
КЛАССИФИКАЦИЯ И СРАВНИТЕЛЬНЫЙ АНАЛИЗ ГЕНЕРАТИВНЫХ МОДЕЛЕЙ ДЛЯ ЗАДАЧИ ГЕНЕРАЦИИ ПЛАНОВ ПОМЕЩЕНИЙ НА ОСНОВЕ ГРАФОВЫХ ПРЕДСТАВЛЕНИЙ

Парамонова Екатерина Михайловна,

Бакалавр

МГТУ имени Н.Э. Баумана, кафедра «Программное обеспечение ЭВМ и информационные технологии», Москва, Россия

paramonovaem@student.bmstu.ru

Аннотация

Представлены классификация и сравнительный анализ генеративных моделей применительно к задаче автоматизированной генерации планов помещений на основе графовых представлений. Рассмотрены основные классы генеративных моделей: вариационные автокодировщики, генеративно-состязательные сети, модели авторегрессии, модели нормализующих потоков, модели на основе энергии и модели диффузии. Предложена классификация методов по наличию функции плотности, уровню контроля над топологией генерируемого плана, детализации геометрии результата и стабильности обучения. Проведён сравнительный анализ на основе метрик FID, IS и вычислительной структуры моделей. Результаты показывают, что для задачи генерации планов помещений на основе графовых структур наиболее перспективны диффузионные модели и генеративно-состязательные сети. Представлены рекомендации по применению рассмотренных моделей для различных сценариев генерации планов помещений.

Ключевые слова: генеративные модели, генерация планов помещений, графовые представления, архитектурное проектирование, вариационные автокодировщики, генеративно-состязательные сети, диффузионные модели, сравнительный анализ.

CLASSIFICATION AND COMPARATIVE ANALYSIS OF GENERATIVE MODELS FOR THE TASK OF ROOM LAYOUT GENERATION BASED ON GRAPH REPRESENTATIONS

Paramonova Ekaterina Mikhailovna,

Bachelor's Degree Student

Bauman Moscow State Technical University, Department of Computer Software and Information Technologies, Moscow, Russia

paramonovaem@student.bmstu.ru

ABSTRACT

The classification and comparative analysis of generative models applied to the task of automated room layout generation based on graph representations is presented. The main classes of generative models are considered: variational autoencoders, generative adversarial networks,

autoregressive models, normalizing flow models, energy-based models and diffusion models. A classification of methods is proposed based on the presence of a density function, the level of control over the topology of the generated layout, the geometric detail of the result, and training stability. A comparative analysis is carried out based on FID and IS and the computational structure of the models. The results show that diffusion models and generative adversarial networks are the most promising for the task of graph-based room layout generation. Recommendations on the application of the considered models for various room layout generation scenarios are presented.

Keywords: generative models, room layout generation, graph representations, architectural design, variational autoencoders, generative adversarial networks, diffusion models, comparative analysis.

Введение

Автоматизированная генерация планов помещений на основе формализованных описаний – контуров зданий, схем функционального зонирования и графовых представлений связей между помещениями – является одной из востребованных задач применения генеративных моделей в архитектурном проектировании. Графовое представление, в котором узлы соответствуют помещениям, а рёбра – связям между ними, позволяет компактно формализовать требования к планировке и передать их генеративной модели в виде условия [1].

Возможность моделей учитывать подобное структурированное условие, сохранять устойчивость обучения и обеспечивать геометрически точный и семантически корректный результат существенно различается между классами генеративных моделей. Это делает актуальной задачу их классификации и сравнительного анализа применительно к задаче генерации планов помещений.

Генеративные модели

Генеративная модель – это статистическая модель, которая обучается воспроизводить распределение данных обучающей выборки и за счёт этого способна генерировать новые объекты, статистически похожие на исходные [2]. В задаче генерации планов помещений в роли обучающих данных выступают изображения планов или их структурированные представления, а генерация, как правило, выполняется с условием – графом связей помещений, схемой зонирования или текстовым описанием [3].

Ниже рассмотрены основные классы генеративных моделей, применимые к данной задаче.

