

УДК: 004.912.4

ГРНТИ: 28.23.25

Молчанов А.Д.

Магистр

1 курс, направление «Информатика и вычислительная техника»

Национальный исследовательский технологический университет

«МИСиС»

Россия, г. Москва

ОБЗОР МЕТОДОВ АВТОМАТИЧЕСКОЙ ТРАНСФОРМАЦИИ СТИЛЯ ТЕКСТА

Статья посвящена обзору методов автоматической трансформации стиля текста (ТСТ). Основное применение данных методов заключается в изменении стилистических характеристик и атрибутов текста при сохранении его смыслового содержания. Рассмотрены ключевые подходы. Уделено внимание найденным решениям проблемы недостатка размеченных данных за счет генерации псевдопараллельных корпусов. Проведен анализ современных исследований, применяющих искусственные нейросетевые методы ТСТ для решения таких задач, как изменение эмоционального окраса, преобразование формальности речи и генерация текстов на устаревших версиях языков, таких как староанглийский.

Ключевые слова: Трансформация стиля текста, Машинное Обучение, последовательность-в-последовательность, генерация естественного языка, большие языковые модели, обучение с учителем, обучение без учителя.

This article is devoted to an overview of automatic text style transformation (TST) methods, whose task is to change the stylistic characteristics and attributes of a text while preserving its semantic content. The key approaches are reviewed. Attention is paid to the solutions found to the problem of the lack of marked-up data through the generation of pseudo-parallel corpora. An analysis of current research applying artificial neural network-based TST methods to solve such tasks as changing emotional

colouring, transforming the formality of speech and generating texts in obsolete versions of languages such as Old English has been carried out.

Keywords: Text style transformation, Machine Learning, sequence-to-sequence, natural language generation, large language models, supervised training, unsupervised training.

Введение:

Трансформация стиля текста (ТСТ) является одной из важных проблем во многих подобластях искусственного интеллекта (ИИ), таких как обработка естественного языка (NLP) [1] и компьютерное зрение [2], поскольку она отражает способность интеллектуальных систем генерировать новое содержание. В частности, трансформация стиля текстов на естественном языке является важным компонентом генерации естественного языка. Она облегчает работу многих приложений НЛП, например, автоматическое преобразование заголовка статьи в заголовок новости или преобразование изначального стиля статьи в публицистический стиль, что может, например, способствовать сокращению человеческих усилий при подготовке академических новостей. ТСТ может применяться и для таких задач, как генерация стихов [3] и трансформация текстов на устаревшем языковом стиле в современную редакцию языка [4]. Для последнего, Ксу и др. [4] предложили одну из первых работ по применению модели машинного перевода на основе фраз (РВМТ) для выполнения ТСТ. Они создали параллельный корпус из 30 тыс. пар предложений, используя современные переводы шекспировских пьес и обучили систему РВМТ переводу с современного английского на шекспировский английский. Тем не менее, прогресс в передаче стилей языка отстает от других областей, таких как компьютерное зрение, в основном из-за отсутствия параллельных корпусов и надежных метрик оценки, так как BLEU и ROGUE не обеспечивают желаемой точности.

Актуальность автоматизации ТСТ подтверждается стремительным ростом объема специализированной литературы [5] а также широким спектром

практических применений в различных областях. Например, в медиаиндустрии трансформация научных статей в публицистический стиль позволяет ускорить производство и публикацию научно-популярных материалов. В образовательной сфере ТСТ может использоваться для упрощения архаичных текстов, облегчая их восприятие. Автоматизированное ТСТ также может снискать применение в маркетинговой сфере для рекламных текстов под разные целевые аудитории.

В данной статье проводится обзор современных методов ТСТ. Рассматриваются как классические алгоритмы решения с использованием моделей МП (машинного перевода), решения с использованием генеративно-состязательных нейронных сетей [6] и архитектуры на моделях трансформерной архитектуры [5], так и использование языковых моделей, наподобие ChatGPT, для выполнения данной задачи. Также статья включает в себя сопоставление результатов работы данных моделей для выявления наиболее подходящих для дальнейшей разработки ПО для трансформации стиля из научного в публицистический.

Целью данного исследования является анализ современных методов автоматической трансформации стиля текста, для их последующего применения в разработке ПО для такой задачи.

Определение стиля

Перед тем как перейти к самому обзору технологий ТСТ, необходимо для начала обозначить определение основного термина, применяемого в статье: стиля текста.

