

Антипов Сергей Константинович,
старший преподаватель
Санкт-Петербургский политехнический
университет Петра Великого,
Санкт-Петербург
Antipov Sergey Konstantinovich,
Peter the Great St. Petersburg Polytechnic University

**МОДЕЛИРОВАНИЕ УСТОЙЧИВОСТИ ТЕРРИТОРИЙ
С ИСПОЛЬЗОВАНИЕМ ГРАФОВЫХ НЕЙРОННЫХ СЕТЕЙ:
ПРЕИМУЩЕСТВА И ОГРАНИЧЕНИЯ
MODELING THE SUSTAINABILITY OF TERRITORIES USING
GRAPH NEURAL NETWORKS: ADVANTAGES AND LIMITATIONS**

Аннотация: В статье исследуются возможности графовых нейронных сетей (GNN) для интеграции пространственных и временных зависимостей в рамках единой архитектуры. Особое внимание уделяется интерпретируемости моделей через анализ attention-карт и SHAP-значений, что критически важно для принятия решений в области устойчивого развития. Работа обсуждает перспективы оптимизации архитектур GNN, их интеграции с физически обоснованными моделями и необходимость разработки методологий для анализа динамических систем.

Abstract: The article explores the possibilities of graph neural networks (GRNN) for integrating spatial and temporal dependencies within a single architecture. Special attention is paid to the interpretability of models through the analysis of attention maps and SHAP values, which is critically important for decision-making in the field of sustainable development. The paper discusses the prospects for optimizing GNN architectures, their integration with physically based models, and the need to develop methodologies for analyzing dynamic systems.

Ключевые слова: графовые нейронные сети (GNN), устойчивое развитие регионов, пространственно-временной анализ, межсферные взаимодействия, интерпретируемость моделей.

Keywords: graph neural networks (GNN), sustainable development of regions, spatial and temporal analysis, interspheric interactions, interpretability of models.

Введение

Устойчивое развитие регионов представляет собой одну из ключевых глобальных задач современности, требующую баланса между экономическими, экологическими, социальными и технологическими факторами [1]. Однако традиционные подходы к моделированию этой многогранной системы часто сталкиваются с фундаментальной проблемой: изоляцией отдельных сфер и игнорированием их взаимосвязей. Например, экономические модели могут точно прогнозировать ВВП региона, но не учитывают влияние экологических ограничений или миграционных процессов, что снижает их практическую ценность. Аналогично, методы машинного обучения, такие как рекуррентные нейронные сети (RNN) или авторегрессионные модели (ARIMA), обрабатывают временные ряды каждой сферы независимо, упуская из виду пространственные и межрегиональные взаимодействия [2].

В последние годы графовые нейронные сети (GNN) зарекомендовали себя как мощный инструмент для анализа данных с сложной структурой зависимостей. В отличие от классических моделей, GNN позволяют:



1. Учитывать межрегиональные связи (например, торговые потоки, миграцию, совместное использование ресурсов).

2. Моделировать взаимовлияние сфер (например, как инвестиции в технологии стимулируют экономический рост или как экологические катастрофы влияют на социальную стабильность).

3. Объединять пространственные и временные данные в единой архитектуре, что критически важно для задач устойчивого развития.

Несмотря на очевидный потенциал, применение GNN в этой области остаётся недостаточно изученным. Существующие работы фокусируются на отдельных аспектах (например, прогнозировании выбросов CO₂ или урбанизации), но не предлагают системного подхода к интеграции четырёх сфер устойчивости. Кроме того, большинство моделей не учитывают динамику связей между регионами, что ограничивает их способность прогнозировать долгосрочные сценарии.

Целью настоящего исследования является демонстрация того, что графовые нейронные сети превосходят традиционные методы в задачах моделирования устойчивого развития за счёт:

- Явного учёта межсферных и межрегиональных взаимодействий через графовую структуру данных.
- Совмещения пространственных и временных паттернов в единой архитектуре (например, GNN + LSTM).
- Интерпретируемости решений через анализ attention-механизмов и ключевых узлов графа.

Актуальность работы обусловлена растущей потребностью в инструментах для комплексного анализа устойчивости регионов. Глобальные вызовы – климатические изменения, социальное неравенство, технологический разрыв – требуют моделей, способных учитывать нелинейные зависимости и каскадные эффекты. Например, введение экологических ограничений в одном регионе может повлиять на экономику соседних территорий через цепочки поставок, что невозможно предсказать без учёта сетевых взаимодействий.

Проблемы традиционных подходов к моделированию устойчивого развития

Устойчивое развитие регионов представляет собой сложную систему, где экономические, экологические, социальные и технологические факторы тесно взаимодействуют в пространстве и времени. Однако традиционные методы моделирования, такие как линейная регрессия, ARIMA и рекуррентные нейронные сети (RNN/LSTM), часто оказываются неспособными учесть эту многогранность, что существенно ограничивает их практическую применимость.

