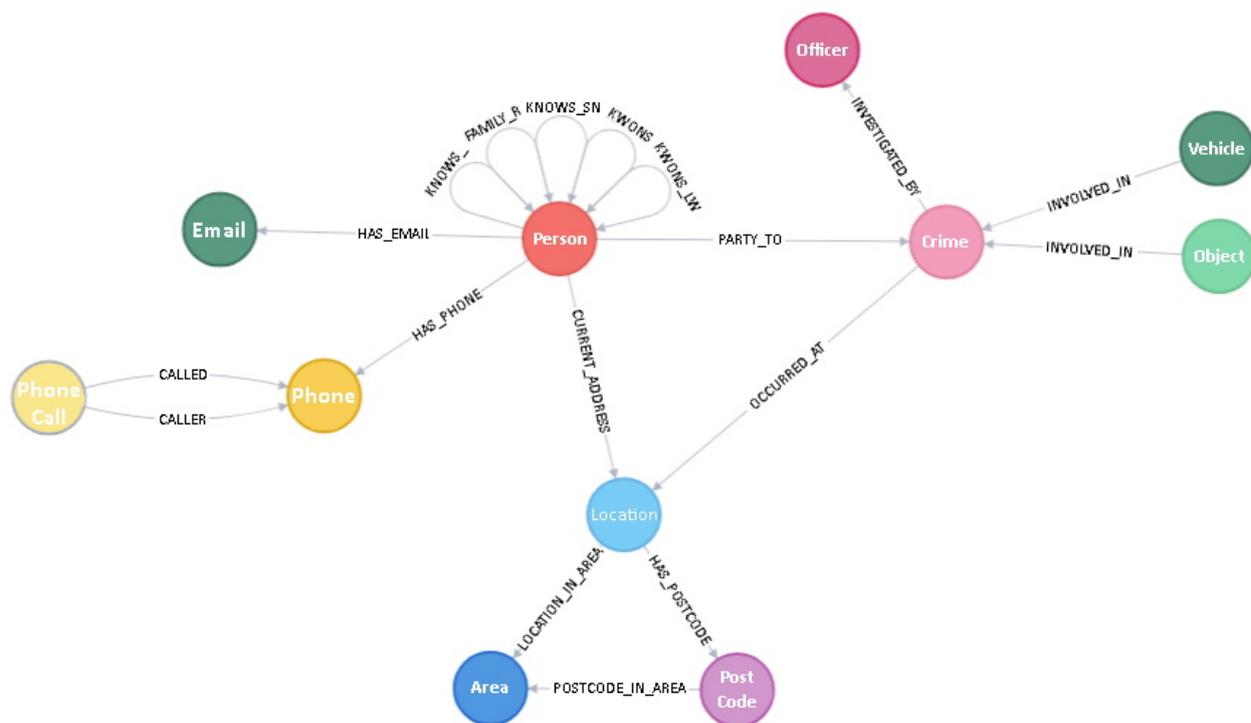


Рис. 2. Представление модели данных «POLE» в виде графа
(Fig. 2. Representation of the “POLE” data model as a graph)

Для понимания сложных данных в наборе данных «ICIJ Offshore Leaks» [36], была построена сетевая (графовая) модель. В данной модели используются следующие семантические типы узлов и связей:

Узлы:

1. Субъект (Person) – люди, которые строят и используют сеть активов.
2. Компания (Company) – компании включают оффшорные компании, поставщиков банковских услуг и предприятия.
3. Адрес (Address) – это места регистрации людей и компаний. Поскольку они имеют юридическую значимость (компания, зарегистрированная в оффшоре, платит налогов меньше или вовсе их не платит), адреса могут дать интересную информацию.

Связи:

1. Субъект – Адрес и Компания – Адрес (USES_ADDRESS). Связывает людей и компании по адресам.
2. Субъект – Семья – Субъект (FAMILY). Люди могут быть связаны через семейные узы.
3. Субъект – Связь с – Компания (IS_LINKED_TO). Связь человека с компанией. Также связи между людьми и компаниями имеют свойство «роль» (директор, учредитель и т.д.).
4. Компания – Связь с – Компания (IS_LINKED_TO). Отображает, как первая компания связана со второй компанией. Связь также имеет свойство «роль».
5. Компания – Оффшор – Компания (IS_OFFSHORE_PROVIDER_OF). Отображает связь компании с компанией, предоставляющей услуги оффшорной системы.

