

doi: 10.17586/2226-1494-2025-25-3-438-445

УДК 004.852

Исследование возможности применения эволюционных алгоритмов для условной генерации атрибутированных графов

**Ирина Юрьевна Деева¹✉, Полина Олеговна Андреева², Егор Николаевич Шиков³,
Анна Владимировна Калужная⁴**

^{1,2,3,4} Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

¹ iriny.deeva@gmail.com✉, <https://orcid.org/0000-0001-8679-5868>

² polinaspb@ya.ru, <https://orcid.org/0000-0002-3130-1012>

³ egorshikov@itmo.ru, <https://orcid.org/0000-0001-5749-4222>

Karyazma

Аннотация

Введение. Область синтетической генерации атрибутированных графов активно развивается благодаря прогрессу в генеративном моделировании. Однако ключевой проблемой современных методов остается ограниченное разнообразие синтезируемых графов, которое зависит от характеристик реальных данных, используемых для обучения генеративных моделей. Также ограничение связано с топологическими свойствами графов и статистическими характеристиками атрибутов, критически влияющими на эффективность графовых моделей машинного обучения. В данной работе проверена гипотеза о том, что комбинация эволюционных алгоритмов и байесовских сетей может обеспечить гибкий контроль над генерацией как топологии, так и атрибутов графа. **Метод.** Предложенный подход включает два ключевых компонента: эволюционные алгоритмы для управления топологическими характеристиками графа (например, средняя степень вершины, коэффициент кластеризации) и байесовские сети для генерации атрибутов с заданными статистическими параметрами, такими как ассортативность или средняя корреляция между атрибутами. Метод позволяет явно задавать ограничения на свойства графа, обеспечивая вариативность, не зависящую от исходных данных. **Основные результаты.** Эксперименты подтвердили, что подход способен генерировать атрибутированные графы с широким спектром топологических характеристик и заданными статистическими параметрами атрибутов с достаточно низкой ошибкой генерации. **Обсуждение.** Результаты демонстрируют перспективность использования эволюционных и байесовских методов для условной генерации графов. Основное преимущество подхода — возможность декомпозиции задачи на независимое управление топологией и атрибутами, что открывает новые возможности для тестирования алгоритмов машинного обучения в контролируемых условиях. Ограничением является вычислительная сложность эволюционной оптимизации, что требует дальнейшей работы по оптимизации алгоритма. В перспективе метод может быть расширен для генерации динамических графов и интеграции с глубокими генеративными моделями.

Ключевые слова

атрибутированные графы, генерация синтетических графов, эволюционная оптимизация, байесовские сети, топологические характеристики графов, статистические характеристики атрибутов

Благодарности

Исследование выполнено при финансовой поддержке Российского научного фонда, договор № 24-71-10093, <https://rscf.ru/en/project/24-71-10093/>.

Ссылка для цитирования: Деева И.Ю., Андреева П.О., Шиков Е.Н., Калюжная А.В. Исследование возможности применения эволюционных алгоритмов для условной генерации атрибутированных графов // Научно-технический вестник информационных технологий, механики и оптики. 2025. Т. 25, № 3. С. 438–445. doi: 10.17586/2226-1494-2025-25-3-438-445

Investigation of the possibility of using evolutionary algorithms for conditional generation of attributed graphs

Irina Yu. Deeva¹✉, Polina O. Andreeva², Egor N. Shikov³, Anna V. Kalyuzhnaya⁴

^{1,2,3,4} ITMO University, Saint Petersburg, 197101, Russian Federation

¹ iriny.deeva@gmail.com✉, <https://orcid.org/0000-0001-8679-5868>

² polinaspb@ya.ru, <https://orcid.org/0000-0002-3130-1012>

³ egorshikov@itmo.ru, <https://orcid.org/0000-0001-5749-4222>

⁴ kalyuzhnaya.ann@gmail.com, <https://orcid.org/0000-0002-9612-8601>

Abstract

The field of synthetic generation of attributed graphs is actively developing due to advances in generative modeling. However, a key problem of current methods remains the limited diversity of synthesized graphs, due to the dependence on the characteristics of real data used to train generative models. This is a problem because topological properties of graphs and statistical characteristics of attributes critically affect the performance of graph-based machine learning models. In this paper, we test the hypothesis that a combination of evolutionary algorithms and Bayesian networks can provide flexible control over the generation of both graph topology and attributes. The proposed approach includes two key components: evolutionary algorithms to control topological characteristics of the graph (e.g. average vertex degree, clustering coefficient) and Bayesian networks to generate attributes with given statistical parameters such as assortativity or average correlation between attributes. The method allows explicitly setting constraints on graph properties, providing variability independent of the original data. Experiments confirmed that the approach can generate attributed graphs with a wide range of topological characteristics and given statistical parameters of the attributes with sufficiently low generation error. The results demonstrate the promising use of evolutionary and Bayesian methods for conditional graph generation. The main advantage of the approach is the ability to decompose the problem into independent control of topology and attributes, which opens new possibilities for testing machine learning algorithms under controlled conditions. A limitation is the computational complexity of evolutionary optimization, which requires further work to optimize the algorithm. In the future, the method can be extended to generate dynamic graphs and integrate with deep generative models.

Keywords

attributed graphs, synthetic graph generation, evolutionary optimization, Bayesian networks, topological characteristics of graphs, statistical characteristics of attributes

Acknowledgements

This research is financially supported by the Russian Scientific Foundation, Agreement 24-71-10093, <https://rscf.ru/en/project/24-71-10093/>.

