

И.И. Князев**ИССЛЕДОВАНИЕ МЕТОДОВ ПОСТРОЕНИЯ КАУЗАЛЬНЫХ ГРАФОВЫХ МОДЕЛЕЙ ДЛЯ СЛОЖНЫХ СОЦИОГУМАНИТАРНЫХ СИСТЕМ**

Сложные социогуманитарные системы - это разновидность систем, которые изучаются в социологии, антропологии, экономике, политологии, и других гуманитарных науках. Эти системы характеризуются сложностью взаимодействий между их составляющими элементами, которые могут быть как людьми (индивидами, группами), так и культурными, социальными, экономическими и политическими аспектами. Например, общество как социогуманитарная система состоит из различных элементов, таких как люди, культура, институты, ценности и так далее. Они взаимодействуют между собой, образуя сложную сеть связей и влияний, которая определяет поведение и развитие общества. Чтобы лучше понять такие системы, используются различные подходы, включая системный анализ, социальную сетевую теорию, теорию сложности и другие методы. Эти подходы помогают выявить основные закономерности в функционировании сложных социогуманитарных систем и предсказать их развитие в будущем. В данной статье рассматриваются подходы к выявлению причинно-следственных связей, выделяются основные требования к построению этих связей в контексте сложных социогуманитарных систем, имеющих дело, в основном, со слабоструктурированной информацией, часто в виде естественного языка и текстов. Были определены слабые и сильные стороны выявленных подходов, а также рассмотрены примеры использования современных методов построения графов на разных задачах: выявление рисков в бизнесе, анализ социальных явлений, выявление наличия причинности в текстах. Исследование показало, что наиболее продуктивными являются методы машинного обучения, например языковые модели для извлечения знаний из текста в совокупности с нейросетевыми технологиями и графовым представлением знаний. Они требуют уверенных знаний математики, статистики и программирования, как минимум на языке Python, имеющих самую внушительную инструментальную поддержку для решения задач машинного обучения. Также, выявление причинности основывается не только на корреляции, но и на других методах, таких как тест Грейнджера, используемый для анализа временных рядов.

Каузальные графы; построение причинно-следственных связей; представление знаний; машинное обучение; социогуманитарные системы; выявление причинности.

I.I. Knyazev**RESEARCH OF METHODS FOR CONSTRUCTING CAUSAL GRAPH MODELS FOR COMPLEX SOCIO-HUMANITARIAN SYSTEMS**

Complex socio-humanitarian systems are a type of systems that are studied in sociology, anthropology, economics, political science, and other humanities. These systems are characterized by the complexity of interactions between their constituent elements, which can be both human (individuals, groups) and cultural, social, economic and political aspects. For example, society as a socio-humanitarian system consists of various elements, such as people, culture, institutions, values, and so on. They interact with each other, forming a complex network of connections and influences that determines the behavior and development of society. To better understand such systems, various approaches are used, including systems analysis, social network theory, complexity theory, and other methods. These approaches help to identify the main patterns in the functioning of complex socio-humanitarian systems and predict their development in the future. This article discusses approaches to identifying cause-and-effect relationships and highlights the basic requirements for building these connections in the context of complex socio-humanitarian systems that deal mainly with semi-structured information, often in the form of natural language and texts. The strengths and weaknesses of the identified approaches were identified, and examples of the use of modern methods of constructing graphs on various tasks were considered: identifying risks in business, analyzing social phenomena, identifying the presence of causality in texts. The study showed that the most productive methods are machine learning, for example, language models for extracting knowledge from text in combination with neural network technologies and graph representations of knowledge. They require solid knowledge of mathematics, statistics and programming, at least in Python, with the most impressive tool support for solving machine learning problems. Also, identifying causality is based not only on correlation but also on other methods such as the Granger test used for time series analysis.

Causal graphs; building cause-and-effect relationships; knowledge representation; machine learning; socio-humanitarian systems; identification of causality.