К вопросу формулировки стиля текста можно обратиться с точки зрения двух разных подходов: лингвистического, и общепринятого в исследованиях на тему ТСТ.

С точки зрения лингвистики: стиль — это интуитивное понятие, подразумевающее под собой манеру передачи некой семантики. В данном контексте, семантика/содержание текста — это предметная область или идея,

которую хочет донести автор своим текстом. В таком случае стиль текста – это литературный элемент, описывающий совокупность применяемых автором литературных и языковых средств, таких как строение предложений, переносные смыслы, выбор свойственных автору слов и выражений. Стиль указывает на то, как именно автор описывает события и идеи. То, как он предоставляет читателю информацию для самостоятельной интерпретации. [7][8].

С точки зрения специальной литературы по ТСТ: в отличие от лингвистики, где определение стиля текста больше основано на теории и опирается на набор правил, исследования по ТСТ используют более ориентированный на данные подход к определению понятия стиля текста. К примеру, в исследованиях на эту тему, стиль часто рассматривается как набор атрибутов или меток, опирающихся на корпуса с конкретными стилями. Такие корпуса содержат в себе атрибуты стиля текста, хорошо подходящие для обучения на них моделей машинного обучения. Как пример, задачи трансформации эмоционального окраса (положительный и отрицательный как атрибуты стиля, если брать самый простой случай в качестве примера) или трансформация формальности текста (формальный и неформальный). Две эти задачи являются одними из наиболее популярных в исследованиях ТСТ, поэтому качество метода ТСТ при решении данных задач часто выбираются в качестве эталонов для оценки качества работы метода. Можно возразить, что эмоциональный окрас не является стилем текста, но, как утверждают Нинг Даи и др. в [1], поскольку у эмоционального окраса тоже есть набор конкретных атрибутов, его можно считать стилем, и, соответственно, применять к нему методы ТСТ.

Материалы и методы

Все существующие на данный момент модели ТСТ можно классифицировать по методам обучения, подходам и архитектуре конкретных моделей. В данной обзорной статье будет рассматриваться именно классификация по обучению, а именно подразделение методов ТСТ на:

параллельно обучаемые с учителем, обучаемые с учителем не параллельно, обучаемые без учителя. Из-за малой представленности в литературе, последние в этом обзоре будут затронуты только в форме обзора применения существующих языковых моделей (ChatGPT, DeepSeek и др.) для решения задачи трансформации стиля. Классификация по конкретным методам будет затронута именно при обзоре этих методов.

Ниже представлена более полноценная классификация существующих методов ТСТ на категории в зависимости от применяемого метода обучения:

Параллельно обучаемые с учителем: при использовании этого способа обучения, модели ТСТ обучаются на наборах известных парных (параллельных) текстов с разными стилями. Зачастую, для трансформации стиля в таких моделях используются методы нейронного машинного перевода (НМП), как, например, метод последовательность-в-последовательность (sequence-to-sequence, Seq2Seq) [4][9][10]. Например, в [11] Кит Карлсон и др. использовали метод статистического машинного перевода Moses и вышеупомянутый метод НМП Seq2Seq для трансформации стилей Библейских текстов на английском языке. Корпус для обучения включал в себя 34 варианта, и соответственно стиля текста в Библии, но только 7 были выделены как основные и использованы для оценки результатов.

Обучаемые с учителем не параллельно: При непараллельном обучении, модели ТСТ нацеливаются на трансформацию стиля текста без наличия параллельного корпуса [14][15][16]. Поскольку это именно та ситуация, которая будет встречаться после тренировки модели, то ожидаемо, это самый часто встречающийся в литературе по ТСТ метод.

Обучаемые без учителя: В отличие от предыдущих двух типов обучения, для этого типа доступен только корпус с неразмеченным текстом, не содержащим маркеры стиля. Поскольку результаты моделей с обучением без учителя невысоки, в литературе представлены слабо.

