

ПРИМЕНЕНИЕ ГРАФОВЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ АВТОМАТИЧЕСКОЙ ПРОВЕРКИ ИНФОРМАЦИОННЫХ МОДЕЛЕЙ ЗДАНИЙ

О. В. Полеткина¹ [0009-0003-2938-7640], **О. М. Атаева**² [0000-0003-0367-5575]

^{1, 2}*Московский физико-технический институт, г. Долгопрудный, Россия*

¹poletkina.ov@phystech.edu, ²oataeva@frccsc.ru

Аннотация

Автоматизация проверки информационной модели здания на соответствие нормам пожарной безопасности остается актуальной задачей для архитектурно-строительной отрасли. Существующие системы такой автоматизированной проверки ориентированы на подходы, основанные на правилах, которые не учитывают топологический контекст здания и плохо адаптируются к новым проектам.

В работе предложены и экспериментально проверены методы прогнозирования параметров противопожарной защиты дверей в информационных моделях зданий с использованием графовых нейронных сетей, а также валидация подхода на реальных проектных данных семи жилых зданий крупного застройщика. Предложена методология прогнозирования класса огнестойкости дверей на основе реляционных графовых сверточных сетей, а также разработан пайплайн извлечения данных из специального формата с построением графа и формированием признаков с учетом геометрических, семантических и топологических характеристик. Проведены эксперименты по прогнозированию наличия и класса огнестойкости с кросс-проектной валидацией по принципу «одно здание вне выборки». Разработанный подход позволяет автоматизировать проверку параметров противопожарной защиты и сократить время анализа моделей зданий. Применение графовых нейронных сетей обеспечивает учет топологического контекста и высокую точность прогнозирования, а использование реальных данных подтверждает практическую применимость метода.

Ключевые слова: информационная модель зданий, графовые нейронные сети, реляционная графовая нейросеть, огнестойкость дверей, открытый стандарт обмена данными IFC, автоматизированная проверка, графовое машинное обучение, кросс-проектная валидация.

ВВЕДЕНИЕ

Информационное моделирование зданий (Building Information Modeling, BIM) [1] широко применяется в проектировании и способствует повышению качества проектных решений. Далее будет использован термин BIM-модель для обозначения цифровой информационной модели объекта, созданной в рамках BIM-процесса. При этом проверка BIM-моделей по-прежнему во многом остается ручной: под проверкой понимаются процедуры контроля качества и соответствия модели требованиям (выявление коллизий, проверка полноты/корректности параметров и соответствия регламентам). Согласно исследованию компании nCircle Tech, 87.5% специалистов отмечают необходимость совершенствования процесса проверки BIM-стандартов, при этом около 51% проверок выполняются вручную. Типичный жилой комплекс может содержать более 13500 дверей и свыше 85000 элементов модели, что делает полноценную ручную проверку без значительных временных затрат практически невозможной [2, 3].

Существующие системы автоматизированной проверки ориентированы преимущественно на подходы, основанные на явно заданных правилах, которые ограниченно учитывают сложный топологический контекст здания и с трудом адаптируются к новым проектам и вариативным практикам моделирования. Нами рассмотрен подход на основе графовых нейронных сетей, позволяющий использовать графовое представление BIM-модели для учета пространственно-топологических связей между элементами.

Общей задачей исследования является разработка каскадной системы машинного обучения для автоматизированной проверки параметров дверей в BIM-моделях. Система включает несколько последовательных этапов, представленных на рис. 1, где этап 1 классифицирует стены по наличию двери, этапы

2–5 решают задачи регрессии и классификации дверей, этап 6 проверяет соответствие нормативным требованиям с помощью Cypher-запроса¹.




Рис. 1. Шаги каскадной системы, реализованные в рамках исследования.

Настоящая статья посвящена одному из модулей этой системы, который используется для проверки параметров дверей и решает две задачи:

- 1) определение необходимости требований к огнестойкости²;
- 2) прогнозирование класса огнестойкости (EI-30, EI-60) для дверей, требующих противопожарной защиты².

Исследование выполнено на реальных данных компании ПАО «ПИК СЗ»³ для семи секций жилых зданий.