For citation: Deeva I.Yu., Andreeva P.O., Shikov E.N., Kalyuzhnaya A.V. Investigation of the possibility of using evolutionary algorithms for conditional generation of attributed graphs. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2025, vol. 25, no. 3, pp. 438–445 (in Russian). doi: 10.17586/2226-1494-2025-25-3-438-445

Введение

Современное развитие методов машинного обучения на графовых данных тесно связано с качеством и разнообразием датасетов-бенчмарков, используемых для их тестирования и валидации. Как отмечено в [1, 2], большинство существующих архитектур графовых нейронных сетей испытываются на ограниченном наборе реальных графов, что снижает обобщающую способность полученных результатов. При этом реальные графы обычно не отражают полного спектра топологических и атрибутивных характеристик, способных существенно влиять на эффективность алгоритмов [3]. Данный факт создает следующую проблему: отсутствует универсальный генератор графов, способный воспроизводить как типичные, так и экстремальные случаи, необходимые для адекватной оценки устойчивости и производительности графовых моделей.

Одним из перспективных направлений решения данной проблемы является условная генерация графов, позволяющая создавать синтетические структуры с заранее заданными характеристиками. В последние годы было предложено множество параметрических генераторов, ориентированных на управление топологическими особенностями, такими как структура

сообществ [4–6] или распределение степеней по закону мощности [7, 8]. Однако данные методы часто ограничены своей способностью моделировать комплексные и многогранные особенности графов, поскольку требуют индивидуальной настройки под каждую характеристику. Аналогично, современные глубокие генеративные модели, включая диффузионные методы [9, 10], автoregressионные модели [11], VAE [12, 13] и GAN [14], преимущественно нацелены на воспроизведение обучающих данных, что ограничивает их применение при необходимости генерации редких или специально сконфигурированных структур.

Основная проблема, решаемая в настоящей работе, заключается в разработке методологии, способной объединить эволюционные алгоритмы для оптимизации топологических характеристик графов и байесовские сети (БС) для генерации атрибутов с заданными статистическими свойствами. Существующие подходы часто фокусируются на отдельном аспекте графа — на его структуре или на свойствах атрибутов — что приводит к несоответствию реальным сценариям применения, где необходимо учитывать сложное взаимодействие между структурой и атрибутами [4, 7]. Таким образом, задача состоит в создании гибкого и масштабируемого инструмента для условной генерации атрибути-

рованных графов, способного учитывать корреляции между атрибутами соседних вершин и обеспечивать воспроизводимость экстремальных случаев, имеющих практическое значение для тестирования графовых моделей [5, 6].

Для проверки гипотезы о перспективах условной генерации графов был разработан подход, основанный на эволюционных алгоритмах, оптимизирующих структуру графа посредством минимизации функции стоимости, зависящей от желаемых топологических характеристик. Дополнительно предложена интеграция БС для генерации атрибутов, что позволяет задавать и контролировать статистические зависимости между признаками вершин. Такой комбинированный подход позволяет обеспечить более глубокое соответствие синтетических графов реальным сценариям, где топология и атрибуты взаимодействуют сложным и взаимозависимым образом.

Основные понятия и обозначения

Графы. Граф $G = (V, E)$ можно определить как множества его вершин $V = \{v_1, \dots, v_n\}$ и ребер $E = \{(v_i, v_j) | v_i, v_j \in V\}$.

Предполагается, что каждая вершина имеет атрибуты в виде матрицы признаков $\mathbf{X} \in \mathbb{R}^{n \times d}$, в которой i -ая строка соответствует вектору признаков x_i вершины v_i , где n — количество вершин в графе; d — размерность пространства признаков. Для простоты предполагается, что графы являются неориентированными, хотя те же методы с минимальными изменениями применимы и к направленным графикам.

Топологические инварианты. Инвариантом графа G называется функция $I(G)$, которая характеризует структуру графа и не зависит от способа разметки узлов или образа графа.

Проведенный комплексный анализ свойств графовых моделей машинного обучения, а также результаты тематических научных работ выявляют несколько ключевых инвариантов, которые существенно влияют на результаты: средний коэффициент кластеризации I_c , средняя длина кратчайшего пути I_{asp} [15], средняя степень I_d [16], ассортативности лейблов I_{la} и атрибутов I_{aa} [16]. Однако важно отметить, что предлагаемый метод является адаптивным и может быть расширен для включения других характеристик графа, например степени узла, локальной кластеризации, и другие [17–19].

Выбранные ключевые инварианты обычно используются в сетевых науках, информацию о которых можно найти в известных исследованиях, за исключением атрибутивной ассортативности I_{aa} , которая в настоящей работе определяется аналогично ассортативности меток:

$$I_{aa}(G) = \frac{1}{n} \sum_{i=1}^n \frac{|\{v_j \in \mathcal{N}(v_i) : \cos(x_i, x_j) < q\}|}{|\mathcal{N}(v_i)|},$$

где q — пороговое значение; \mathcal{N} — соседи вершины v_i .

Генерация условных графов. В данной работе задача генерации синтетических графов с заданными

характеристиками формулируется как многоцелевая оптимизационная задача:

$$\min_{G \sim p(G)} (\|I_1(G) - \tilde{I}_1\|, \|I_2(G) - \tilde{I}_2\|, \dots, \|I_k(G) - \tilde{I}_k\|),$$

где $\tilde{I}_1, \dots, \tilde{I}_k$ — заранее заданные значения инвариантов; G — граф. В процессе оптимизации графы выбираются из заданного распределения на пространстве графов $p(G)$ и подбирается экземпляр, наиболее подходящий для заданных значений.