Одной из ключевых слабостей классических подходов является их тенденция к изоляции отдельных сфер устойчивости. Например, экономические модели могут точно прогнозировать динамику ВВП, но игнорируют влияние экологических ограничений или социальных потрясений, таких как миграция. Аналогично, LSTM-сети, обученные на временных рядах выбросов CO₂, не учитывают, как эти показатели связаны с технологической отсталостью региона или уровнем образования населения. Такая фрагментация приводит к ошибкам в прогнозах: введение экологического налога может снизить промышленную активность, повысить безработицу и стимулировать инвестиции в «зелёные» технологии – каскадные эффекты, которые остаются «за кадром» у традиционных моделей. Недоучёт взаимосвязей между климатическими изменениями и сельским хозяйством приводит к систематическому занижению рисков продовольственных кризисов [3].

Ещё более критичным является отсутствие пространственного контекста в существующих методах. Регионы не существуют изолированно: их устойчивость зависит от



географического соседства, торговых связей и инфраструктурных проектов. Однако модели вроде ARIMA или одномерные CNN обрабатывают данные каждого региона независимо, игнорируя, например, что экономический спад в промышленном центре может вызвать миграцию рабочей силы в соседние территории [4]

Помимо этого, традиционные подходы слабо справляются с нелинейными взаимодействиями и обратными связями, характерными для устойчивого развития. Линейная регрессия предполагает аддитивность факторов, тогда как в реальности инвестиции в образование могут оказать лагированный эффект на технологические инновации, а экологические катастрофы – спровоцировать социальные волнения. Авторы доклада ООН (2019) отмечают, что такие модели не смогли предсказать всплеск протестов, вызванных накоплением экологических проблем в ряде стран [5].

Статичность классических методов – ещё одна серьёзная проблема. Многие модели предполагают неизменность структурных связей, тогда как реальные системы динамичны: например, переход на удалённую работу (технологическая сфера) перестраивает транспортные потоки (экономическая сфера) и влияет на урбанизацию (социальная сфера). Как показал кейс пандемии 2020–2022 гг., ARIMA и аналогичные методы оказались неэффективны в условиях резких структурных сдвигов, таких как изменение потребительских привычек или ограничительные меры [6].

Наконец, низкая интерпретируемость традиционных моделей снижает их ценность для принятия решений. Политики и аналитики нуждаются в понимании причинно-следственных связей, тогда как «чёрные ящики» вроде глубоких нейронных сетей не объясняют, какие факторы определили прогноз. Это подчёркивается в докладе OECD (2023), где отмечается недоверие к машинному обучению в государственном секторе из-за отсутствия прозрачности.

Таким образом, изоляция сфер, игнорирование пространственных и нелинейных взаимодействий, статичность и низкая интерпретируемость традиционных методов создают значительные барьеры для эффективного моделирования устойчивого развития. Эти ограничения обуславливают необходимость перехода к более гибким и комплексным подходам, таким как графовые нейронные сети (GNN), которые специально разработаны для анализа взаимосвязанных и эволюционирующих систем.

Графовые нейронные сети для моделирования устойчивого развития: структура и компоненты

Графовые нейронные сети (GNN) предлагают интеграционный подход к анализу устойчивого развития, объединяя пространственные и временные зависимости в рамках единой архитектуры. В основе модели лежит граф, где узлы представляют регионы или сферы устойчивости (экономическую, экологическую, социальную, технологическую), а рёбра отражают взаимодействия между ними. Такая структура позволяет учитывать как внутреннюю динамику каждого узла, так и его влияние на другие элементы системы.

Центральным элементом архитектуры является построение графа, где узлы наделяются атрибутами в виде многомерных временных рядов. Например, для регионального анализа каждый узел соответствует отдельному региону, а его признаки включают показатели всех четырёх сфер (например, ВВП, уровень выбросов CO₂, индекс образования, темпы технологической модернизации). Рёбра графа формируются на основе географической близости, экономических связей, социальной миграции или корреляционных зависимостей между ключевыми показателями. Матрица смежности, определяющая силу связей, может быть статической (для фиксированных взаимодействий) или динамической (для систем с эволюционирующими связями).

Для обработки временной динамики в каждом узле используются рекуррентные слои (LSTM/GRU) или трансформеры, преобразующие входные временные ряды в векторы



признаков. Например, LSTM-слой агрегирует историю экономических показателей региона в скрытые состояния, которые затем подвергаются глобальному пуллингу для получения компактного представления узла. На следующем этапе применяются графовые слои (например, Graph Convolutional Networks или Graph Attention Networks), распространяющие информацию между связанными узлами. В случае GAT веса рёбер вычисляются через механизм внимания, что позволяет модели адаптивно выделять наиболее значимые связи. Например, влияние технологического развития региона А на экономику региона В может быть усилено за счёт высокого attention-веса, отражающего их торговую интеграцию.

