推理引擎-模型转换与优化

计算图优化

ZOMI

Talk Overview

1. **推理系统介绍**
   - 推理系统架构
   - 推理引擎叫故
2. **模型小型化**
   - CNN小型化结构
   - Transform小型化结构
3. **离线优化压缩**
   - 低比特量化
   - 模型剪枝
   - 知识蒸馏
4. **模型转换与优化**
   - 架构与流程
   - 模型转换技术
   - 计算图优化
5. **Runtime与在线优化**
   - 动态batch
   - bin Packing
   - 多副本并行

Talk Overview

1. 计算图优化

- Challenges and Architecture - 挑战与架构
- graph Optimization - 计算图优化
- Example - ONNX Runtime 图优化
- Optimize Details - 计算图优化详解

- **代数简化**
- **算子优化**

图优化方式

1. **Basic:** 基础优化涵盖了所有保留计算图语义的修改，如：O1常量折叠、O2冗余节点消除和O3有限数量的算子融合。
2. **Extended:** 扩展优化仅在运行特定后端，如 CPU、CUDA、NPU 后端执行提供程序时适用。其针对硬件进行特殊且复杂的 Kernel 融合策略和方法。
3. **Layout & Memory:** 布局转换优化，主要是不同 AI 框架，在不同的硬件后端训练又在不同的硬件后端执行，数据的存储和排布格式不同。