Предлагаемый подход

Главная особенность разработанного метода — итеративная модификация графа, постепенно сходящаяся к заданным топологическим характеристикам, представляемым в качестве входных данных. Процесс генерации состоит из двух этапов (на рис. 1 — шаги внутри обеих частей рисунка): *инициализации*, когда генерируется исходный случайный граф, и *оптимизации* — эволюционные операторы итеративно применяются для модификации графа. Эволюционные алгоритмы, используемые в представленном подходе, основаны на фреймворке GOLEM¹, который реализует генетический алгоритм NSGA-II [20]. Фреймворк позволяет определять собственные генетические операторы, а также достаточно гибко варьировать параметры генетического алгоритма. Общая схема подхода показана на рис. 1 и представляет собой генерацию синтетического графа и генерацию синтетических атрибутов для синтетического графа.

Условная генерация синтетических графов.

Исходные графы строятся как случайные графы с помощью генератора Эрдоса–Рены [21] с заданным числом вершин и числом ребер. В отличие от существующих подходов, где каждое новое изменение характеристик графа требует полной генерации нового образца графа, предлагаемый подход позволяет постепенно изменять существующие образцы. В качестве функции стоимости в данном контексте используется средняя квадратичная ошибка, которая измеряет несоответствие между фактическими характеристиками графа и заранее заданными целевыми значениями. Основная мутация, применяемая к графу, заключается в случайных изменениях ребра внутри графа и блока из пяти ребер.

Условная генерация синтетических атрибутов.

Использование БС в качестве модели генерации атрибутов обусловлено двумя ключевыми факторами.

Во-первых, БС [22] способна учитывать зависимости между атрибутами, которые обычно встречаются в реальных данных. Во-вторых, графовая структура БС позволяет использовать тот же подход к оптимизации (как и для генерации графов) и тот же инструмент (фреймворк GOLEM). Важно отметить, что в рамках текущей работы рассматривается только генерация непрерывных атрибутов. Использование БС в качестве генеративной модели для атрибутов требует, чтобы структура и параметры распределений в ее узлах были

¹ [Электронный ресурс]. Режим доступа: <https://github.com/aimclub/GOLEM> (дата обращения: 01.04.2025).

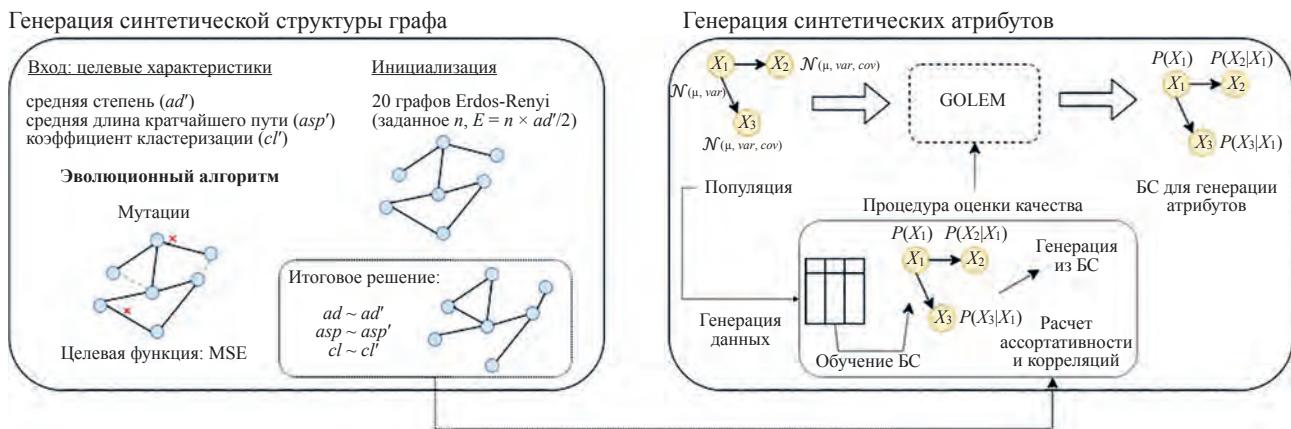


Рис. 1. Общая схема условной генерации атрибутированных графов с помощью эволюционных вычислений.

MSE — средняя квадратическая ошибка между целевыми характеристиками и полученными; X_1, X_2, X_3 — атрибуты; μ, var, cov — среднее, дисперсия и ковариация распределений атрибутов

Fig. 1. General scheme of conditional generation of attributed graphs using evolutionary computation, MSE — mean square error between target features and obtained ones, X_1, X_2, X_3 — attributes, μ, var, cov — mean, variance and covariance of attribute distributions

полностью заданы или обучены. В контексте данного исследования фиксируется структура сети, а параметры распределений определяются с помощью эволюционного подхода к обучению. В частности, распределения в узлах БС моделируются как гауссовые распределения. В процессе обучения вводятся мутации и кроссоверы для изменения параметров этих распределений в узлах. Процедура оценки включает в себя создание обучающей выборки из БС без ребер (только на основе маргинальных распределений) с использованием заранее заданных параметров распределений. Затем эта выборка используется для обучения БС с ребрами, из которой в последствии и семплируются синтетические атрибуты.

Экспериментальные результаты

Метрики качества. Для оценки результатов экспериментов предложено использовать следующие метрики. Оценку качества воспроизведения топологических характеристик предлагается измерять как абсолютную ошибку между значением на сгенерированном графе и целевым значением:

$$\varepsilon_{topo} = |F_{gen} - F_{target}|.$$

Чем меньше значение, тем точнее генерация.

