

鲲鹏 HPC 挑战赛 S2

优化答辩

参赛队伍 · ACETaffy喵

CONV / TRSM / ZGEMM

2026.9.6



ChenyuHeee · CONV、整合与验收（组长）



Bill Feng · ZGEMM



Evelina · TRSM

Part ε · 背景 & 环境

缩写	英文全称	中文含义	要完成的计算	本题的优化重点
CONV	Convolution	二维卷积	用卷积核扫描输入，得到输出特征图	保持 FP32 累加顺序，同时计算更多输出
TRSM	Triangular Solve	三角方程求解	求解 $L \times X = B$ ，其中 L 是下三角矩阵	按依赖顺序求解，把更新阶段并行化
ZGEMM	Double-precision complex General Matrix-Matrix Multiplication	双精度复数通用矩阵乘法	计算 $C = \alpha \times A \times B + \beta \times C$	组织复数数据、寄存器块和缓存访问

GitHub 仓库管理

☐	☒	[ZGEMM] 修复全组合测试的 ColMajor leading dimension	zgemm	1
		#50 · by bfyee was closed 1w ago		
☐	☒	[TRSM] 微核深度调优: prefetch / 更大寄存器块 / K展开 / 打包复用 / 对角块流水	trsm	1 3
		#44 · by Evelina-IS was closed 1w ago		
☐	☒	[基础] 集群编译环境: 必须用 HPCKit gcc 12.3.1 (系统 gcc10 链接 kblas 失败)	infra	3
		#42 · by Evelina-IS was closed 1w ago		
☐	☒	[基础] 公开资料调研汇总 (NEON 微核 / TRSM / BLIS 参考)	infra	1 1
		#31 · by ChenyuHeee was closed 2w ago		
☐	☒	[文档] results.md 数据记录模板与回填检查单	docs	1
		#30 · by ChenyuHeee was closed 2w ago		
☐	☒	[文档] 各题 README 完善 (集群/本地编译运行 + 结果示例)	docs	1 1
		#29 · by ChenyuHeee was closed 1w ago		

- 用 Issue 记录假设和待验证的问题
- 在分支里写代码，并在集群完成对照实验
- PR

提出假设 → 修改代码 → 误差检查 → 对比测试后决定保留或回退


贡献 协作

Summary

Excluding merges, **3 authors** have pushed **23 commits** to main and **25 commits** to all branches.

On main, **60 files** have changed and there have been **3,942 additions** and **281 deletions**

Top committers



常用命令

```
# 本地：编译并检查三题是否 PASS
```

```
./scripts/build_local.sh
```

```
# 鲲鹏集群：加载 TRSM 需要的 KML 环境，跑全部官方用例
```

```
source ./env_kunpeng.sh && bash run_all.sh
```




- 本地只核对正确性；性能数据以鲲鹏集群复测结果为准
- run_all.sh 会编译并运行 10 个官方用例，结果写入 results.md

环境/线程

Whole-node thread sweep

Thread counts are chosen from the measured workload, not by blindly filling every core

Final defaults CONV 120 | ZGEMM 120 | TRSM 96



Green dashed line and outlined point show the final default. ZGEMM case1 peaks at 993 GFLOPS with 124 threads.

- 鲲鹏 920, 共 128 个物理核
- NEON 是 ARM 架构提供的 SIMD 向量指令, 一条指令可以同时处理多个数据

```
#include <arm_neon.h>

float32x4_t acc = vdupq_n_f32(0);    // 4 个 FP32 累加器
float32x4_t x   = vld1q_f32(input);  // 一次加载 4 个数据
acc = vfmaq_n_f32(acc, x, weight);   // 4 路同时做乘加
vst1q_f32(output, acc);
// 写回 4 个结果
```

这段代码来自 CONV/conv2d.c 的向量化路径；float32x4_t 表示 4 个单精度浮点数，vld1q、vfmaq_n 和 vst1q 分别完成向量加载、乘加和存储。

Part 1 • CONV


CONV 的约束

- 卷积计算使用单精度浮点数 (FP32)
- 每个输出点都按参考代码的顺序计算：先遍历卷积核的行，再遍历列
- 一次多算几个输出点；连续数据用向量指令处理，并尽量复用已经读入的输入
- 边缘凑不满一个完整块时，改走收尾代码，保证所有尺寸的结果都正确

CONV 的计算与优化过程

CONV 计算过程

先保证一个输出元素的累加顺序不变，再扩大不同输出之间的并行度，并复用输入行



保留累加顺序

```
for (int kh = 0; kh < kH; ++kh) {  
    for (int kw = 0; kw < kW; ++kw) {  
        acc += input[row + kh][col + kw] * kernel[kh][kw];  
    }  
}
```