1. БЛИЗКИЕ ПО ТЕМАТИКЕ ИССЛЕДОВАНИЯ

BIM-модель может быть представлена как граф, в котором элементы здания связаны пространственными и семантическими отношениями. Поэтому графовые нейронные сети (Graph Neural Network, GNN)⁴ являются естественным и обоснованным инструментом для анализа структуры здания и автоматизированной проверки проектных решений. Исследования использования графовых нейронных сетей в проектировании информационных моделей зданий в основном касаются отдельных задач: это классификация помещений, семантическое обогащение или оценка качества элементов. В работе [4] продемонстрирована эффективность графовых нейронных сетей с механизмом внимания (Graph Attention Networks, GAT)⁵ для анализа строительных элементов. В исследованиях, посвященных семантическому обогащению BIM-моделей [5, 6], графовые нейронные сети (GNN)⁴ применены для классификации помещений.

¹ Cypher Query Language: документация Neo4j // URL: <https://neo4j.com/docs/cypher-manual/current/introduction/>

² СП 1.13130.2020. Системы противопожарной защиты. Эвакуационные пути и выходы // URL: <https://tiflocentre.ru/download/sp-1-13130-2020.pdf>

³ PIK Group: официальный сайт // URL: <https://www.pik.ru/>

⁴ Graph Neural Networks in PyTorch Geometric: документация // URL: <https://pytorch-geometric.readthedocs.io/en/latest/tutorial/heterogeneous.html>

⁵ Graph Attention Networks (GAT): документация PyTorch Geometric // URL: https://pytorch-geometric.readthedocs.io/en/latest/generated/torch_geometric.nn.models.GAT.html

Системы автоматизированного контроля соответствия нормам (ACC), такие как Solibri⁶ и RuleChecker⁷, реализуют нормативные требования в виде машиночитаемых правил. В графо-ориентированных представлениях данных такие правила могут задаваться как SPARQL-запросы⁸, что обеспечивает детерминированную и воспроизводимую проверку [7]. Однако подходы, основанные на явно заданных правилах, ограниченно учитывают сложные пространственно-топологические зависимости между элементами BIM-модели и слабо масштабируются при переносе на новые проекты и вариативные практики моделирования.

Существующие гибридные решения [8, 9] объединяют правила и графовые модели для обогащения BIM-графа и последующего извлечения информации с помощью запросов. При этом задача прогнозирования нормативно значимых параметров элементов обычно остается вне рассмотрения.

Настоящая работа ориентирована на предсказание нормативно-критичных параметров огнестойкости дверей с использованием реляционных графовых сверточных сетей (R-GCN)⁹. В отличие от существующих подходов, предложенная методология решает две последовательные задачи: классификацию наличия требований к огнестойкости и последующее определение класса (EI-30/EI-60) на основе контекста размещения двери в структуре здания. Применение схемы валидации по принципу «одно здание вне выборки» (Leave-One-Building-Out, далее LOBO) на реальных промышленных данных обеспечивает оценку обобщающей способности моделей на ранее не виденных зданиях.

2. ИСХОДНЫЕ ДАННЫЕ И ПОСТАНОВКА ЗАДАЧИ

2.1. Описание данных

В проведенном исследовании были использованы BIM-модели семи реальных жилых проектов компании ПАО «ПИК СЗ»³, крупнейшего девелопера России. Каждая модель представляет собой отдельную секцию многоквартирного дома (один подъезд) с этажностью от 16 до 31. Модели содержат полную

⁶ Solibri Office: система автоматизированной проверки BIM моделей // URL: <https://www.solibri.com/>

⁷ RuleChecker: BIM Model Rule Checker //URL: <https://add.io/product/bim-model-rule-checker/>

⁸ SPARQL 1.1 Overview: W3C Recommendation, 2013 // URL: <https://www.w3.org/TR/2013/REC-sparql11-overview-20130321/>

⁹ Relational Graph Convolutional Networks (R-GCN): документация PyTorch Geometric // URL: https://pytorch-geometric.readthedocs.io/en/latest/generated/torch_geometric.nn.conv.RGCNConv.html

информацию о планировке, конструкциях и инженерных системах в формате IFC. Визуализация графов зданий представлена на рис. 2. На рис. 3 показано соответствие узлов графа элементам BIM-модели, а также приведен пример сформированного признакового пространства.

