PerfXLab

# 异构计算软件栈进展

**张先轶**

PerfXLab 澎峰（北京）科技有限公司

xianyi@perfxlab.com

2023.6

# 澎峰介绍

- 公司由张先轶博士于**2016年**在北京创立。
- 团队致力于**算力基础软件**研究，十多年的领域积累，国内领先。
- 公司为行业伙伴提供**加速计算解决方案**，为各类计算平台提供**算力软件基座**。

- 2016年，中国计算机学会科技进步二等奖
- 2017年，中国科学院杰出科技成就奖
- 2018年，北京雏鹰人才计划，国家高新企业
- 2021年，数字中国·**集成电路赛道**特等奖
- 2021年，创芯中国·决赛一等奖
- 2021年，CRVA联盟，软件工作组副组长单位
- 2022年，OpenCAX SIG10组长单位
- 相关著作：《高性能科学与工程计算》，《OpenCL异构计算》，《并行编程模式》，《视频图像处理与性能优化》，《人工智能三驾马车》等


2016年中国计算机学会科技进步二等奖

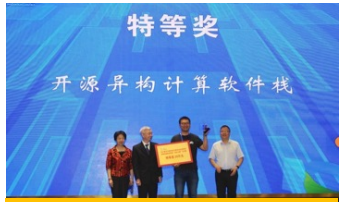


2021年**数字中国**.集成电路赛道


2020年RISC-V Global


2019年CRVA生态贡献奖


2016年中国计算机学会科技进步二等奖

# 全球开源矩阵计算库OpenBLAS介绍

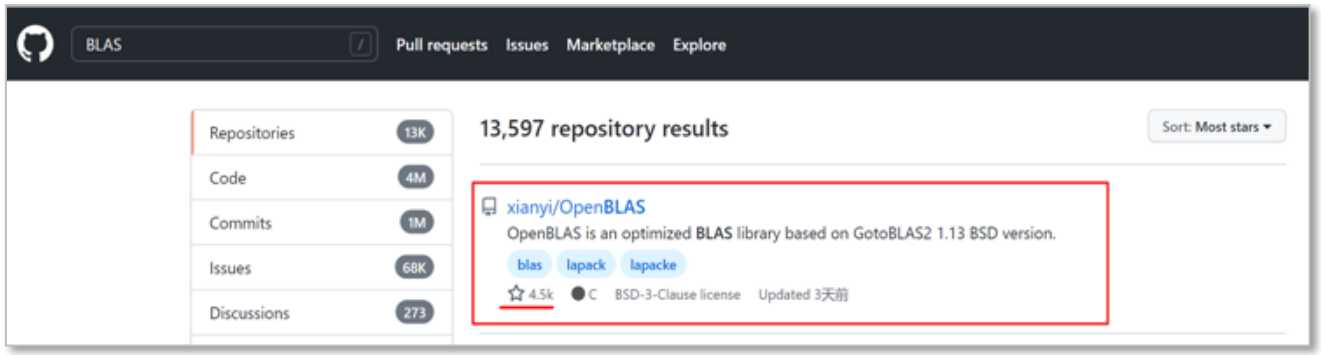


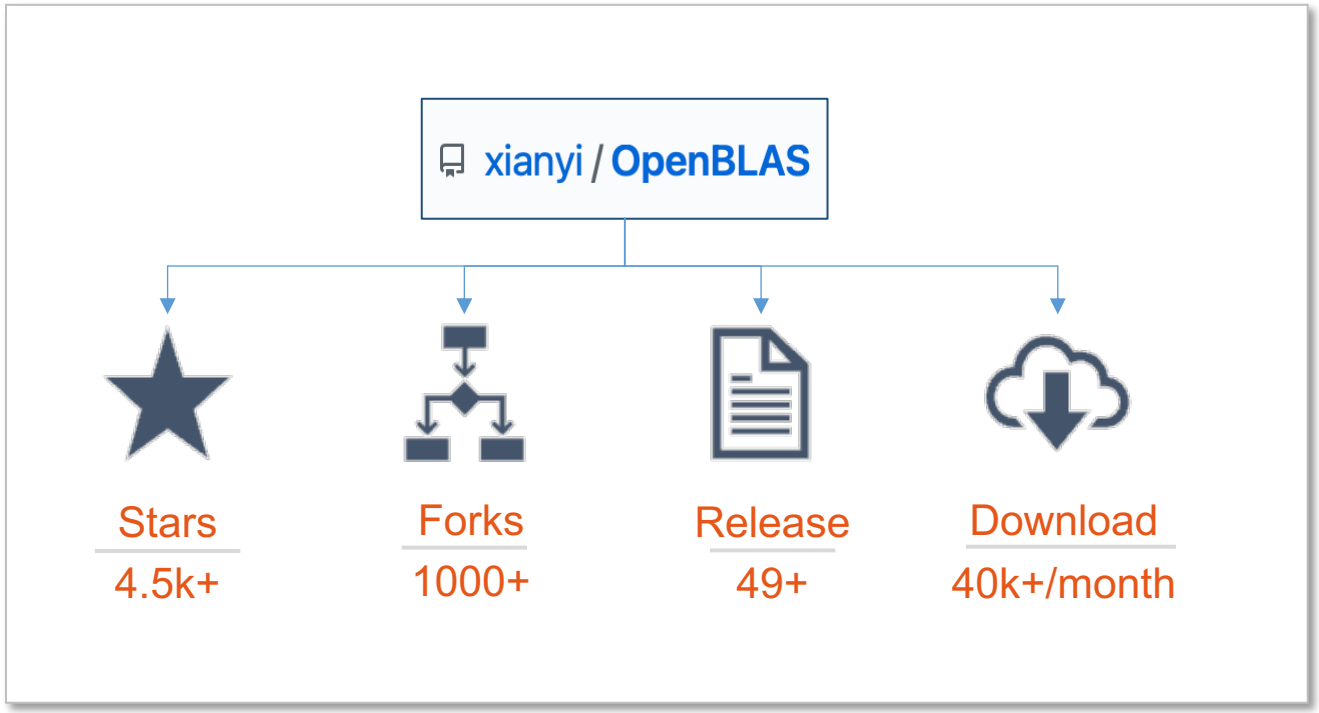


- OpenBLAS 是国际知名的开源矩阵计算库，同领域全球排名前三，由公司创始人张先轶博士（中国）在2011年发起并管理维护，是极少有的由中国人发起并管理的全球开源项目。也被下述项目或公司核心产品作为基础组件使用：

openSUSE　Caffe　GNU Octave　julia

Ubuntu openblas package　dmlc mxnet　PathScale　IBM

- OpenBLAS 是科学计算、人工智能等领域的基础软件和根技术。在支持国产CPU、GPU、DSA“大芯片”做出了卓越贡献，并得到了行业的认可。

# 异构计算语言OpenCL顾问委员会成员

**Khronos Group**
**Advisory Panel Participation Agreement**

**This agreement enables membership on**
**Advisory Panels for one or more Khronos Working Groups**

**PLEASE TYPE OR PRINT CLEARLY: THIS IS A LEGAL DOCUMENT**
**ILLEGIBLE AGREEMENTS CANNOT BE PROCESSED**

**Contact for processing this agreement:**

| | |
|---|---|
| **NAME:** | Xianyi Zhang |
| **COMPANY:** | PerfXLab Technology Co., Ltd. |
| **EMAIL:** | xianyi@perfxlab.com |
| **PHONE:** | +86-13466545921 |

**Guidelines for completing this agreement:**

1. This Advisory Panel agreement is normally executed by invited individuals, however if you wish to execute on behalf of a company/institute which is a legal entity that you are able to represent, and has been invited to participate in the Advisory Panel, you may execute this agreement on behalf of that entity and designate colleagues within that entity that will also be bound by this agreement and so able to access Advisory Panel resources.

