

# Построение признаковых пространств в задаче прогнозирования химических реакций

Никитин Филипп

Московский физико-технический институт  
Физтех-школа прикладной математики и информатики  
Кафедра интеллектуальных систем

Научный руководитель д.ф.-м.н. В. В. Стрижов  
Научный консультант PhD О. Исаев  
Москва,  
2020 г.



## Требуется

Построить модель предсказания молекулярного графа основного продукта химической реакции по графам исходных веществ.

На модель накладываются ограничения:

- применима к данным в виде несвязанного молекулярного графа;
- допускает использования экспертных знаний о локальной структуре молекулярного графа;

## Проблема

Пространство молекулярных структур высоко-размерное. Количество механизмов реакций растет с ростом числа известных структур.


## Метод

Графовая нейронная сеть, допускающая использование экспертных знаний о структуре молекулярного графа.

- 1 Butler K. T., Davies D. W., Cartwright H., Isayev O., Walsh A. *Machine learning for molecular and materials science*. Nature 2018, pp 547-559.
- 2 Schwaller P., Gaudin T., Lanyi D., Bekas C., Laino T. *"Found in Translation": predicting outcomes of complex organic chemistry reactions using neural sequence-to-sequence models* Chemical science 2018, 9, pp 6091–6098.
- 3 Jaworski W., Szymkuc S. *Automatic mapping of atoms across both simple and complex chemical reactions*. Nature communications 2019, 10, pp 1–11.
- 4 Corey E., Wipke W. T. *Computer-assisted design of complex organic syntheses*. Science 1969, 166, pp 178–192.

- 1 Schlichtkrull M., Kipf T. N., Welling M. *Modeling relational data with graph convolutional networks*. European Semantic Web Conference. 2018; pp 593–607.
- 2 Vaswani A., Shazeer N., Parmar N. *Attention is all you need*. Advances in neural information processing systems. 2017; pp 5998–6008.
- 3 Li J., Cai D., He X. *Learning graph-level representation for drug discovery*. arXiv preprint arXiv:1709.037412017.

# Структура решения



# Молекулярный граф

## Атом

Атом — элемент конечного множества  $a \in \mathcal{A} = \{a_1, a_2, \dots, a_n\}$ , (C, N, S, Br).

## Химическая связь

Химическая связь — элемент конечного множества  $b \in \mathcal{B} = \{b_1, b_2, \dots, b_k\}$ , (одинарная, двойная, водородная).

## Молекула

Молекула — это планарный, неориентированный граф  $M = (\mathbf{a}, \mathbf{h}, \mathbf{B})$ , где:

- $\mathbf{a} = [a_{k_1}, \dots, a_{k_l}]$  — упорядоченное множество атомов,
- $\mathbf{h} = [h_1, \dots, h_l]$ , где  $h_i \in \mathbb{H}$ , пространство описаний атомов,
- $\mathbf{B}$  — матрица смежности  $l \times l$ ,  $b_{i,j} \in \mathcal{B}$  — тип связи между  $a_{k_i}$  и  $a_{k_j}$ .

# Химическая реакция — отображение исходных веществ в продукты

## Химическая реакция

Дано:

- исходные вещества — множество  $S = \{M_1, \dots, M_m\}$ ,
- продукты — множество  $T = \{M_1, \dots, M_k\}$ .

Химическая реакция — отображение  $f : S \rightarrow T$ , где  $f \in \mathcal{F}$ .

## Задача выбора модели

Задано семейство параметрических функций  $\mathcal{F}$  (в работе графовые CNN)

$$f = \arg \min_{f \in \mathcal{F}} L(T, f(S)),$$

где  $L$  целевая функция потерь.

## База реакций

База реакций из американских патентов США, Lowe, 2012:

- 1 млн. реакций в формате SMARTS,
- 1976-2016 год регистрации патента,
- Разделены катализаторы и реагенты,
- Для заданных реагентов, катализаторов известен основной продукт.

**SMILES** — язык, который позволяет однозначно закодировать молекулярный граф строкой символов ASCII, SMARTS — надстройка SMILES, позволяющая специфицировать меж-структурные взаимосвязи в молекулах.