Полученная сетевая (графовая) модель представлена на рис. 3.

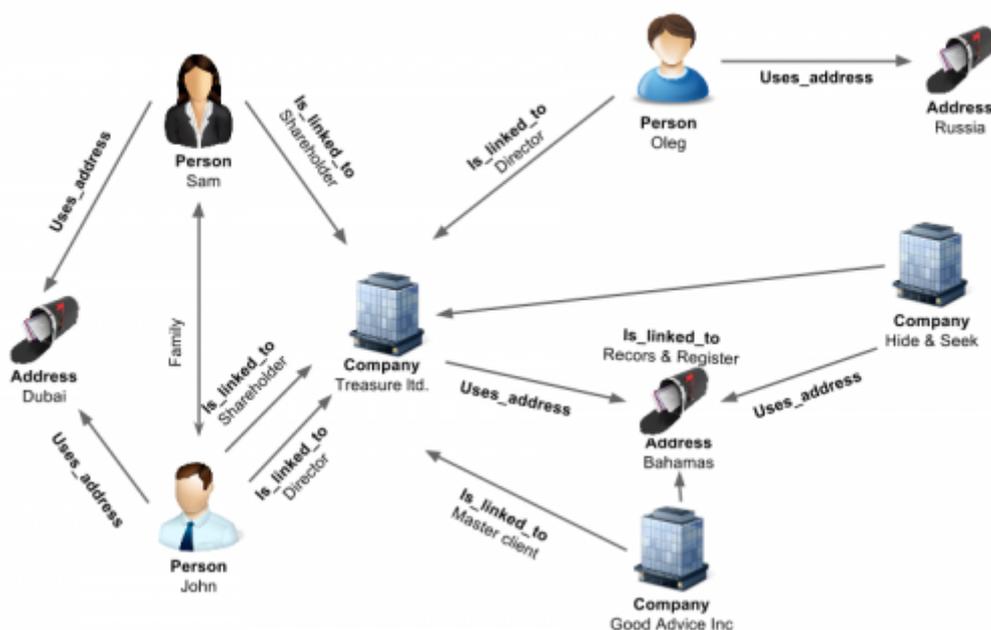


Рис. 3. Сетевая (графовая) модель набора данных «ICIJ Offshore Leaks»
(Fig. 3. Network (graph) model of the “ICIJ Offshore Leaks” data set)

Таким образом, уже сейчас можно с уверенностью утверждать, что сетевые (графовые) модели данных могут эффективно использоваться в рассматриваемой нами предметной области предварительное следствие.

2. Уровни реализации

Модель

Предлагается использовать модель данных, основанную на ориентированных графах с метками.

Модель данных, основанная на ориентированных графах с метками – это среда описания ресурса (Resource Description Framework, RDF), которая разработана и поддерживается консорциумом Всемирной паутины (W3C) [37]. RDF – это общий метод описания данных путем определения отношений между объектами данных. RDF-выражение состоит из субъекта, предиката и объекта.

База данных

В качестве базы данных нами предлагается использовать одну из графовых баз данных, например, [38–40] и др.

Графовые базы данных отлично подходят для:

- когда данные не содержат схемы;
- отношения в данных вносят смысл;
- динамических систем, в которых трудно предсказать топологию данных;
- требуется расширение по мере развития;
- хороши для сложных данных.

Кроме того, моделирование данных в виде графа обеспечивает большую гибкость для интеграции новых источников данных по сравнению со стандартной реляционной моделью, где схема должна быть определена заранее и отслеживаться на каждом этапе.

Язык запросов

Для запросов к базе данных могут быть использованы такие языки как Sparql, Gremlin и Cypher, которые используются для выбора подграфов и анализа.

Анализ

Для анализа могут быть применены различные методы анализа сетевых структур. Перечислим некоторые из них [41]:

- центральность: стремится идентифицировать наиболее значимые узлы или связи сети;
- обнаружение сообщества: цель состоит в том, чтобы идентифицировать сообщества сети, то есть кластеры, которые более плотно связаны внутри, чем с остальной частью сети;
- связность: стремится оценить, насколько хорошо связана сеть, показывая, например, устойчивость и (не) достижимость элементов сети;
- сходство узлов: стремится найти узлы, которые похожи на другие узлы в силу того, как они связаны внутри своего соседства;
- поиск пути: целью является поиск путей в сети, обычно между парами узлов, заданными в качестве входных данных.