2. Please enter your name, email address on this cover page and select the working groups to which you have been invited to advise on the signature page.

3. Select the tick box on the signature to confirm whether you are executing this agreement as an individual or on behalf of a legal entity. If you are executing this on behalf of an entity, then enter the name of the legal entity on this cover page and as the Signatory on the signature page (instead of your own name) and enter a list of Designated Colleagues in Attachment B. If the legal entity requires more than one authorized signatory, duplicate the signature page for each required signature.

4. Mail a copy **OR** email a PDF of the executed agreement to the contact address below. If mailed, send two signed copies and one completed copy will be returned for your records

**Contact Details:**
Khronos Group Member Services
Khronos Group Inc, 9450 SW Gemini Drive #45043, Beaverton, OR 970088-6018, USA
memberservices@khronos.org
Voice mail: +1 (415) 869-8627

Your **Advisory Privileges** will commence when Khronos has acknowledged receipt of the executed agreement.

Khronos Advisory Panel Participation Agreement V13 Dec21 1

**Advisory Panel Participation Agreement**
**Signature Page**

| **For Khronos** | **For Signatory** |
|---|---|
| 9450 SW Gemini Drive #45043, Beaverton, OR 97008-6018 USA | Xianyi Zhang (Signatory name) |
| | Room 304, Cuihu Building 9#, No.55 Zique Road (Street address) |
| | Beijing, 100190, China (City, State, ZIP, Count) |
| [redacted] | [redacted] |
| Emily Stearns (Printed Name) | Xianyi Zhang (Printed Name) |
| Managing Director (Title) | (Title (if applicable)) |
| emily@khronosgroup.org (Email Address) | xianyi@perfxlab.com (Email Address) |
| March 16, 2023 (Date of Signature) | Mar 16, 2023 (Date of Signature) |

**Tick ONE of the following boxes:**

☐ Signing on behalf of legal entity as entered as Signatory above (and see Attachment B)

☒ Signing as individual as entered as Signatory above

**Selected Working Groups:**

Working groups in the Graphics and Compute IP Zone:

☐ Vulkan ☒ OpenCL ☐ SYCL ☐ Vulkan SC

今年三月，张先轶博士受邀加入异构计算语言OpenCL顾问委员会。

# 异构计算软件栈

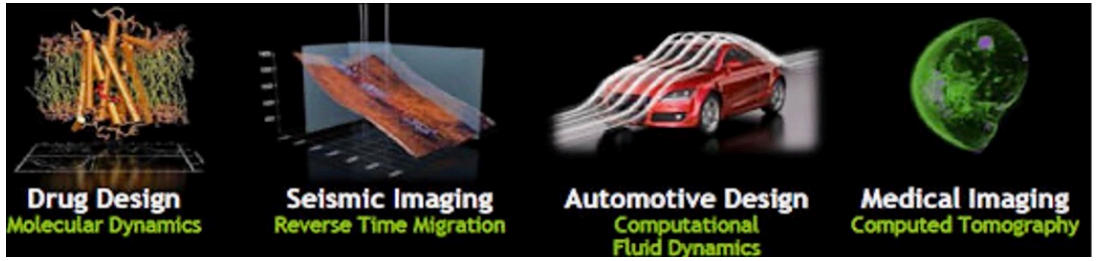


ChatGPT

异构计算编程

异构计算库与框架

开发工具

高性能异构计算平台

x86/ARM/RISC-V CPU, GPU、NPU/DSA、FPGA

# 异构计算编程模型

- 异构计算语言
- CUDA （2007）
  - 异构计算代名词
- Brook+ (2007)
  - BrookGPU
  - 有事烧纸
- OpenCL (2009)
  - 试图与CUDA竞争
- SyCL (2014)
  - Intel新宠
- OpenACC (2012)
  - 类似CPU编程，类似CPU的性能