Количественные характеристики моделей приведены в табл. 1. Общее количество дверных элементов во всех проектах составляет 7928, помещений – 13063, связей между элементами – 210219. Объем и разнообразие данных позволяют выполнить обучение моделей машинного обучения и провести оценку их обобщающей способности в условиях межпроектного переноса. Схема графowego представления BIM-модели приведена на рис. 4 и иллюстрирует преобразование элементов IFC и отношений между ними в графовую структуру, используемую в качестве входных данных для графовых нейронных сетей.




Рис. 2. Визуализация графов зданий 160, 109, 246.

Табл. 1. Количественные характеристики BIM-моделей.

Проект	Двери	Окна	Помещения	Этажи	Типы помещений	Связи
246	1715	1198	2628	31	14	54290
302	1148	970	1885	24	11	24244
109	1012	1442	2058	24	12	39105
160	1104	900	1766	24	11	29172
1081	1086	860	1787	24	8	22044
1082	505	419	912	16	10	11205
1083	717	673	1275	17	9	17168




Рис. 3. Структура BIM-графа: соответствие узлов элементам здания и признаковое пространство.




Рис. 4. Графовое представление BIM-элементов и их взаимосвязей.

2.2. Постановка задачи прогнозирования класса огнестойкости

Предел огнестойкости элемента определяется требованиями строительных правил² и задается в виде класса EI (EI-30, EI-60 и др.).

Рассмотрим две задачи:

- 1) определение необходимости противопожарной защиты (огнестойкость требуется/не требуется);
- 2) прогнозирование конкретного класса огнестойкости для дверей, требующих противопожарной защиты. По нормативам предусмотрено четыре класса, что соответствует многоклассовой постановке задачи. Однако в связи с ограничениями данных и использованием только надземной части зданий в анализируемых моделях представлены только два класса (EI-30, EI-60). Соответственно, на текущем этапе эта задача решается как бинарная классификация, но с перспективой расширения до четырехклассовой при включении полных данных зданий.

Обе задачи решаем с использованием графовых нейронных сетей⁹, которые позволяют учитывать топологический контекст здания: положение двери относительно помещений, стен, лестничных клеток и путей эвакуации.

3. МЕТОДОЛОГИЯ ИССЛЕДОВАНИЯ

3.1. Пайплайн извлечения и обработки данных

Для решения задачи прогнозирования класса огнестойкости был разработан полный пайплайн обработки BIM-данных, включающий следующие этапы:

- 1) извлечение из заданных геометрических характеристик элементов (центроиды, габариты, ориентации) их семантических атрибутов (IFC-тип, имя, пользовательские параметры), а также отношений между элементами (например, заполнение проемов, связь помещений со стенами и т. д.);
- 2) построение графа, в котором узлы соответствуют строительным элементам (дверям, стенам, помещениям), а ребра описывают их пространственные и логические связи (IfcRelFillsElement, IfcRelVoidsElement, IfcRelSpaceBoundary и др.). Такое представление позволяет явно моделировать контекст двери: связи с соседними помещениями, лестничными клетками и пу-

тями эвакуации. Примеры подграфов топологического контекста дверей, сформированных в пределах двух переходов от целевого узла, представлены на рис. 5. Граф формируется в формате PyTorch Geometric¹⁰;

3) формирование признаков векторов для узлов разных типов (IfcDoor, IfcWall, IfcOpeningElement, IfcSpace и др.): геометрические признаки (габариты, площади, объемы), семантические характеристики (тип и назначение помещения, атрибут FireRating), текстовые эмбединги названий помещений (кухня, спальня, коридор и т. п.), топологические параметры (соседство, положение в структуре здания, количество связанных помещений), а также параметры из IFC Property Sets¹¹;

4) формирование целевых меток: для первой задачи используется бинарная метка (требуется/не требуется огнестойкость двери), для второй – класс EI-30 или EI-60 на основе параметра огнестойкости (FireRating).



Рис. 5. Подграфы топологического контекста дверей (2-hop окрестность).