Метод Seq2Seq

Модель последовательность-в-последовательность [4][9][10][11] обладает большой популярностью в решениях задач генерации естественного языка [12] и имеет архитектуру, состоящую из пары кодировщик-декодировщик. Обучение этой модели происходит на параллельных корпусах: в кодировщик подаётся текст в оригинальном стиле, а декодировщик выводит искомый текст в целевом стиле. Наблюдается вариативность в подходах разных исследователей к данной модели. Так, например, в [11] исследователями к базовой архитектуре этой модели был добавлен механизм внимания, а в [10] было предложено дополнение архитектуры сетью указателей для упрощения работы со староанглийским. Но, несмотря на обилие вариантов модернизаций модели, её существенным недостатком остаётся необходимость обучения на параллельных наборах данных и их очень ограниченное количество. Для решения этой проблемы исследователи прибегли к искусственной генерации параллельных наборов данных. Так в [13], Занг и др. предложили использовать комментарии и посты на интернет форумах для формирования набора данных с неформальным стилем, который затем несколько раз пропускаялся через системы машинного перевода, получая на выход более формальный параллельный набор данных. После постобработки набора данных, обученная на нём модель показала хорошие (72.63) показатели по метрике BLEU. Однако этот подход фундаментально не решает проблемы ограниченности под каждую задачу, что вынуждает отметить эту модель как работоспособную и эффективную для некоторых узкоспециализированных задач, но уступающую методам непараллельного обучения с учителем.

Модели с явной заменой ключевых слов стиля

Практически всегда, в литературе, стилистические атрибуты текста зачастую являются ярко выраженные слова и словосочетания. Больше всего это будет заметно в задаче ТСТ по изменению эмоционального окраса, где сразу заметны слова положительного и отрицательного оценочного характера. Исходя

из этого, можно предположить, что такой метод замены ключевых слов может быть применён для решения общих задач ТСТ.

Первыми такой подход в своей работе [14] предложили Джунцен Ли и др. Исследователи работали именно над задачей трансформации эмоционального окраса с дополнительной задачей трансформации объективного, фактического стиля в субъективный. Предложенная модель основывается на утверждении, что ключевые для стиля слова в исходном тексте встречаются с повышенной частотой. Исходя из этого, первым шагом работы модели является анализ поданного на вход текста на предмет частоты употребления различных слов. Для случаев, где обнаружение ключевых слов методом расчёта частоты, в модели используются заранее размеченные корпуса для обучения и в последствии для контекстной замены ключевых слов. После обнаружения, ключевые слова оригинального текста удаляются, оставляя в тексте только фактическую информацию. Далее, из заранее размеченных корпусов моделью выбирается схожий по контексту текст, соответствующий целевому эмоциональному окрасу, и из него извлекаются новые ключевые слова для замены в оригинальном тексте. Генерация нового текста с заменами происходит по средствам методов последовательность-в-последовательность.

Исследование [14] послужило основой для [15][16]. В первом, Занг и др. предложили использование классификаторов с механизмами внимания. Во втором Васвани и др. использовали трансформеры для генерации нового текста с заменёнными ключевыми словами. Оба исследования показали улучшение в качестве результата.

Модель	Точность %	BLEU	Источник
DELETEANDRETRIEVE (YELP dataset)	88.7	8.4	15
DELETEANDRETRIEVE (Caption dataset)	96.8	7.3	15
DELETEANDRETRIEVE (AMAZON dataset)	48.0	22.8	15
SMAE	76.64	24.00	16
Transformer (base model)	-	38.1	17
Transformer (big)	-	41.8	17

Таблица 1 – сопоставление оценок работы моделей замены ключевых слов

Основным достоинством подхода замены ключевых слов является его простота имплементации. Модели для него довольно просты и не требуют долгого обучения. Но у этого метода есть критический недостаток: задачи, для решения которых он подходит очень ограничены. Он почти полностью ограничен задачей изменения эмоционального окраса, и, из-за принципа своей работы, не может быть применён к задачам изменения оригинального стиля написания на целевой или к задачам изменения уровня формальности текста.

Модели, обучаемые без учителя

Как уже описывалось выше, эта модель обучения слабо представлена в тематической литературе. Это обусловлено тем, что остальные исследования по ТСТ подразумевают наличие заранее размеченного корпуса для обучения модели, вне зависимости от того, параллельный этот корпус или нет. Обучаемые без учителя модели усложняют эту задачу, подразумевая, что модель должна будет полностью самостоятельно обучиться на смешанных неразмеченных корпусах. Впервые идея такого обучения для моделей ТСТ возникла после публикации работы [17], где исследовались свойства применяемых к языковым задачам рекуррентных нейронных сетей, обучая без учителя модель Долгой Краткосрочной Памяти (Long Short-Term Memory; LSTM) на тексте, преобразованном в последовательность байтов в кодировке UTF-8. Ими было выявлено, что после завершения обучения модели Долгой Краткосрочной Памяти, отдельные наборы нейронов в ней соответствовали конкретным эмоциональным окрасам элементов смешанного корпуса. Манипуляции этими группами нейронов позволили исследователям трансформировать эмоциональный окрас выходных последовательностей, ненамеренно решая задачу, поставленную Нингом Даи и др. в [1].