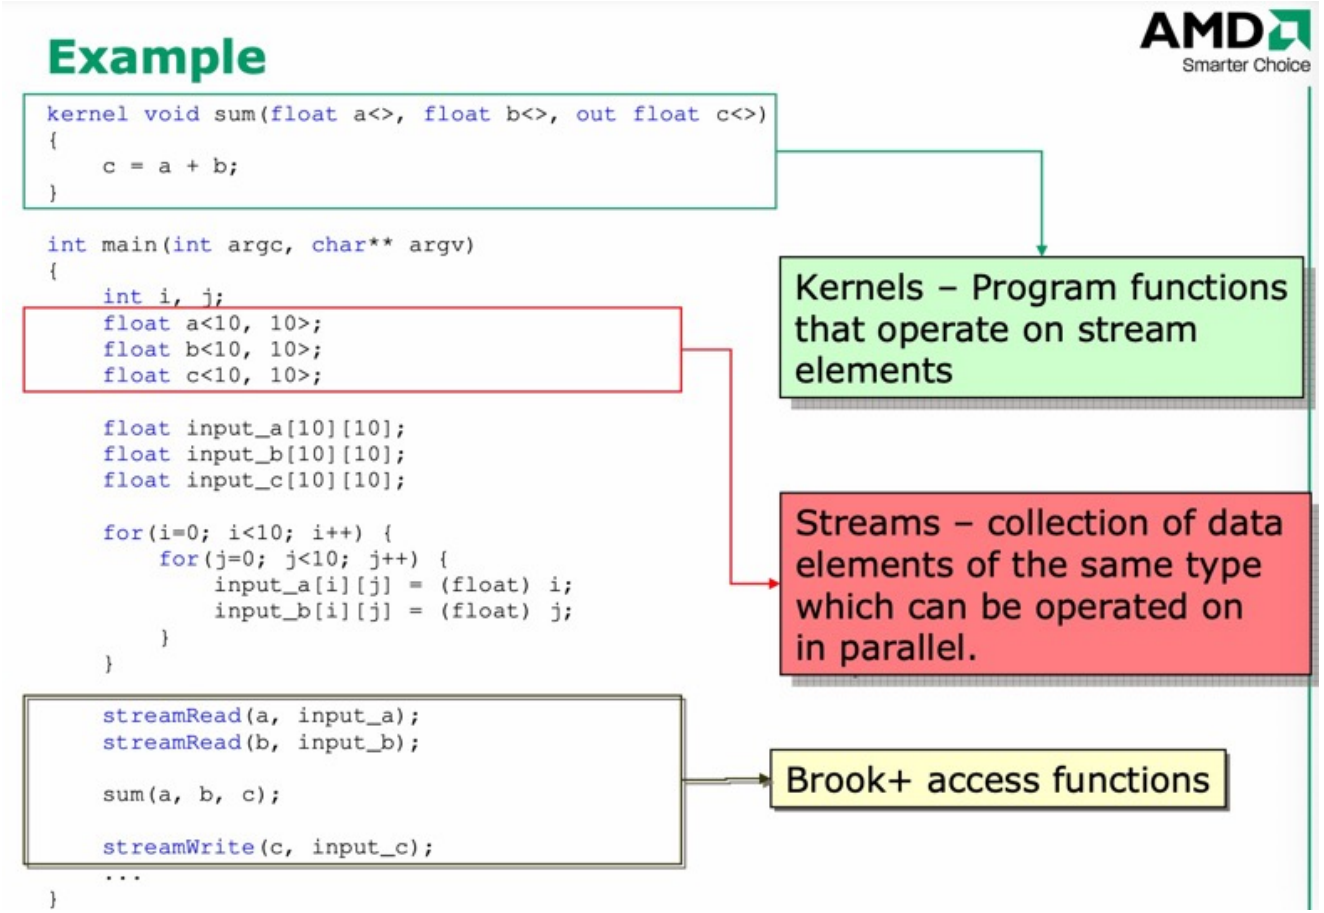

# CUDA vs OpenCL 编程模型差别不大

PerfXLab

- CUDA和OpenCL 编程模型相差不大
  - OpenCL相对繁琐一些

- 开放标准和开源就能胜利吗？

- OpenCL 标准自身的弯路
  - OpenCL 2.0标准，大量芯片公司不支持
    - 编程模型与硬件体系结构密切相关
    - 2.0加入的大量功能特性，不实用

  - 基于广泛使用的1.2，发展3.0

## OpenCL 3.0 Specification Finalized and Initial Khronos Open Source OpenCL SDK Released

September 30, 2020 by OpenCL Working Group opencl

Today, the Khronos® OpenCL™ Working Group is happy to announce the release of the finalized OpenCL 3.0 specifications, including a new unified OpenCL C 3.0 language specification, together with an early initial release of a Khronos OpenCL SDK to enable developers to quickly get up to speed using OpenCL.

# CUDA vs OpenCL的库和框架生态差距大

PerfXLab

- 库/框架差距巨大
  - LAPACK/Magma
  - PETSc
  - OpenCV
  - FFmpeg
  - AI框架等（PyTorch/PaddlePaddle/Oneflow…）
  - …
- 直接写CUDA的人不多，但是用支持CUDA库和框架的人很多

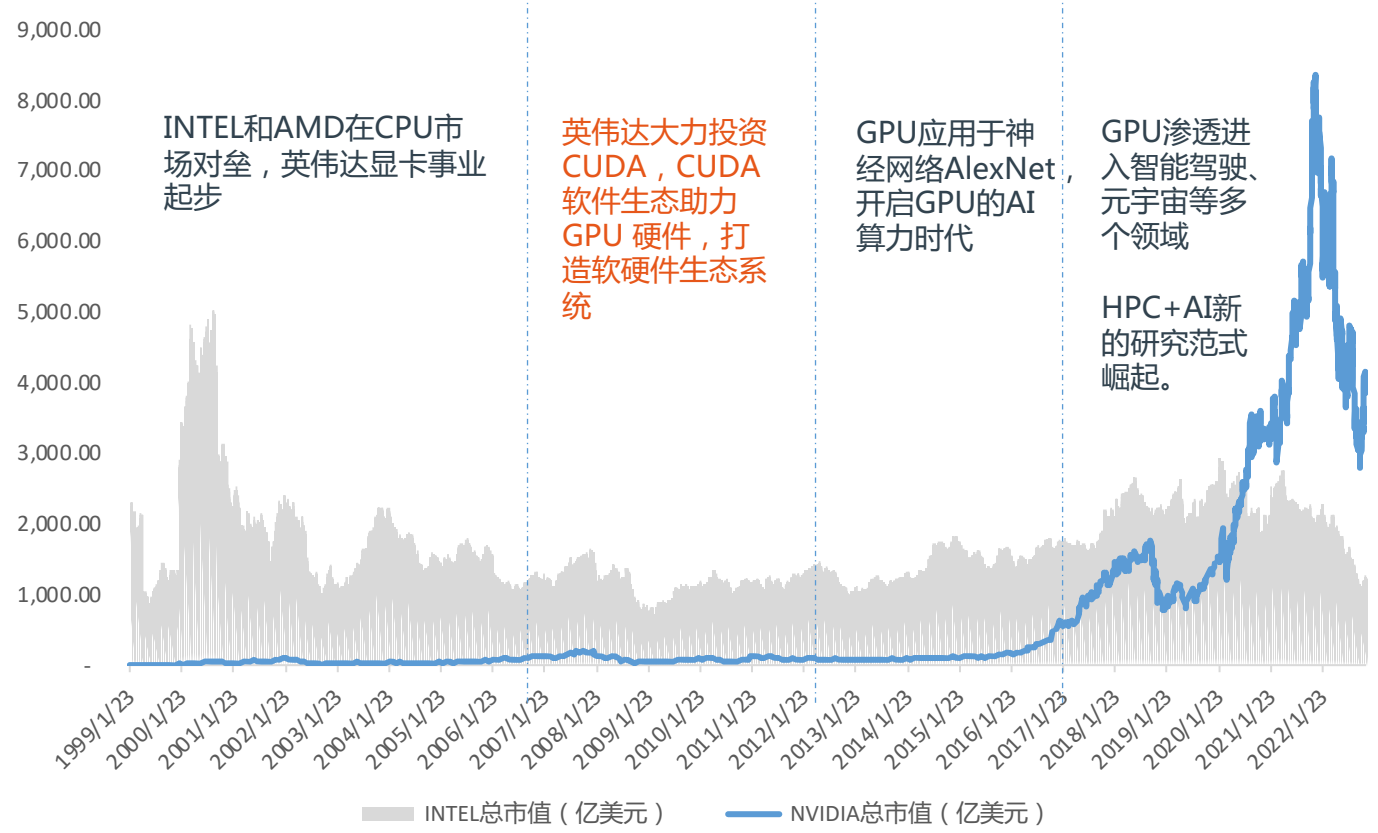

# 已有计算领域软件生态（库/框架）

- Intel公司
  - MKL库（数学库、几千个函数）
    - 稠密矩阵计算BLAS/LAPACK
    - 快速傅里叶变换FFT
    - 稀疏矩阵计算 SparseBLAS
    - 稀疏解法器（直接、迭代）
    - 随机数发生器
    - 向量数学库VML
    - 统计加速..
  - DAAL库（数据分析）
  - IPP库（图像、信号处理）
  - MKL-DNN库（深度学习）
  - 持续增长、持续优化