Оценку качества генерируемых атрибутов производят с точки зрения двух метрик. Оценку ассортативности можно также выполнять с помощью расчета абсолютной ошибки. Для оценки корреляций генерируемых атрибутов используется евклидово расстояние между целевым вектором корреляций атрибутов и вектором на сгенерированных атрибутах:

$$\varepsilon_{corr} = \sqrt{\sum_{i=1}^d (Corr_{gen,i} - Corr_{target,i})^2}.$$

Условная генерация синтетических графов. В настоящем исследовании проведен анализ применения

эволюционных алгоритмов для генерации графов с заданными топологическими характеристиками. В качестве критериев оценки рассматривались следующие параметры: коэффициент кластеризации, варьирующийся в пределах от 0,1 до 0,45 с шагом 0,05; средняя длина кратчайших путей, принимающая значения 1,5, 2 и 2,5; а также средняя степень, изменяющаяся от 2 до 35 с шагом 5. Экспериментальная база формировалась с использованием графов, содержащих 20, 30, 40 и 50 узлов. Эффективность предложенного алгоритма оценивалась посредством сопоставления вычисленных характеристик графа с заранее заданными значениями, что позволило выявить степень соответствия синтезированных структур требуемым параметрам. Выполнен анализ вычислительной сложности алгоритма на основе времени обработки (рис. 2). Полученные данные демонстрируют приблизительно линейную зависимость между временем обработки (в секундах) и параметрами, такими как средняя степень и количество узлов, что

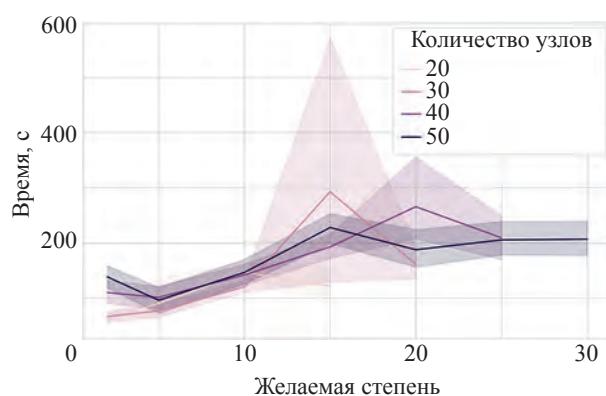


Рис. 2. Зависимость времени генерации от количества узлов и значения желаемой средней степени

Fig. 2. Dependence of generation time on number of nodes and value of desired average degree

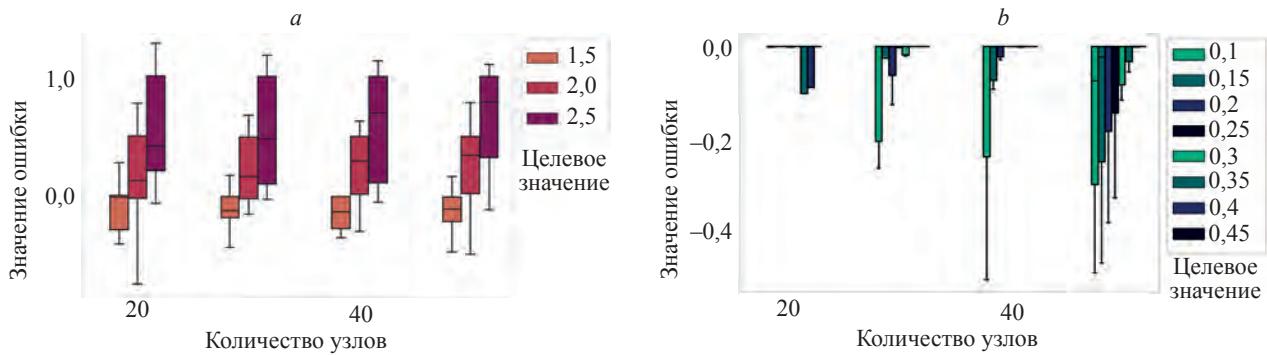


Рис. 3. Зависимости абсолютных ошибок характеристик сгенерированного графа от количества узлов при средней длине кратчайшего пути (а) и для коэффициента кластеризации (б)

Fig. 3. The dependence of the absolute errors of the characteristics of the generated graph vs. the number of nodes for the average length of the shortest path (a) and for the clustering coefficient (b)

свидетельствует о потенциальной масштабируемости предложенного метода.

На рис. 3 представлены различия между заданными и фактическими характеристиками сгенерированных графов. На рис. 3, а видно, что среднее значение ошибки остается на приемлемом уровне вне зависимости от размера графа, однако наблюдается увеличение дисперсии ошибки при больших значениях средней длины кратчайших путей. Рис. 3, б иллюстрирует тенденцию к систематическому занижению коэффициента кластеризации для графов, содержащих свыше 40 узлов, что свидетельствует о склонности алгоритма генерировать структуры с коэффициентами кластеризации, значительно меньшими, чем предусмотренные в параметрах моделирования.

На рис. 4 представлены ошибки в оценке средней длины кратчайшего пути и коэффициента кластеризации относительно целевой средней степени графа. На рис. 4, а видна тенденция к увеличению ошибки в определении средней длины кратчайшего пути для графов с целевой средней степенью, превышающей 5. Следует отметить, что наблюдается общее увеличение ошибки с ростом значения целевой средней степени, за исключением случая наименьшего значения, равного 2.

Это объясняется тем, что средняя степень 2 может быть достигнута только в циклическом графе, вследствие чего предложенный алгоритм обычно переоценивает этот показатель. Примечательно, что при увеличении числа вершин ошибка часто оказывается ниже. Рис. 4, б иллюстрирует ошибку в оценке коэффициента кластеризации по отношению к заданной средней степени. Из представленных данных следует, что ошибка возрастает с увеличением целевой степени, что характерно для всех рассматриваемых размеров графа. Наибольшая ошибка наблюдается при высоких значениях средней степени, что свидетельствует о повышенной точности алгоритма в аппроксимации заданного коэффициента кластеризации для более разреженных графов.