Кроме того, векторное представление узлов и связей позволяют применять стандартные методы анализа данных и машинного обучения к сетевым структурам [42]. Машинное обучение может использоваться для уточнения самой сети знаний – прогнозирование новых связей или выявление ошибочных. Сеть знаний также может служить набором данных для обучения моделей.

Для примера, можно использовать методы машинного обучения для определения недостающей информации, когда, учитывая два элемента триплета, необходимо предсказать недостающий: $(?, r, t)$, $(h, ?, t)$ или $(h, r, ?)$ [43].

Визуализация

Ввиду того, что в разрабатываемой нами системе конечными пользователями являются следователи и криминалисты, не владеющие языками программирования и запросов, пользовательский интерфейс должен обеспечивать графическое представление сети и позволять выполнить визуальный анализ.

Заключение

В последнее время наблюдается растущий интерес к применению методов искусственного интеллекта в расследовании преступлений. Ожидается, что такие методы, используемые для обработки и прогнозирования данных, могут улучшить производительность, скорость и точность процесса расследования преступлений.

В свою очередь, мы считаем, что применение сети знаний в предварительном следствии позволит улучшить процесс принятия решений, извлекать интересующие шаблоны, а графическое представление сети позволит выполнить визуальный анализ накопленных сведений.

Моделирование данных в виде сети обеспечивает большую гибкость для интеграции новых источников данных, а также позволит проводить интеллектуальный анализ текста, извлечение сущностей и анализ социальных сетей.

Сеть знаний может использоваться не только для накопления знаний, но и для вывода новых фактов.

Однако, стоит отметить препятствия, связанные с применением этих методов, в частности, формулирование государственной политики в отношении искусственного интеллекта.

СПИСОК ЛИТЕРАТУРЫ:

1. Суходолов А.П., Бычкова А.М. Искусственный интеллект в противодействии преступности, ее прогнозировании, предупреждении // *Всероссийский криминологический журнал*. 2018. Т. 12. № 5. С. 753–766. DOI: [https://doi.org/10.17150/2500-4255.2018.12\(6\).753-766](https://doi.org/10.17150/2500-4255.2018.12(6).753-766).
2. Мазуров В.А., Стародубцева М.А. Искусственный интеллект как средство прогнозирования и противодействия преступности // *Российско-азиатский правовой журнал*. 2019. № 3. С. 46–50. URL: <http://journal.asu.ru/ralj/article/view/6991> (дата обращения: 17.06.2020).
3. Кравцов Д.А. Искусственный разум: предупреждение и прогнозирование преступности // *Вестник Московского университета МВД России*. 2018. № 3, С. 108–110. URL: <https://cyberleninka.ru/article/n/iskusstvennyy-razum-preduprezhdenie-i-prognozirovanie-prestupnosti> (дата обращения: 24.06.2020).
4. Осипенко А.Л. Перспективы использования информационно-аналитических технологий в оперативно-розыскной деятельности // *Общество и право*. 2018. № 4. С. 80–87. URL: <https://cyberleninka.ru/article/n/perspektivy-ispolzovaniya-informatsionno-analiticheskikh-tehnologiy-v-operativno-rozysknoy-deyatelnosti> (дата обращения: 23.06.2020).
5. Себякин А.Г. Искусственный интеллект в криминалистике: система поддержки принятия решений // *Baikal Research Journal*. 2019. Т. 10. № 4. С. 21–21. DOI: [https://doi.org/10.17150/2411-6262.2019.10\(4\).21](https://doi.org/10.17150/2411-6262.2019.10(4).21). URL: <http://cj.bgu.ru/reader/article.aspx?id=23649> (дата обращения: 23.06.2020).
6. Степаненко Д.А., Бахтеев Д.В., Евстратова Ю.А. Использование систем искусственного интеллекта в правоохранительной деятельности // *Всероссийский криминологический журнал*. 2020. Т. 14, № 2, С. 206–214. DOI: [https://doi.org/10.17150/2500-4255.2020.14\(2\).206-214](https://doi.org/10.17150/2500-4255.2020.14(2).206-214).
7. Кузьмин И.А. Искусственные нейронные сети: перспективы использования в правоохранительной деятельности // *Криминалистика: вчера, сегодня, завтра*. 2018. № 4 (8). С. 109–116. URL: <https://cyberleninka.ru/article/n/iskusstvennyye-neyronnye-seti-perspektivy-ispolzovaniya-v-pravoohranitelnoy-deyatelnosti> (дата обращения: 27.06.2020).
8. Дуга, Сергей В. и др. Концепция системы поддержки принятия решения в предварительном следствии. Безопасность информационных технологий, [S.l.]. Т. 26, № 3. С. 45–57, сен. 2019. ISSN 2074-7136. URL: <https://bit.mephi.ru/index.php/bit/article/view/1216>. (дата обращения: 27.06.2020). DOI: <http://dx.doi.org/10.26583/bit.2019.3.04>.
9. Singhal A. Introducing the knowledge graph: things, not strings. URL: <https://www.blog.google/products/search/introducing-knowledge-graph-things-not> (дата обращения: 16.05.2020).
10. Marchi E., Miguel O. On the Structure of the Teaching-learning Interactive Process // *International Journal of Game Theory*. 1974. Vol. 3. no. 2. P. 83–99. DOI: <https://doi.org/10.1007/BF01766394>.
11. R.R. Bakker. Knowledge Graphs: Representation and Structuring of Scientific Knowledge // Ph.D. thesis, University of Twente, Enschede. 1987.
12. P.H. de Vries. Representation of Science Texts in Knowledge Graphs // Ph.D. thesis, University of Groningen, Groningen, The Netherlands, 1989.
13. Zhang L. Knowledge graph theory and structural parsing // Twente University Press. 2002. С. 216. URL: <https://ris.utwente.nl/ws/portalfiles/portal/6073799/t0000020.pdf> (дата обращения: 27.05.2020).
14. Popping R. Knowledge graphs and network text analysis // *Social Science Information*. 2003. Vol. 42, no. 1. P. 91–106. DOI: <https://doi.org/10.1177/0539018403042001798>.
15. Lisa Ehrlinger, Wolfram Wöß. Towards a Definition of Knowledge Graphs // *Joint Proceedings of the Posters and Demos Track of 12th International Conference on Semantic Systems - SEMANTiCS2016 and 1st International Workshop on Semantic Change & Evolving Semantics (SuCCESS16)*, Leipzig, Germany. 2016. URL: <http://ceur-ws.org/Vol-1695/paper4.pdf> (дата обращения: 01.07.2020).
16. Paulheim H. Knowledge graph refinement: A survey of approaches and evaluation methods // *Semantic web*. 2017. Vol. 8. no. 3. P. 489–508. DOI: <https://doi.org/10.3233/SW-160218>.
17. Chenyan Xiong. Text representation, retrieval, and understanding with knowledge graphs. // *ACM SIGIR Forum*. 2018. Vol. 52. no. 2. P. 180–181. DOI: <https://doi.org/10.1145/3308774.3308808>.
18. Bellomarini L. et al. Knowledge graphs and enterprise AI: the promise of an enabling technology // *IEEE 35th International Conference on Data Engineering (ICDE)*. 2019. P. 26–37. DOI: <https://doi.org/10.1109/ICDE.2019.00011>.
19. Knowledge Graph. URL: https://ru.wikipedia.org/wiki/Knowledge_Graph (дата обращения: 01.07.2020).
20. Ji S. et al. A survey on knowledge graphs: Representation, acquisition and applications // *arXiv preprint arXiv:2002.00388*. 2020. URL: <https://arxiv.org/abs/2002.00388> (дата обращения: 20.06.2020).