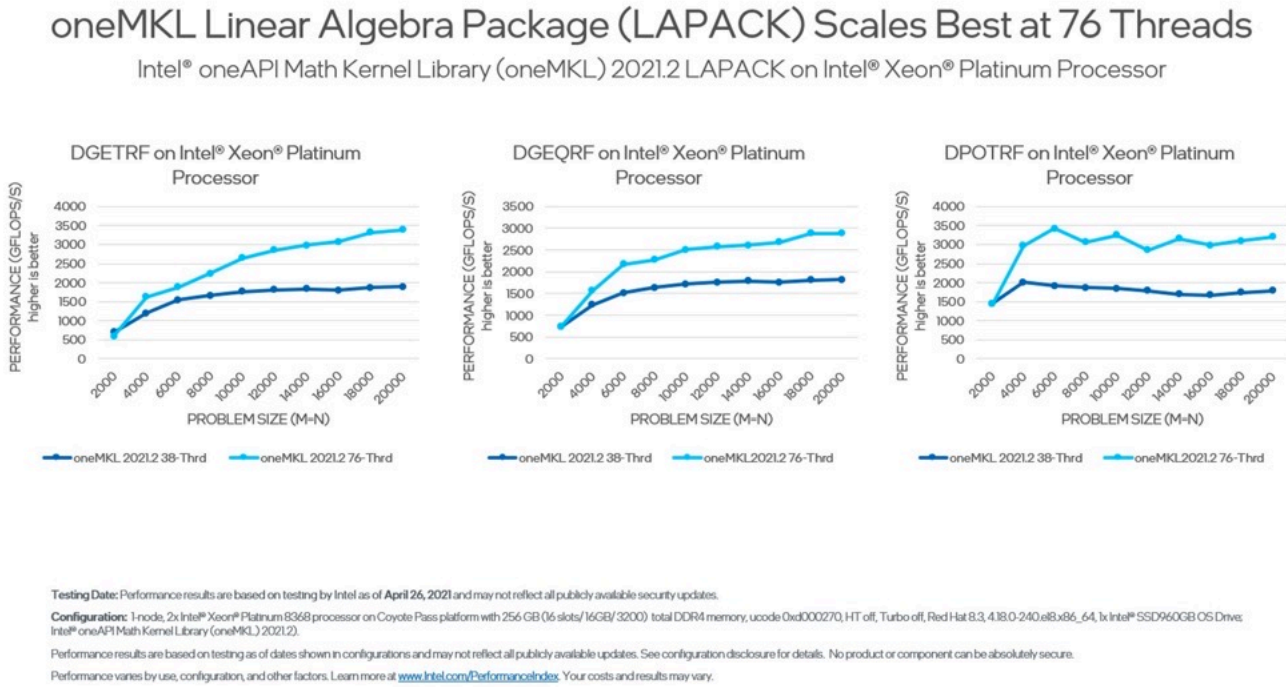

# 已有计算领域软件生态（库/框架）

- ARM公司
  - APL库
    - 稠密矩阵计算BLAS/LAPACK
    - 快速傅里叶变换FFT
    - 64-bit ARM，包含ARM Neoverse (SVE指令集)
  - ACL库
    - ML应用
    - ARM CPU/GPU