3.2. Архитектура модели R-GCN

На начальном этапе были протестированы архитектуры GraphSAGE¹², GCN¹³ и R-GCN⁹. По результатам предварительных экспериментов для дальнейшей работы были выбраны реляционные графовые сверточные сети

¹⁰ PyTorch Geometric: библиотека для графового машинного обучения // URL: <https://pytorch-geometric.readthedocs.io/en/latest>

¹¹ IFC Property Sets: спецификация IFC4.2. buildingSMART // URL: https://standards.buildingsmart.org/IFC/DEV/IFC4_2/FINAL/HTML/schema/ifckernel/lexical/ifcpropertyset.htm

¹² GraphSAGE: документация PyTorch Geometric // URL: https://pytorch-geometric.readthedocs.io/en/latest/generated/torch_geometric.nn.models.GraphSAGE.html

¹³ Graph Convolutional Networks: документация PyTorch Geometric // URL: https://pytorch-geometric.readthedocs.io/en/latest/generated/torch_geometric.nn.models.GCN.html

(R-GCN)⁹, поскольку они явно моделируют множественные типы отношений $r \in R$ между узлами, что критично для BIM-графов, содержащих несколько семантически различных связей (IfcRelFillsElement, IfcRelVoidsElement, IfcRelSpaceBoundary).

Архитектура модели включает входной слой, 2–3 слоя RGCNConv⁹ для агрегирования информации с учетом типов отношений, слой Dropout¹⁴ с вероятностью 0.3 и выходной полносвязный классификационный слой. Размер скрытого представления подбирается из множества {64, 128} в зависимости от конфигурации эксперимента. В обозначениях конфигураций H64_L2_W_LR0.005 символ H соответствует размерности скрытого слоя, L – числу слоев, W – использованию взвешивания классов, а LR – скорости обучения. Обучение выполнялось с использованием оптимизатора AdamW¹⁵, функции потерь CrossEntropyLoss¹⁶ (при необходимости с весами классов для учета дисбаланса) и механизма ранней остановки по валидационной выборке.

3.3. Стратегия кросс-валидации по принципу LOBO

Для оценки обобщающей способности использована кросс-валидация по зданиям LOBO: на каждом шаге одно из семи зданий полностью исключается из обучения и используется как тестовое, а оставшиеся здания – как обучающая выборка. Такая схема позволяет оценить переносимость модели на ранее не встречавшийся объект и сравнить вариативность качества между зданиями по фолдам. Для каждого LOBO-фолда выполняется серия экспериментов с четырьмя конфигурациями гиперпараметров, варьирующими размерность скрытого слоя (64/128), число слоев (2/3), использование весов классов и скорость обучения.

4. РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТОВ

4.1. Классификация наличия огнестойкости

В рамках бинарной классификации было выполнено 28 экспериментов (7

¹⁴ Dropout: документация PyTorch // URL: <https://docs.pytorch.org/docs/stable/generated/torch.nn.Dropout.html>

¹⁵ AdamW Optimizer: документация PyTorch // URL: <https://docs.pytorch.org/docs/stable/generated/torch.optim.AdamW.html>

¹⁶ CrossEntropyLoss: документация PyTorch // URL: <https://docs.pytorch.org/docs/stable/generated/torch.nn.CrossEntropyLoss.html>

зданий × 4 конфигурации моделей). Наилучшие результаты получены для зданий 109, 160, 246 и 302, где показатель F1-score составил 0.91–0.996 при точности 0.93–0.995. В табл. 2 представлены три лучших и три худших эксперимента, упорядоченных по F1-метрике. Конфигурация H64_L2_W_LR0.005 (64 нейрона скрытого слоя, 2 слоя, взвешенная функция потерь, скорость обучения 0.005) достигла максимального значения F1 = 0.996 для здания 109. Конфигурации с пониженной скоростью обучения (LR = 0.005) и взвешиванием классов демонстрируют стабильно высокие результаты для большинства зданий.

Табл. 2. Результаты классификации наличия огнестойкости по F1-метрике.