Условная генерация синтетических атрибутов. В настоящем исследовании была поставлена задача выяснить, могут ли БС генерировать атрибуты с заданным уровнем ассоциативности и корреляции для полно связанных графов, в частности для 500 вершин. Для этого проведены эксперименты с различными конфигурациями, манипулируя количеством атрибутов и целевыми значениями ассоциативности и корреляции. Целевые значения ассоциативности были установлены на 0,2 (низкая) и 0,9 (высокая). Для целевого значения

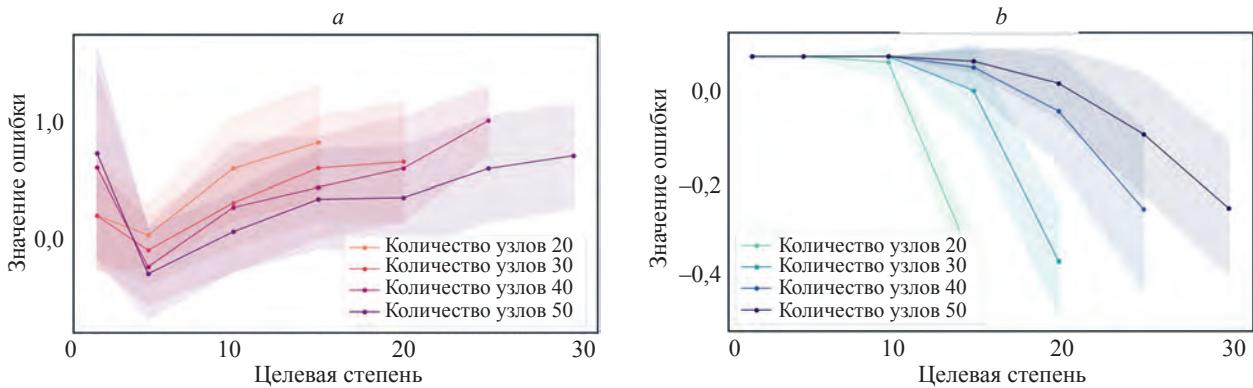


Рис. 4. Зависимости абсолютных ошибок характеристик сгенерированного графа от значений средней степени для различного количества вершин для длины кратчайшего пути (а) и коэффициента кластеризации (б)

Fig. 4. The dependence of the absolute errors of the characteristics of the generated graph vs. the values of the average degree for a different number of vertices for the length of the shortest path (a) and the clustering coefficient (b)

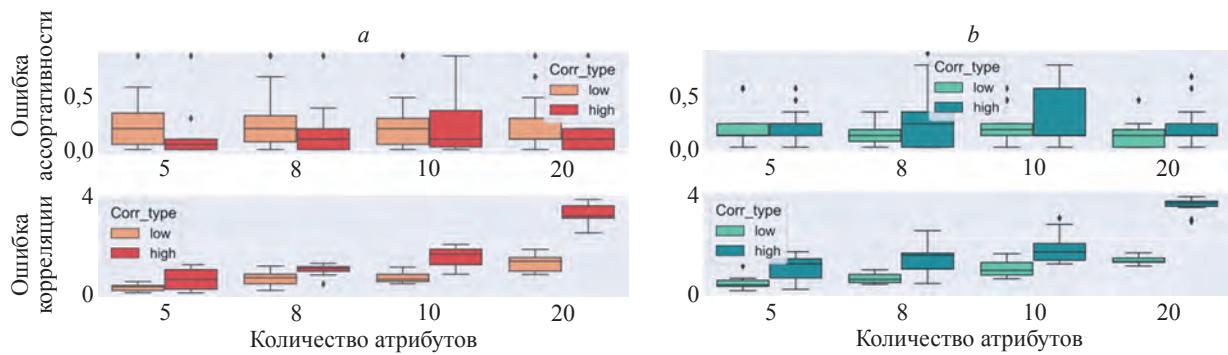


Рис. 5. Сравнение качества генерации атрибутов для различных экспериментальных конфигураций и количества атрибутов с точки зрения их близости к целевым характеристикам: высокая (0,9) (а) и низкая (0,2) (б) целевые ассортативности

Fig. 5. Comparison of the quality of attribute generation for various experimental configurations and the number of attributes in terms of their proximity to the target characteristics: high (0.9) (a) and low (0.2) (b) target assortativeness

корреляции (Corr_type) существует два режима: высокая корреляция (high), когда все значения корреляции для связанных атрибутов находятся в диапазоне от 0,7 до 0,9, и низкая корреляция (low), когда значения варьируются от 0,0 до 0,3. Структура БС всегда за-

дается как разреженная случайная структура с меньшим количеством ребер, чем узлов. На рис. 5 видно, что ошибка в ассортативности (абсолютная разница) в среднем не превышает 0,2 и остается стабильной для разного количества атрибутов. Это говорит о том, что