- NVIDIA公司
  - CUDA-X， GPU加速库、框架和工具等
  - 数学库、并行算法库、图像视频库
  - 通信库、深度学习库等

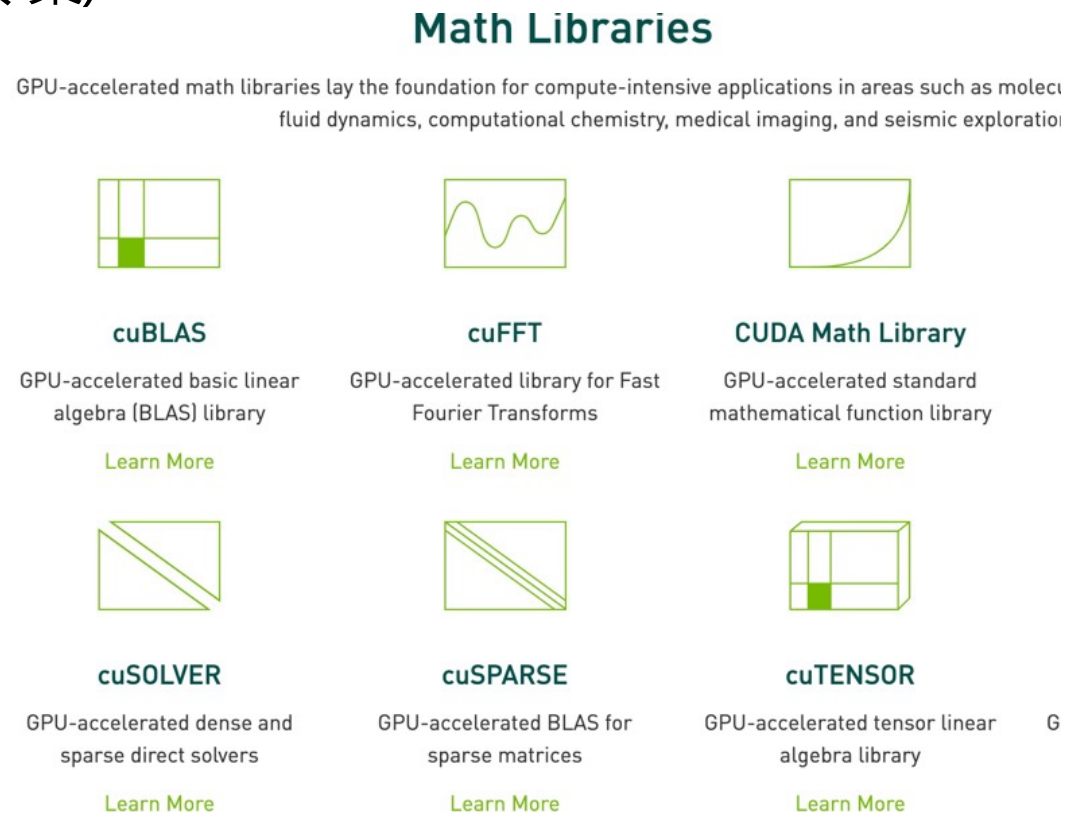

# 国内计算芯片的生态现状

PerfXLab

- 老牌HPC强队
  - 科学计算领域已有一定积累
  - 异构编程方式和库API等，各家一套

- 新兴AI芯片公司
  - 兼容CUDA
  - 独立自研

中国芯 ? 算力时代的开启与爆发

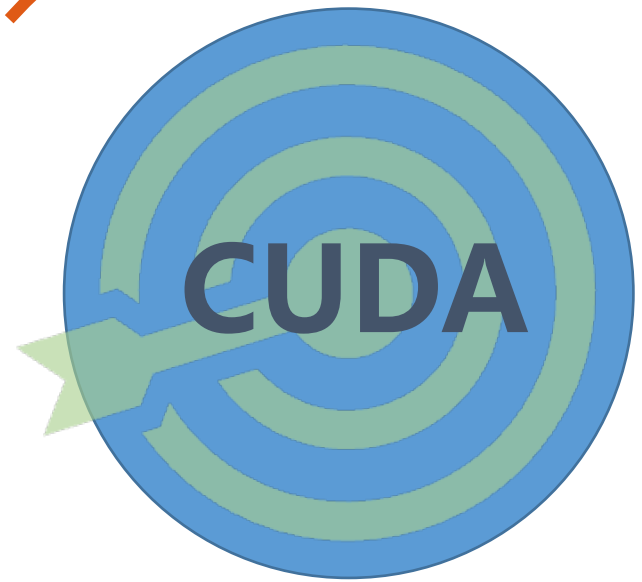


- 人工智能
- 工业软件
- AI for Science

2022年相继收购
Codeplay，Arrayfire

Intel
OneAPI

AMD
ROCm

PerfXLab

# 参与开源，共建生态，立足国内，走向国际

# PerfXAPI异构计算软件栈

**PerfXAPI** 围绕应用侧需求，是旨在创建一个开放、基于开源标准的**跨架构**API编程模型，在面对大量跨各种架构的硬件和复杂工作负载时简化开发工作。