

13. *Sivak M.A., Timofeev V.S.* Postroenie robastnykh neyronnykh setey s razlichnymi funktsiyami poter' [Construction of robust neural networks with different loss functions], *Sistemy analiza i obrabotki dannykh* [Systems of data analysis and processing], 2021, No. 2 (82), pp. 67-82. DOI: 10.17212/2782-2001-2021-2-67-82.
14. *Haykin S.* Neural Networks and Learning Machines. 3rd ed. Pearson Education, 2009, 906 p.
15. *Bishop C.M.* Neural Networks for Pattern Recognition. New York, US: Oxford University Press, 1995, 502 p.
16. *Brownlee J.* A Gentle Introduction to the Rectified Linear Unit (ReLU), 2019. Available at: <https://inlnk.ru/agw2E2> (visited on 02/19/2022).
17. GeeksforGeeks A computer science portal for geeks. Available at: <https://www.geeksforgeeks.org/regression-metrics/>.
18. *Sivak M.A.* Robastnoe obuchenie neyronnykh setey s prostoy arkhitekturoy dlya resheniya zadach klassifikatsii: diss. ... kand. Nauk [Robust training of neural networks with simple architecture for solving classification problems: cand. of eng. sc. diss.]: 05.13.17. Novosibirsk: NGTU, 2022, 111 s.
19. *Dubyago M.N., Poluyanovich N.K.* Sovershenstvovanie metodov diagnostiki i prognozirovaniya elektroizolyatsionnykh materialov sistem energosnabzheniya: monografiya [Improving methods for diagnostics and forecasting of electrical insulating materials of power supply systems: monograph]. Rostov-on-Don; Taganrog: Izd-vo YuFU, 2019, 192 p.
20. *Poluyanovich N.K., Bur'kov D.V., Dubyago M.N.* Neyrosetevoy metod prognozirovaniya elektropotrebleniya i ego instrumental'naya realizatsiya: monografiya [Neural network method for forecasting electricity consumption and its instrumental implementation: monograph]. Rostov-on-Don; Taganrog: Izd-vo YuFU, 2023, 151 p.
21. *Pal'chevskiy E.V.* Metody neyrosetevoy obrabotki bol'shikh temporal'nykh dannykh dlya informatsionnoy podderzhki prinyatiya upravlencheskikh resheniy (na primere elektroenergetiki): diss. ... kand. tekhn. nauk [Methods of neural network processing of big temporal data for information support of management decisions (on the example of the electric power industry): cand. of eng. sc. diss.]: 2.3.1. Ufa: Ufimskiy universitet nauki i tekhnologii, 2024.

Полуянович Николай Константинович – Южный федеральный университет; e-mail: nik1-58@mail.ru; г. Таганрог, Россия; тел.: 89185693365; кафедра электротехники и мехатроники; к.т.н.; доцент.

Качелаев Олег Вадимович. – Южный федеральный университет; e-mail: 22.olezhka@mail.ru; г. Таганрог, Россия; тел.: 89281163960; кафедра техносферной безопасности и химии; аспирант.

Дубяго Марина Николаевна – Южный федеральный университет; e-mail: w_m88@mail.ru; тел.: 89281758225; кафедра электротехники и мехатроники; к.т.н.; доцент.

Poluyanovich Nikolay Konstantinovich – Southern Federal University; e-mail: nik1-58@mail.ru; Taganrog, Russia; phone: +79185693365; the Department of Electric Technics and Mechatronics; cand. of eng. sc.; associate professor.

Kachelaev Oleg Vadimovich – Southern Federal University; e-mail: 22.olezhka@mail.ru; Taganrog, Russia; phone: +79281163960; the Department of Techno-sphere Safety and Chemistry; postgraduate student.

Dubyago Marina Nikolaevna – Southern Federal University; e-mail: w_m88@mail.ru; phone: +79281758225; Taganrog, Russia; the Department of Electrical Engineering and Mechatronics; cand. of eng. sc.; associate professor.

УДК 004.8

DOI 10.18522/2311-3103-2025-1-118-129

А.Н. Целых, И.А. Валухов, Л.А. Целых

ИЗВЛЕЧЕНИЕ ПРИЧИННО-СЛЕДСТВЕННЫХ КОРТЕЖЕЙ ИЗ ТЕКСТА НА ОСНОВЕ ГЛУБОКОГО ОБУЧЕНИЯ С ИСПОЛЬЗОВАНИЕМ СИНТЕТИЧЕСКИХ ДАННЫХ

Рассматривается проблема разработки модели извлечения полных причинных кортежей из неструктурированных текстов для представления ситуаций принятых решений в сложных социогуманитарных средах. Совокупность извлекаемых кортежей из определенного набора текстов представляет собой связанные сущности конкретной среды, что позволяет создать причинно-следственные графы. В этой статье предлагается модель извлечения причинно-следственных