21. Molontay R., Nagy M. Twenty Years of Network Science: A Bibliographic and Co-authorship Network Analysis // arXiv preprint arXiv:2001.09006. 2020. URL: <https://arxiv.org/abs/2001.09006> (дата обращения: 25.06.2020).
22. Albert-László Barabási, Márton Pósfai. Network Science // Cambridge University Press. 2016. – 475 p.
23. Saleh M., Esa Y., Mohamed A. Applications of complex network analysis in electric power systems // Energies. 2018. Vol. 11. № 6. DOI: <https://doi.org/10.3390/en11061381>.
24. Wu X. et al. Analysis of metro network performance from a complex network perspective // Physica A: Statistical Mechanics and its Applications. 2018. Vol. 492. P. 553–563. DOI: <https://doi.org/10.1016/j.physa.2017.08.074>.
25. Wachs-Lopes G. A., Rodrigues P. S. Analyzing natural human language from the point of view of dynamic of a complex network // Expert Systems with Applications. 2016. Vol. 45. P. 8–22. DOI: <https://doi.org/10.1016/j.eswa.2015.09.020>
26. Jiang Z. Y. et al. Vehicle demand evolution analysis from the complex network perspective // Physica A: Statistical Mechanics and its Applications. 2019. Vol. 532. DOI: <https://doi.org/10.1016/j.physa.2019.121889>.
27. Noy N. et al. Industry-scale knowledge graphs: Lessons and challenges // Queue. 2019. Vol. 17. no. 2. P. 48–75. DOI: <https://doi.org/10.1145/3331166>.
28. Graphs in Government – Fulfilling Your Mission with Neo4j. URL: <https://www.paperpicks.com/graphs-in-government-fulfilling-your-mission-with-neo4j> (дата обращения: 06.06.2020).
29. How NASA Finds Critical Data through a Knowledge Graph. URL: <https://neo4j.com/blog/nasa-critical-data-knowledge-graph/?ref=blog> (Дата обращения: 09.06.2020).
30. Ashurova Z, Tikhomirov A, Trufanov A, Kinash N, Berestneva O и Rossodivita. A 2017 Network platform of program governance for E-health service // 2017 12th Int. Sci. and Tech. Conf. on Computer Sciences and Information Technologies (CSIT), Lviv Ukraine. 2017. DOI: <https://doi.org/10.1109/STC-CSIT.2017.8099429>.
31. Тушканова О. Н., Самойлов В. В. Knowledge Net: модель и система накопления, представления и использования знаний и данных // Онтология проектирования. 2019. Т. 9. № 1. С. 117–131. DOI: <https://doi.org/10.18287/2223-9537-2019-9-1-117-131>.
32. Подружкина Т. А., Федоров Д. Ю. Алгоритмы планирования процесса обучения на основе семантических сетей знаний // Научно-аналитический журнал «Вестник Санкт-Петербургского университета Государственной противопожарной службы МЧС России». 2017. № 1. С. 107–116. URL: <https://cyberleninka.ru/article/n/ispolzovanie-informatsionnyh-tehnologiy-dlya-obespecheniya-bezopasnosti-lichnosti-obschestva-i-gosudarstva> (дата обращения: 23.06.2020).
33. Савченко А. П. Открытая сеть документированных знаний организации: концептуальная модель // Политематический сетевой электронный научный журнал Кубанского государственного аграрного университета. 2014. № 103. URL: <https://cyberleninka.ru/article/n/otkrytaya-set-dokumentirovannyh-znaniy-organizatsii-kontseptualnaya-model> (дата обращения: 22.06.2020).
34. Announcing the Neo4j Crime Investigation Sandbox. URL: <https://medium.com/neo4j/announcing-the-neo4j-crime-investigation-sandbox-c0c3bd9e71b1> (дата обращения: 30.06.2020).
35. Neo4j and the Offshore Leaks: the Case of Azerbaijan. URL: <https://neo4j.com/graphgist/neo4j-and-the-offshore-leaks-the-case-of-azerbaijan> (дата обращения: 02.07.2020).
36. ICIJ Offshore Leaks Database. URL: <https://offshoreleaks.icij.org> (дата обращения: 02.07.2020).
37. Richard Cyganiak, David Wood, Markus Lanthaler. RDF 1.1 Concepts and Abstract Syntax, W3C Recommendation 25 February 2014. URL: <https://www.w3.org/TR/2014/REC-rdf11-concepts-20140225> (дата обращения: 03.07.2020).
38. HypergraphDB - A Graph Database. URL: <http://www.hypergraphdb.org> (дата обращения: 16.06.2020).
39. AllegroGraph. URL: <https://allegrograph.com> (дата обращения: 16.06.2020).
40. Neo4j Graph Platform – The Leader in Graph Databases. URL: <https://neo4j.com> (дата обращения: 16.06.2020).
41. Iosup A. et al. LDBC Graphalytics: A benchmark for large-scale graph analysis on parallel and distributed platforms // Proceedings of the VLDB Endowment. 2016. Vol. 9. no. 13. P. 1317–1328. DOI: <https://doi.org/10.14778/3007263.3007270>.
42. Hogan A. et al. Knowledge graphs // arXiv preprint arXiv:2003.02320. 2020. URL: <https://arxiv.org/abs/2003.02320> (дата обращения: 17.06.2020).
43. Rosso P., Yang D., Cudré-Mauroux P. Beyond triplets: hyper-relational knowledge graph embedding for link prediction // Proceedings of The Web Conference 2020. P. 1885–1896. DOI: <https://doi.org/10.1145/3366423.3380257>.

