



Конференция
для IT-специалистов,
интересующихся темой
Artificial Intelligence

Искусственный интеллект глазами разработчика



НовГУ им.
Ярослава Мудрого



**Искусственный
интеллект
глазами
разработчика**

29 мая 2021



Мастерская инструментов
разработки
mir.dev

Компилятор для нейронных сетей на базе фреймворка Apache TVM


Создание бэкенда для
тензорного ускорителя

Илья Гозман

Архитектор, компания МИР

Выбор TVM

- Открытый исходный код и лицензия Apache
- Активное большое комьюнити
- Участие в разработке крупных компаний (Amazon, ARM)
- Поддержка различных фронт- и бэкендов
- Python- и C- API
- Достаточная гибкость и набор инструментов для нетипичных архитектур
- Разработка под Linux и Windows, сборка через CMake



Внутренние представления



Вход – Tensorflow, ONNX, PyTorch, ...


- Преобразует сеть в собственный формат Relay
- Преобразования на уровне графа, поиск и выделение сабграфов, изменение формы тензоров (layout)
- Общие оптимизации на уровне слоя, внедрение интринсик
- Генерация целевого представления для TIR-субграфов (nodes), например LLVMIR, C-код, .so библиотека

Виды бэкендов



BYOC (Bring Your Own Codegen)

Бэкенд для Relay-компилятора, позволяет заменять операции или слои на составные device-функции



LLVM

Использование инфраструктуры LLVM (через API) для получения объектных файлов или биткода:

ADMGPU, ARM, Mali, X86 (_64), Hexagon, NVPTX



Виды бэкендов



Source

Генерация исходного кода для использования с внешним компилятором (например NVCC или NVRTC для CUDA):


C, CUDA, METAL, OpenCL, Vivado HLS

Custom

Использование в планировщике механизма tensorize:

- Внедрение интринсик
- Использование внешних вызовов
- Вставки на целевом ассемблере или биткоде

VTA (Versatile Tensor Accelerator) бэкенд




- Дизайн ускорителя операций линейной алгебры (модули GEMM, ALU)
- Реализации на Vivado HLS C++, Chisel, OpenCL
- Симулятор TSIM на базе Verilator
- Готовая интеграция в TVM

Особенности разработки и отладки



TVM PackedFunc (FFI) – универсальный механизм функций, для реализации и вызова из Python/C++/C кода
Используется в компиляторе и в runtime


Для Windows – Visual Studio + PyCharm
Можно использовать PTVS, но есть проблемы с отладкой



