

Диалект MLIR для Общего Тайлинга Циклов

А.В. Левченко

2@lto.ru

Суперкомпьютерный центр СПбПУ

Диалект MLIR Common Loop Tiling (CLT)

Progressive lowering



Figure 1 – Схема взаимодействия CLT с некоторыми диалектами инфраструктуры MLIR

Диалект MLIR Common Loop Tiling (CLT)

Полиэдральный тайлинг с использованием конверсии диалектов Affine → GPU

```
1 // Циклы CLT/Affine
2 func.func @clt_loop(%arg0: memref<?x?x?xf32>, 
3 % arg1: memref<?x?x?xf32>) {
4   clt.launch [dev = 'gpu'] {
5     clt.for %arg2 = 0 to 512 {
6       clt.for %arg3 = 0 to 256 {
7         clt.for %arg4 = 0 to 128 {
8           clt.for %arg5 = 0 to 64 {
9             % 0 = memref.load %arg0[%arg2, %arg3, %arg4,
10               % arg5] : memref<?x?x?xf32>
11             memref.store %0, %arg1[%arg2, %arg3, %arg4, %arg5]
12             : memref<?x?x?xf32>
13           [...]
14         }
15       }
16     }
17     // Тайлинг (размер тайна = 256, размер кеша = 1024)
18     func.func @loop_tiling(
19       % arg0: memref<196608x1xf32>,
20       % arg1: memref<196608x1xf32>
21     -> memref<196608x1xf32> {
22       clt.launch [dev = 'gpu', tss = 256, cache = 1024] {
23         clt.for %arg2 = 0 to 196608 step 1024 {
24           clt.for %arg3 = 0 to 1 step 256 {
25             clt.for %arg4 = #map(%arg2) to #map1(%arg2) step 256 {
26               clt.for %arg5 = #map(%arg3) to #map2(%arg3) step 256 {
27                 clt.if #set(%arg4) {
28                   clt.for %arg6 = #map(%arg4) to #map2(%arg4) {
29                     clt.for %arg7 = #map(%arg5) to #map3(%arg5) {
30                       % 0 = clt.load %arg0[%arg6, %arg7]
31                         : memref<196608x1xf32>
32                       clt.store %0, %arg1[%arg6, %arg7]
33                         : memref<196608x1xf32>
34           [...]
35         }
36       }
37     }
38   }
39 }
```

```
1 // Циклы GPU/Affine
2 module {
3   func.func @clt_loop(%arg0: memref<?x?x?xf32>,
4     % arg1: memref<?x?x?xf32>) {
5     % c0 = arith.constant 0 : index
6     % c512 = arith.constant 512 : index
7     % 0 = arith.subi %c512, %c0_0 : index
8     % c1 = arith.constant 1 : index
9     % c0_0 = arith.constant 0 : index
10    % c256 = arith.constant 256 : index
11    % 1 = arith.subi %c256, %c0_0 : index
12    % c1_1 = arith.constant 1 : index
13    % c1_2 = arith.constant 1 : index
14    // Операции запуска ядра GPU
15    gpu.launch blocks(%arg2, %arg3, %arg4)
16    in (%arg1 = %c0, %arg9 = %c1_2, %arg10 = %c1_2)
17    threads(%arg5, %arg6, %arg7)
18    in (%arg11 = %c1, %arg12 = %c1_2, %arg13 = %c1_2) {
19      % 2 = arith.addi %c0, %arg2 : index
20      % 3 = arith.addi %c0_0, %arg5 : index
21      affine.for %arg14 = 0 to 128 {
22        affine.for %arg15 = 0 to 64 {
23          % 4 = memref.load %arg0[%c2, %c3, %arg14, %arg15]
24            : memref<?x?x?xf32>
25          memref.store %4, %arg1[%c2, %c3, %arg14, %arg15]
26            : memref<?x?x?xf32>
27        }
28      }
29    }
30    gpu.terminator
31  }
32  return
33 }
```

Figure 2 – Циклы с параметрическим тайлингом в MLIR CLT/Affine (листинг 1) и пример конверсии в GPU (листинг 2)

Низкоуровневый полиэдральный тайлинг

LLVM/Polly + Integer Set Library




Figure 3 – Представление циклов в SCOP в LLVM-IR (листинг 1) и в полиэдральном описании с генерацией тайлового кода (листинг 2)

Экспериментальные результаты трансляции SCOP

Оценка эффективности операций




Figure 4 – CLT/Affine → GPU → NVGPU → NVVM-IR




Figure 5 – CLT/Affine → LLVM → LLVM-IR → Polly + ISL

Figure 6 – Ускорение тайлового кода Stencils относительно версии NoOpt

- ◆  <ftp://ftp.lto.ru/clt.pdf>
- ◆ Gysi, Müller, Zinenko, Herhut, Davis, Wicky, Fuhrer, Hoefer, Grosser. Domain-Specific Multi-Level IR Rewriting for GPU: The Open Earth Compiler for GPU-accelerated Climate Simulation (2021)
- ◆ Moses, Chelini, Zhao, Zinenko. Polygeist: Raising C to Polyhedral MLIR (2021)