优化没有重排单个输出点的累加链，先保证结果和参考实现一致，再从多个输出点之间寻找并行性。

NEON 向量化

```
float32x4_t x = vld1q_f32(inrow);  
q0 = vfmaq_n_f32(q0, x, k0);  
q1 = vfmaq_n_f32(q1, x, k1);
```

一次加载 4 个 FP32 数据，并同时更新多个输出累加器。向量化放在不改变单个输出顺序的位置。

四行复用输入

```
q0 = vfmaq_n_f32(q0, x, k0);  
q1 = vfmaq_n_f32(q1, x, k1);  
q2 = vfmaq_n_f32(q2, x, k2);  
q3 = vfmaq_n_f32(q3, x, k3);
```

同一批输入服务四个输出累加器，减少重复加载。凑不满向量的边界区域则走收尾路径。

Part 2 • TRSM


TRSM 的依赖

- 下三角方程要沿着对角线逐块求解：当前块算完，下一块才能继续
- 右端矩阵矮而宽时，独立的列块很多，可以把不同列块分给不同线程
- 右端矩阵高而窄时，列块不够分；先解出当前块，再并行更新后面的区域
- 大小完整的块使用 AArch64 汇编核；边缘剩下的小块用 NEON 代码处理

TRSM 的分块求解过程

TRSM 计算过程

三角依赖决定步骤顺序，线程放在已经求出解之后的尾随更新上



按矩阵形状分派

```
if (nrhs >= n) {  
    solve_by_columns(L, B, nrhs);  
} else {  
    solve_right_looking(L, B, n, nrhs);  
}
```

右端矩阵矮而宽时优先利用列并行，高而窄时转向右视分块，避免线程没有足够的独立列块可做。

对角块与更新阶段

```
solve_diagonal_block(Bc, Lc);  
#pragma omp parallel for schedule(dynamic)  
for (int b = bs; b < n; b += bs)  
    update_trailing_block(Bc, Lc, b);
```

先完成有依赖的对角块，再并行更新后面的区域。并行从依赖允许的位置开始。

完整块与边界块

```
if (mr == 4 && nr == 8)
    micro_asm_4x8(Ap, Bp, C);
else
    micro_neon_edge(Ap, Bp, C, mr, nr);
```

完整块使用 AArch64 汇编微核，边缘尺寸使用 NEON 兜底，兼顾主路径效率和任意尺寸的正确性。

Part 3 • ZGEMM

ZGEMM 的优化范围

- 我们重点优化行主序、A 和 B 都不转置的常用调用
- 一个复数乘法拆成实部和虚部的实数运算，方便用向量指令计算
- 打包 A 时顺手乘上 alpha；第一次读取 C 块时再处理 beta，减少内层循环的重复工作
- 其他存储方式或转置组合继续用通用代码处理，保证各种调用都能正确运行


ZGEMM

ZGEMM 计算过程

先展开复数乘法，再让打包、寄存器块和缓存复用都服务同一个内层循环

一个输出元素怎么算

$$C_{ij} \leftarrow \text{beta} \cdot C_{ij} + \text{alpha} \cdot \sum_k A_{ik} \cdot B_{kj}$$
$$A = a_r + i a_i \quad B = b_r + i b_i \quad \text{Re} += a_r \cdot b_r - a_i \cdot b_i \quad \text{Im} += a_r \cdot b_i + a_i \cdot b_r$$



数据打包与复数计算

```
// A、B 按微核需要的布局打包
pack_A(A, Ap);
pack_B(B, Bp);

// 复数乘法拆成实部和虚部的实数乘加
real = ar * br - ai * bi;
imag = ar * bi + ai * br;
```

先把 A 和 B 整理成连续布局，再把复数乘法拆成实部和虚部的实数乘加，便于使用 NEON。A 在打包时融合 alpha，第一次读取 C 小块时处理 beta。

4×2 复数微核

```
for (int k = 0; k < K; ++k) {  
    acc[0] += Ap[k] * Bp[2 * k + 0];  
    acc[1] += Ap[k] * Bp[2 * k + 1];  
}  
store_4x2(C, acc);
```

微核一次计算 C 中的一个 4×2 小块，把中间结果放在寄存器中持续累加，最后集中写回，减少数据搬运。

Part 4 · 总结

总结

- CONV: 不改每个输出点的计算顺序。把相邻的一小块输出放在一起算
- TRSM: 该按顺序算的地方按顺序算; 能同时更新的地方就交给多个线程
- ZGEMM: 提前把数据整理好, 让 CPU 少花时间找数据, 多花时间做计算

感谢聆听。