Пример: c1cccc[c:1]1[NH2:2]>>c1cccc[c:1]1[N:2](=O)=O

**Основной продукт** — молекула, включающая в себя наибольшее количество атомов среди продуктов реакции.

**RDKit** — библиотека для работы с молекулярными графами.


# Классификация вершин в графе

## Определение атомов основного продукта

Для множества атомов исходных веществ требуется определить вероятность принадлежности к множеству атомов основного продукта.

## Определение центров реакции

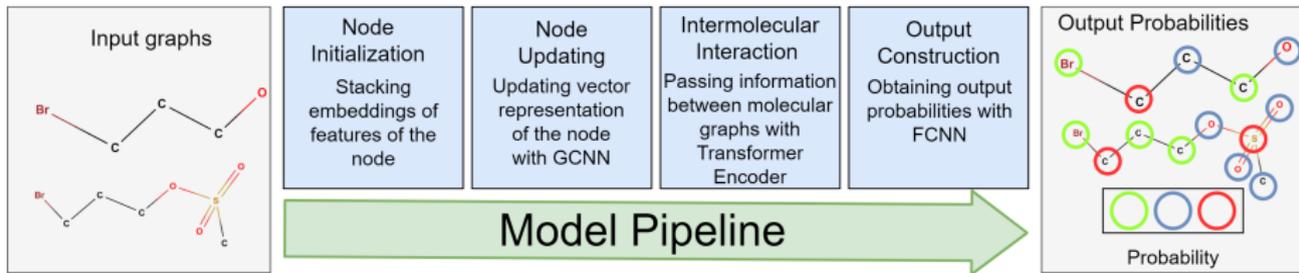
Для множества атомов основного продукта требуется выделить те, конфигурация которых изменилась в течение реакции.



Химическая реакция отображает реагенты в продукты. Выделены атомы основного продукта и центры реакции.

# Модель классификации вершин в несвязанном графе

- Эмбединг признаков вершин молекулярного графа.
- Обновление состояний вершин графовой сверточной сетью.
- Преобразование состояний вершин кодировщиком архитектуры Transformer.
- Получение вероятностей меток атомов полносвязанной нейронной сетью.



## Формула обновления состояний вершин

$$\mathbf{h}_i^{(l+1)} = \sigma \left( \mathbf{W}^{(l)} \mathbf{h}_i^{(l)} + \sum_{r \in R} \sum_{j \in N_i} \frac{1}{c_{i,r}} \mathbf{W}_r^{(l)} \mathbf{h}_j^{(l)} \right),$$

$R$  — множество типов ребер графа, типов химической связи,

$\mathbf{W}, \mathbf{W}_r$  — параметры преобразования,

$\mathbf{h}_i^{(l)}$  — векторное представление вершины графа, атома  $a_i$  в слое  $l$ ,

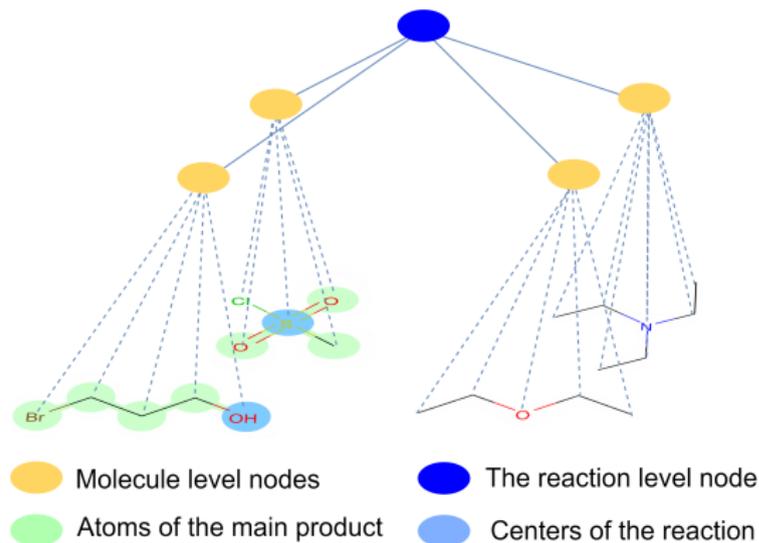
$c_{i,r}$  — нормировочный множитель, обычно кратность вершины графа,

$\sigma$  — нелинейная функция

## Проблема

$\mathbf{h}_i^{(l+1)}$  зависит только от векторных представлений вершин  $\mathbf{h}_j^{(l)}$  той же компоненты связности, что и  $a_i$ . Химическая реакция обусловлена межмолекулярным взаимодействием.