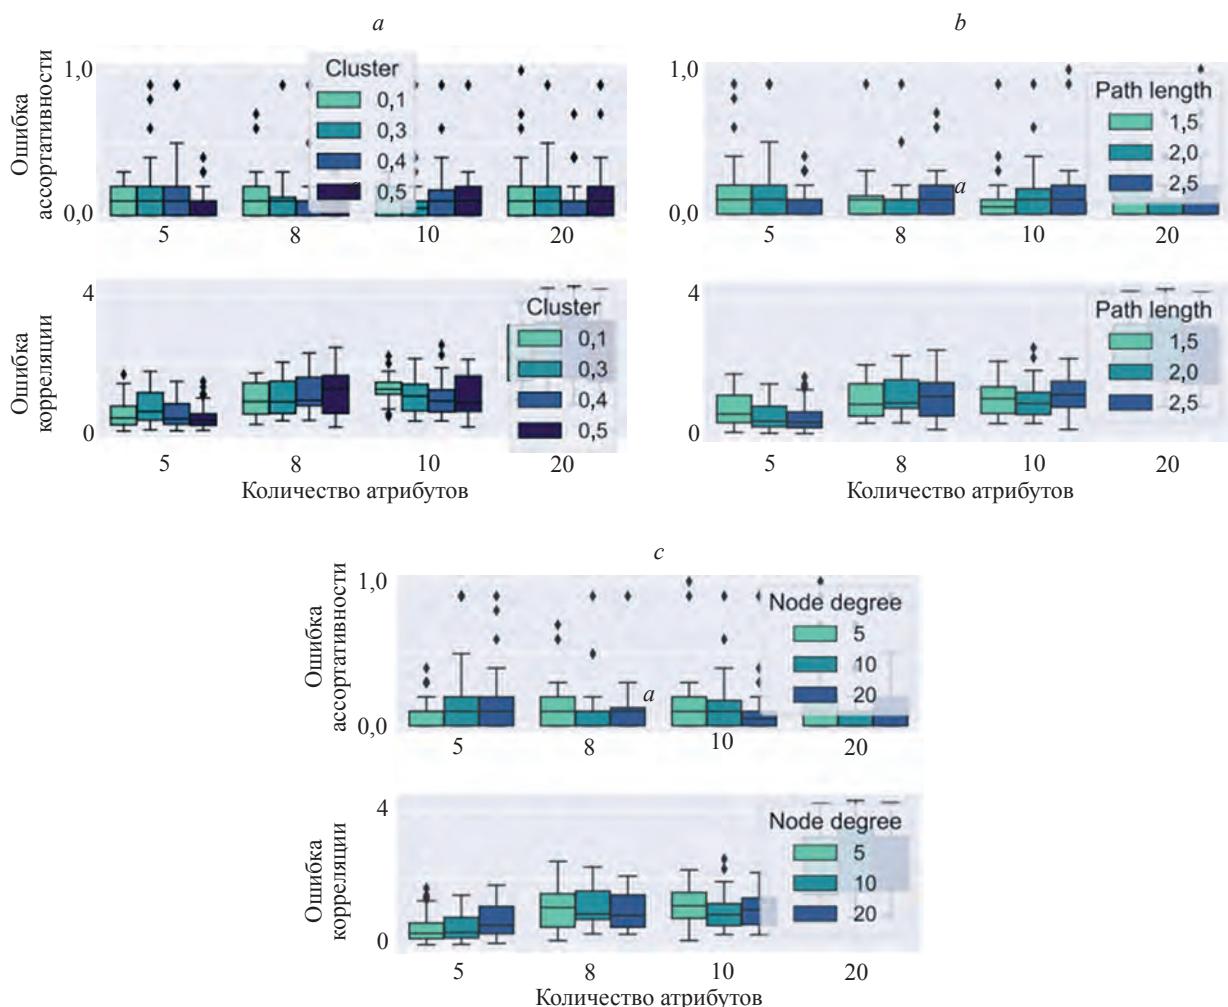


Рис. 6. Зависимости результатов генерации атрибутов от характеристик синтетического графа для различных коэффициентов кластеризации (а), длин кратчайших путей (б) и степеней вершин (с)

Fig. 6. The dependences of the attribute generation results vs. the characteristics of the synthetic graph for various clustering coefficients (a), shortest path lengths (b), and vertex degrees (c)

предложенный подход может генерировать атрибуты с необходимой ассортативностью. Важно отметить, что ошибка корреляции (евклидово расстояние между целевым вектором корреляций и полученным) увеличивается с ростом числа атрибутов, что ожидаемо в связи с ростом размера целевого вектора корреляции. Однако ошибка остается на приемлемом уровне.

В заключительной серии экспериментов были использованы синтетические графы, описанные в подразделе «Условная генерация синтетических атрибутов», обладающие разнообразными характеристиками: коэффициентом кластеризации, длиной кратчайших путей и степенью вершин. Для каждого из этих графов проведены эксперименты по генерации синтетических атрибутов с целевыми значениями ассортативности и корреляции. Структура БС формировалась случайным образом с варьированием степени плотности, а также изменялось число атрибутов. Рис. 6 демонстрирует, что БС способны эффективно генерировать атрибуты на синтетических графах, при этом качество исходных графовых структур не оказывает существенного влияния на данный процесс.

Заключение

В данной работе исследована возможность условной генерации синтетических графов с использованием эволюционного алгоритма. Экспериментальные результаты подтвердили эффективность предложенного подхода в создании графов с заданными топологическими характеристиками и статистическими свойствами атрибутов. Анализ показал, что алгоритм способен воспроизводить целевые параметры, включая коэффициент кластеризации, среднюю длину кратчайшего пути и среднюю степень вершин, однако его точность снижается в более плотных графах. Это может быть связано с недостижимостью некоторых областей гиперпространства характеристик, что требует дальнейшего изучения. Предложенный метод открывает новые возможности для управляемой генерации графов и может быть полезен в исследованиях графовых нейронных сетей. Дальнейшие исследования могут быть направлены на повышение точности алгоритма и расширение его применимости.