JIT-компилятор



Преобразование констант или исполнение неподдерживаемых операций на хосте

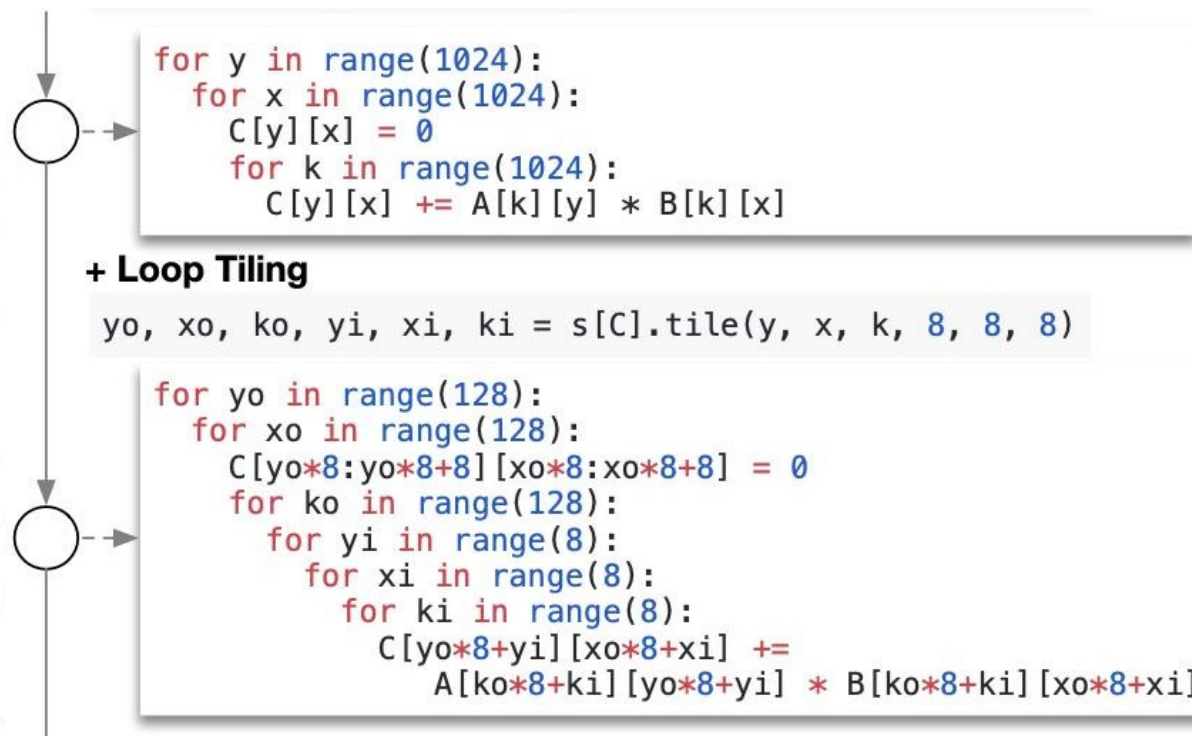


Настройка планировщика



Возможности:

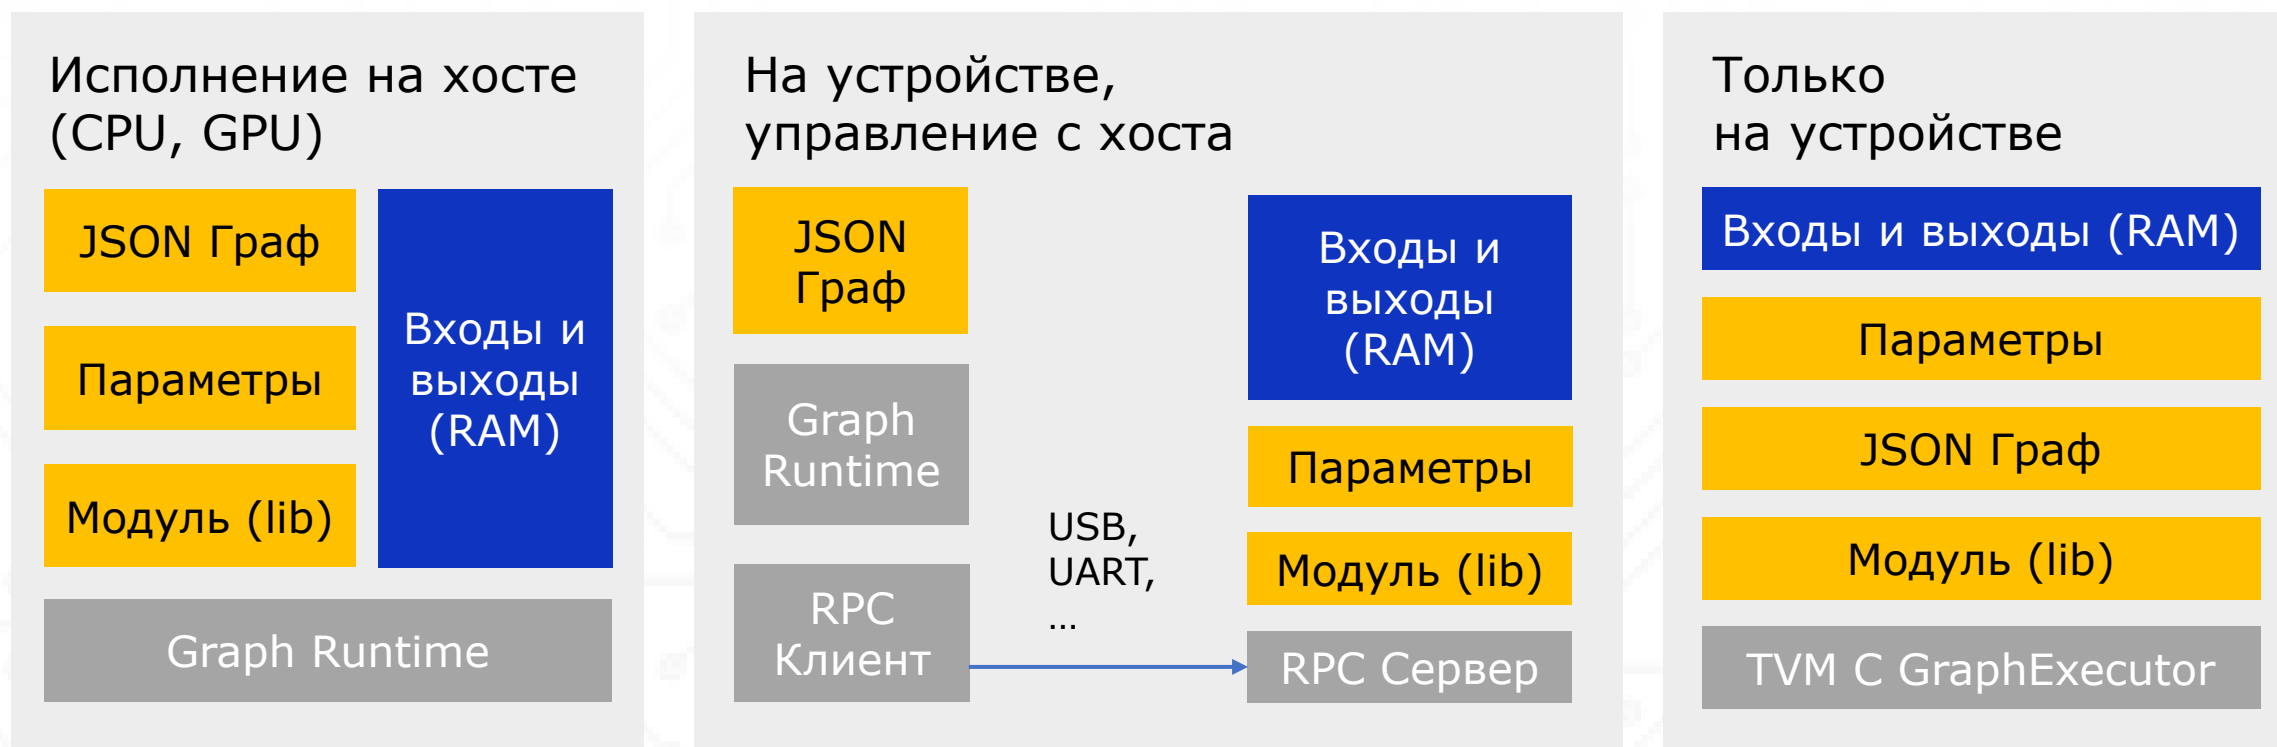
- **split, tile** – разделение по осям
- **fuse** – объединение осей
- **reorder** – изменение порядка вычислений по осям
- **bind** – распределение по виртуальным потокам
- **compute_at, compute_inline, compute_root** – перенос/встраивание вычислительного цикла на другой уровень
- **tensorize** – замена фрагмента вычислений на вызов внешней функции



Runtime



- GraphRuntime (Graph Executor)
- uTVM (microTVM)





Искусственный интеллект глазами разработчика

29 мая 2021



Мастерская инструментов
разработки
mir.dev

Вопросы?