Введение. Каузальная графовая модель - это математическая модель, которая используется для представления причинно-следственных отношений между различными переменными в системе. В отличие от простых статистических моделей, каузальные графовые модели позволяют не только описывать статистические связи между переменными, но и делать выводы о причинно-следственных взаимосвязях.

В основе каузальных графовых моделей лежит концепция направленных графов, где узлы представляют переменные, а направленные ребра указывают направление влияния между переменными. Такие модели помогают исследователям выявить не только статистические связи между данными, но и понять, как одна переменная влияет на другую.

Важным преимуществом каузальных графовых моделей является возможность проведения анализа причинно-следственных отношений на основе данных, что помогает исследователям делать более обоснованные выводы о влиянии переменных друг на друга в сложных системах. Эти модели активно применяются в различных областях, таких как медицина, экономика, социология и машинное обучение. Они помогают выявить факторы, влияющие на определенные явления, и улучшить принятие решений на основе понимания причинно-следственных связей.

Особенности каузальных графовых моделей для социогуманитарных систем.

При исследовании были выделены следующие особенности таких моделей:

1. Многоуровневость переменных: в социогуманитарных системах часто есть многоуровневая природа переменных, где факторы на разных уровнях взаимосвязаны. Каузальные графовые модели позволяют учитывать эту сложность и взаимосвязи между разными уровнями.

2. Обратные связи и циклы: часто встречаются обратные связи и циклические взаимодействия между переменными. При построении каузальных графов нужно учитывать возможность таких взаимосвязей, чтобы корректно моделировать причинно-следственные отношения.

3. Неопределенность и контекст: социогуманитарные системы могут быть подвержены различным воздействиям и иметь неопределенные результаты. При построении каузальных графов нужно учитывать контекст и возможную неопределенность, чтобы точно интерпретировать результаты моделирования.

4. Интерпретируемость и вовлеченность экспертов: важно, чтобы каузальные графовые модели были интерпретируемыми для специалистов в социогуманитарных областях. Построение моделей с участием экспертов из социогуманитарных областей поможет создать более достоверные и полезные модели.

В соответствии с потребностями социогуманитарных систем были выделены следующие аспекты, необходимые для построения графовых моделей:

1. Тщательный анализ данных: выявить ключевые переменные и их взаимосвязи перед построением модели.

2. Экспертное мнение и контекст: участие экспертов из социогуманитарных областей поможет лучше понять специфику системы и правильно интерпретировать результаты моделирования.

3. Учет неопределенности и динамичности: необходимо учитывать неопределенность и динамичность социогуманитарных систем при построении моделей, чтобы они были более адаптивными к изменениям в системе.

4. Тестирование и валидация.

Для сбора данных, используемых потом для построения каузальных графовых моделей используются методы выявления причинности.

Методы выявления причинности — это инструменты и подходы, которые позволяют исследователям определять причинно-следственные взаимосвязи между переменными в данных и системах. Эти методы помогают не только выявить связи между переменными, но и сделать выводы о том, как одна переменная влияет на другую.

Основные методы выявления причинности. Когда мы говорим о построении каузальных графовых моделей, методы выявления причинности становятся ключевым этапом в процессе. В контексте построения каузальных графовых моделей методы выявления при-

чинности помогают исследователям определить направление влияния между переменными и построить корректные и информативные модели. На основе результатов изучения причинности строятся направленные графы, отражающие причинно-следственные отношения между переменными.

Проанализировав литературу из открытых ресурсов ScienceDirect, были выделены основные методы, применяемый для выявления причинности, сравнение приведено в табл. 1.