связей с использованием предобученной модели BERT с дообучением на основе дополнительных признаков. Для уточнения причинной классификации модель использует два вида признаков (каузальность глаголов и метрики качества причинного влияния) для распознавания причинного кортежа, автоматически изучает семантические признаки из предложений, повышая точность извлечения. Предварительная обработка текста осуществляется с помощью библиотеки SpaCy с открытым исходным кодом. Извлеченные причинно-следственные кортежи в формате <фраза причины, фраза глагола, фраза следствия, полярность> легко трансформируются в соответствующие элементы графа <исходящий узел, направление связи, входящий узел, знак веса связи> и далее могут быть использованы для построения направленного взвешенного знакового графа с детерминированной причинностью на дугах. В целях снижения зависимости от внешних знаний для дообучения и тестирования модели BERT используются синтетически сгенерированные аннотированные наборы данных. Экспериментальные результаты показывают, что точность извлечения причинно-следственных связей на синтетических данных достигает 94%, а значение F1 – 95%. Преимуществами представленного технологического решения является то, что модель не требует высоких эксплуатационных затрат, реализована на компьютере со стандартными характеристиками, использует свободное программное обеспечение, что делает ее доступной для широкого круга пользователей. Ожидается, что предложенная модель может быть использована для автоматизации анализа текстов и поддержки принятия решений в условиях высокой неопределенности, что особенно актуально для социогуманитарных сред.

Извлечение причинно-следственных связей; глубокое обучение; BERT; когнитивные каузальные модели; графовое представление; обработка текстов на естественном языке; автоматизированное обучение; поддержка принятия решений.

A.N. Tselykh, I.A. Valukhov, L.A. Tselykh

APPLYING DEEP LEARNING TO EXTRACT CAUSALITY FROM TEXT USING SYNTHETIC DATA

This article addresses the problem of developing a causal full-tuples extraction model from unstructured texts to represent decision-making situations in complex social and humanitarian environments. We present a causal full-tuples extraction model using a pre-trained BERT with additional feature-based special fine-tuning. To refine the causal classification, the model uses two types of features (verb causality and cause-and-effect quality metrics) to recognize a causal tuple, automatically extracts semantic features from sentences, increasing the accuracy of extraction. Text preprocessing is performed using the open source SpaCy library. The extracted cause-and-effect tuples in the format <cause phrase, verb phrase, effect phrase, polarity> are easily transformed into the corresponding elements of the graph <outgoing graph node, graph arc direction, incoming graph node, graph connection weight sign> and can then be used to construct a directed weighted signed graph with deterministic causality on arcs. In order to reduce dependence on external knowledge, synthetic generated annotated datasets are used to fine-tune and test the BERT model. Experimental results show that the accuracy of extracting cause-and-effect relationships on synthetic data reaches 94%, and the F1 value is 95%. The advantages of the presented technological solution are that the model does not require high operating costs, is implemented on a computer with standard characteristics, uses free software, which makes it accessible to a wide variety of users. It is expected that the proposed model can be used to automate text analysis and support decision-making in conditions of high uncertainty, which is especially important for social and humanitarian environments.

Extracting causal relationships; deep learning; BERT; cognitive causal models; graph representation; natural language processing; automated learning; decision support.

Введение. В современном мире извлечение причинно-следственных связей становится все более важным для многих задач обработки естественного языка (Natural Language Processing, NLP) [1]. Однако поиск универсальной модели усложнен из-за неоднозначности смыслов и разнообразия текстов на естественном языке. Поэтому извлечение причинно-следственных связей остается сложной задачей NLP.

Существующие методы используют шаблоны, ограничения и методы машинного обучения для извлечения причинности. Традиционные подходы к извлечению причинно-следственных связей требуют ручной аннотации и обработки текста, что может быть трудоемким и неэффективным, а также в значительной степени зависят от знаний предметной области [2]. С развитием методов глубокого обучения предварительно обученные

языковые модели вывели современные методы извлечения причинно-следственных отношений на новый уровень, позволяя максимально автоматизировать процесс извлечения полных причинных кортежей с высокой точностью [3, 4].

В данном исследовании рассматривается проблема разработки модели извлечения полных причинных кортежей из неструктурированных текстов для дальнейшего представления ситуаций принятых решений в сложных социогуманитарных средах. Рассматривая совокупность извлекаемых кортежей из определенного набора текстов, как связанные сущности конкретной среды, возможно создать графовое представление ситуации, функционирования системы, представление о предметной области. Создание таких графов на основе извлечения причинно-следственных связей рассматривалось в работах [5–7]. Однако, надо отметить, высокую трудоемкость предлагаемых решений.

В этом исследовании используется предобученная модель BERT (Bidirectional Encoder Representation from Transformers) [3, 8] с дообучением на основе дополнительных признаков для построения модели извлечения причинно-следственных связей с целью повышения точности. Эта модель позволяет классифицировать слова в предложении и выявлять полные причинные кортежи с высокой точностью [3]. Для уточнения причинной классификации при дообучении дополнительно учитывались следующие признаки: каузальность глаголов и качество причинного влияния в причинном кортеже. Модель использует эти два вида признаков, автоматически изучает семантические признаки из предложений, снижая зависимость от внешних знаний и повышая точность извлечения. Далее извлеченные причинно-следственные кортежи могут быть использованы для построения направленного взвешенного знакового графа с детерминированной причинностью на дугах. В зависимости от целей применения, такие графы имеют в литературе разные названия – граф знаний [9], причинно-ассоциативная сеть (causal-associational network, CASNET) [10], когнитивная карта [11].