工作流程

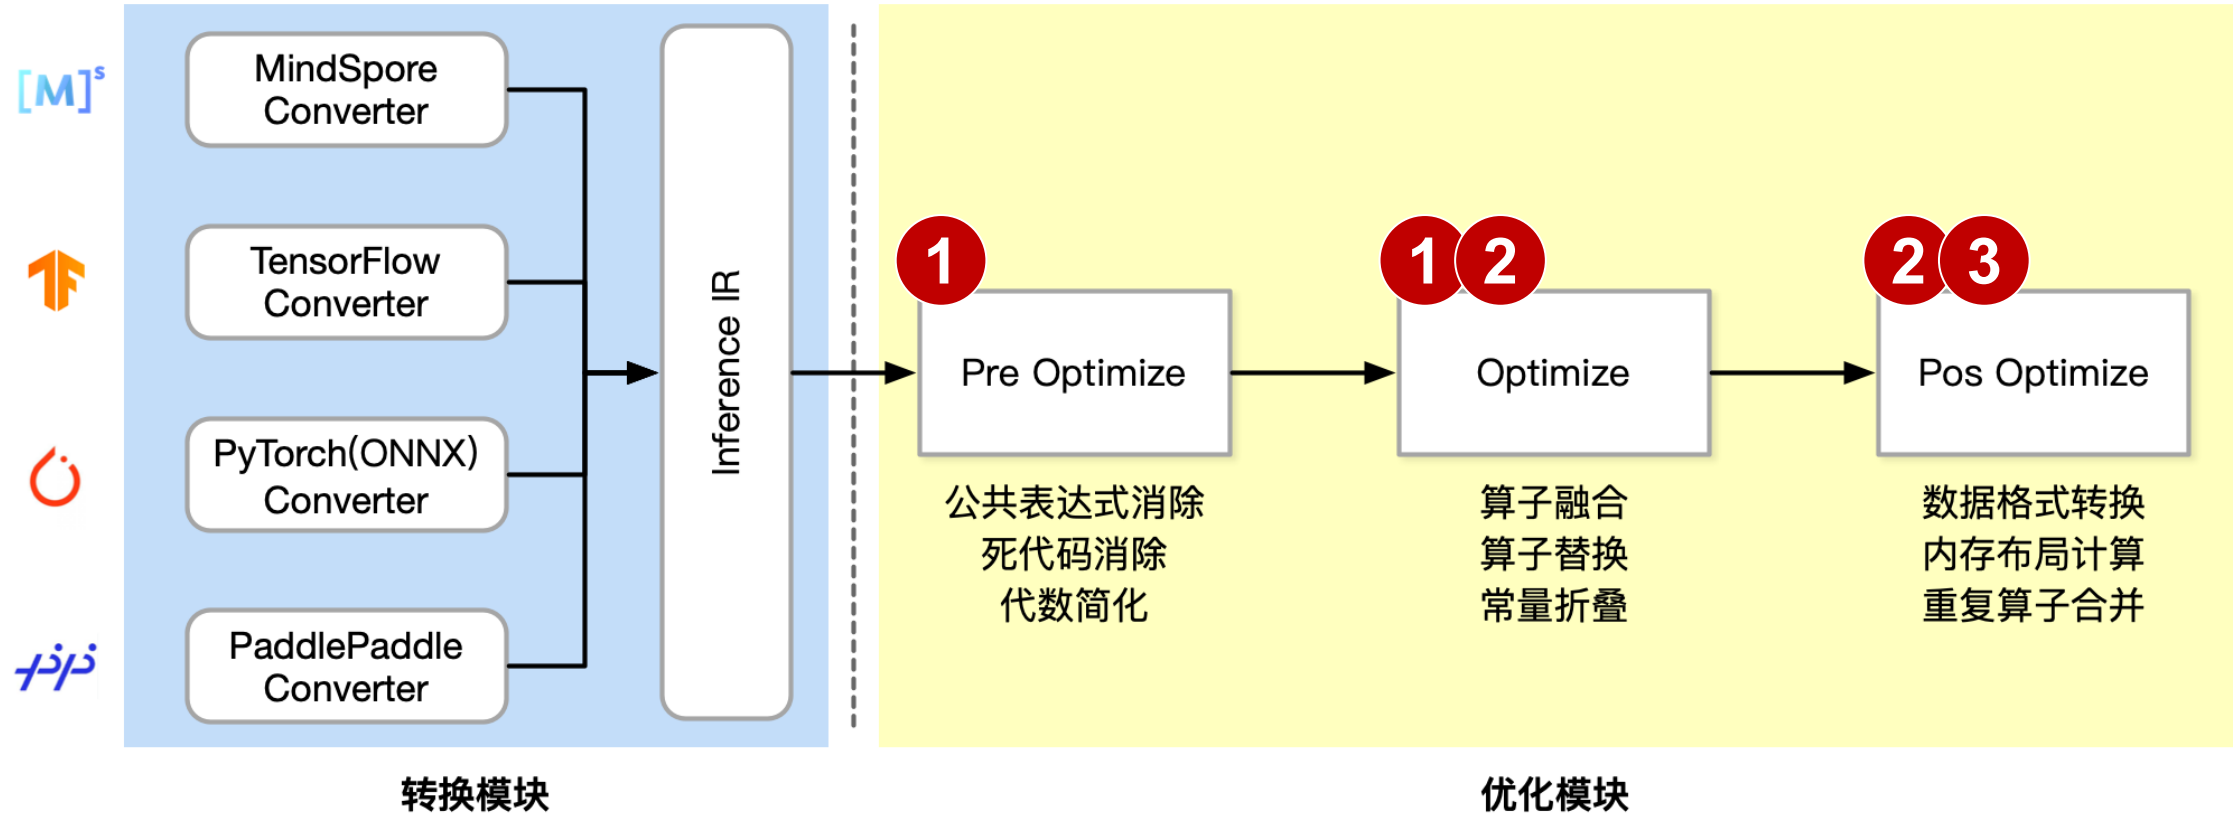

AI编译器之前端优化

播放全部

结构在快速演化，底层计算硬件技术更是层出不穷，对于广大开发者来说不仅要考虑如何在复杂多，还要应对计算框架的持续迭代。AI编译器就成了应对以上问题广受关注的技术方向，让用户仅...

默认排序　升序排序　编辑

AI编译器前端"图层优化"内容概览！！【AI编译器】系列之前端优

600　2022-12-13

图层IR(Graph IR)是什么？AI编译器如何接收图层IR进行优化呢？【AI编

519　2022-12-13

算子融合了解下！AI编译器如何实现算子融合的？【AI编译器】系列

915　2022-12-16

编译器为什么要对数据布局转换呢Layout Transformations？【AI编

404　2022-12-17

详解AI编译器数据布局转换方法！华为昇腾处理器的数据布局格式！

225　2022-12-17

AI编译器内存优化算法！动态内存和静态内存区别！【AI编译器】前

328　1-16

常量折叠原理！AI编译器常量折叠跟传统编译器什么关系？计算图也

356　2022-12-18

编译器公共子表达式消除的方法！AI编译器消除公共子表达式【AI编译

270　2022-12-20

编译器死代码消除的原理！AI编译器死代码消除【AI编译器】系列之

375　2022-12-20

编译器的代数化简原理！AI编译器的代数化简来啦！【AI编译器】系

315　2022-12-21

计算图优化详解 (II)

