



Санкт-Петербургский государственный университет
Кафедра системного программирования

Улучшение производительности алгоритма достижимости с регулярными ограничениями на графическом ускорителе

Козенко Дмитрий Сергеевич, группа 23.Б08-мм

Научный руководитель: к.ф.-м.н. С.В. Григорьев, доцент кафедры системного программирования

Санкт-Петербург
2025

Графовые базы данных и запросы с регулярными ограничениями

- Запросы с регулярными ограничениями активно используются в графовых базах данных
- Алгоритм RPQ^1 основан на операциях линейной алгебры, которые отлично подходят вычислений на GPU
- Текущая реализация RPQ^2 на GPU на наборе данных Wikidata проигрывает CPU почти в 4 раза

¹RPQ с линейной алгеброй: https://se.math.spbu.ru/thesis/texts/Beljanin_Georgij_Olegovich_Spring_practice_2nd_year_2024_text.pdf (Дата доступа: 19.06.2025)

²GitHub репозитория с реализацией алгоритма на GPU:
<https://github.com/mitya-y/rpq/tree/cb2583e> (Дата доступа: 19.06.2025)

Постановка задачи

Целью работы является анализ узких мест реализации алгоритма на GPU и улучшение ее производительности

Задачи:

- 1 Воспроизвести тестирование из прошлой работы, проанализировать результаты и найти узкие места алгоритма
- 2 Улучшить производительность алгоритма
- 3 Провести эксперименты с итоговой версией алгоритма
- 4 Перенести свою ветку update-cuda-12.6 в основной репозиторий cuBool, организовать репозиторий с алгоритмами, использующими cuBool, и добавить в нее свой алгоритм

Описание данных и стендов

В ходе работы над анализом алгоритма были проведены измерения на следующих наборах данных

- Wikidata³: набор данных из реального мира вместе с 660 запросами
- RPQ-Bench⁴: синтетический набор данных, 20 типов запросов. Было создано 2 датасета: с графом на 10^7 вершин, по 1000 запросов каждого типа и с графом на 10^8 вершин и 100 запросов каждого вида

Были использованы следующие тестовые стенды

- Intel i5-10400f и Nvidia RTX 3050 (8 Gb VRAM), 16 Gb RAM, Manjaro 6.14
- AMD Ryzen 9 7900X и Nvidia RTX 3090 (24 Gb VRAM), 128 Gb RAM, Ubuntu 24.04

³База знаний WikiData: https://www.wikidata.org/wiki/Wikidata:Database_download (Дата доступа 19.06.25)

⁴Набор данных RPQ-Bench: <https://github.com/Mamenglu/LD-RPQB> (Дата доступа 19.06.25)

Улучшение алгоритма

Для улучшения производительности алгоритма были применены следующие изменения:

- ❶ Изменена реализация функции сложения матриц — используется схожая поэлементному умножению матриц реализация вместо библиотеки Nsparse
- ❷ Исправлена ошибка в stake с конфигурациями сборки
- ❸ Добавлена возможность передавать транспонированные матрицы в алгоритм

Таблица: Сравнение времени работы алгоритма до и после изменений

Версия алгоритма	Время выполнения 520 запросов, с	Время загрузки, с
Без изменений	273.09	5704.66
С изменениями	84.61	666.15

Организация репозитория cuBoolGraph⁵

```
cuBoolGraph [add-rpq] tree -d -L 2
.
├── deps
│   ├── cuBool
│   ├── fast_matrix_market
│   └── googletest
├── include
├── src
├── tests
│   └── test_data
```

Особенности проекта

- Система сборки — CMake
- Зависимости скачиваются через git submodule
- CI/CD: GitHub Actions (сборка и тесты)

Рис.: Структура репозитория cuBoolGraph

⁵GitHub репозиторий cuBoolGraph: <https://github.com/SparseLinearAlgebra/cuBoolGraph> (Дата доступа: 19.06.2025)

Эксперимент

Для дальнейшего анализа производительности алгоритма были поставлены следующие задачи

- 1 Замерить время работы реализаций на CPU и GPU и проанализировать типы запросов, работающих на GPU медленнее, чем на CPU
- 2 Изучить масштабируемость реализации для GPU, сравнив время работы на двух разных по мощности тестовых стендах

Суммарное время работы выполнения всех запросов:

Данные	Время GPU,	Время CPU,	Ускорение GPU
Wikidata	115.73	136.30	1.18
RPQ-bench 10^7	185.28	55.19	0.30

Таблица: Результаты сравнения CPU и GPU

Анализ набора данных Wikidata




Рис.: Облако распределения времени исполнения запросов

Анализ набора данных RPQ-bench

Таблица: Время работы каждой операции на наборе данных RPQ-bench 10^7 в реализациях на GPU и CPU

Операция	GPU, s	CPU, s
MxM	148.96 (80.11%)	20.37 (37.13%)
VxM	21.19 (11.49%)	8.08 (14.73%)
cuBool_EwiseAdd	6.55 (3.52%)	—
cuBool_EwiseMulInverted	9.23 (4.96%)	—
GrB_Matrix_assign	—	26.22 (47.79%)

Анализ масштабируемости алгоритма

Суммарное время работы выполнения всех запросов:

Таблица: Результаты замеров на RTX 3050 и RTX 3090

Набор данных	RTX 3050, s	RTX 3090, s	Ускорение
wikidata	116.50	100.99	1.15
RPQ-bench 10^7	185.28	131.46	1.41
RPQ-bench 10^8	318.86	300.17	1.06

Таблица: Время работы каждой операции на RTX 3050 и RTX 3090 на датасете RPQ-bench на 10^8 вершин

Операция	RTX 3050,	RTX 3090,	Ускорение
MxM	274.71 (85.00%)	269.33 (90.27%)	1.02
VxM	22.65 (7.00%)	11.22 (3.76%)	2.02
EwiseAdd	15.28 (4.73%)	11.67 (3.91%)	1.31
EwiseMulInverted	10.57 (4.27%)	6.15 (2.06%)	1.72

- Найдены узкие места в алгоритме и исправлены ошибки, вследствие чего производительность выросла
- Проведено сравнение финальной версии реализации на GPU с реализацией на CPU, показавшее, что на крупных запросах GPU может дать выигрыш, а на маленьких предпочтительнее использовать CPU
- Проведено исследование масштабируемости алгоритма, который выявил узкое место — операция умножения матриц
- Изменения cuBool были перенесены в основной репозиторий, а исходный код в cuBoolGraph⁶

⁶GitHub репозиторий cuBoolGraph: <https://github.com/SparseLinearAlgebra/cuBoolGraph> (Дата доступа: 19.06.2025)