Вариационные автокодировщики (VAE) сжимают план помещения в скрытое пространство с помощью кодировщика, а декодировщик восстанавливает план по точке этого пространства [4]. Стохастичность кодирования обеспечивает разнообразие генерируемых планов, а структура скрытого пространства удобна для условной генерации на основе графа. Однако генерируемые планы нередко получают недостаточно детализированными, с искажёнными или неточными границами комнат.

Генеративно-состязательные сети (GAN) состоят из генератора, преобразующего случайный вектор или вектор, полученный из графового представления, в план помещения, и дискриминатора, обучаемого отличать сгенерированные планы от реальных [4]. Их обучение должно быть согласованным, чтобы предотвратить схлопывание мод если дискриминатор обучается быстрее генератора, тот перестаёт получать полезный сигнал для улучшения; если же генератор находит несколько вариантов, стабильно обманывающих дискриминатор, он начинает производить только их [5]. Условие генерации задаётся через

модификацию скрытого пространства, что не всегда даёт достаточный контроль над топологией результата [6].

Модели авторегрессии (AR) генерируют план последовательно: каждый следующий элемент – например, пиксель изображения или точка контура – предсказывается на основе уже сгенерированных [4]. В отличие от текста, где порядок элементов задан языком, для двумерного плана естественного порядка обхода нет, и его приходится задавать искусственно, что может приводить к несогласованности между удалёнными в этом порядке, но соседними на плане элементами – например, двумя сторонами одной стены. Кроме того, число шагов генерации растёт с числом помещений.

Модели нормализующих потоков (NF) моделируют распределение данных с помощью обратимого преобразования между пространством планов и простым базовым распределением, например, гауссовым. Обратимость нужна, чтобы точно вычислить плотность вероятности плана. Такая точность недостижима для GAN и труднодостижима для диффузионных моделей, где плотность моделируется лишь приближённо. Однако не любую сеть можно сделать обратимой с эффективно вычисляемой плотностью вероятности, поэтому сложность такого вычисления для многомерных данных остаётся высокой [4].

Модели на основе энергии (EBM) сопоставляют каждому плану скалярное значение энергии, при этом более вероятным планам соответствует меньшая энергия [4]. Генерация выполняется итеративно с помощью динамики Ланжевена – метода математического описания движения частиц в среде [7]. Вычислительная сложность нормирующего интеграла и необходимость аппроксимации ограничивают применение таких моделей для сложных графовых условий на практике.

Диффузионные модели (DM) генерируют план путём итеративного удаления шума: при обучении к координатам плана постепенно добавляется гауссов шум, а сеть учится предсказывать этот шум на каждом шаге с учётом условия – например, графа связей помещений. При генерации происходит обратный процесс начиная со случайного шума, модель итерационно убирает предсказанный шум, восстанавливая план [4]. Поскольку условие можно добавлять на каждом шаге, а не только один раз, как в GAN или VAE, диффузионные модели допускают более гибкое согласование результата с заданным графом.

Классификация рассматриваемых классов моделей

Для классификации классов генеративных моделей применительно к задаче генерации планов помещений на основе графовых представлений предложены следующие критерии.

Наличие функции плотности характеризует, моделирует ли метод явно вероятностное распределение данных [4]. Выделены следующие классы: аппроксимированная плотность (приближённое моделирование), управляемая плотность (точное, но ограниченное по форме моделирование) и неявная плотность (распределение не вычисляется явно, а данные генерируются посредством стохастического процесса).

Контроль над топологией плана отражает, насколько точно графовое условие определяет структуру сгенерированного плана: явный контроль означает прямую связь условия с результатом, ограниченный – влияние условия опосредовано скрытым представлением без строгих гарантий, гибкий – возможность вносить условие многократно в процессе генерации.

Детализация геометрии характеризует, насколько чётко сгенерированное изображение отражает границы помещений, без искажений размеров и формы комнат. Оценка по этому критерию в таблица 1 носит качественный характер и основана на выводах анализа источников, а не на измеренных метриках.

Стабильность обучения определяет предсказуемость и устойчивость процесса обучения модели при увеличении сложности графового условия.

Результаты классификации представлены в таблице 1.