Литература

- Palowitch J., Tsitsulin A., Mayer B., Perozzi B. Graphworld: Fake graphs bring real insights for GNNs // Proc. of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. 2022. P. 3691–3701. <https://doi.org/10.1145/3534678.3539203>
- Hu W., Fey M., Zitnik M., Dong Y., Ren H., Liu B., Catasta M., Leskovec J. Open graph benchmark: Datasets for machine learning on graphs // Advances in Neural Information Processing Systems. 2020. V. 33. P. 22118–22133.
- Shah N. Scale-free, attributed and class-assortative graph generation to facilitate introspection of graph neural networks // Proc. of the MLG '20: ACM Symposium on Neural Gaze Detection. 2020.
- Maekawa S., Sasaki Y., Fletcher G., Onizuka M. Gencat: Generating attributed graphs with controlled relationships between classes, attributes, and topology // Information Systems. 2023. V. 115. P. 102195. <https://doi.org/10.1016/j.is.2023.102195>
- Kim M., Leskovec J. Multiplicative attribute graph model of real-world networks // Internet mathematics. 2012. V. 8. N 1-2. P. 113–160. <https://doi.org/10.1080/15427951.2012.625257>
- Tsitsulin A., Rozemberczki B., Palowitch J., Perozzi B. Synthetic graph generation to benchmark graph learning // arXiv. 2022. arXiv:2204.01376. <https://doi.org/10.48550/arXiv.2204.01376>
- Largeron C., Mougel P.-N., Rabban R., Zaïane O.R. Generating attributed networks with communities // PLoS ONE. 2015. V. 10. N 4. P. e0122777. <https://doi.org/10.1371/journal.pone.0122777>
- Barabási A.-L. The Barabási-Albert Model // Network Science. 2016. P. 164–202.
- Tseng A.M., Diamant N., Biancalani T., Scalvia G. GraphGUIDE: interpretable and controllable conditional graph generation with discrete bernoulli diffusion // arXiv. 2023. arXiv:2302.03790. <https://doi.org/10.48550/arXiv.2302.03790>
- Li M., Kreacic E., Potluru V.K., Li P. GraphMaker: Can diffusion models generate large attributed graphs? // arXiv. 2023. arXiv:2310.13833. <https://doi.org/10.48550/arXiv.2310.13833>
- Faez F., Dijujin N.H., Baghshah M.S., Rabiee H.R. SCGG: A deep structure-conditioned graph generative model // PLoS ONE. 2022. V. 17. N 11. P. e0277887. <https://doi.org/10.1371/journal.pone.0277887>
- Kipf T.N., Welling M. Variational graph auto-encoders // arXiv. 2016. arXiv:1611.07308. <https://doi.org/10.48550/arXiv.1611.07308>
- Simonovsky M., Komodakis N. Graphvae: Towards generation of small graphs using variational autoencoders // Lecture Notes in Computer Science. 2018. V. 11139. P. 412–422. https://doi.org/10.1007/978-3-030-01418-6_41

References

- Palowitch J., Tsitsulin A., Mayer B., Perozzi B. Graphworld: Fake graphs bring real insights for GNNs. *Proc. of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, 2022, pp. 3691–3701. <https://doi.org/10.1145/3534678.3539203>
- Hu W., Fey M., Zitnik M., Dong Y., Ren H., Liu B., Catasta M., Leskovec J. Open graph benchmark: Datasets for machine learning on graphs. *Advances in Neural Information Processing Systems*, 2020, vol. 33, pp. 22118–22133.
- Shah N. Scale-free, attributed and class-assortative graph generation to facilitate introspection of graph neural networks. *Proc. of the MLG '20: ACM Symposium on Neural Gaze Detection*, 2020.
- Maekawa S., Sasaki Y., Fletcher G., Onizuka M. Gencat: Generating attributed graphs with controlled relationships between classes, attributes, and topology. *Information Systems*, 2023, vol. 115, pp. 102195. <https://doi.org/10.1016/j.is.2023.102195>
- Kim M., Leskovec J. Multiplicative attribute graph model of real-world networks. *Internet mathematics*, 2012, vol. 8, no. 1-2, pp. 113–160. <https://doi.org/10.1080/15427951.2012.625257>
- Tsitsulin A., Rozemberczki B., Palowitch J., Perozzi B. Synthetic graph generation to benchmark graph learning. *arXiv*, 2022, arXiv:2204.01376. <https://doi.org/10.48550/arXiv.2204.01376>
- Largeron C., Mougel P.-N., Rabban R., Zaïane O.R. Generating attributed networks with communities. *PLoS ONE*, 2015, vol. 10, no. 4, pp. e0122777. <https://doi.org/10.1371/journal.pone.0122777>
- Barabási A.-L. The Barabási-Albert Model. *Network Science*, 2016, pp. 164–202.
- Tseng A.M., Diamant N., Biancalani T., Scalvia G. GraphGUIDE: interpretable and controllable conditional graph generation with discrete bernoulli diffusion. *arXiv*, 2023, arXiv:2302.03790. <https://doi.org/10.48550/arXiv.2302.03790>
- Li M., Kreacic E., Potluru V.K., Li P. GraphMaker: Can diffusion models generate large attributed graphs? *arXiv*, 2023, arXiv:2310.13833. <https://doi.org/10.48550/arXiv.2310.13833>
- Faez F., Dijujin N.H., Baghshah M.S., Rabiee H.R. SCGG: A deep structure-conditioned graph generative model. *PLoS ONE*, 2022, vol. 17, no. 11, P. e0277887. <https://doi.org/10.1371/journal.pone.0277887>
- Kipf T.N., Welling M. Variational graph auto-encoders. *arXiv*, 2016, arXiv:1611.07308. <https://doi.org/10.48550/arXiv.1611.07308>
- Simonovsky M., Komodakis N. Graphvae: Towards generation of small graphs using variational autoencoders. *Lecture Notes in Computer Science*, 2018, vol. 11139, pp. 412–422. https://doi.org/10.1007/978-3-030-01418-6_41