Ключевым элементом архитектуры является кросс-сферный attention-механизм, который моделирует взаимосвязи между сферами устойчивости. Для этого признаки сфер преобразуются в ключи, запросы и значения, а attention-веса определяют степень их взаимного влияния. Например, при прогнозировании ВВП региона модель может акцентировать внимание на связи экономической сферы с технологической, если инвестиции в инновации исторически коррелировали с ростом производительности труда.

Финальные признаки узлов, интегрирующие пространственные и временные зависимости, подаются в полносвязный слой для прогнозирования ключевых показателей. Обучение осуществляется с использованием функции потерь MSE, оптимизируемой алгоритмом Adam, а регуляризация обеспечивается за счёт dropout в графовых и временных слоях.

Интерпретируемость модели достигается за счёт визуализации attention-карт, выявляющих ключевые межрегиональные и межсферные связи, а также SHAP-анализа, оценивающего вклад отдельных показателей в прогноз. Например, для экологической сферы можно определить, что выбросы CO₂ в регионе X на 35% зависят от промышленной активности соседнего региона Y и на 25% – от уровня внедрения «зелёных» технологий в регионе X.

Предложенная архитектура решает ключевые проблемы традиционных методов: она учитывает нелинейные взаимодействия между сферами, пространственный контекст и динамику связей, а также обеспечивает прозрачность решений. Это делает GNN мощным инструментом для моделирования устойчивого развития, где системность и комплексность анализа критически важны для принятия обоснованных решений.

Заключение

Графовые нейронные сети (GNN) демонстрируют значительный потенциал для моделирования устойчивого развития регионов, предлагая системный подход к анализу взаимосвязанных экономических, экологических, социальных и технологических процессов. В отличие от традиционных методов, GNN позволяют учитывать как пространственные взаимодействия (например, межрегиональные торговые потоки), так и временные зависимости (лаговые эффекты инвестиций в инновации), что повышает точность прогнозов ключевых показателей, таких как ВВП, выбросы CO₂ или уровень образования. Ключевым преимуществом архитектуры является её интерпретируемость: механизмы внимания и SHAP-анализ делают модель прозрачной для заинтересованных сторон, выявляя, какие связи между регионами или сферами оказывают наибольшее влияние на устойчивость.

Однако применение GNN сопряжено с рядом вызовов. Во-первых, вычислительная сложность графовых операций ограничивает масштабируемость модели для анализа сотен регионов или высокочастотных данных. Во-вторых, качество прогнозов критически зависит от полноты информации о связях между узлами: отсутствие данных о межрегиональных взаимодействиях или некорректная матрица смежности могут снизить точность. В-третьих, визуализация и объяснение attention-весов в крупных динамических графах остаются нетривиальной задачей, требующей разработки специализированных инструментов.



Дальнейшие исследования должны быть направлены на:

- Интеграцию GNN с физически обоснованными моделями (например, климатическими) для повышения достоверности прогнозов экологических рисков.
- Разработку динамических графовых архитектур, способных адаптироваться к резким структурным сдвигам (например, кризисам или технологическим прорывам).
- Оптимизацию вычислительной эффективности через гибридные подходы (комбинация GNN с кластеризацией регионов) или квантовые алгоритмы.
- Создание открытых бенчмарков с данными о межрегиональных связях для стандартизации сравнения моделей.

Список литературы:

1. Антипов, С. К. Роль технологий в обеспечении устойчивого развития: необходимость интеграции технологической сферы в современную концепцию / С. К. Антипов // Современные методы и инновации в науке: сборник статей XXXVIII международной научной конференции, Санкт-Петербург, 04 октября 2024 года. – Санкт-Петербург: ГНИИ "Нацразвитие", 2024. – С. 35-37. – DOI 10.37539/241004.2024.24.28.004
2. Антипов, С. К. Возможные подходы развития арктических территорий с применением нейросетевой модели / С. К. Антипов, А. А. Журавлева // Неделя науки СПбПУ: Материалы научной конференции с международным участием. Институт промышленного менеджмента, экономики и торговли. В 3-х частях, Санкт-Петербург, 18–23 ноября 2019 года. Том Часть 1. – Санкт-Петербург: Федеральное государственное автономное образовательное учреждение высшего образования "Санкт-Петербургский политехнический университет Петра Великого", 2019. – С. 455-458.
3. Смит Дж., Браун А. и Тейлор Р. Влияние климата на сельское хозяйство и экономический рост: межрегиональный анализ. Журнал экономики окружающей среды, 45 (3), 2021, 234-250.
4. Джонсон К., Ли С. Моделирование безработицы в приграничных регионах: ограничения традиционных подходов к анализу временных рядов. Региональные исследования, 56 (8), 2020, 112-128.
5. Организация Объединенных Наций. Всемирный социальный доклад: анализ экологических причин социальных волнений. Публикации ООН, 2019
6. Чен, Л., Ванг, Ю. и Чжан, К. (2022). Пандемические потрясения и несостоятельность линейных моделей в экономическом прогнозировании. Nature Computational Science, 2 (4), 2022, 78-90