REFERENCES:

- [1] Sukhodolov A.P., Bychkova A.M. Artificial intelligence in crime counteraction, prediction, prevention and evolution. *Russian Journal of Criminology*, 2018. Vol. 12, no 5. P. 753–766. DOI: [https://doi.org/10.17150/2500-4255.2018.12\(6\).753-766](https://doi.org/10.17150/2500-4255.2018.12(6).753-766) (in Russian).
- [2] Mazurov V. A., Starodubtseva M. A. Artificial intelligence as a means for forecasting and countering crime. *Russian-Asian legal journal*, 2019, no. 3. P. 46–50. URL: <http://journal.asu.ru/ralj/article/view/6991> (accessed: 17.06.2020) (in Russian).
- [3] Kravcov D.A. Artificial intelligence: crime prevention and prediction. *Vestnik of Moscow University of the Ministry of Internal Affairs of Russia*, 2018, no. 3. P. 108–110. URL: <https://cyberleninka.ru/article/n/iskusstvennyy-razum-preduprezhdenie-i-prognozirovanie-prestupnosti> (accessed: 24.06.2020) (in Russian).
- [4] Osipenko A.L. The prospects of use of information and analytical technologies in operational-search activity. *Society and law*, 2018, no. 4. P. 80–87. URL: <https://cyberleninka.ru/article/n/perspektivy-ispolzovaniya-informatsionno-analiticheskikh-tehnologiy-v-operativno-rozysknoy-deyatelnosti> (accessed: 23.06.2020) (in Russian).
- [5] Sebyakin A.G. Artificial intelligence in criminalistics: system of decision-making support. *Baikal Research Journal*, 2019. Vol. 10, no. 4. DOI: [https://doi.org/10.17150/2411-6262.2019.10\(4\).21](https://doi.org/10.17150/2411-6262.2019.10(4).21). URL: <http://cj.bgu.ru/reader/article.aspx?id=23649> (accessed: 23.06.2020) (in Russian).
- [6] Stepanenko D.A., Bakhteev D.V., Evstratova Y.A. The use of artificial intelligence systems in law enforcement. *Russian Journal of Criminology*, 2020, vol. 14, no. 2, pp. 206-214. DOI: [https://doi.org/10.17150/2500-4255.2020.14\(2\).206-214](https://doi.org/10.17150/2500-4255.2020.14(2).206-214) (in Russian).
- [7] Kuzmin I.A. Artificial neural networks: prospects for use in law enforcement. *Forensics: yesterday, today, tomorrow*, 2018, no. 4. URL: <https://cyberleninka.ru/article/n/iskusstvennye-neyronnye-seti-perspektivy-ispolzovaniya-v-pravoohranitelnoy-deyatelnosti> (accessed: 27.06.2020) (in Russian).
- [8] Duga Sergey V. et al. The concept of decision support system in preliminary investigation. *IT Security (Russia)*, [S.l.], V. 26, n. 3. P. 45–57, sep. 2019. ISSN 2074-7136. URL: <https://bit.mephi.ru/index.php/bit/article/view/1216> (accessed: 27.06.2020) DOI: <http://dx.doi.org/10.26583/bit.2019.3.04> (in Russian).