14. Bojchevski A., Shchur O., Zügner D., Günnemann S. NetGAN: Generating graphs via random walks // arXiv. 2018. arXiv:1803.00816. <https://doi.org/10.48550/arXiv.1803.00816>
15. Gasteiger J., Bojchevski A., Günnemann S. Predict then propagate: Graph neural networks meet personalized pagerank // arXiv. 2018. arXiv:1810.05997. 2018. <https://doi.org/10.48550/arXiv.1810.05997>
16. Kim D., Oh A. How to find your friendly neighborhood: Graph attention design with self-supervision // arXiv. 2022. arXiv:2204.04879. <https://doi.org/10.48550/arXiv.2204.04879>
17. Attar N., Aliakbary S., Nezhad Z.H. Automatic generation of adaptive network models based on similarity to the desired complex network // Physica A: Statistical Mechanics and its Applications. 2020. V. 545. P. 123353. <https://doi.org/10.1016/j.physa.2019.123353>
18. Verstraeten M., Varbanescu A.L., de Laat C. Synthetic graph generation for systematic exploration of graph structural properties // Lecture Notes in Computer Science. 2017. V. 10104. P. 557–570. https://doi.org/10.1007/978-3-319-58943-5_45
19. Barry A., Griffith J., O'Riordan C. An evolutionary and graph-rewriting based approach to graph generation // Proc. of the 7th International Joint Conference on Computational Intelligence (IJCCI 2015). 2015. V. 1. P. 237–243. <https://doi.org/10.5220/0005597102370243>
20. Deb K., Pratap A., Agarwal S., Meyarivan T. A fast and elitist multiobjective genetic algorithm: NSGA-II // IEEE Transactions on Evolutionary Computation. 2002. V. 6. N 2. P. 182–197. <https://doi.org/10.1109/4235.996017>
21. Erdos P., Renyi A. On the evolution of random graphs // The Structure and Dynamics of Networks. 2011. P. 38–82.
22. Koller D., Friedman N. Probabilistic Graphical Models: Principles and Techniques. The MIT Press, 2009. 1231 p.
14. Bojchevski A., Shchur O., Zügner D., Günnemann S. NetGAN: Generating graphs via random walks. *arXiv*, 2018, arXiv:1803.00816. <https://doi.org/10.48550/arXiv.1803.00816>
15. Gasteiger J., Bojchevski A., Günnemann S. Predict then propagate: Graph neural networks meet personalized pagerank. *arXiv*, 2018, arXiv:1810.05997. <https://doi.org/10.48550/arXiv.1810.05997>
16. Kim D., Oh A. How to find your friendly neighborhood: Graph attention design with self-supervision. *arXiv*, 2022, arXiv:2204.04879. <https://doi.org/10.48550/arXiv.2204.04879>
17. Attar N., Aliakbary S., Nezhad Z.H. Automatic generation of adaptive network models based on similarity to the desired complex network. *Physica A: Statistical Mechanics and its Applications*, 2020, vol. 545, pp. 123353. <https://doi.org/10.1016/j.physa.2019.123353>
18. Verstraeten M., Varbanescu A.L., de Laat C. Synthetic graph generation for systematic exploration of graph structural properties. *Lecture Notes in Computer Science*, 2017, vol. 10104, pp. 557–570. https://doi.org/10.1007/978-3-319-58943-5_45
19. Barry A., Griffith J., O'Riordan C. An evolutionary and graph-rewriting based approach to graph generation. *Proc. of the 7th International Joint Conference on Computational Intelligence (IJCCI 2015)*, 2015, vol. 1, pp. 237–243. <https://doi.org/10.5220/0005597102370243>
20. Deb K., Pratap A., Agarwal S., Meyarivan T. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 2002, vol. 6, no. 2, pp. 182–197. <https://doi.org/10.1109/4235.996017>
21. Erdos P., Renyi A. On the evolution of random graphs. *The Structure and Dynamics of Networks*, 2011, pp. 38–82.
22. Koller D., Friedman N. *Probabilistic Graphical Models: Principles and Techniques*. The MIT Press, 2009, 1231 p.

Авторы

Деева Ирина Юрьевна — кандидат физико-математических наук, старший научный сотрудник, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация,  57210416999, <https://orcid.org/0000-0001-8679-5868>, iriny.deeva@gmail.com

Андреева Полина Олеговна — аспирант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация,  57223144672, <https://orcid.org/0000-0002-3130-1012>, polinaspb@ya.ru

Шиков Егор Николаевич — кандидат технических наук, младший научный сотрудник, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация,  57209451139, <https://orcid.org/0000-0001-5749-4222>, egorshikov@itmo.ru

Калюжная Анна Владимировна — кандидат технических наук, старший научный сотрудник, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация,  56218089100, <https://orcid.org/0000-0002-9612-8601>, kalyuzhnaya.ann@gmail.com

Статья поступила в редакцию 01.03.2025
Одобрена после рецензирования 15.04.2025
Принята к печати 23.05.2025



Received 01.03.2025
Approved after reviewing 15.04.2025
Accepted 23.05.2025

Работа доступна по лицензии
Creative Commons
«Attribution-NonCommercial»