Таблица 1: Классификация классов генеративных моделей

Модель	Наличие функции плотности	Контроль над топологией плана	Детализация геометрии	Стабильность обучения
VAE	Аппроксимированная [4]	Явный, через условное скрытое пространство	Невысокая, возможны искажения границ	Стабильное
GAN	Неявная [4]	Ограниченный, через модификацию скрытого вектора	Высокая, но нестабильная	Нестабильное
AR	Управляемая [4]	Явный, последовательный	Зависит от порядка генерации элементов	Стабильное
NF	Управляемая [4]	Явный, через обратимое отображение	Высокая теоретически, ограничена структурой сети	Стабильное
EBM	Аппроксимированная [4]	Ограниченный, через энергетическую функцию	Ограничена сложностью выборки	Нестабильное
DM	Аппроксимированная [4]	Гибкий, условие на каждом шаге диффузии	Высокая, с хорошей детализацией	Стабильное

Сравнительный анализ рассматриваемых моделей

Для количественного сравнения использованы метрики FID (сходство распределений признаков реальных и сгенерированных изображений, чем меньше – тем лучше) и IS (чёткость и разнообразие генерации, чем больше – тем лучше), а также число обучаемых сетей и применимость модели для условной генерации по графу.

Результаты представлены в таблице 2.

Таблица 2: Результаты репрезентативных представителей различных классов генеративных моделей

Класс	Представитель	FID	IS	Кол-во сетей	Условная генерация по графу
VAE	VQ-VAE-2	31.11 [9]	–	1	Да
GAN	BigGAN	8.4 [10]	166.3 [10]	2	Да
AR	PixelCNN++	65.93 [11]	4.60 [11]	1	Да
NF	Glow	46.90 [12]	–	1	Ограниченно
EBM	IGEBM	21.10 [13]	–	1	Нет
DM	ADM	2.97 [14]	221.70 [14]	1	Да

Заключение

Диффузионные модели, наиболее подходящие для генерации планов по графовому описанию: условие можно вносить на каждом шаге, а устойчивость к схлопыванию мод обеспечивает разнообразие и точность результата. Основной их недостаток – высокая вычислительная сложность итеративной генерации.

GAN обеспечивают высокое качество и низкий FID при однократной генерации, что подходит для решения задач, где важна скорость. Однако ограниченный контроль над топологией и нестабильность обучения требуют дополнительных механизмов управления условием при усложнении графа.

VAE и AR стабильны в обучении и показывают сопоставимо высокий CAS, что делает их разумным выбором при ограниченных ресурсах – однако VAE обеспечивают невысокую детализацию, а AR чувствительны к отсутствию естественного порядка генерации.

NF и EBM уступают по практической применимости из-за сложности точного моделирования плотности и обеспечения эффективной выборки.

Список литературы:

1. Салех М. С. Внедрение цифровых методов на различных этапах архитектурного проектирования / М. С. Салех // Архитектура и современные информационные технологии. – 2021. – № 1(54).
2. Намиот Д. Е. Порождающие модели в машинном обучении / Д. Е. Намиот, Е. А. Ильюшин // Компьютерные и информационные науки. – 2021. – № 3(15).
3. Ли Ч. Генеративные модели ИИ для различных этапов архитектурного проектирования: обзор литературы / Ч. Ли, Т. Чжан, С. Ду, Я. Чжан, Х. Xie // Frontiers of Architectural Research. – 2025. – Т. 14. – С. 759–783. – DOI: 10.1016/j.foar.2024.10.001.
4. Фостер Д. Генеративное глубокое обучение. Как машины рисуют картины, пишут романы и музыку: [пер. с англ.] / Д. Фостер. – 2-е изд., междунар. – Астана: Спринт Бук, 2024. – 448 с.
5. Барщевский Е. Г. Генеративно-состязательные нейронные сети / Е. Г. Барщевский // East European Scientific Journal. – 2024. – № 1(98).
6. Катаев А. В. Обзор метрик с целью оценки качества работы генеративных моделей для создания изображений / А. В. Катаев, Ю. М. Власова, Д. А. Гусынин, В. А. Ким // Инженерный вестник Дона. – 2025. – № 6.
7. Дубко В. А. Нахождение решения характеристического уравнения для одной неклассической модели диффузии / В. А. Дубко, С. В. Зубарев, Е. В. Карачанская // Математические заметки СВФУ. – 2021. – Т. 28, № 1.
8. Ravuri S. Classification Accuracy Score for Conditional Generative Models / S. Ravuri, O. Vinyals // Advances in Neural Information Processing Systems 32 (NeurIPS 2019). – 2019.
9. Razavi A., van den Oord A., Vinyals O. Generating Diverse High-Fidelity Images with VQ-VAE-2 // Advances in Neural Information Processing Systems 32 (NeurIPS 2019). – 2019.
10. Brock A., Donahue J., Simonyan K. Large Scale GAN Training for High Fidelity Natural Image Synthesis // International Conference on Learning Representations (ICLR). – 2019.
11. Salimans T., Karpathy A., Chen X., Kingma D. P. PixelCNN++: Improving the PixelCNN with Discretized Logistic Mixture Likelihood and Other Modifications // International Conference on Learning Representations (ICLR). – 2017.