Важным условием использования методов машинного обучения для задач извлечения причинно-следственных связей является создание аннотированных наборов данных. В связи с экспоненциальным расширением человеческих знаний и накоплением огромных массивов текстовых данных, ручная маркировка данных нереалистична. Тогда применение методов глубокого обучения для создания синтетических данных представляется обоснованным решением. В рамках работы мы использовали для дообучения и тестирования модели BERT синтетически сгенерированные наборы данных. Экспериментальные результаты показывают, что точность извлечения причинно-следственных связей достигает 94%, а значение F1 – 95%.

Преимуществом нашей работы является также то, что модель реализована на компьютере со стандартными характеристиками, не требующем высоких эксплуатационных затрат, что делает ее доступной для широкого круга пользователей. Результаты наших исследований демонстрируют приемлемую эффективность предложенного подхода и показывают возможности применения методов глубокого обучения в задачах извлечения причинно-следственных связей.

Обзор публикаций, связанных с темой исследования. В данном разделе мы рассмотрим ключевые работы, посвященные методам и моделям, которые используются для решения этой задачи, а также их применимость к нашей теме.

Традиционные методы извлечения причинно-следственных связей часто основаны на правилах и шаблонах, которые требуют ручной аннотации и обработки текста. Например, в работе [12] описывается подход, основанный на использовании лексических и синтаксических шаблонов для выявления причинно-следственных отношений в тексте. Однако такие методы часто оказываются трудоемкими и недостаточно гибкими для обработки разнообразных текстовых данных. С развитием машинного обучения появились более эффективные методы автоматического извлечения причинно-следственных связей. В работе [13] предложен подход, основанный на использовании классификаторов машинного обучения, таких как Support Vector Machines (SVM), для выявления причинно-следственных отношений в тексте. Авторы используют различные лингвистические признаки, части речи, зависимости между словами и семантические роли, для улучшения

качества классификации. Графовое представление причинно-следственных связей является важным аспектом в задачах анализа текста. В работе [14] предложен метод построения графов причинно-следственных связей с использованием глубокого обучения. Авторы используют архитектуру GNN для моделирования сложных зависимостей между сущностями в тексте. Этот подход позволяет эффективно представлять причинно-следственные связи в виде графа, что может быть полезно для дальнейшего анализа и визуализации. В последние годы глубокое обучение и предобученные языковые модели, такие как BERT, стали основным инструментом для решения задач NLP, включая извлечение причинно-следственных связей. В работе [15] предложен подход, основанный на использовании BERT для классификации причинно-следственных отношений в тексте. Авторы демонстрируют, что BERT позволяет достичь высокой точности благодаря своей способности учитывать контекст и семантические связи между словами.

Оценка эффективности моделей извлечения причинно-следственных связей является важным аспектом исследований. В работе [16] предложен метод оценки моделей на основе метрик F1-оценки и точности. Авторы подчеркивают важность учета энергоемкости и экономичности моделей, что особенно актуально для практического применения в условиях ограниченных ресурсов. Этот подход согласуется с нашей задачей, где мы также учитываем параметры эффективности модели.

В данном разделе мы рассмотрели ключевые работы, посвященные методам и моделям извлечения причинно-следственных связей из текста. Традиционные подходы, основанные на правилах и шаблонах, уступают по эффективности современным методам машинного обучения и глубокого обучения. Предобученные языковые модели, такие как BERT, демонстрируют высокую точность и гибкость в задачах извлечения причинно-следственных связей.

Модель извлечения причинно-следственных связей. Постановка проблемы. В этом разделе мы представляем модель извлечения причинно-следственных кортежей из текста для графового представления ситуаций принятых решения в сложных социогуманитарных средах. Состояние среды может быть описано системой институциональных факторов (социальных, экономических, экологических, культурных, политических, технологических), составляющих и определяющих эту среду, с их причинно-следственными связями. Распространенным формальным представлением, описывающим состояние такой среды, является когнитивная каузальная модель (ККМ), описываемая в виде направленного взвешенного знакового графа с детерминированной причинностью на дугах. Граф ККМ предназначен для моделирования стратегий управляющих воздействий при принятии управленческих решений лицом, принимающим решения (ЛПР), в ситуациях высокой цены. Примеры и описание таких графовых представлений описаны в [17–19]. С учетом вышеизложенного, с целью максимального снижения субъективности ККМ извлечение причинных отношений должно быть ограничено явной причинностью, выраженной в тексте.

Тогда, исходя из формализма графового представления ситуативной среды необходимыми условиями формирования кортежа являются асимметричный и полярный характер причинности, выражающийся, соответственно, в направленности и полярности причинных отношений в графе. Направленность определяется последовательностью записи в шаблоне извлечения грамматики *<причина, следствие>*. Полярность выражается в лимитировании корпуса глаголов выражениями, обеспечивающими прямую констатацию качества причинного влияния *<уменьшение | увеличение>*.

Тогда проблема извлечения причинных кортежей из текста для графового представления ККМ описывается следующим образом:

1. Извлечение определяется кортежем в формате *<фраза причины, фраза глагола, фраза следствия, поляризация>*.
2. Идентификация причинности осуществляется на основе следующих правил формирования кортежа.