# Расширенный граф химической реакции



Расширенный граф химической реакции: введены вершины, соответствующие векторным описаниям молекул и всей химической реакции.

## Обновление векторных состояний вершин

$$\mathbf{h}_i^{(l+1)} = \text{ReLU} \left( \mathbf{W}^{(l)} \mathbf{h}_i^{(l)} + \mathbf{W}_{ml}^{(l)} \mathbf{h}_{m_k}^{(l)} + \sum_{r \in R} \sum_{j \in N_i} \frac{1}{c_{i,r}} \mathbf{W}_r^{(l)} \mathbf{h}_j^{(l)} \right),$$

$$\mathbf{h}_{m_k}^{(l+1)} = \text{ReLU} \left( \mathbf{W}^{(l)} \mathbf{h}_{m_k}^{(l)} + \mathbf{W}_{rl}^{(l)} \mathbf{h}_r^{(l)} + \sum_{j \in m_k} \frac{1}{|m_k|} \mathbf{W}_{ml}^{(l)} \mathbf{h}_j^{(l)} \right),$$

$$\mathbf{h}_r^{(l+1)} = \text{ReLU} \left( \mathbf{W}^{(l)} \mathbf{h}_r^{(l)} + \sum_{m_j \in M} \frac{1}{|M|} \mathbf{W}_{rl}^{(l)} \mathbf{h}_{m_j}^{(l)} \right).$$

$\mathbf{h}_i^{(l+1)}$  — векторное представление атома

$\mathbf{h}_{m_k}^{(l+1)}$  — векторное представление молекулы

$\mathbf{h}_r^{(l+1)}$  — векторное представление реакции

## Self-Attention

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax} \left( \frac{\mathbf{KQ}^T}{\sqrt{d_{\text{model}}}} \right) \mathbf{V}.$$

## Transformer

$$\begin{aligned} \mathbf{H}_{\text{mha}}^{(l)} &= \text{concat}[\text{head}_1, \text{head}_2, \dots, \text{head}_h] \mathbf{W}^O, \\ \text{head}_i &= \text{Attention} \left( \mathbf{H}^{(l)} \mathbf{W}_i^Q, \mathbf{H}^{(l)} \mathbf{W}_i^K, \mathbf{H}^{(l)} \mathbf{W}_i^V \right). \end{aligned}$$

Векторные состояния в матрице  $\mathbf{H}_{\text{mha}}^{(l)}$  есть выпуклые комбинации векторных состояний из матрицы  $\mathbf{H}^{(l)}$  с оптимизируемыми коэффициентами.

Эволюционное семейство моделей:

- 1 Базовая модель (BASE) не учитывает типы ребер, признаки атомов; не использует механизмы работы с несвязанными графами.
- 2 Модель расширенного молекулярного графа (EG). По сравнению с базовой моделью, использует расширенный молекулярный граф.
- 3 Модель Трансформер (T). По сравнению с базовой моделью, после сверточных слоев используется преобразование self-attention.
- 4 Модель EGT Использует обе предложенных модификации.
- 5 Модель EGTB использует разные типы ребер в соответствии с типом химической связи.
- 6 Модель EGTBF использует признаки атомов (валентность, заряд и тд).
- 7 Модель MT\_EGTBF использует многозадачное обучение для двух рассматриваемых задач.

# Сводная таблица результатов

	Product mapping		Center detection	
	$FM$	$F_1$	$FM$	$F_1$
BASE	$0.21 \pm 0.01$	$0.92 \pm 0.002$	$0.15 \pm 0.01$	$0.502 \pm 0.002$
EG	$0.45 \pm 0.01$	$0.943 \pm 0.002$	$0.40 \pm 0.01$	$0.714 \pm 0.002$
T	$0.36 \pm 0.01$	$0.938 \pm 0.002$	$0.29 \pm 0.01$	$0.643 \pm 0.002$
EGT	$0.47 \pm 0.01$	$0.946 \pm 0.002$	$0.43 \pm 0.01$	$0.731 \pm 0.002$
EGTB	$0.53 \pm 0.01$	$0.950 \pm 0.002$	$0.55 \pm 0.01$	$0.809 \pm 0.002$
EGTBF	$0.59 \pm 0.01$	$0.959 \pm 0.002$	$0.60 \pm 0.01$	$0.838 \pm 0.002$
MT_EGTBF	$0.60 \pm 0.01$	$0.963 \pm 0.002$	$0.61 \pm 0.01$	$0.841 \pm 0.002$

$FM$  среднее значение точности полного совпадения (1, если все метки атомов в реакции предсказаны верно, 0 иначе).  $F_1$  среднее значение  $F_1$ -меры между предсказанными и правильными метками атомов в реакции.