❷ Extended Graph Optimizations 其他图优化

- These optimizations include complex node fusions. They are run after graph partitioning and are only applied to the nodes assigned to the CPU or CUDA or ROCm execution provider.
- 有些 Op 在一些框架上可能没有直接的实现，而是通过一些 Op 的组合，如果推理引擎实现了该 Op，就可以把这些组合转成这个 Op，能够使得网络图更加简明清晰。

❷ Extended Graph Optimizations 其他图优化

Fuse Layer Norm	• 组合实现的 Norm Op 直接转换成一个Op
Fuse PReLU	• 组合实现的 PReLU Op 直接转换成一个Op
Fuse Matmul Transpose	• 有些框架的矩阵乘法Matmul层自身是不带转置操作的，当需要转置的矩阵乘法时需要前面加一个transpose层。如 Onnx 的 Matmul 自身有是否转置的参数，因此可以将前面的transpose层转换为参数即可
Fuse Binary Eltwise	• x3 = x1 *b1+x2 *b2，把 BinaryOp Add 转换成 Eltwise Sum，而 Eltwise Sum是有参数 coeffs，可以完成上述乘法的效果，因此把两个 BinaryOp Mul 的系数融合到 Eltwise Sum 的参数 coeffs
Fuse Reduction with Global Pooling	• 对一个三维 tensor 先后两次分别进行w维度的 reduction mean 和h维度的 reducetion mean，最终只剩下c这个维度，就等于进行了一次global_mean_pooling