Пусть $\mathbf{S} = [S_1, \dots, S_n] \in R^{1 \times |S|}$ относится к предложению с токенами $|S|$, где каждый токен S_i является словом, включая специальные идентификаторы для указания пары причина-следствие (S_{e1}, S_{e2}) . В этом исследовании используются специальные запросы на семантику глагола (на основе списка каузальных глаголов) как потенциальное альтернативное решение задачи идентификации причинности.

Правило 1. Отбор предложений-кандидатов. Обозначим индикатор маски как $m = [m_1, \dots, m_{|S|}] \in \{0, 1\}^{1 \times |S|}$, где $m_i = 0$, если S_i не является токеном из списка каузальных глаголов *list of verbs*, в противном случае $m_j = 1$, $j \in [1, \dots, |S|]$, $j \neq i$. В результате получаем базовый корпус предложений-кандидатов S_m содержащих каузальные глаголы.

Правило 2. Идентификация полярности. Учитывая базовый корпус входных предложений-кандидатов (S_m) , дискриминатор D исследует наличие причинно-семантической полярности в предложении S_m . $D = [D_m] \in \{-1, 0, +1\}^{1 \times |S_m|}$, где $n_i = -1$, если S_i является токеном из списка слов *decreasing_words*, уменьшающих причинный эффект в причинно-следственной связи, $n_j = +1$, если S_j принадлежит списку слов *increasing_words*, увеличивающих причинный эффект в причинно-следственной связи, в противном случае $m_k = 0$, $k \in [1, \dots, |S|]$, $j \neq i \neq k$. В результате получаем элемент кортежа $\langle \text{полярность} \rangle$.

Дополнительные требования к технологическому решению: использование свободного программного обеспечения, дообучение предобученной модели на синтетических данных без сложной и длительной ручной аннотации данных, низкие показатели эксплуатационных затрат.

Формирование списков глаголов. Извлечение предложений-кандидатов из текста включает процессы фильтрации и определения полярности причинных отношений на основе использования списков каузальных глаголов. Для реализации этих процессов мы использовали два типа списков: список инфинитивных каузальных глаголов и списки качества причинного влияния $\langle \text{уменьшение} \mid \text{увеличение} \rangle$.

В качестве основы для формирования списка инфинитивных каузальных глаголов *list of verbs* использовался словарь причинных глаголов, определенных в лексической базе данных английского языка WordNet, разработанной в Принстонском университете [5, 20]. Список включает 76 глаголов, содержащий 62 глагола из [5] и 11 дополнительных глаголов. Списки качества причинного влияния включают глаголы, отражающие соответственно уменьшение (*decreasing_words*) и увеличение причинного эффекта (*increasing_words*) в причинно-следственной связи.

Соответствующие списки глаголов доступны по адресу https://github.com/igFullStack/Causal_Relation_Extraction_Lists.

Описание модели извлечения причинно-следственных кортежей из текста. Процесс извлечения причинного кортежа включает следующие этапы:

1. Ввод корпуса данных.
2. Препроцессинг текста с использованием библиотеки SpaCy version 3.7.6 с открытым исходным кодом для расширенной обработки естественного языка, написанная на языках программирования Python и Cython [21, 22].
3. Извлечение базового списка предложений-кандидатов для обучения модели Bert в формате $\langle \text{предложение}, \text{фраза глагола} \rangle$ путем фильтрации на основе глаголов с использованием библиотеки SpaCy.
4. Извлечение корпуса причинных кортежей типа 1: $\langle \text{предложение}, \text{фраза глагола}, \text{полярность} \rangle$ с использованием алгоритма определения полярности причинных отношений в кортежах.

5. Извлечение корпуса причинных кортежей типа 2: <фраза причины, фраза глагола, фраза следствия, полярность> с использованием программы Bert version 4.45.2.
6. Оценка кортежей с помощью стандартных метрик для машинного обучения (F1-score, Accuracy, Precision, Recall).

Предлагаемая модель состоит из трех основных частей, которые обеспечивают процесс извлечения причинных кортежей из текстов: (1) *Preprocessing Module*, (2) *Causal Polarity Detection Module*, (3) *Tuple Generation Module*. Архитектурная схема процесса извлечения причинных кортежей показана на рис. 1.

Preprocessing Module предназначен для извлечения базового корпуса предложений-кандидатов для обучения модели Bert на основе естественного языка для задач классификации текста с использованием библиотеки SpaCy. Модуль состоит из двух частей: *Candidate Sentence Extractor* и *Filtering Engine*.

Candidate Sentence Extractor сначала извлекает из сырого необработанного текста в формате *.txt*, *.doc*, *.docx*, *.pdf* очищенный список предложений *list of sentences*, используя собственную модель *en_core_web_sm* библиотеки SpaCy [11]. Схема алгоритма и программный код процесса генерации списка предложений приведены соответственно в табл. 1 и на рис. 2. Далее этот список подвергается фильтрации с использованием списка глаголов *list of verbs*. Отфильтрованный базовый корпус предложений-кандидатов *list of candidate sentences* в формате <предложение, фраза глагола> передается в модуль *Causal Polarity Detection Module* для извлечения кортежей типа 1 <предложение, фраза глагола, полярность>.