Полноценно применена эта информация для решения задач ТСТ была Джейн Параг и др. в работе [18], где исследователи предложили подход обучения без учителя для решения задачи формализации (трансформации неформального текста в формальный, в исследовании [18] разбитым на два уровня

формальности) текста. При обучении модели энкодер-декодер-классификатор исследователи использовали сторонние системы-оценщики [19][20] на основе суждения которых составлялась информация о стиле текста. Уровень формальности (Formalness Control-Mid, Formalness Control-High) присваивался на основе выданной системами-оценщиками оценки, что призвано упрощать распознавание моделью ТСТ информации о формальности.

Более пристальное изучение работы [17] и принадлежность её исследователей к компании OpenAI подвигло меня добавить современные большие языковые модели в эту статью и категорию. Их добавление в обзорную статью обусловлено самой возможностью использования их для решения задач ТСТ. Добавление же в эту категорию объясняется отсутствием у них специфического обучения под данную задачу на маркированных корпусах, что значит модели будут сами определять маркеры стиля в смешенном тексте. Но то что большие языковые модели подходят под классификацию не значит, что они будут эффективны в этой задаче. Их эффективность была протестирована в этой обзорной статье.

Для эксперимента были выбраны 4 языковые модели: ChatGPT, DeepSeek, ChadGPT (платная версия ChadGPT mini) и YandexGPT. Тестирование производилось на двух текстовых отрывках из работ [14] и [21], примерно 750 слов каждом, отрывок из [14] был переведён на русский язык, так как именно он был избран как целевой язык тестирования. В качестве экспериментальной задачи была выбрана трансформация формального стиля оригинальных статей в публицистический.

При экспериментальном тестировании была выявлена ограниченность по количеству токенов выходного текста. Если во входном отрывке было около 750 слов, то трансформированные тексты не превышали 580 слов. Для изучения этого вопроса были рассмотрены другие модели написания кратких содержаний текстов, BART и T5, а именно количество токенов, которое они подают на выход. BART на выход подаёт до 1024 токенов, что приблизительно равно 5000 символов или 800 словам. T5 же имеет ограничение по выводу только в 512

токенов, или приблизительно 400 слов. Исходя из этого, легко предположить, что ChatGPT ограничивает ответ своей архитектуры для такого задания количеством токенов в этом диапазоне. Такое ограничение на длину входных или выходных данных пусть и не влияет на результаты тестирования по эталонным наборам данных, состоящих из отдельных предложений, но уже указывает на то, что языковые модели уступают способным к работе с большими наборами данных моделям ТСТ [10][11].

Для оценки самих результатов работы языковых моделей были использованы метрики BLEU, которая используется для оценки качества машинного перевода текста путем вычисления модифицированной точности n-грамм между сгенерированным и эталонным текстом, также широко применяется в задачах ТСТ, и ROGUE, оценивающая схожесть текстов по n-граммам, биграммам и самой длинной схожей последовательности:

Модель	BLEU	ROGUE-1	ROGUE-2	ROGUE-L	Источник
Mueller et al.	5.09	0.41	-	-	23
ChadGPT(mini)	14.07	0.83	0.76	0.8	-
ChatGPT	38.4	0.41	0.26	0.41	-
DeepSeek	40.3	0.5	0.31	0.46	-
YandexGPT	35	0.45	0.25	0.35	-
Formalness-Mid	21.81	0.58	-	-	19
Formalness-High	21.14	0.57	-	-	19

Таблица 2 – Результаты работы моделей, обучаемых без учителя

Для оценки результата использовались наивысшие оценки по метрикам на каждом из двух экспериментов для каждой модели. Результаты эти были сопоставлены с результатами других моделей, обучаемых без учителя, представленными Мюллером и др. в [22] и Параг и др. в [18]. Как можно наблюдать из результатов, современные большие языковые модели конкурентоспособны в сравнении с другими моделями ТСТ, обучаемыми без учителя, но их показатели не достигают результатов, получаемых моделями параллельно и не параллельно обучаемых с учителем, чьи показатели по BLEU могут достигать 70 и более [6][10][11]. Наивысший результат по этой метрике был достигнут DeepSeek. Однако, стоит отметить, что у DeepSeek во время экспериментов наблюдалась и наименьшая точность выводов. Каждый третий

запрос на изменение стиля статьи с научного на публицистический в выходном тексте имел галлюцинации: в тексте появлялась прямая речь или примеров, не указанных в исходном тексте и не соответствующих реальности. Это делает DeepSeek нежелательной моделью для решения задачи ТСТ по изменению стиля текста с исходного на целевой.