Таблица 1

Основные методы выявления причинности

Метод	Ключевые особенности	Недостатки	Преимущества
Экспериментальные исследования	Проведение контролируемых тестов с измерением показателей переменных	- серия испытаний в разных условиях более информативна, чем серия испытаний в одинаковых условиях. Повторение в теоретически эквивалентных, но конкретно различных обстоятельствах обеспечивает лучший тест, чем даже самое тщательно спланированное одиночное исследование - ограниченные возможности - несамостоятельный метод	В рамках узкой задачи гуманитарной направленности метод может быть достаточно эффективен [1]
Наблюдательные исследования	Происходит наблюдение за поведением системы и объектов без вмешательства в нее. На основе полученных наблюдений производится анализ и выявление закономерностей	- необходимо использовать дополнительные статистические методы для анализа и расчёта ключевых показателей и их связей	Эффективен в рамках поставленной задачи при наличии большого количества исходных данных для анализа
Методы машинного обучения	Использование алгоритмов машинного обучения для выявления связей	- результат сильно зависит от качества данных - поиск наборов данных для обучения - требуются знания ЯП (Python, R)	- Возможность не только выявить взаимосвязи в рамках гипотезы, но и выявить аномалии и скрытые связи - обработка огромных массивов данных - прогнозирование эффектов

Экспериментальные исследования. В экспериментах проводятся контролируемые тесты, где изменяются определенные переменные, чтобы определить их влияние на другие переменные. Эксперименты позволяют устанавливать причинно-следственные связи. Работа [1] посвящена исследованию использования экспериментов в социальных науках, представлен обзор существующего состояния и предложения для будущих исследований.

В работе авторами был зафиксирован впечатляющий рост использования экспериментов в социальных науках. Как и любой инструмент, эксперименты для одних целей лучше, чем для других, и имеют соответствующие сильные и слабые стороны. Разные области и субдисциплины, которые ограничиваются использованием одного метода, ограничивают типы исследовательских вопросов, которые они могут решать, а также связывают свои знания с ограничениями метода. Авторы считают, что методологический плюрализм социальных наук является одной из их сильных сторон.

Наблюдательные исследования. В наблюдательных исследованиях изучаются данные из натуральной среды без вмешательства исследователя. На основе анализа данных пытаются найти возможные причинно-следственные отношения. В работе [2] задачей было оценить, в какой степени индивидуальный ресурс (медицинская грамотность) и социальные ресурсы (поддержка друзей и семьи) смягчают связь между рядом индивидуальных характеристик (пол, возраст, семейный достаток и депрессивные чувства) и проблему использования социальных сетей (ПИСС); также связь между ПИСС и показателями здоровья (самооценка здоровья, удовлетворенность жизнью и трудности со сном), как на межнациональном, так и на национальном уровне.

Исследование проведено на 22 226 подростках из шести европейских стран с использованием данных опроса "Поведение детей школьного возраста в отношении здоровья" за 2017/2018 год. Использовались модели случайных эффектов и анализ модераторов (используется для проверки гипотезы о различиях во вкладе независимой переменной в зависимость при разных уровнях переменной-модератора).

Методы машинного обучения. Машинное обучение позволяет строить модели, которые могут выявлять причинно-следственные связи на основе больших объемов данных и сложных паттернов.

1. Регрессионный анализ: данный метод используется для определения статистической связи между одной зависимой переменной и одной или более независимых переменных. Это позволяет моделировать и предсказывать значения зависимой переменной на основе независимых факторов.

2. Кластерный анализ: данный метод позволяет группировать события на основе их сходства и выявлять паттерны и взаимосвязи внутри каждой группы. Он может быть полезен, когда в данных отсутствуют явно заданные зависимые переменные.

3. Методы временных рядов: эти методы используются для анализа последовательных данных во времени, таких как данные о временных рядах событий. Примерами методов временных рядов являются ARIMA [3,4] (авторегрессионное интегрированное скользящее среднее), SARIMA (сезонная модель ARIMA) [5, 6] и LSTM [7–9] (долгая краткосрочная память).

Отдельно стоит отметить тест причинно-следственной связи по Грейнджеру [10, 11], который используется в эконометрике для выявления каузальных связей во временных рядах. Реализация этого метода доступна в MATLAB, Python и других современных инструментах. Корреляции не всегда достаточно для подтверждения причинно-следственных связей, потому используют в дополнение этот тест, однако, причинность по Грейнджеру является необходимым, но не достаточным условием причинно-следственной связи.