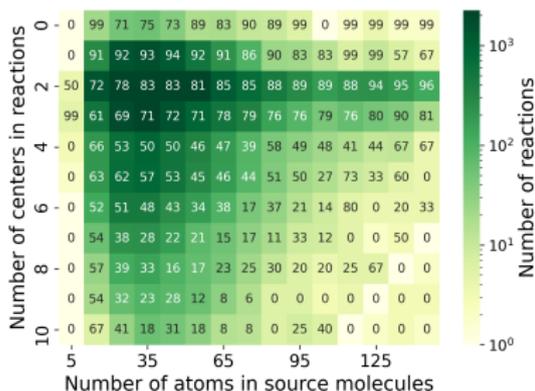
## Вывод

Предложенные методы работы с несвязанными графами значительно улучшают качество модели. Использование признаков вершин и ребер молекулярного графа приводит к повышению качества.

# Анализ ошибки

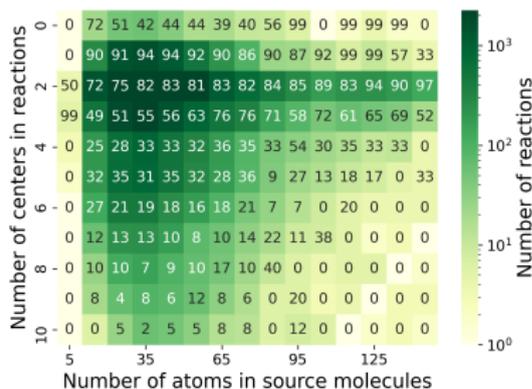
На графике представлена совместная зависимость качества модели от количества центров и длины исходных молекул. Цветом указано распределение исходных данных.