特性： 1）支持多种异构设备；2）统一API调用接口；3）高性能

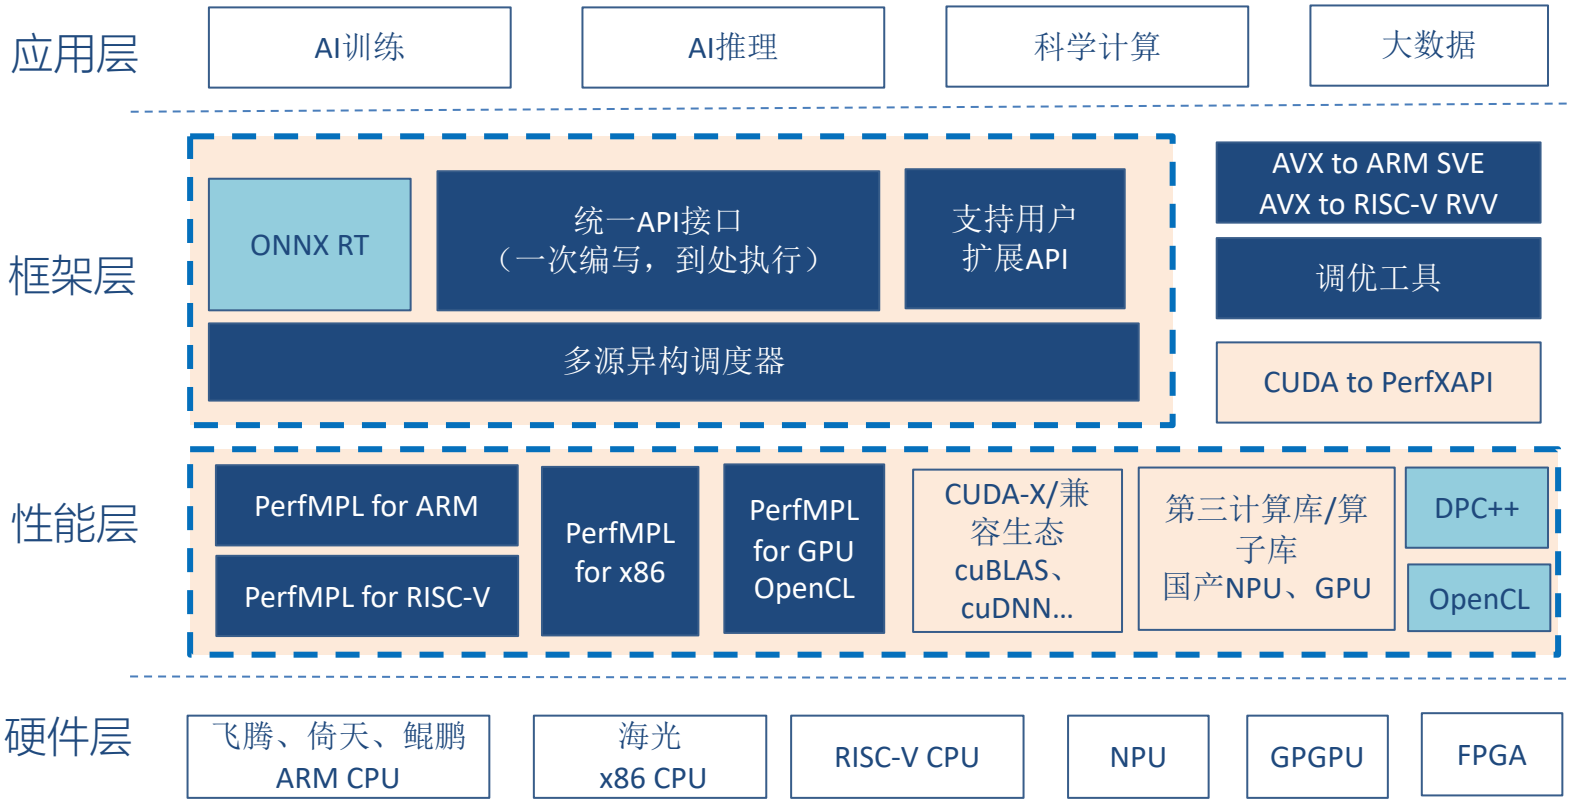


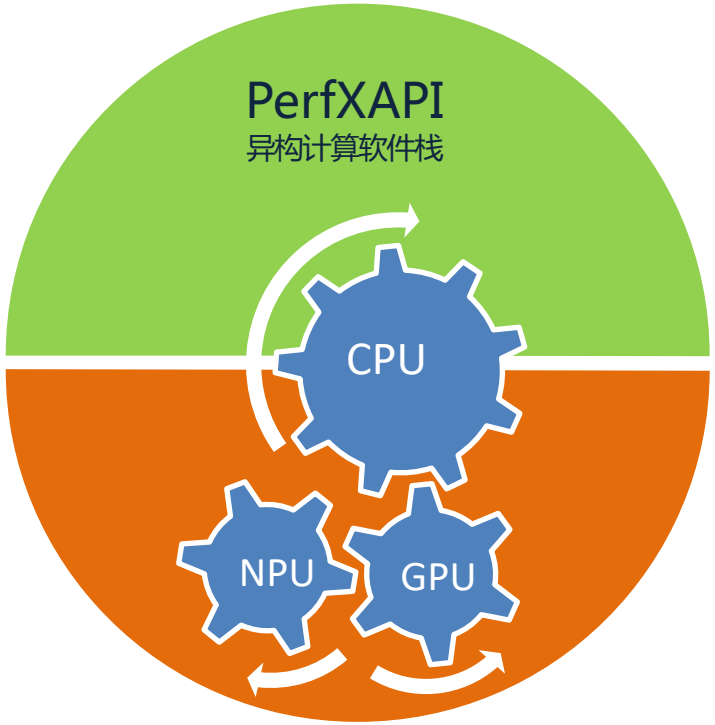

# 高性能数学库PerfMPL

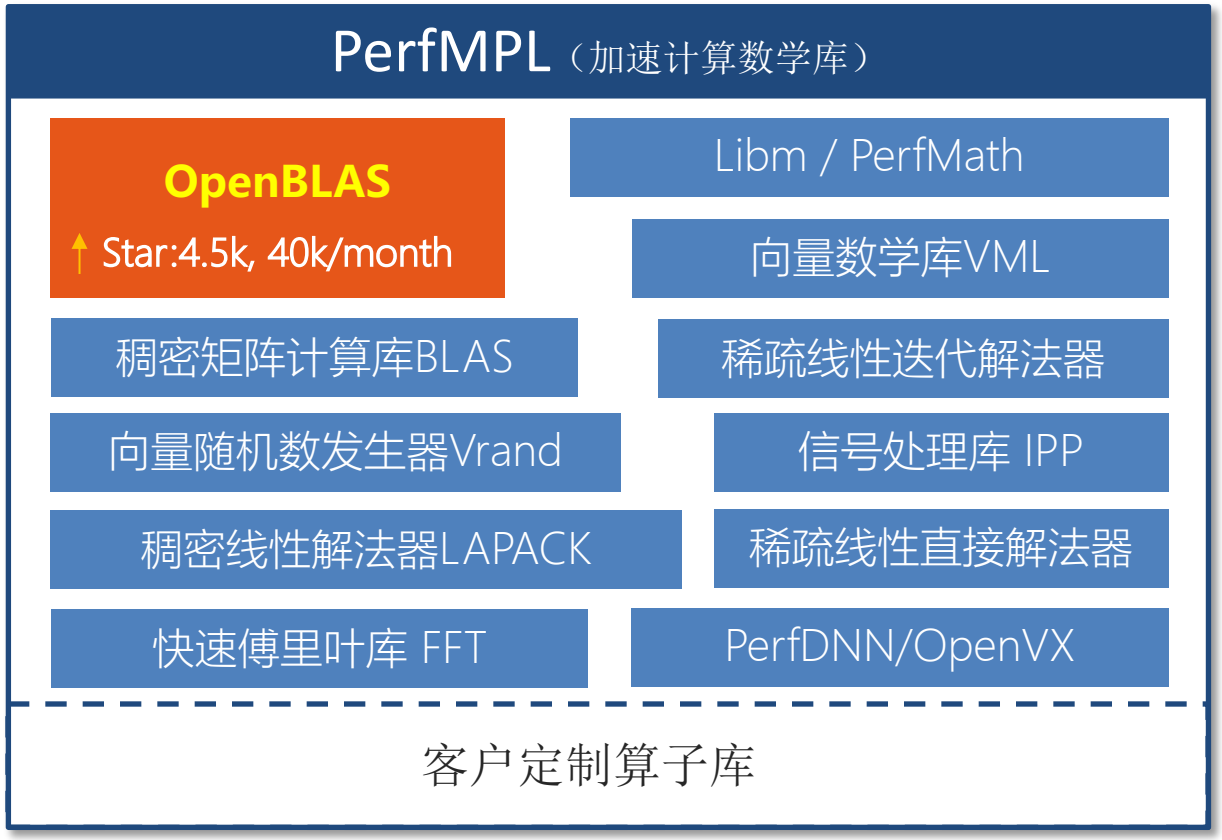


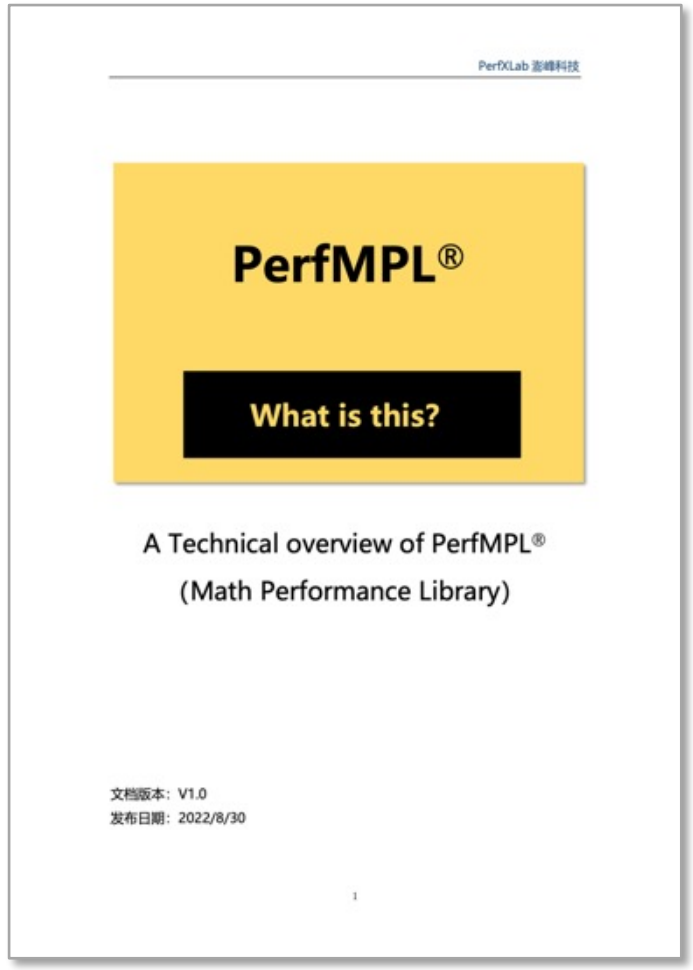


- **标准版本**：PerfMPL for ARM，PerfMPL for RISC-V（RVCL）
- **领域版本**：为应用领域提供定向优化。例如EDA、CFD、VSIPL、CV、Big Data等。
- **定制版本**：为国产GPU/NPU厂商提供PerfMPL的定制服务，对标 cuBLAS，cuFFT，cuMath...。