Работа [12] демонстрирует применение данного подхода к выявлению взаимосвязей. Целью исследования было выявление эффектов, связанных с самоубийствами военнослужащих, сосредоточившись на конкретном историческом случае самоубийства кронпринца Рудольфа в 1889 году.

Для достижения цели исследования были проведены анализ временных рядов самоубийств среди военнослужащих в период с 1873 по 1910 год. Подход авторов основан на методах прерванного анализа временных рядов, позволяющих выявить изменения в тенденциях после конкретного события, такого как самоубийство кронпринца.

4. Байесовская сеть: данная модель представляет события в виде вершин графа, где ребра между вершинами указывают на вероятностные зависимости между событиями. Байесовские сети могут использоваться для моделирования взаимосвязей и предсказания вероятности возникновения событий.

5. Ассоциативные правила: этот метод используется для поиска скрытых взаимосвязей между событиями на основе частоты их совместной встречаемости. Например, анализ ассоциативных правил может помочь выявить, какие события часто происходят вместе и как одно событие может быть следствием другого.

Конечный выбор метода зависит от типа данных, доступной информации и цели анализа взаимосвязей в событиях. Важно учитывать, что эти методы машинного обучения могут использоваться в комбинации или совмещаться с другими методами для более точного анализа.

Таким образом, методы выявления причинности являются важным инструментом при построении каузальных графовых моделей, позволяя более точно представить причинно-следственные связи в данных и системах.

Применение каузальных графов в исследованиях. В работе [13] выявление причинно-следственной связи между событиями является важнейшей исследовательской задачей в области обработки естественного языка. Однако, существующие методы либо игнорируют фоновые знания о событиях, либо не учитывают влияние шума графа знаний на представления событий. В этой статье предложена новая сеть расширенных знаний на основе контраста графов (GCKAN) для задачи идентификации причинно-следственных связей событий, которая объединяет комплексные фоновые знания о событиях из графов знаний и устраняет проблему шума графа знаний. Во-первых, предлагается модуль расширения описательных знаний для агрегирования информации о соседях с одним переходом в графах знаний и получения значимых описательных знаний о событиях. Затем модуль расширения реляционных знаний предназначен для кодирования информации о многопрыжковом пути и изучения скрытых знаний о рассуждениях между парами событий. Кроме того, в двух модулях разработаны схемы контрастного обучения на основе достоверности и степени, которые подавляют шум графа знаний во время агрегации информации и создают более надежные представления событий с учетом знаний. Обширные эксперименты с тремя общедоступными наборами данных демонстрируют последовательное превосходство GCKAN над современными методами, основанными на знаниях. Эксперименты с шумовыми помехами и эксперименты по межтематической адаптации дополнительно подтверждают надежность и обобщение GCKAN.




Рис. 1. Архитектура модели преобразования знаний

На рис. 1 представлена архитектура от авторов которая состоит из модуля кодирования контекста, модуля описательного расширения знаний, модуля реляционного расширения знаний и модуля классификации. Фиолетовые части обозначают контрастное обучение графа.

Выделим инструменты и методы, задействованные в этой модели и рассмотрим подробнее.

ConceptNet – открытая и бесплатная база знаний, структурно реализованная в виде семантической сети, включающей знания о мире для понимания слов. Предыдущие версии ConceptNet – краудсорсинговый проект, в рамках которого создатели управляли веб-сайтом (Open Mind Common Sense), собирая факты от людей, которые заходили на этот сайт [14].

Данные поступают из множества различных источников, содержит реляционные знания, предоставленные Open Mind Common Sense и родственными ему проектами на других языках. В источники входит Википедия, Викисловарь, Open Multilingual WordNet [15, 16], онтология высокого уровня из OpenCyc, ряд знаний об интуитивных словесных ассоциациях людей извлекаются при помощи «целенаправленных игр». Например, факты на английском языке из Verbosity, словесной игры, ранее запущенной проектом GWAP, а на японском языке – из игры «nadya.jp» от Nihon Unisys и Dentsu.

Преобразование текста делается с помощью модели BERT [17].