Номер графа	Гиперпараметры модели	Размер скрытого слоя (H)	Число слоев (L)	Взвешивание классов (W.)	Скорость обучения (LR)	F1-мера	Точность (Accuracy)	Точность положительного класса (Precision)	Полнота (Recall)	Эпохи обучения
109	H64_L2_W_LR0.005	64	2	Yes	0.005	0.996	0.995	0.995	0.996	1096
109	H64_L2_NoW_LR0.05	64	2	No	0.05	0.974	0.972	1.000	0.950	1025
160	H64_L2_NoW_LR0.05	64	2	No	0.05	0.969	0.976	0.940	1.000	1084
1082	H64_L2_NoW_LR0.05	64	2	No	0.05	0.400	0.620	0.587	0.303	791
1083	H128_L3_W_LR0.005	128	3	Yes	0.005	0.322	0.689	1.000	0.192	690
1083	H64_L2_NoW_LR0.05	64	2	No	0.05	0.250	0.573	0.386	0.185	1080

Для конфигурации H64_L2_W_LR0.005 значения F1-score для всех зданий не опускались ниже 0.746, что указывает на ее устойчивость к вариативности структуры BIM-графов. Средний F1-score по всем зданиям составил 0.835 ± 0.168 ,

при этом для части объектов (1081–1083) наблюдалось значительное снижение метрик качества на некоторых конфигурациях.

4.2. Классификация типа огнестойкости

Для задачи классификации классов огнестойкости EI-30/EI-60 также было проведено 28 экспериментов (7 зданий × 4 конфигурации). Дисбаланс классов (EI-30 составил 70–72% примеров, EI-60 – 28–30%) не помешал моделям достичь высоких результатов на тестовых зданиях: для объектов 160, 1082 и 1083 в рамках схемы LOBO получено значение $F1 = 1.00$, т. е. все двери корректно отнесены к своим классам огнестойкости. Табл. 3 содержит информацию о трех лучших и трех худших экспериментов, упорядоченных по $F1$ -метрике.

Табл. 3. Результаты классификации типа огнестойкости по $F1$ -метрике.

Номер графа	Гиперпараметры модели	Размер скрытого слоя (H)	Число слоев (L)	Взвешивание классов (W.)	Скорость обучения (LR)	F1-мера	Точность (Accuracy)	Точность положительного класса (Precision)	Полнота (Recall)	Эпохи обучения
1082	H64_L2_NoW_LR 0.005	64	2	No	0.005	1.000	1.000	1.000	1.000	711
1083	H64_L2_NoW_LR 0.005	64	2	No	0.005	1.000	1.000	1.000	1.000	676
160	H64_L3_W_LR0.005	64	3	Yes	0.005	1.000	1.000	1.000	1.000	449
246	H64_L2_NoW_LR 0.005	64	2	No	0.005	0.848	0.858	0.884	0.858	388
1081	H64_L2_W_LR0.005	64	2	Yes	0.005	0.812	0.849	0.873	0.849	621
1081	H64_L3_W_LR0.005	64	3	Yes	0.005	0.802	0.781	0.894	0.781	430

Среднее значение F1-score по всем экспериментам составляет 0.949 ± 0.058 , что заметно выше, чем в задаче бинарной классификации наличия требований к огнестойкости (0.835 ± 0.168). Наилучшие результаты обеспечили конфигурации H64_L2_W_LR0.005 и H64_L2_NoW_LR0.005 (64 скрытых нейрона, 2 слоя, скорость обучения 0.005); при этом использование весов классов во второй задаче почти не повлияло на качество и было критичным только для отдельных сложных зданий.

Высокое качество прогнозирования в обоих экспериментах достигается за счет эффективного использования топологического контекста здания: в R-GCN-модели агрегирована информация о типах помещений, связях с лестничными клетками и эвакуационными путями, что позволяет корректно определять наличие и класс огнестойкости даже при неполных исходных данных. Вторая задача оказалась проще первой, что указывает на наличие более четких структурных паттернов для конкретных классов EI-30/EI-60 по сравнению с бинарным определением самого факта необходимости огнестойкости.

Полученные результаты подтверждают, что оптимальная архитектура зависит от топологических характеристик графа и распределения классов для конкретного здания. Вариативность F1 между зданиями (от 0.25 до 1.00 в первой задаче и от 0.802 до 1.00 во второй) связана с различиями в структурной сложности, плотности графа и полноте IFC-данных¹⁷. При этом для большинства объектов (для 6 из 7 зданий) конфигурации, основанные на R-GCN⁹ с двумя слоями и малой скоростью обучения ($LR = 0.005$), обеспечивают $F1 > 0.85$ для задачи EI-30/EI-60 и $F1 > 0.75$ для бинарной классификации, что подтверждает практическую применимость подхода в реальных BIM-проектах.