- [9] Singhal A. Introducing the knowledge graph: things, not strings. URL: <https://www.blog.google/products/search/introducing-knowledge-graph-things-not> (accessed: 16.05.2020).
- [10] E. Marchi, O. Miguel. On the Structure of the Teaching-learning Interactive Process. *International Journal of Game Theory*, 1974. Vol. 3, no. 2. P. 83–99. DOI: <https://doi.org/10.1007/BF01766394>
- [11] R.R. Bakker. Knowledge Graphs: Representation and Structuring of Scientific Knowledge. Ph.D. thesis, University of Twente, Enschede. 1987.
- [12] P.H. de Vries. Representation of Science Texts in Knowledge Graphs. Ph.D. thesis, University of Groningen, Groningen, The Netherlands. 1989.
- [13] Zhang L. Knowledge graph theory and structural parsing. Twente University Press, 2002. P. 216. URL: <https://ris.utwente.nl/ws/portalfiles/portal/6073799/t0000020.pdf> (accessed: 27.05.2020).
- [14] Popping R. Knowledge graphs and network text analysis. *Social Science Information*, 2003. Vol. 42, no. 1. P. 91–106. DOI: <https://doi.org/10.1177/0539018403042001798>.
- [15] Lisa Ehrlinger, Wolfram Wöß. Towards a Definition of Knowledge Graphs. Joint Proceedings of the Posters and Demos Track of 12th International Conference on Semantic Systems - SEMANTiCS2016 and 1st International Workshop on Semantic Change & Evolving Semantics (SuCESS16), Leipzig, Germany, 2016. URL: <http://ceur-ws.org/Vol-1695/paper4.pdf> (accessed: 01.07.2020).
- [16] Paulheim H. Knowledge graph refinement: A survey of approaches and evaluation methods. *Semantic web*, 2017. Vol. 8, no. 3. P. 489–508. DOI: <https://doi.org/10.3233/SW-160218>.
- [17] Chenyan Xiong. Text representation, retrieval, and understanding with knowledge graphs. *ACM SIGIR Forum*, 2018. Vol. 52, no. 2. P. 180–181. DOI: <https://doi.org/10.1145/3308774.3308808>.
- [18] Bellomarini L. et al. Knowledge graphs and enterprise AI: the promise of an enabling technology. *IEEE 35th International Conference on Data Engineering (ICDE)*, 2019. P. 26–37. DOI: <https://doi.org/10.1109/ICDE.2019.00011>.
- [19] Knowledge Graph. URL: https://ru.wikipedia.org/wiki/Knowledge_Graph (accessed: 01.07.2020).
- [20] Ji S. et al. A survey on knowledge graphs: Representation, acquisition and applications. arXiv preprint arXiv:2002.00388, 2020. URL: <https://arxiv.org/abs/2002.00388> (accessed: 20.06.2020).
- [21] Molontay R., Nagy M. Twenty Years of Network Science: A Bibliographic and Co-authorship Network Analysis. arXiv preprint arXiv:2001.09006, 2020. URL: <https://arxiv.org/abs/2001.09006> (accessed: 25.06.2020).