❷ Extended Graph Optimizations 其他图优化

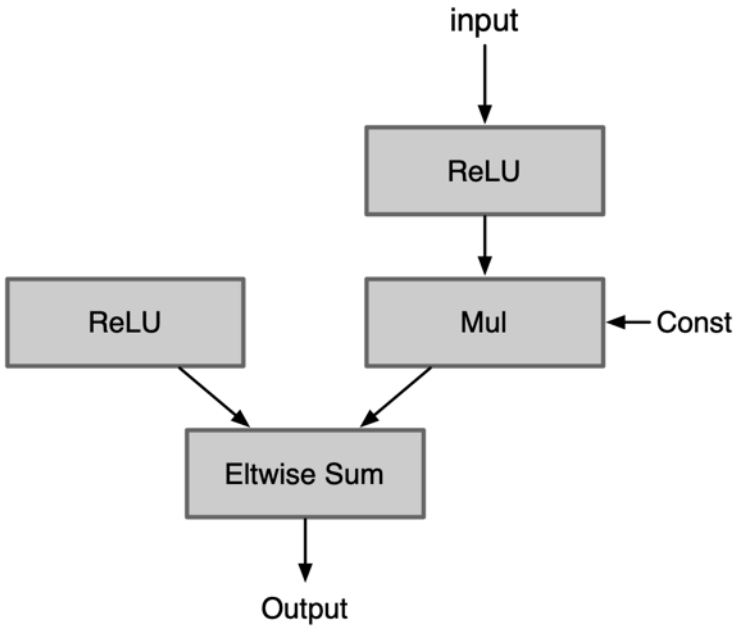

- Fuse PReLU

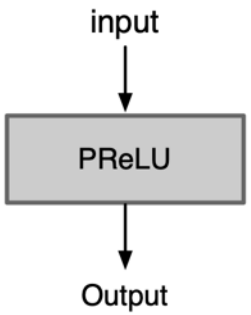

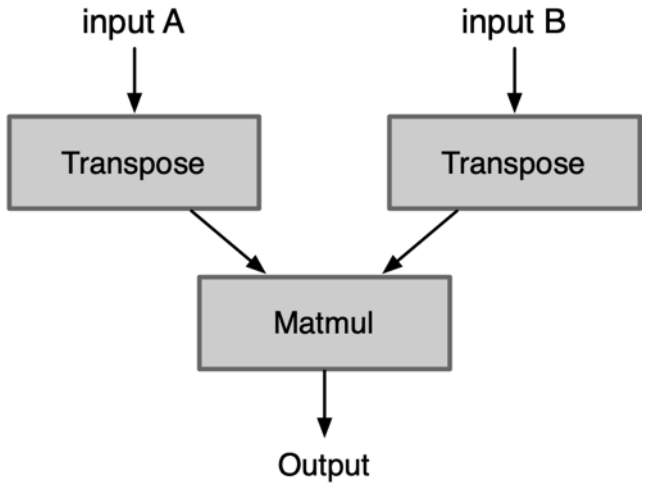

- Fuse Matmul Transpose

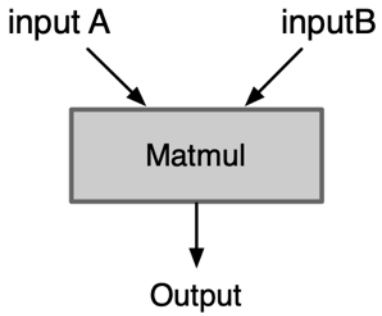

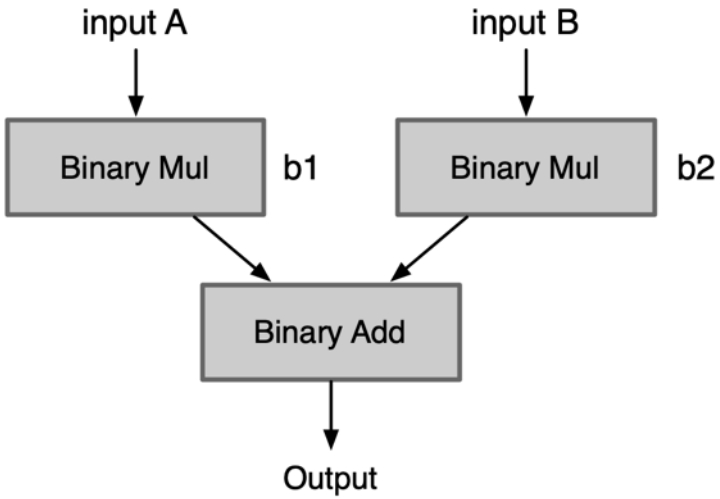

- Fuse Binary Eltwise

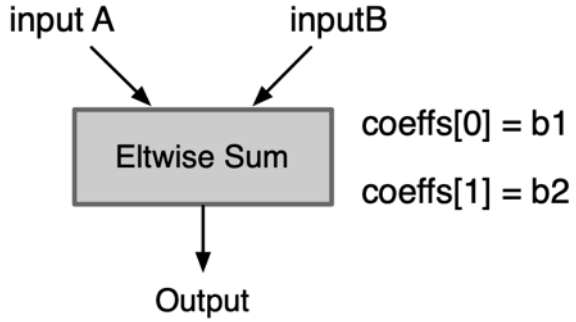

❷ Extended Graph Optimizations 其他图优化

FLASHATTENTION: Fast and Memory-Efficient Exact Attention with IO-Awareness

Tri Dao[†], Daniel Y. Fu[†], Stefano Ermon[†], Atri Rudra[‡], and Christopher Ré[†]