Наивысший же по ROGUE результат был получен ChadGPT. Поскольку эта модель имеет самый низкий показатель по BLEU, данный результат был изначально воспринят как аномалия, но по итогу экспериментов другими изначально русскоязычными отрывками из [21] были показаны схожие результаты, что можно объяснить специализацией ChadGPT на этом языке. Таким образом, установлено, что использование современных больших языковых моделей для решения задач ТСТ общей направленности целесообразно, но для узкоспециализированных задач специальная модель будет показывать лучшие результаты, что утверждает необходимость моделей с непараллельным обучением с учителем.

Выводы:

В предложенной обзорной статье была произведена классификация существующих методов трансформации стиля текста по методам их обучения. Были разобраны их сильные и слабые стороны, как например недостаток параллельных корпусов в открытом доступе для параллельного обучения с учителем. Было произведено сравнение результатов современных больших языковых моделей в решениях задач ТСТ с ранее предложенными решениями. Было выявлено, что ни одна из существующих на данный момент моделей, включая модели GPT, не демонстрируют абсолютного превосходства над другими современными моделями, показывая разные результаты на общих и частных задачах. Была затронута проблема недостаточности оценочных метрик для передачи полноты данных результата. Путём сравнительного анализа было выявлено, что модели с непараллельным обучением с учителем всё ещё остаются

самым многообещающим направлением исследований, но современные языковые модели могут сравниться с ними в общих задачах.

Использованные источники:

1. Dai N. et al. Style transformer: Unpaired text style transfer without disentangled latent representation // arXiv preprint arXiv:1905.05621. – 2019. – Режим доступа: <https://arxiv.org/pdf/1905.05621> (дата обращения: 23.03.2025).
2. Gatys L. A., Ecker A. S., Bethge M. A neural algorithm of artistic style // arXiv preprint arXiv:1508.06576. – 2015. – Режим доступа: <https://arxiv.org/pdf/1508.06576> (дата обращения: 25.03.2025).
3. Yan R. i, Poet: Automatic poetry composition through recurrent neural networks with iterative polishing schema // Proceedings of the 25th International Joint Conference on Artificial Intelligence (IJCAI). – 2016. – Т. 2238. – С. 2244. – Режим доступа: <https://www.ijcai.org/Proceedings/16/Papers/319.pdf> (дата обращения: 27.03.2025).
4. Xu W., Ritter A., Dolan B. et al. Paraphrasing for style // Proceedings of COLING 2012: 26th International Conference on Computational Linguistics. – 2012. – С. 2899–2914. – Режим доступа: <https://aclanthology.org/C12-1177.pdf> (дата обращения: 27.03.2025).
5. Luo F., Li P., Zhou J. et al. A dual reinforcement learning framework for unsupervised text style transfer // arXiv preprint arXiv:1905.10060. – 2019. – Режим доступа: <https://arxiv.org/pdf/1905.10060v1> (дата обращения: 15.06.2025).
6. Hu Z., Yang Z., Liang X., Salakhutdinov R. et al. Toward controlled generation of text // Proceedings of the 34th International Conference on Machine Learning (ICML 2017). – PMLR, 2017. – С. 1587–1596. – Режим доступа: <https://arxiv.org/pdf/1703.00955> (дата обращения: 05.04.2025).