4.3. Анализ влияния гиперпараметров

Анализ 56 запусков (7 LOBO-фолдов $\times$ 4 конфигурации) показал, что чувствительность качества к гиперпараметрам зависит от постановки задачи и различий между тестовыми зданиями. Взвешивание классов заметно влияет в задаче прогнозирования наличия требований к огнестойкости: для зданий со сложной структурой и менее полной IFC-разметкой (1081–1083) улучшение F1

¹⁷ Industry Foundation Classes (IFC): стандарт buildingSMART. – buildingSMART // URL: <https://www.buildingsmart.org/standards/bsi-standards/industry-foundation-classes/>

достигает 0.10–0.15, тогда как для типовых жилых секций (109, 160, 246, 302) оно может немного ухудшать результаты; в задаче классификации EI-30/EI-60 средний показатель F1 изменялся с 0.947 до 0.949, т. е. эффект минимален. Увеличение размерности скрытого слоя с 64 до 128 нейронов обычно снижает межфолдовую вариативность метрик (std, стандартное отклонение примерно на 0.032 для конфигурации H128_L2_W_LR0.005) и дает прирост 0.03–0.08 для структурно отличающихся зданий, тогда как для типовых секций достаточно 64 нейронов.

Увеличение глубины до трех слоев чаще сопровождается снижением F1 из-за эффекта чрезмерного сглаживания: например, для здания 1083 качество в первой задаче упало с 0.857 (2 слоя) до 0.322 (3 слоя). Наиболее устойчивые результаты в обеих задачах обеспечил learning rate 0.005; значение 0.05 может ускорять сходимость при отсутствии взвешивания классов, но дает менее стабильные метрики. В качестве практических конфигураций для переноса на новые здания рекомендуется использовать H128_L2_W_LR0.005 (более стабильный вариант для объектов, не известных по структуре) и H64_L2_NoW_LR0.005 как более компактную конфигурацию с хорошим соотношением скорости обучения и качества.

5. ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Полученные результаты показали, что использование R-GCN⁹ позволяет надежно извлекать нормативно значимую информацию из BIM-графов даже при неполной и неоднородной IFC-разметке¹¹. Модели опираются не только на локальные атрибуты дверей, но и на их положение в структуре здания, связи с помещениями, лестничными клетками и путями эвакуации, что особенно важно для задач пожарной безопасности.

Кросс-валидация по схеме LOBO показала, что разработанный подход сохраняет качество при переносе на здания, ранее не включенные в обучение. При этом заметная вариативность метрик между отдельными объектами указывает на чувствительность к топологии графа и полноте исходных данных, что требует аккуратного подбора гиперпараметров под конкретный проект. Анализ конфигураций подтвердил, что увеличенная размерность скрытого слоя и взвешивание классов повышают устойчивость к доменному сдвигу, тогда как чрезмерное углубление сети приводит к эффекту сглаживания и ухудшению качества.

В совокупности полученные результаты демонстрируют, что графовые нейронные сети могут служить надежным ядром каскадной системы поддержки проектных решений в BIM-среде, дополняя подходы, основанные на правилах, с учетом неявных пространственно-топологических закономерностей.

ЗАКЛЮЧЕНИЕ

Предложена и экспериментально проверена методология автоматизированной проверки параметров огнестойкости дверей в BIM-моделях [1] с использованием реляционных графовых сверточных сетей. Разработан полный пайплайн: от извлечения данных из IFC¹¹ и построения BIM-графа до обучения моделей и оценки по схеме LOBO на реальных проектах ПИК Групп. Показано, что учет топологического контекста здания позволяет надежно предсказывать как факт необходимости противопожарной защиты, так и конкретный класс EI-30/EI-60, что делает подход пригодным для включения в практические процессы контроля качества проектной документации.