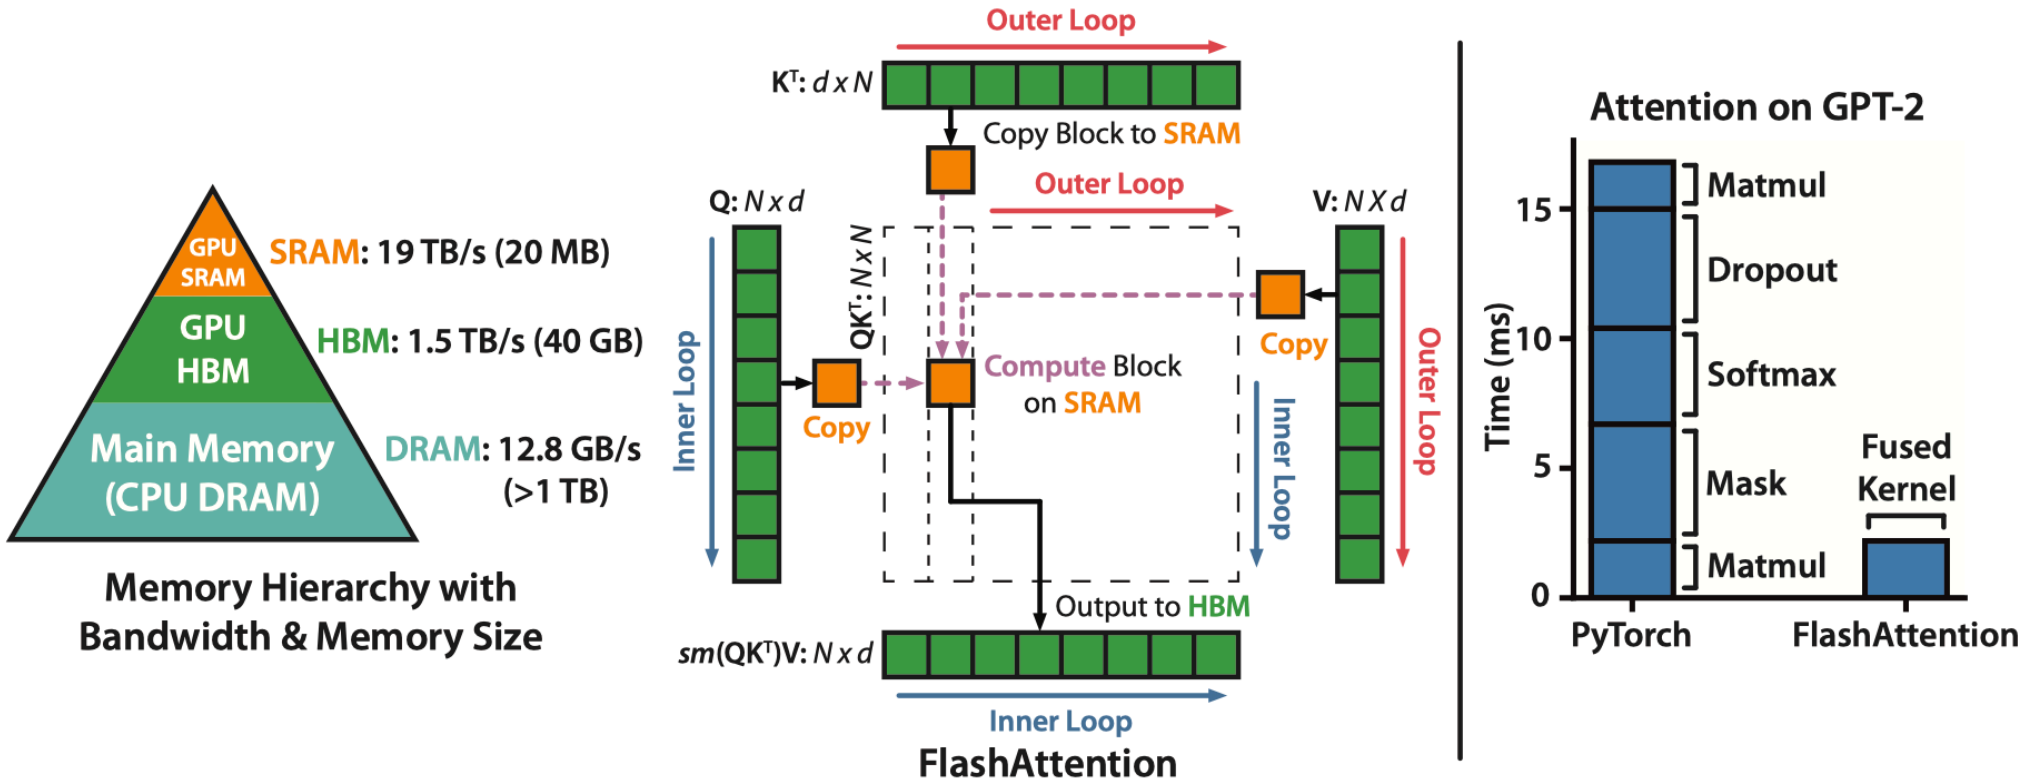

Figure 1: **Left:** FLASHATTENTION uses tiling to prevent materialization of the large $N \times N$ attention matrix (dotted box) on (relatively) slow GPU HBM. In the outer loop (red arrows), FLASHATTENTION loops through blocks of the **K** and **V** matrices and loads them to fast on-chip SRAM. In each block, FLASHATTENTION loops over blocks of **Q** matrix (blue arrows), loading them to SRAM, and writing the output of the attention computation back to HBM. **Right:** Speedup over the PyTorch implementation of attention on GPT-2. FLASHATTENTION does not read and write the large $N \times N$ attention matrix to HBM, resulting in an 7.6× speedup on the attention computation.