12. Kingma D. P., Dhariwal P. Glow: Generative Flow with Invertible 1×1 Convolutions // Advances in Neural Information Processing Systems 31 (NeurIPS 2018). – 2018.
13. Du Y., Mordatch I. Implicit Generation and Generalization in Energy-Based Models // Advances in Neural Information Processing Systems 32 (NeurIPS 2019). – 2019.
14. Dhariwal P., Nichol A. Diffusion Models Beat GANs on Image Synthesis // Advances in Neural Information Processing Systems 34 (NeurIPS 2021). – 2021.

References:

1. Saleh M.S. Implementation of digital methods at various stages of architectural design // Architecture and Modern Information Technologies. – 2021. – No. 1(54).
2. Namiot D.E., Ilyushin E.A. Generative models in machine learning // Computer and Information Sciences. – 2021. – No. 3(15).
3. Li C., Zhang T., Du S., Zhang Y., Xie H. Generative AI models for various stages of architectural design: a literature review // Frontiers of Architectural Research. – 2025. – Vol. 14. – P. 759–783. – DOI: 10.1016/j.foar.2024.10.001.
4. Foster D. Generative Deep Learning. How machines paint pictures, write novels and music: [transl. from English] / D. Foster. – 2nd int. ed. – Astana: Sprint Book, 2024. – 448 p.
5. Barshchevsky E.G. Generative adversarial neural networks // East European Scientific Journal. – 2024. – No. 1(98).
6. Kataev A.V., Vlasova Yu.M., Gusynin D.A., Kim V.A. A review of metrics for evaluating the quality of generative models for image synthesis // Engineering Journal of Don. – 2025. – No. 6.
7. Dubko V.A., Zubarev S.V., Karachanskaya E.V. Finding a solution to the characteristic equation for a non-classical diffusion model // Mathematical Notes of NEFU. – 2021. – Vol. 28, No. 1.
8. Ravuri S., Vinyals O. Classification Accuracy Score for Conditional Generative Models // Advances in Neural Information Processing Systems 32 (NeurIPS 2019). – 2019.
9. Razavi A., van den Oord A., Vinyals O. Generating Diverse High-Fidelity Images with VQ-VAE-2 // Advances in Neural Information Processing Systems 32 (NeurIPS 2019). – 2019.
10. Brock A., Donahue J., Simonyan K. Large Scale GAN Training for High Fidelity Natural Image Synthesis // International Conference on Learning Representations (ICLR). – 2019.
11. Salimans T., Karpathy A., Chen X., Kingma D.P. PixelCNN++: Improving the PixelCNN with Discretized Logistic Mixture Likelihood and Other Modifications // International Conference on Learning Representations (ICLR). – 2017.
12. Kingma D.P., Dhariwal P. Glow: Generative Flow with Invertible 1×1 Convolutions // Advances in Neural Information Processing Systems 31 (NeurIPS 2018). – 2018.
13. Du Y., Mordatch I. Implicit Generation and Generalization in Energy-Based Models // Advances in Neural Information Processing Systems 32 (NeurIPS 2019). – 2019.
14. Dhariwal P., Nichol A. Diffusion Models Beat GANs on Image Synthesis // Advances in Neural Information Processing Systems 34 (NeurIPS 2021). – 2021.