Основными ограничениями текущей работы являются анализ жилых зданий одного девелопера, зависимость от качества IFC-разметки¹¹ и сокращенный набор классов огнестойкости. Эти факторы задают направления дальнейших исследований: расширение набора рассматриваемых параметров дверей и других элементов модели, адаптация методологии к новым типологиям зданий и нормативным базам, а также интеграция GNN-моделей⁴ с формализованными правилами в графовой базе данных для обеспечения трассируемости решений до конкретных пунктов норм. Развитие предложенного подхода в составе каскадной архитектуры модулей машинного обучения и компонентов, основанных на правилах, создает основу для масштабируемой, объяснимой и практически ориентированной системы автоматизированного нормативного контроля BIM-моделей [1].

СПИСОК ЛИТЕРАТУРЫ

1. Building Information Modeling (BIM) // URL: <https://www.autodesk.com/solutions/aec/bim> (дата обращения: 14.12.2025).
2. Bhartiya V. Automatic BIM Standards Checking in BIM360: материалы Autodesk University // URL: <https://static.au-uw2->

- prd.autodesk.com/Class_Handout_AS468731_Varun_Bhartiya.pdf (дата обращения: 14.12.2025).
3. *Fuchs S. et al.* The challenge of automated compliance checking: a regulatory view // CIB W78 Conference on IT in Construction. Porto, Portugal, July 14–17, 2025. <https://doi.org/10.35490/EC3.2025.264>
 4. *Kayhani N. et al.* BIM-based construction quality assessment using Graph Neural Networks // Proc. of the 40th International Symposium on Automation and Robotics in Construction (ISARC 2023). Chennai, India, 2023. P. 9–16. <https://doi.org/10.22260/ISARC2023/0004>
 5. *Koo B. et al.* Automatic classification of wall and door BIM element subtypes using 3D geometric deep neural networks // Advanced Engineering Informatics. 2021. Vol. 47. Art. 101200. <https://doi.org/10.1016/j.aei.2020.101200>
 6. *Wang Z.* Room Type Classification for Semantic Enrichment of Building Information Modeling Using Graph Neural Networks // Proc. of the CIB W78 Conference 2021. Luxembourg, 11–15 October 2021. P. 769–776. URL: <https://itc.scix.net/pdfs/w78-2021-paper-077.pdf> (дата обращения: 26.12.2025).
 7. *Wu J. et al.* The Beginning, Not the End: Revisiting Automated Compliance Checking for BIM-based Design Adaptation // URL: https://mediatum.ub.tum.de/doc/1781688/zxnigbgg5wkuz29v4k9jjk0hl.2025_Wu_RevisitACC.pdf (дата обращения: 26.12.2025).
 8. *Wang Z. et al.* CBIM: A Graph-based Approach to Enhance Interoperability Using Semantic Enrichment // arXiv:2304.11672v1. <https://doi.org/10.48550/arXiv.2304.11672>
 9. *Zhu J et al.* Cypher4BIM: Releasing the Power of Graph for Building Knowledge Discovery // arXiv:2405.16345. <https://doi.org/10.1016/j.autcon.2025.106034>

APPLICATION OF GRAPH NEURAL NETWORKS FOR AUTOMATIC VERIFICATION OF BIM MODELS

O. V. Poletkina¹ [0009-0003-2938-7640], O. M. Ataeva² [0000-0003-0367-5575]

^{1, 2}Moscow Institute of Physics and Technology, Dolgoprudny, Russia

¹poletkina.ov@phystech.edu, ²oataeva@frccsc.ru

Abstract

Automating the verification of building information models for compliance with fire safety regulations remains a pressing issue in the architectural and construction industry. Existing automated verification systems rely on rule-based approaches that ignore the building's topological context and are poorly adapted to new projects. This paper examines the development and experimental verification of methods for predicting door fire protection parameters in BIM models using graph neural networks and validating the approach using real-world design data from seven residential buildings provided by a major real estate developer. A methodology for predicting door fire resistance classes based on relational graph convolutional networks is proposed, along with a pipeline for extracting data from a specialized format, constructing a graph, and generating features that take into account geometric, semantic, and topological characteristics. Experiments were conducted to predict the presence and fire resistance class with cross-project validation using the "one building out of sample" principle. The developed approach enables automated verification of fire protection parameters and reduces the time required to analyze building models. The use of graph neural networks ensures that topological context is taken into account and high prediction accuracy is achieved, while the use of real data from a major real estate developer confirms the practical applicability of the method.