# OpenBLAS项目

PerfXLab

- **开源矩阵计算库，12年历史**
  - https://github.com/xianyi/openblas
- **矩阵和向量基本计算**
  - 当前版本：0.3.21
- **支持主流处理器**
  - X86/ARM/Power/龙芯
- **支持多种操作系统**
  - Linux/Windows/Mac OSX/Android
- **目前支持RISC-V架构**
  - 已经支持C910 RVV指令优化（RVV 0.7.1，1.0进行中）
  - RVV 1.0进行中


Caffe IBM Ubuntu openblas package openSUSE debian VERSATUShpc 平头哥 HYGON 中科海光 dmlc mxnet julia PathScale GNU Octave 網易 NETEASE www.163.com HUAWEI 360 www.360.com LOONGSON 龙芯 国家超级计算济南中心 NATIONAL SUPERCOMPUTER CENTER IN JINAN

# OpenBLAS RVV 1.0支持进展

- BLAS 1级/2级
  - 向量化采用intrinsic实现
  - 已经支持RVV 1.0 intrinsic规范
- BLAS 3级
  - 当前向量化采用内嵌汇编实现，RVV 0.7.1
  - 9月份开始，进行RVV 1.0移植

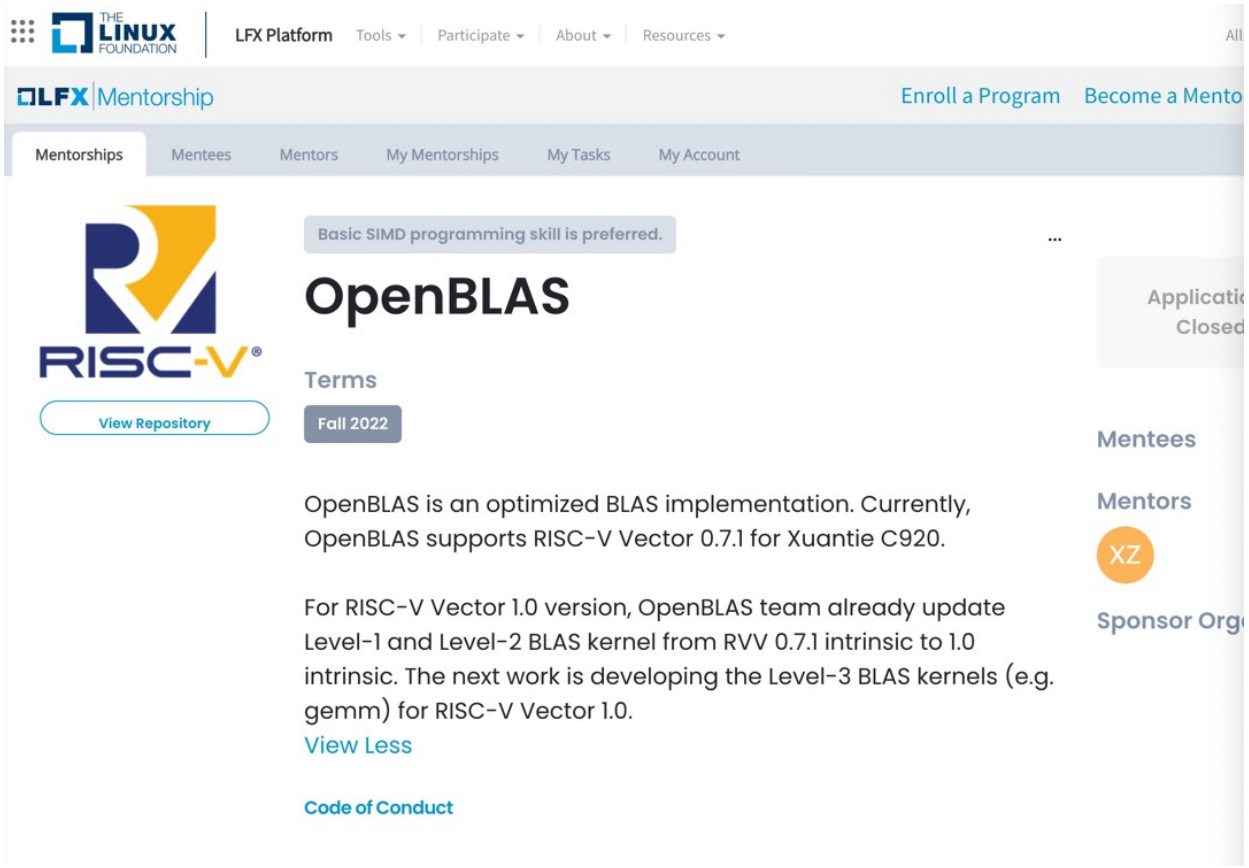

# 高性能FFT库OpenFFT/PerfFFT

- **自主研发(不基于FFTW)，版权协议可控**
  - 采用Cooley-Tukey FFT算法
  - 核心代码纯汇编编写，高效实现了$2^m*3^n*5^k*7^j*11^i*13^l$
  - 支持多种精度、多种维度、包括复数和实数在内的多种变换类型
- **支持主流处理器，性能优秀**
  - X86/ARM/RISC-V