Расширение описательных знаний, которое использует сеть внимания графов с учетом отношений (RAGAN) для агрегирования описательных знаний о событиях и разрабатывает основанную на надежности схему контрастного обучения графов, чтобы сделать представление знаний менее чувствительным к связям с шумным соседом;

BiLSTM [18] для расширения реляционных знаний, которое сначала организует пути между событиями в графы, а затем изучает многошаговые реляционные знания с помощью сетей внимания графов, учитывающих отношения.

Далее все сводится к задаче бинарной классификации, определяя, есть ли причинно-следственная связь между событиями.

На рис. 2 представлен пример описания ситуации «Враг атаковал остров, и жители бежали». Граф отражает связи с близкими по значению словами, на ребрах указан вид связей, на вершинах слова.

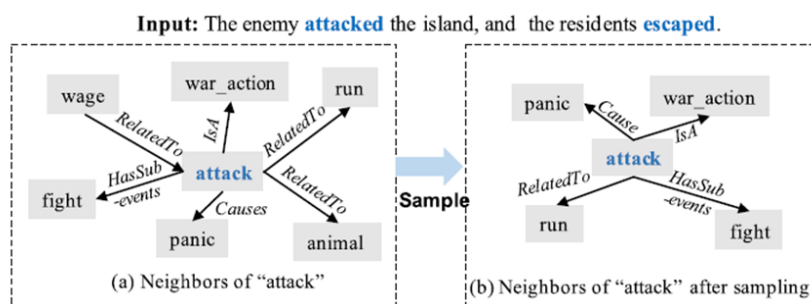


Рис. 2. Фрагмент визуализации каузального графа

В работе [19] применяется графовая модель выявления неявных знаний в области выявления рисков бизнеса. Целью данного исследования было проанализировать цепочки рисков и извлечь неявную информацию из раскрытых документов. Во-первых, была предложена классификация ребер и предложены подходящие метки для ребер графа цепочки рисков. Кроме того, разработана классификация типов ребер в гетерогенных графах с использованием нейронных сетей графов (GNN[20]). Это было достигнуто путем определения шести рисков и построения графиков цепочек рисков. Результаты показали, что классификация по типу ребер оказалась эффективным подходом по сравнению с существующим методом. Этот метод потенциально может помочь инвесторам увеличить свою прибыль и принять более обоснованные решения.

Заключение. В данной работе было проведено исследование каузальных графов в задачах социогуманитарных систем. Были выделены основные достоинства и недостатки применения этого подхода в рамках социогуманитарных аспектов, а также требования к их построению с учетом особенностей предметной области. Среди них были выделены и описаны следующие: многоуровневость переменных, обратные связи и циклы, неопределенность и контекст, интерпретируемость и вовлеченность экспертов.

Исследуя вышеописанный подход, были определены основные методы выявления причинности, в таблице указаны их сильные и слабые стороны, выделенные из современных исследований. Как показало исследование, на данном этапе развития мощнейшим инструментом являются методы машинного обучения, но они требуют качественной подготовки и знаний в области математики, статистики и программирования.