Keywords: *Building Information Modeling, graph neural networks, Relational Graph Convolutional Network, door fire resistance, Industry Foundation Classes, automated compliance checking, graph machine learning, cross-project validation.*

REFERENCES

1. Autodesk. Building Information Modeling (BIM). URL: <https://www.autodesk.com/solutions/aec/bim> (accessed: 14.12.2025).

2. Bhartiya V. Automatic BIM Standards Checking in BIM 360 // Autodesk University. URL: https://static.au-uw2-prd.autodesk.com/Class_Handout_AS468731_Varun_Bhartiya.pdf (accessed: 14.12.2025).
3. Fuchs S. et al. The Challenge of Automated Compliance Checking: A Regulatory View // Proceedings of the CIB W78 Conference on IT in Construction. Porto, Portugal, July 14–17, 2025. DOI: <https://doi.org/10.35490/EC3.2025.264>.
4. Kayhani N. et al. BIM-Based Construction Quality Assessment Using Graph Neural Networks // Proceedings of the 40th International Symposium on Automation and Robotics in Construction (ISARC 2023). Chennai, India, 2023. P. 9–16. DOI: <https://doi.org/10.22260/ISARC2023/0004>.
5. Koo B. et al. Automatic Classification of Wall and Door BIM Element Subtypes Using 3D Geometric Deep Neural Networks // Advanced Engineering Informatics. 2021. Vol. 47. Art. 101200. DOI: <https://doi.org/10.1016/j.aei.2020.101200>.
6. Wang Z. Room Type Classification for Semantic Enrichment of Building Information Modeling Using Graph Neural Networks // Proceedings of the CIB W78 Conference 2021. Luxembourg, October 11–15, 2021. P. 769–776. URL: <https://itc.scix.net/pdfs/w78-2021-paper-077.pdf> (accessed: 26.12.2025).
7. Wu J. et al. The Beginning, Not the End: Revisiting Automated Compliance Checking for BIM-Based Design Adaptation. URL: https://mediatum.ub.tum.de/doc/1781688/zxnigbgg5wkuz29v4k9jjk0hl.2025_Wu_RevisitACC.pdf (accessed: 26.12.2025).
8. Wang Z. et al. CBIM: A Graph-Based Approach to Enhance Interoperability Using Semantic Enrichment // arXiv. 2023. arXiv:2304.11672. DOI: <https://doi.org/10.48550/arXiv.2304.11672>.
9. Zhu J. et al. Cypher4BIM: Releasing the Power of Graph for Building Knowledge Discovery // Automation in Construction. 2025. Art. 106034. DOI: <https://doi.org/10.1016/j.autcon.2025.106034>.

СВЕДЕНИЯ ОБ АВТОРАХ



ПОЛЕТКИНА Ольга Владимировна – студентка магистратуры МФТИ, направление «Прикладная математика и информатика», профиль «Науки о данных». Область научных интересов: машинное обучение, архитектурное проектирование, цифровое моделирование архитектурных объектов

Olga Vladimirovna POLETKINA – master's student at MIPT (Moscow Institute of Physics and Technology), specializing in Applied Mathematics and Computer Science, with a focus on Data Science. Research interests include machine learning, architectural design, and digital modeling of architectural objects

email: poletkina.ov@phystech.edu

ORCID: 0009-0003-2938-7640



АТАЕВА Ольга Муратовна – старший научный сотрудник Вычислительного центра им. А.А. Дородницына ФИЦ ИУ РАН, к.т.н. Область научных интересов: системное программирование, базы данных, инженерия знаний и онтологии.

Olga Muratovna ATAIEVA – senior researcher at the Dorodnyn Computing Center, Federal Research Center “Computer Science and Control” of the Russian Academy of Sciences; Candidate of Technical Sciences (PhD). Research interests: systems programming, databases, knowledge engineering, ontologies. Number of scientific publications –80.

email: oataeva@frccsc.ru, iroli@yandex.ru

ORCID: 0000-0003-0367-5575

Материал поступил в редакцию 4 апреля 2026 года