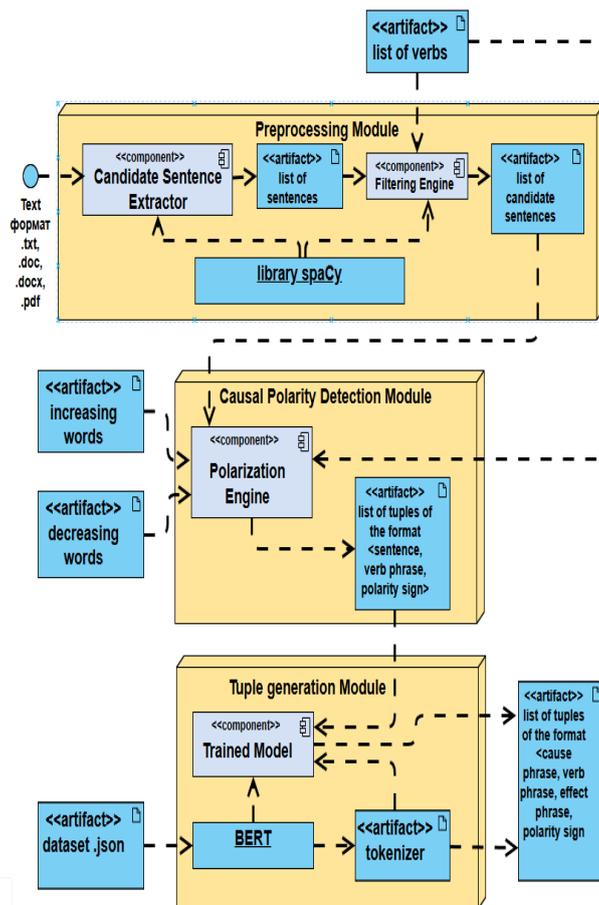


Рис. 1. Архитектурная схема процесса извлечения причинных кортежей

Таблица 1

Алгоритм 1: Схема процесса генерации базового корпуса предложений-кандидатов	
1:	Input: filename; list of verbs;
2:	Output: List of sentences
3:	Function ReadSentencesFromFile(filename):
	# Initialization
4:	sentences <- [];
	# Step 1: Read file content
5:	content <- ReadFileContent(filename);
	# Step 2: Process content using NLP model
6:	doc <- ProcessWithSpaCy(content);
	# Step 3: Extract sentences
7:	sentences <- ExtractSentences(doc);
8:	return sentences;
9:	Function ReadFileContent(filename):
10:	open(filename) as file:
11:	return file.read();
12:	Function ProcessWithSpaCy(content):
13:	return nlp(content);
14:	Function ExtractSentences(doc):
15:	sentences <- [];
16:	for sentence in doc.sents:
17:	sentences.append(sentence.text);
18:	return sentences

```

119 # Функция для чтения предложений из файла
120 def read_sentences_from_file(filename):
121     with open(filename, 'r', encoding='utf-8') as f:
122         content = f.read()
123         sentences = content.splitlines()
124         return [sentence.strip() for sentence in sentences if sentence.strip()] # Удаляем пустые строки и пробелы
125

```

Рис. 2. Код для генерации базового корпуса предложений

Filtering Engine осуществляет фильтрацию предложений-кандидатов на основе глаголов с использованием библиотеки SpaCy и функции *is_causal*. Функция *is_causal* (рис. 3) принимает на вход список предложений и список казуальных глаголов, с помощью SpaCy убирает стоп-слова (артикли, предлоги, союзы и т.п.) из каждого обрабатываемого в цикле предложения, производит токенизацию предложения и выделяет лемму и часть речи каждого токена. Затем функция *is_causal* выводит предложение в список предложений-кандидатов при двух условиях: наличие в предложении токена с частью речи VERB и его леммы в списке казуальных глаголов.

```

83 # Функция для проверки наличия казуальных глаголов в предложении
84 def is_causal(sentence, nlp, causal_verbs, complex_causal_verbs):
85     doc = nlp(sentence)
86
87     # Проверка на наличие сложных казуальных глаголов
88     for verb in complex_causal_verbs:
89         # Генерация всех форм для сложных глаголов
90         verb_forms = generate_complex_forms(verb)
91         for form in verb_forms:
92             if form in sentence.lower():
93                 return verb
94
95     # Проверка на наличие казуальных глаголов в инфинитивной форме
96     for token in doc:
97         if not token.is_stop and token.pos_ == 'VERB':
98             # Проверка леммы для простых казуальных глаголов
99             if token.lemma_.lower() in causal_verbs:
100                 return token.lemma_.lower()
101
102     return None

```

Рис. 3. Код функции *is_causal*

Causal Polarity Detection Module реализует формирование кортежей формата *<предложение, фраза глагола, полярность>* на основе списка предложений-кандидатов *list of candidate sentences*, полученного из *Preprocessing Module*, списка каузальных глаголов *list of verbs* и списков *increasing_words* и *decreasing_words*. Псевдокод алгоритма представлен в табл. 2. Алгоритм 2 использует цикл для анализа каждого предложения из списка предложений-кандидатов (рис. 4).