Detection of atoms of the main product



50 The number means full-match accuracy

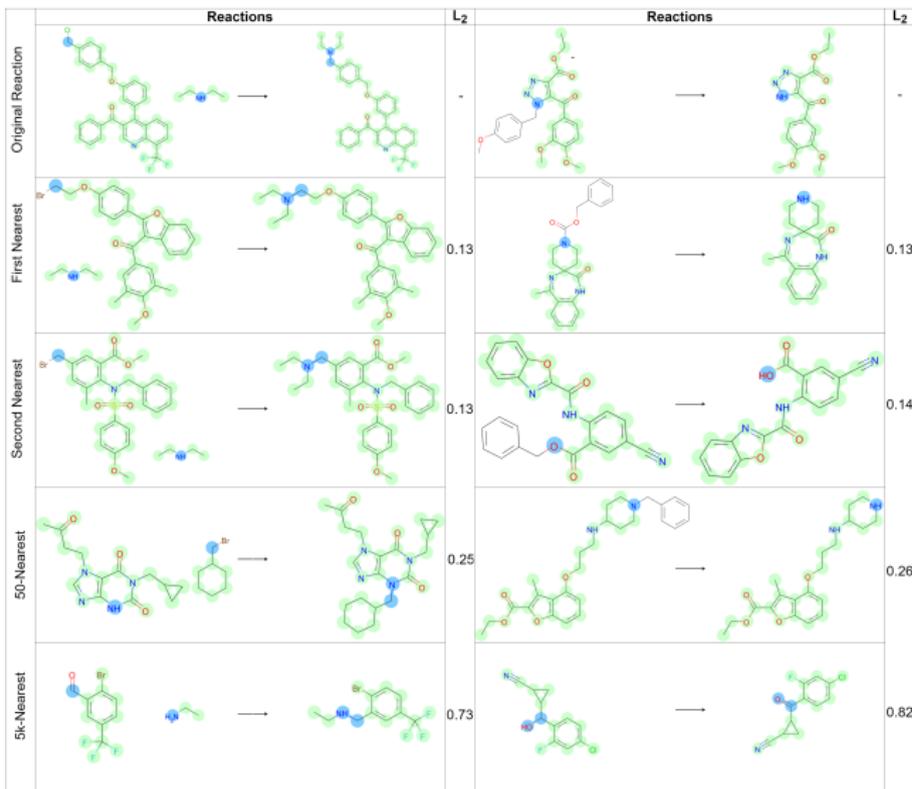
Detection of centers of the reaction



The color means the number of reactions

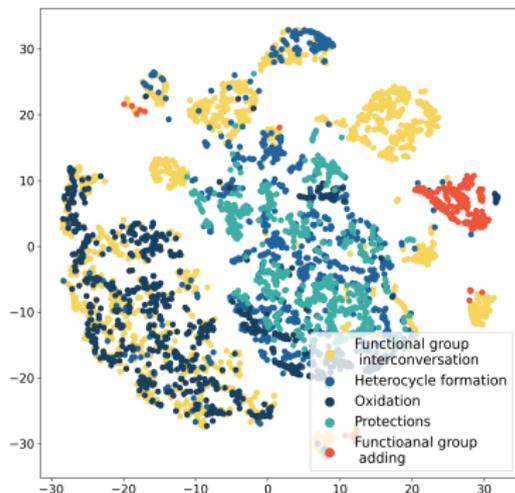
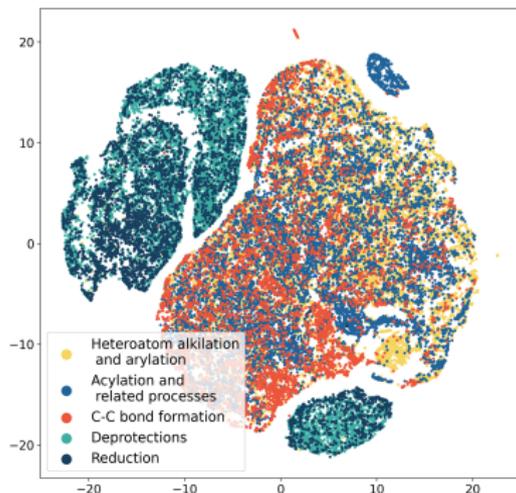
- 1 С увеличением числа центров качество падает;
- 2 Зависимость качества от длины исходных молекул выражена слабо.

# Исследование свойств пространства реакций



Метрически близким векторам, соответствующим состояниям всей реакции, соответствуют реакции с похожим механизмом.

# T-SNE карты реакций



Для датасета USPTO\_50k (10 классов реакций) построены T-SNE проекции в двумерное пространство.

Кластеры векторов состояний реакции скоррелированы с разметкой по классам химических реакций.

# Результаты выносимые на защиту

- 1 Сформулирована задача предсказания продуктов химической реакции в терминах классификации вершин несвязанного графа.
- 2 Предложено обобщение графовых нейронных сетей для работы с несвязанными графами.
- 3 Предложена последовательность вычислительных экспериментов, демонстрирующая необходимость каждой предложенной модификации.
- 4 Проанализирована полученная модель, исследованы свойства векторных состояний химической реакции, формируемых в модели.

## Материалы

- 1 GitHub репозиторий с задокументированными исходными файлами вычислительных экспериментов.
- 2 Web-интерфейс предложенной модели, интерактивное представление t-SNE карт реакций.



Evgeny Egorov, Filipp Nikitin, Vasilyy Alekseev, Alexey Goncharov, and Konstantin Vorontsov.

Topic modelling for extracting behavioral patterns from transactions data.

In *2019 International Conference on Artificial Intelligence: Applications and Innovations (IC-AIAI)*, pages 44–444. IEEE.



Filipp Nikitin and Vadim Strijov.

Graph neural network learning for chemical compounds synthesis.

In *Mathematical Methods of Pattern Recognition conference (MMPR-19)*, pages 311–312. Russian Academy of Sciences, 2019.



Filipp Nikitin, Vladimir Dokholyan, Ilya Zharikov, and Vadim Strijov.

U-net based architectures for document text detection and binarization.

In *International Symposium on Visual Computing*, pages 79–88. Springer, 2019.



Ilya Zharikov, Filipp Nikitin, Ilya Vasiliev, and Vladimir Dokholyan.

Ddi-100: Dataset for text detection and recognition.

*arXiv preprint arXiv:1912.11658*, 2019.