7. Hovy E. Generating natural language under pragmatic constraints // Journal of Pragmatics. – 1987. – Т. 11. – № 6. – С. 689–719. – Режим доступа: <https://aclanthology.org/J90-3008.pdf> (дата обращения: 08.04.2025).
8. McDonald D. D., Pustejovsky J. A computational theory of prose style for natural language generation // Proceedings of the Second Conference of the European Chapter of the Association for Computational Linguistics (EACL 1985). – 1985. – Режим доступа: <https://aclanthology.org/E85-1027.pdf> (дата обращения: 08.04.2025).
9. Cho K., van Merriënboer B., Gulcehre C. et al. Learning phrase representations using RNN encoder–decoder for statistical machine translation // arXiv preprint arXiv:1406.1078. – 2014. – Режим доступа: <https://arxiv.org/pdf/1406.1078> (дата обращения: 15.04.2025).
10. Jhamtani H., Gangal V., Hovy E. et al. Shakespearizing modern language using copy-enriched sequence-to-sequence models // arXiv preprint arXiv:1707.01161. – 2017. – Режим доступа: <https://arxiv.org/pdf/1707.01161> (дата обращения: 15.04.2025).
11. Carlson K., Riddell A., Rockmore D. Evaluating prose style transfer with the Bible // Royal Society Open Science. – 2018. – Т. 5. – № 10. – С. 171920. – Режим доступа: <https://arxiv.org/pdf/1711.04731> (дата обращения: 19.04.2025).
12. Gatt A., Krahmer E. Survey of the state of the art in natural language generation: Core tasks, applications and evaluation // Journal of Artificial Intelligence Research. – 2018. – Т. 61. – С. 65–170. – Режим доступа: <https://arxiv.org/pdf/1703.09902> (дата обращения: 19.04.2025).
13. Zhang Y., Ge T., Sun X. Parallel data augmentation for formality style transfer // arXiv preprint arXiv:2005.07522. – 2020. – Режим доступа: <https://arxiv.org/pdf/2005.07522> (дата обращения: 21.04.2025).
14. Li J., Jia R., He H. et al. Delete, retrieve, generate: a simple approach to sentiment and style transfer // arXiv preprint arXiv:1804.06437. – 2018. – Режим доступа: <https://arxiv.org/pdf/1804.06437> (дата обращения: 22.04.2025).

15. Zhang Y., Xu J., Yang P. et al. Learning sentiment memories for sentiment modification without parallel data // arXiv preprint arXiv:1808.07311. – 2018. – Режим доступа: <https://arxiv.org/pdf/1808.07311> (дата обращения: 26.04.2025).
16. Vaswani A., Shazeer N., Parmar N. et al. Attention is all you need // Advances in Neural Information Processing Systems. – 2017. – Т. 30. – Режим доступа: <https://arxiv.org/pdf/1706.03762> (дата обращения: 23.03.2025).
17. Radford A., Narasimhan K., Salimans T. et al. Improving language understanding by generative pre-training. – 2018. – Режим доступа: https://cdn.openai.com/research-covers/language-unsupervised/language_understanding_paper.pdf (дата обращения: 27.04.2025).
18. Jain P., Mishra A., Azad A. P. et al. Unsupervised controllable text formalization // Proceedings of the AAAI Conference on Artificial Intelligence. – 2019. – Т. 33. – № 1. – С. 6554–6561. – Режим доступа: <https://ojs.aaai.org/index.php/AAAI/article/view/4623/4501> (дата обращения: 30.04.2025).
19. Heafield K. KenLM: Faster and smaller language model queries // Proceedings of the Sixth Workshop on Statistical Machine Translation. – 2011. – С. 187–197. – Режим доступа: <https://aclanthology.org/W11-2123.pdf> (дата обращения: 05.05.2025).
20. Bengio Y., Ducharme R., Vincent P., Jauvin C. A neural probabilistic language model // Journal of Machine Learning Research. – 2003. – Т. 3. – № Feb. – С. 1137–1155. – Режим доступа: <https://www.jmlr.org/papers/volume3/bengio03a/bengio03a.pdf> (дата обращения: 08.05.2025).
21. Артющкина Е. С., Сафиуллин Д. Ф., Чёрная А. В. Использование интеллектуальных систем в защите информации // Индустриальная экономика. – 2023. – № 4. – С. 69–75. – Режим доступа:

<https://cyberleninka.ru/article/n/ispolzovanie-intellektualnyh-sistem-v-zaschite-informatsii/viewer> (дата обращения: 12.05.2025).

22. Mueller J., Gifford D., Jaakkola T. Sequence to better sequence: continuous revision of combinatorial structures // Proceedings of the 34th International Conference on Machine Learning (ICML 2017). – PMLR, 2017. – С. 2536–2544. – Режим доступа: <https://proceedings.mlr.press/v70/mueller17a/mueller17a.pdf> (дата обращения: 16.05.2025).