В *Tuple generation Module* реализуется процесс извлечения причинных кортежей формата *<фраза причины, фраза глагола, фраза следствия, полярность>*. Дообучение модели для извлечения фразы причины и фразы следствия из предложения на основе каузального глагола, происходит на основе предобученной модели BERT и синтетических размеченных данных с аннотациями.

Таблица 2

Алгоритм 2: Алгоритм определения полярности причинных отношений в кортежах	
1:	Input: text; list_of_verbs; increasing_words; decreasing_words;
2:	Output: weight ²
3:	Function CalculateCausalWeight (text, list_of_verbs, increasing_words, decreasing_words):
	weight = 0;
4:	# Step 1: Iterate over tokens in the document
5:	for i, tok in enumerate(text):
	# Step 2: Check if the token is a causal verb
6:	if tok.lemma_lower() in causal_verbs:
	# Step 3: Get the weight of the causal verb
7:	weight = list_of_verbs[tok.lemma_lower()];
	# Step 4: Check if the weight is 0 and adjust it based on modifiers
8:	if weight == 0: weight = AdjustWeightBasedOnModifiers (doc, increasing_words, decreasing_words);
	break;
9:	return weight;
10:	Function AdjustWeightBasedOnModifiers (text, increasing_words, decreasing_words):
11:	# Initialization
	weight = 0;
	# Step 1: Iterate over tokens in the document
12:	for token in text:
	# Step 2: Check if the token is an increasing word
13:	if token.text.lower() in increasing_words:
	# Step 3: Increase the weight
14:	weight = min(1, weight + 1);
	# Step 4: Check if the token is a decreasing word
15:	elif token.text.lower() in decreasing_words:
	# Step 5: Decrease the weight
16:	weight = max(-1, weight - 1);
17:	return weight

² – “weight” обозначает знак полярности в соответствии Правилем 2.

Разметка данных проводилась с помощью генератора обучающего датасета, код которого приведен на рисунке N. Для разметки используются следующие типы меток: O, B-Cause, I-Cause, B-Effect, I-Effect, обозначающие следующие сущности:

- ◆ "Outside" или "Other", т.е. токен не относится ни к одной из определенных сущностей (причине или следствию);
- ◆ B-Cause – начало ("Begin") сущности, обозначающей причину. Метка отмечает первый токен в последовательности, которая относится к причине.

```
294     for i, tok in enumerate(doc):
295         if tok.lemma_.lower() in causal_verbs:
296             weight = causal_verbs[tok.lemma_.lower()]
297
298         # Если вес равен 0, проверяем модификаторы
299         if weight == 0:
300             for token in doc:
301                 if token.text.lower() in increasing_words:
302                     weight = min(1, weight + 1)
303                 elif token.text.lower() in decreasing_words:
304                     weight = max(-1, weight - 1)
```

Рис. 4. Код для определения полярности

◆ I-Cause – внутри ("Inside") сущности, обозначающей причину. Метка отмечает все токены после первого, которые также относятся к причине. Это означает, что все слова, следующие за B-Cause и до следующей сущности или конца предложения, будут помечены как I-Cause, если они являются частью одной и той же причины.

◆ B-Effect – аналогично B-Cause, но обозначает начало сущности, связанной со следствием. Она помечает первый токен последовательности, которая относится к следствию.

◆ I-Effect – аналогично I-Cause, но используется для сущности, обозначающей следствие. Все токены после B-Effect, которые относятся к одной и той же сущности эффекта, будут помечены как I-Effect.

Пример аннотированного датасета представлен на рис. 5.

```
{
  "sentence": "Economic growth has been known to encouraging better work-life balance.",
  "annotations": [
    "B-Cause",
    "I-Cause",
    "O",
    "O",
    "O",
    "O",
    "O",
    "O",
    "O",
    "O",
    "B-Effect",
    "I-Effect",
    "I-Effect"
  ]
},
```

Рис. 5. Пример аннотированного датасета

В отличие от feature extraction, суть дообучения (Fine Tuning) заключается в размораживании последних слоев нейронной сети (Neural Net) и их обучении. Таким образом, корректируются слои, которые имеют наиболее абстрактные представления. Модель обучается распознавать паттерны в тексте, таких как синтаксические зависимости между словами, семантические роли и контекстные маркеры, которые указывают на причинно-следственные отношения. Для обучения модели используются следующие гиперпараметры настройки обучения:

- 1) evaluation_strategy="epoch";
- 2) learning_rate=5e-5;
- 3) per_device_train_batch_size=64;
- 4) num_train_epochs=3;
- 5) weight_decay=0.01;
- 6) from_pretrained("bert-base-uncased");
- 7) test_size=0.2.