- [22] Albert-László Barabási, Márton Pósfai. Network Science. Cambridge University Press, 2016. – 475 p.
- [23] Saleh M., Esa Y., Mohamed A. Applications of complex network analysis in electric power systems. Energies, 2018. Vol. 11, no. 6. DOI: <https://doi.org/10.3390/en11061381>.
- [24] Wu X. et al. Analysis of metro network performance from a complex network perspective. Physica A: Statistical Mechanics and its Applications, 2018. Vol. 492. P. 553–563. DOI: <https://doi.org/10.1016/j.physa.2017.08.074>.
- [25] Wachs-Lopes G. A., Rodrigues P. S. Analyzing natural human language from the point of view of dynamic of a complex network. Expert Systems with Applications, 2016. Vol. 45. P. 8–22. DOI: <https://doi.org/10.1016/j.eswa.2015.09.020>.
- [26] Jiang Z. Y. et al. Vehicle demand evolution analysis from the complex network perspective. Physica A: Statistical Mechanics and its Applications, 2019. Vol. 532. DOI: <https://doi.org/10.1016/j.physa.2019.121889>.
- [27] Noy N. et al. Industry-scale knowledge graphs: Lessons and challenges. Queue, 2019. Vol. 17, no. 2. P. 48–75. DOI: <https://doi.org/10.1145/3331166>.
- [28] Graphs in Government – Fulfilling Your Mission with Neo4j. URL: <https://www.paperpicks.com/graphs-in-government-fulfilling-your-mission-with-neo4j> (accessed: 06.06.2020).
- [29] How NASA Finds Critical Data through a Knowledge Graph. URL: <https://neo4j.com/blog/nasa-critical-data-knowledge-graph/?ref=blog> (accessed: 09.06.2020).
- [30] Ashurova Z, Tikhomirov A, Trufanov A, Kinash N, Berestneva O, Rossodivita. A 2017 Network platform of program governance for E-health service. 2017 12th Int. Sci. and Tech. Conf. on Computer Sciences and Information Technologies (CSIT), Lviv Ukraine, 2017. DOI: <https://doi.org/10.1109/STC-CSIT.2017.8099429>.
- [31] Tushkanova O.N., Samojlov V. V. Knowledge net: a model and system for accumulating, presenting, and using knowledge and data. Ontology of Designing, 2019. Vol. 9, no 1. P. 117–131. DOI: <https://doi.org/10.18287/2223-9537-2019-9-1-117-131> (in Russian).
- [32] Podrzhukina T.A., Fedorov D.Yu. Scheduling algorithms based on process semantic knowledge networks. Vestnik Sankt-Peterburgskogo universiteta GPS MCHS Rossii, no 1. P. 107–116, 2017. URL: <https://cyberleninka.ru/article/n/ispolzovanie-informatsionnyh-tehnologiy-dlya-obespecheniya-bezopasnosti-lichnosti-obschestva-i-gosudarstva> (accessed: 23.06.2020) (in Russian).
- [33] Savchenko A.P. Open network of formal corporative knowledge: a conceptual model. Scientific Journal of KubSAU, 2014, no. 103. URL: <https://cyberleninka.ru/article/n/otkrytaya-set-dokumentirovannyh-znaniy-organizatsii-kontseptualnaya-model> (accessed: 22.06.2020) (in Russian).
- [34] Announcing the Neo4j Crime Investigation Sandbox. URL: <https://medium.com/neo4j/announcing-the-neo4j-crime-investigation-sandbox-c0c3bd9e71b1> (accessed: 30.06.2020).
- [35] Neo4j and the Offshore Leaks: the Case of Azerbaijan. URL: <https://neo4j.com/graphgist/neo4j-and-the-offshore-leaks-the-case-of-azerbaijan> (accessed: 02.07.2020).
- [36] ICIJ Offshore Leaks Database. URL: <https://offshoreleaks.icij.org> (accessed: 02.07.2020).
- [37] Richard Cyganiak, David Wood, Markus Lanthaler. RDF 1.1 Concepts and Abstract Syntax, W3C Recommendation 25 February 2014. URL: <https://www.w3.org/TR/2014/REC-rdf11-concepts-20140225> (accessed: 03.07.2020).
- [38] HypergraphDB - A Graph Database. URL: <http://www.hypergraphdb.org> (accessed: 16.06.2020).
- [39] AllegroGraph. URL: <https://allegrograph.com> (accessed: 16.06.2020).
- [40] Neo4j Graph Platform – The Leader in Graph Databases. URL: <https://neo4j.com> (accessed: 16.06.2020).
- [41] Iosup A. et al. LDBC Graphalytics: A benchmark for large-scale graph analysis on parallel and distributed platforms. Proceedings of the VLDB Endowment, 2016. Vol. 9, no. 13. P. 1317–1328. DOI: <https://doi.org/10.14778/3007263.3007270>.
- [42] Hogan A. et al. Knowledge graphs. arXiv preprint arXiv:2003.02320, 2020. URL: <https://arxiv.org/abs/2003.02320> (accessed: 17.06.2020).
- [43] Rosso P., Yang D., Cudré-Mauroux P. Beyond triplets: hyper-relational knowledge graph embedding for link prediction. Proceedings of The Web Conference, 2020. P. 1885–1896. DOI: <https://doi.org/10.1145/3366423.3380257>.

*Поступила в редакцию – 13 июля 2020 г. Окончательный вариант – 20 августа 2020 г.
Received – July 13, 2020. The final version – August 20, 2020.*