计算图优化详解 (III)

AI编译器之前端优化

播放全部

结构在快速演化，底层计算硬件技术更是层出不穷，对于广大开发者来说不仅要考虑如何在复杂多，还要应对计算框架的持续迭代。AI编译器就成了应对以上问题广受关注的技术方向，让用户仅...

默认排序　升序排序　编辑

AI编译器前端"图层优化"内容概览！！【AI编译器】系列之前端优

600　2022-12-13

图层IR(Graph IR)是什么？AI编译器如何接收图层IR进行优化呢？【AI编

519　2022-12-13

算子融合了解下！AI编译器如何实现算子融合的？【AI编译器】系列

915　2022-12-16

编译器为什么要对数据布局转换呢Layout Transformations？【AI编

404　2022-12-17

详解AI编译器数据布局转换方法！华为昇腾处理器的数据布局格式！

225　2022-12-17

AI编译器内存优化算法！动态内存和静态内存区别！【AI编译器】前

328　1-16

常量折叠原理！AI编译器常量折叠跟传统编译器什么关系？计算图也

356　2022-12-18

编译器公共子表达式消除的方法！AI编译器消除公共子表达式【AI编译

270　2022-12-20

编译器死代码消除的原理！AI编译器死代码消除【AI编译器】系列之

375　2022-12-20

编译器的代数化简原理！AI编译器的代数化简来啦！【AI编译器】系

315　2022-12-21

数据转换节点

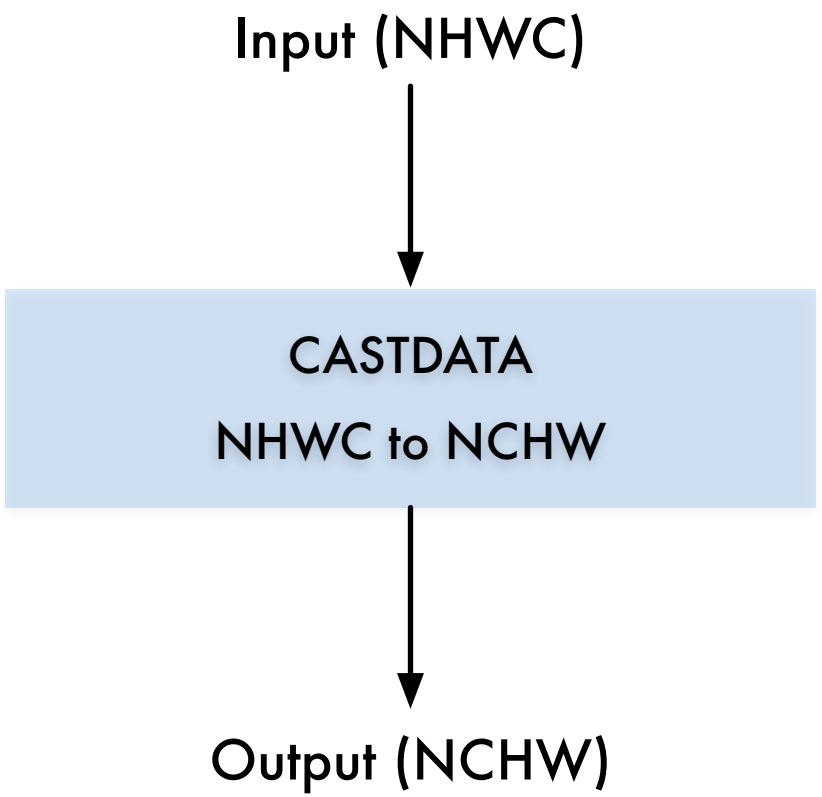

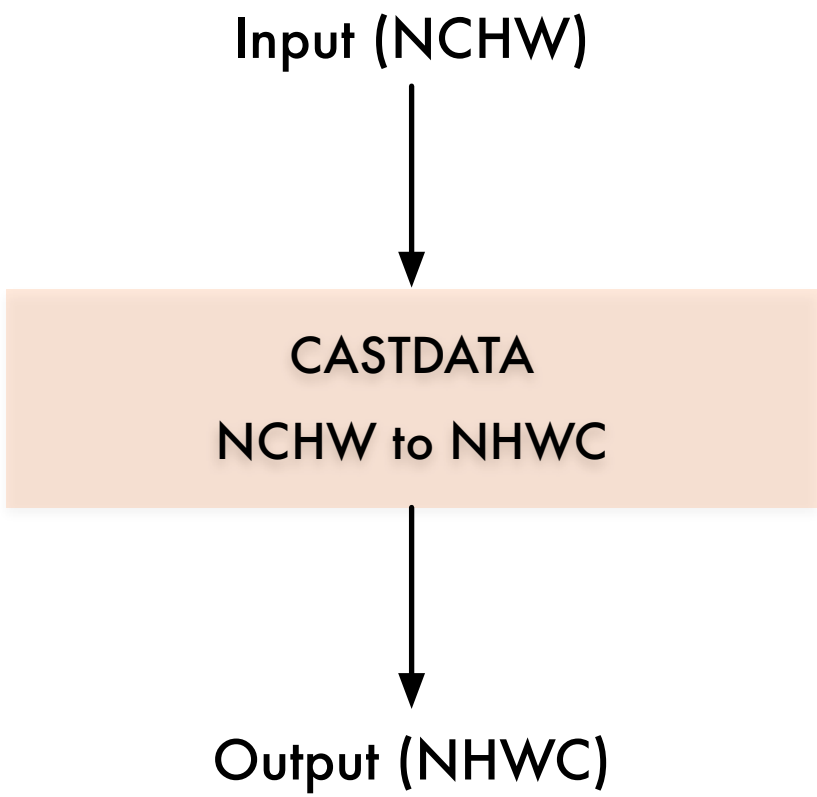

常见数据转换节点

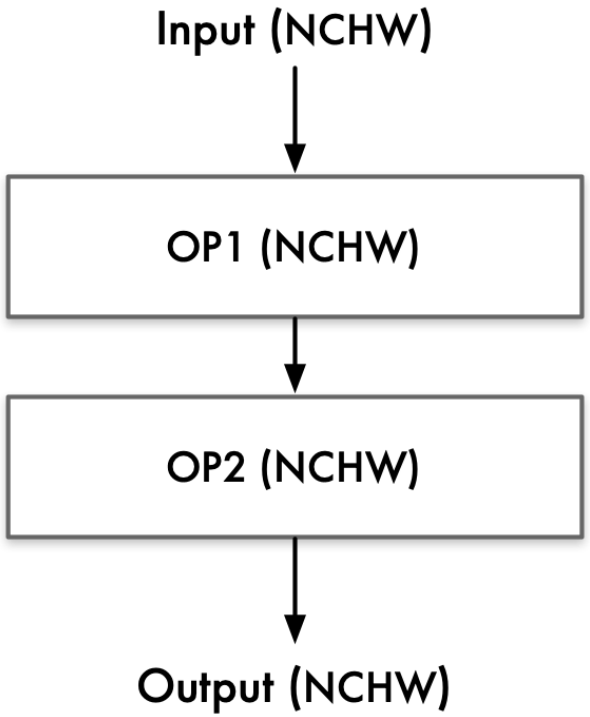

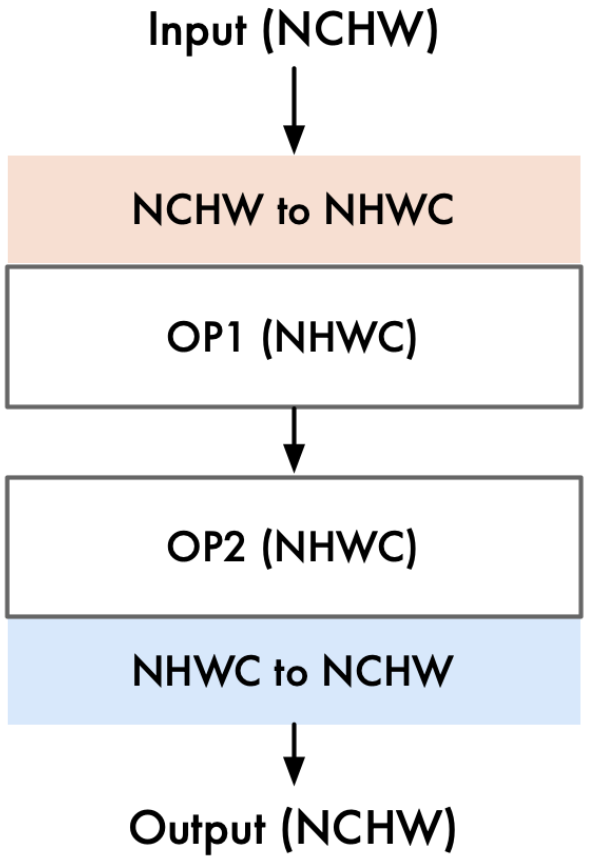

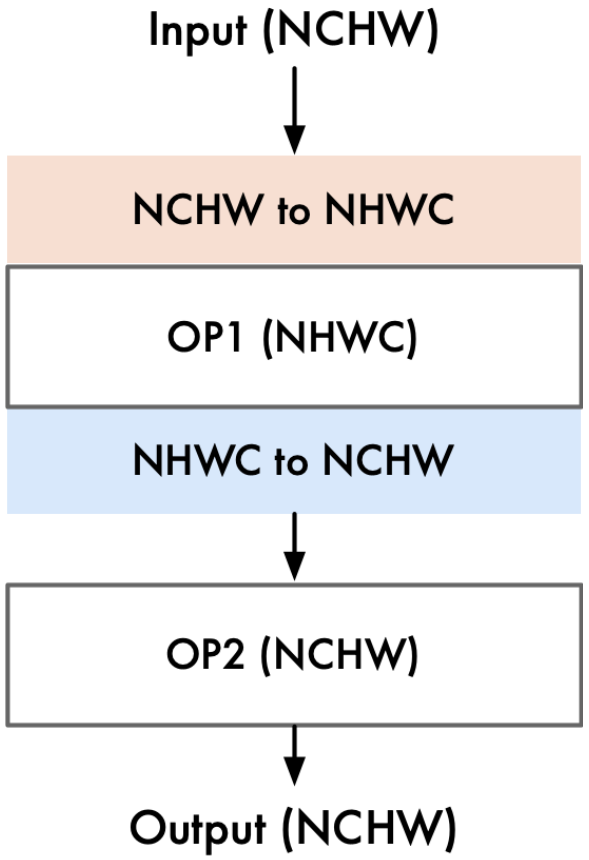

AI编译器之前端优化

播放全部

结构在快速演化，底层计算硬件技术更是层出不穷，对于广大开发者来说不仅要考虑如何在复杂多，还要应对计算框架的持续迭代。AI编译器就成了应对以上问题广受关注的技术方向，让用户仅...

默认排序　升序排序　编辑

1


AI编译器前端"图层优化"内容概览！！【AI编译器】系列之前端优
600　2022-12-13

2


图层IR(Graph IR)是什么？AI编译器如何接收图层IR进行优化呢？【AI编
519　2022-12-13

3


算子融合了解下！AI编译器如何实现算子融合的？【AI编译器】系列
915　2022-12-16

4


编译器为什么要对数据布局转换呢Layout Transformations？【AI编
404　2022-12-17

5


详解AI编译器数据布局转换方法！华为昇腾处理器的数据布局格式！
225　2022-12-17

6


AI编译器内存优化算法！动态内存和静态内存区别！【AI编译器】前
328　1-16

7


常量折叠原理！AI编译器常量折叠跟传统编译器什么关系？计算图也
356　2022-12-18

8


编译器公共子表达式消除的方法！AI编译器消除公共子表达式【AI编译
270　2022-12-20

9


编译器死代码消除的原理！AI编译器死代码消除【AI编译器】系列之
375　2022-12-20

10


编译器的代数化简原理！AI编译器的代数化简来啦！【AI编译器】系
315　2022-12-21

内存优化方法

- Inplace operation：如果一块内存不再需要，且下一个操作是element-wise，可以原地覆盖内存
- Memory sharing：两个数据使用内存大小相同，且有一个数据参与计算后不再需要，后一个数据可以覆盖前一个数据