Параметр $\text{weight_decay}=0.01$ помогает предотвратить переобучение, добавляя штраф за сложность модели. Параметр $\text{test_size}=0.2$ подразумевает, что 20% данных отводится для валидации. Разделение данных 80/20 выбрано для баланса между обучением и валидацией. Меньшая тестовая выборка (например, 10%) может не обеспечить репрезентативной оценки, а большая (например, 30%) – уменьшит объем данных для обучения. Размер батча 64 выбран для эффективного использования памяти GPU, этот размер обеспечивает оптимальную производительность на доступном оборудовании. Меньшие батчи (например, 16 или 32) увеличивают время обучения, а большие (например, 128) могут не поместиться в память GPU. Значение $5e-5$ выбрано как рекомендуемое для моделей на основе BERT. Более высокие значения (например, $1e-4$) могут привести к нестабильному обучению и потере предобученных параметров, а более низкие (например, $1e-5$) замедляют сходимость модели. Три эпохи выбраны как достаточное количество для сходимости модели. Большее число эпох (например, 5 или 10) может привести к переобучению, а меньшее (например, 1 или 2) – к недообучению.

Эксперимент. Для эксперимента мы использовали набор синтетических данных (датасет 1) для дообучения модели и набор синтетических данных (датасет 2) для тестирования модели.

Обучающий набор состоит из 1000 предложений и содержит 650 каузальных триплетов. В тестовом наборе содержится 1500 предложений, включая 700 каузальных триплетов.

Информация о синтетическом наборе данных для дообучения модели приведена в табл. 3.

Таблица 3

Статистика наборов данных

Подмножество	Размер подмножества
Training Set 80%	800
Training Set 60%	600
Training Set 40%	400
Test Set 20%	200
Test Set 10%	100

Эксперимент проводился на компьютере средней мощности, оснащенный процессором Intel Core i5 и 16 ГБ оперативной памяти, без видеокарты. Обучение модели на датасете размером 1000 примеров заняло примерно 4 часа.

Результаты и анализ. Проведенный эксперимент позволил получить результаты, которые позволяют оценить эффективность модели на подмножествах датасетов. Мы оцениваем наш алгоритм на синтетических обучающих и тестовых наборах данных для прогнозирования отношений, поскольку наш подход установлен как неконтролируемый. Основными показателями оценки работы модели являются уровень точности ACC (Accuracy), precision rate P (точность), recall rate R (полнота) и F1 value (F-score). Результаты эксперимента при дообучении и тестировании приведены в табл. 4 и 5, соответственно.

Таблица 4

Результаты дообучения модели (1000 предложений)

Подмножество	Размер подмножества	Accuracy	Precision rate P	Recall rate R	F1-score
Training Set 80%	800	0,94	0,89	0,94	0,92
Training Set 60%	600	0,94	0,89	0,94	0,92
Training Set 40%	400	0,94	0,89	0,94	0,92
Test Set 20%	200	0,95	0,90	0,95	0,92
Test Set 10%	100	0,95	0,90	0,95	0,92

Таблица 5

Результаты тестирования модели (1500 предложений)

Подмножество	Размер подмножества	Accuracy	Precision rate P	Recall rate R	F1-score
Test Set 80%	1200	0,95	0,94	0,95	0,94
Test Set 60%	900	0,95	0,94	0,95	0,95
Test Set 40%	600	0,95	0,94	0,95	0,95
Test Set 20%	300	0,96	0,94	0,96	0,95
Test Set 10%	150	0,96	0,94	0,96	0,95

Результат эксперимента показывает, что точность модели на подмножествах датасета 1 находится в пределах 0,89-0,90 (табл. 4), на подмножествах датасета 2 устанавливается на 0,94 (табл. 5). Сравнение результатов на подмножествах датасетов 1 и 2 показывает, что модель демонстрирует устойчивость точности датасета 2 уже на всех подмножествах. Это может быть объяснено тем, что формирование датасетов происходит по одному принципу.

В целом, полученные результаты позволяют сделать вывод, что модель демонстрирует приемлемую точность на подмножествах датасетов, но ее эффективность зависит от размера и однородности подмножества. Это требует дальнейшего исследования и оптимизации модели для улучшения ее эффективности на различных типах данных.

Предлагаемая модель может быть использована на компьютере средней мощности, что является значительным преимуществом с точки зрения экономики и охраны окружающей среды.

Заключение. В этой работе представлена модель извлечения причинно-следственных связей из текста с явной причинностью, направленностью и полярностью. Данная постановка проблемы обусловлена особенностями применения результатов извлечения для графового представления ситуаций принятых решения в сложных социогуманитарных средах. В таких случаях извлекаемый кортеж <фраза причины, фраза глагола, фраза следствия, полярность> легко трансформируется в соответствующие элементы графа <исходящий узел, направление связи, входящий узел, знак веса связи>.

В этой статье мы формулируем уточнение извлечения причинности как проблему классификации, добавляя слой классификации в предобученную модель BERT поверх выходных данных трансформера для токена [CLS]. Этот новый слой *list of tuples* для дообучения формируется путем последовательной фильтрации на основе семантики каузального глагола.

Экспериментальные результаты показали приемлемую точность модели: F1-оценка для правильного установления причинно-следственной связи между сущностями составила 82%. Предложенная модель не требует использования мощных дата-центров или специализированных компьютеров, что делает ее более доступной и экологически чистой. Кроме того, это позволяет использовать модель на веб-сайте, доступном для неквалифицированных пользователей, без необходимости использования специализированного оборудования. Это показывает возможности применения модели в различных областях, таких как образование, здравоохранение и другие, где важна доступность и простота использования.