Помимо теоретических выводов, было продемонстрировано применение каузальных графов на примере анализа текстов, в основе которых, зачастую лежит именно рассматриваемый в этой работе подход.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Mize T.D., Manago B. The past, present, and future of experimental methods in the social sciences, *Social Science Research*, 2022, Vol. 108, 102799. ISSN 0049-089X.
2. Lahti H., Kulmala M., Hietajärvi L., Lyyra N., Kleszczewska D., Boniel-Nissim M., Furstova J., van den Eijnden R., Sudeck G., Paakkari L. What Counteracts Problematic Social Media Use in Adolescence? A Cross-National Observational Study, *Journal of Adolescent Health*, 2024, Vol. 74, Issue 1, pp. 98-112. ISSN 1054-139X.
3. Asteriou Dimitros, Hall Stephen G. ARIMA Models and the Box–Jenkins Methodology, *Applied Econometrics*. 2nd ed. Palgrave MacMillan, 2011, pp. 265-286. ISBN 978-0-230-27182-1.
4. Terence C. Mills. Time Series Techniques for Economists. Cambridge University Press, 1990. ISBN 978-0-521-34339-8.
5. Percival Donald B., Walden Andrew T. Spectral Analysis for Physical Applications. Cambridge University Press. 1993. ISBN 978-0-521-35532-2.
6. Shumway R.H. and Stoffer D.S. Time Series Analysis and Its Applications: With R Examples. Springer, 2017. DOI: 10.1007/978-3-319-52452-8.
7. Gers F., Schraudolph N., Schmidhuber J. Learning precise timing with LSTM recurrent networks (engl.), *Journal of Machine Learning Research: journal*, 2002, Vol. 3, pp. 115-143.
8. Greff K., Srivastava K., Koutnik Jan, Steunebrink Bas J., Schmidhuber Jürgen. LSTM: A Search Space Odyssey, *Neural and Evolutionary Computing*, 2015
9. Gers F.A., Schmidhuber J. LSTM Recurrent Networks Learn Simple Context Free and Context Sensitive Languages (engl.), *IEEE Transactions on Neural Networks (engl.)* russ.: journal, 2001, Vol. 12, No. 6, pp. 1333-1340. DOI: 10.1109/72.963769.
10. Kaminski M., Ding M., Truccolo W.A., Bressler S.L Evaluating causal relations in neural systems: Granger causality, directed transfer function and statistical assessment of significance, *Biol Cybern*, 2001, 85, pp. 145-57.
11. Ancona N., Marinazzo D., Stramaglia S. Radial basis function approaches to nonlinear Granger causality of time series, *Physical Review E*, 2004, Vol. 70, 056221.
12. Arendt F., Mestas M. Suicide among soldiers and social contagion effects: An interrupted time-series analysis, *Social Science & Medicine*, 2023, Vol. 320, 115747. ISSN 0277-9536.
13. Ding L., Chen J., Du P., Xiang Ya. Event causality identification via graph contrast-based knowledge augmented networks, *Information Sciences*, 2024, Vol. 656, 119905.
14. ConceptNet. Режим доступа: Available at: <https://conceptnet.io/> (accessed 28 March 2024).
15. Bond F., Paik K. A survey of wordnets and their licenses, *In Proceedings of the 6th Global WordNet Conference (GWC 2012)*. Matsue, 2012, pp. 64-71.
16. Bond F., Vossen P., McCrae John. CILI: the Collaborative Interlingual Index./ F. Bond, P. Vossen, John McCrae, Christiane Fellbaum, *In Proceedings of the 8th Global WordNet Conference (GWC2016)*. Bucharest, 2016, pp 50-57.
17. Pre-training of deep bidirectional transformers for language understanding, *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, (Vol. 1: Long and Short Papers), 2019, pp. 4171-4186.
18. Cheng F., Miyao Y. Classifying temporal relations by bidirectional lstm over dependency paths, *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics*, 2017, Vol. 2: Short Papers, pp. 1-6.
19. Hajime Sasaki, Motomasa Fujii, Hiroki Sakaji, Shigeru Masuyama. Enhancing Risk Identification with GNN: Edge Classification in Risk Causality from Securities Reports, *International Journal of Information Management Data Insights*, 2024, Vol. 4. Issue 1, 100217. ISSN 2667-0968.
20. Wu Lingfei, Cui Peng, Pei Jian; Zhao Liang. Graph Neural Networks: Foundations, Frontiers, and Applications. Springer Singapore, 2022, 725 p.

Статью рекомендовал к опубликованию д.т.н., профессор А.В. Боженюк

Князев Иван Игоревич – Южный федеральный университет; e-mail: ikniazev@sfedu.ru; г. Таганрог, Россия; тел.: +79265347104; аспирант.

Knyazev Ivan Igorevich – Southern Federal University; e-mail: ikniazev@sfedu.ru; Taganrog, Russia; phone: +79265347104; postgraduate student.