В дальнейших исследованиях планируется продолжить совершенствование модели извлечения каузальных связей между предложениями, в частности, сосредоточившись на улучшении точности выявления причинно-следственных отношений между предложениями с разными уровнями абстракции и сложности.

Исследование выполнено за счет гранта Российского научного фонда № 25-21-00029, <https://rscf.ru/project/25-21-00029/> в Южном федеральном университете.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Li Z. et al. Causality extraction based on self-attentive BiLSTM-CRF with transferred embeddings, *Neurocomputing*, 2021, Vol. 423, pp. 207-219.
2. Banko M., Etzioni O. The Tradeoffs Between Open and Traditional Relation Extraction, *Annual Meeting of the Association for Computational Linguistics*, 2008.
3. Shao Y. et al. Extraction of causal relations based on SBEL and BERT model, *Database*, 2021, Vol. 2021.
4. Zhao X. et al. A Comprehensive Survey on Relation Extraction: Recent Advances and New Frontiers, 2023.
5. Bojduj B.N. Extraction of Causal-Association Networks from Unstructured Text Data. San Luis Obispo, California: California Polytechnic State University, 2009, 61 p.
6. Alibage A. Achieving High Reliability Organizations Using Fuzzy Cognitive Maps - the Case of Offshore Oil and Gas. Portland, OR: Portland State University, 2020, 342 p.
7. An N. et al. Extracting causal relations from the literature with word vector mapping, *Comput. Biol. Med.*, 2019, Vol. 115, pp. 103524.
8. Devlin J. et al. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding, 2018.
9. Paulheim H. Knowledge graph refinement: A survey of approaches and evaluation methods, *Semant. Web*, ed. Cimiano P., 2016, Vol. 8, No. 3, pp. 489-508.
10. Kulikowski C.A., Weiss S.M. Representation of Expert Knowledge for Consultation: The CASNET and EXPERT Projects, *Artificial Intelligence in Medicine*. Routledge, 2019, pp. 21-55.
11. Kosko B. Hidden patterns in combined and adaptive knowledge networks, *Int. J. Approx. Reason*, 1988, Vol. 2, No. 4, pp. 377-393.
12. Yang J., Han S.C., Poon J. A survey on extraction of causal relations from natural language text, *Knowl. Inf. Syst.*, 2022, Vol. 64, No. 5, pp. 1161-1186.
13. Park J., Cardie C. Identifying Appropriate Support for Propositions in Online User Comments, *Proceedings of the First Workshop on Argumentation Mining*. Stroudsburg, PA, USA: Association for Computational Linguistics, 2014, pp. 29-38.
14. Job S. et al. Exploring Causal Learning through Graph Neural Networks: An In-depth Review, 2023.
15. Li Z. et al. CausalBERT: Injecting Causal Knowledge Into Pre-trained Models with Minimal Supervision, *ArXiv*. 2021, Vol. abs/2107.0.
16. Felgueira T. et al. The Impact of Feature Causality on Normal Behaviour Models for SCADA-based Wind Turbine Fault Detection, 2019.
17. Tselykh A., Vasilev V., Tselykh L. A Method for Modeling the Control Impact Strategy Based on the Mental Frame of References of the Decision-Maker, 2023, pp. 315-324.
18. Tselykh A. et al. Influence control method on directed weighted signed graphs with deterministic causality, *Ann. Oper. Res.*, 2022, Vol. 311, No. 2, pp. 1281-1305.
19. Tselykh A., Vasilev V., Tselykh L. Assessment of influence productivity in cognitive models, *Artif. Intell. Rev.*, 2020.
20. Fellbaum C. WordNet / ed. Fellbaum C. The MIT Press, 1998.
21. Vasiliev Y. Natural language processing with Python and spaCy: A practical introduction. No Starch Press, 2020.
22. Schmitt X. et al. A Replicable Comparison Study of NER Software: StanfordNLP, NLTK, OpenNLP, SpaCy, Gate, *2019 Sixth International Conference on Social Networks Analysis, Management and Security (SNAMS)*. IEEE, 2019, pp. 338-343.

Цельх Александр Николаевич – Южный федеральный университет; e-mail: ant@sfedu.ru; г. Таганрог, Россия; тел.: +79185562047; кафедра ИАСБ; д.т.н.; профессор.

Валухов Игорь Алексеевич – Южный федеральный университет; e-mail: valuhov@sfedu.ru; г. Таганрог, Россия; тел.: +79515263364; кафедра ИАСБ; магистрант.

Цельх Лариса Анатольевна – Южный федеральный университет; e-mail: l.tselykh58@gmail.com; г. Таганрог, Россия; тел.: +79185562047; кафедра ИАСБ; к.э.н.; доцент.

Tselykh Alexander Nikolayevich – Southern Federal University; e-mail: ant@sfedu.ru; Taganrog, Russia; phone: +79185562047; the department IASB; dr. of eng. sc.; professor.

Valukhov Igor Alekseevich – Southern Federal University; e-mail: valuhov@sfedu.ru; Taganrog, Russia; phone: +79515263364; the department IASB; postgraduate student.

Tselykh Larisa Anatolievna – Southern Federal University; e-mail: l.tselykh58@gmail.com; Taganrog, Russia; phone: +79185562047; the department IASB; dr. of eng. sc.; senior lecturer.