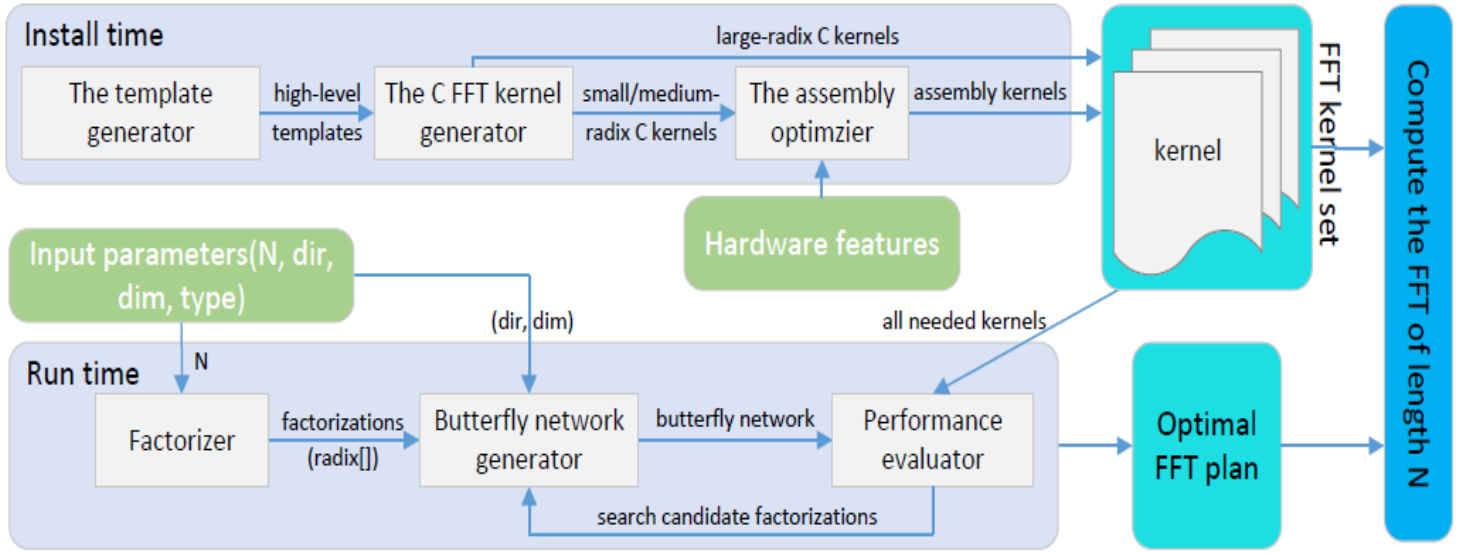


**典型应用**

- 信号与信息处理使用傅里叶变换应用非常广泛。所以，FFT运算能力已经成为处理器的性能标尺之一。
- 例如图像领域中的压缩，

**OpenFFT相对其他FFT库性能提升**

| | Intel Xeon E5-2670 V3 | ARMV8 |
|---|---|---|
| Intel MKL 2019 | 60% ↑ | *NA* |
| ARM PL | *NA* | 72% ↑ |
| FFTW | 138% ↑ | 61% ↑ |

# 高性能FFT库OpenFFT/PerfFFT

- 数据访存——读取方便
  - ➢实部、虚部交替存储
  - ➢二维数组列优先存储
    - 实部虚部之间的计算——冗余指令
  - ➢行优先读取


```
vlseg<nf>e.v vd, (rs1)
# offset = sew/8
# for (k = 0; k < nf; k++)
#   V_(d+k)[i] = mem[rs1 + k*offset + i*nf*offset]
```

```
v0[0]=mem[x5],       v0[1]=mem[x5+4],
v0[2]=mem[x5+8],     v0[3]=mem[x5+12]
v1[0]=mem[x5+16],    v1[1]=mem[x5+16+4],
v1[2]=mem[x5+16+8],  v1[3]=mem[x5+16+12]
```

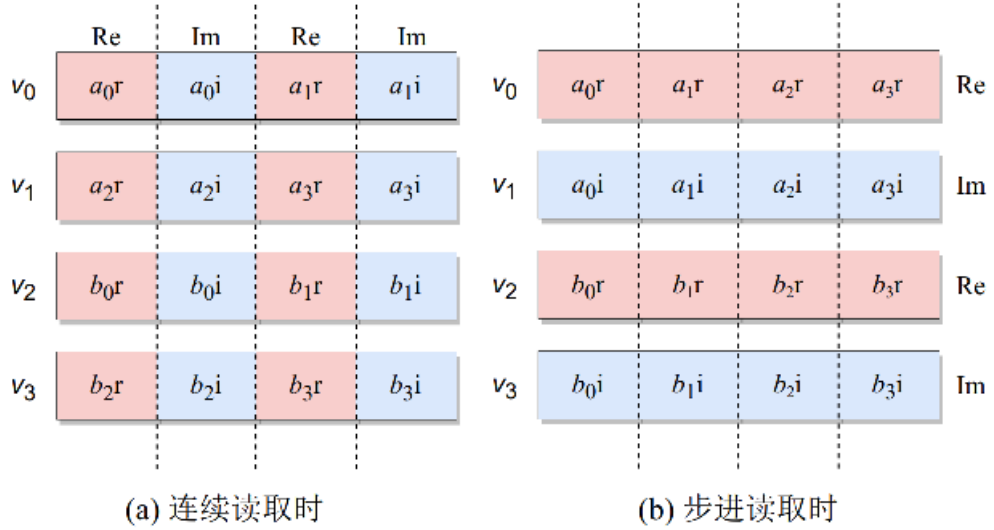

# 高性能数学库（PerfMPL）on ARM CPU

优势：1）性能对标国际；2）一致精度；3）安全、可靠、稳定。

双精度实数 GEMM NN单线程性能 (越高越好)

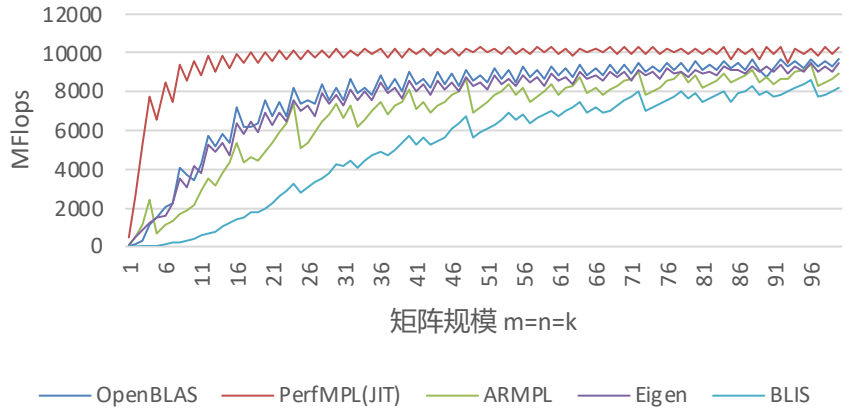


**华为鲲鹏920**

1D FFT C2C Out-of-Place单线程性能（越高越好）

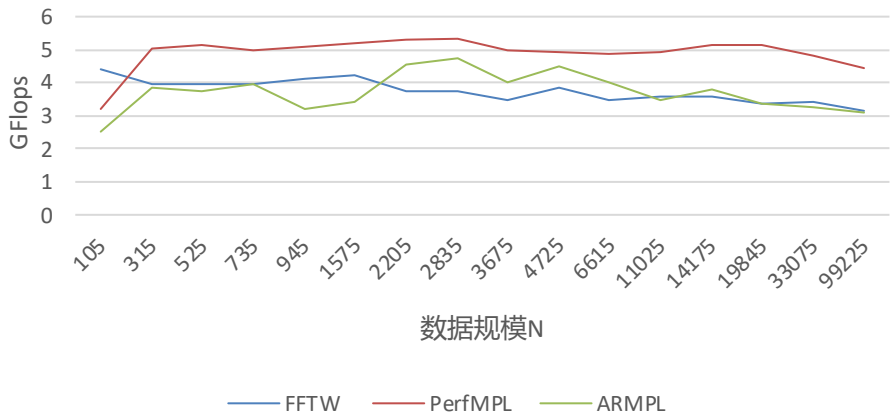


**FT-2000（ARM）**

1D FFT C2C InPlace单线程性能（越高越好）

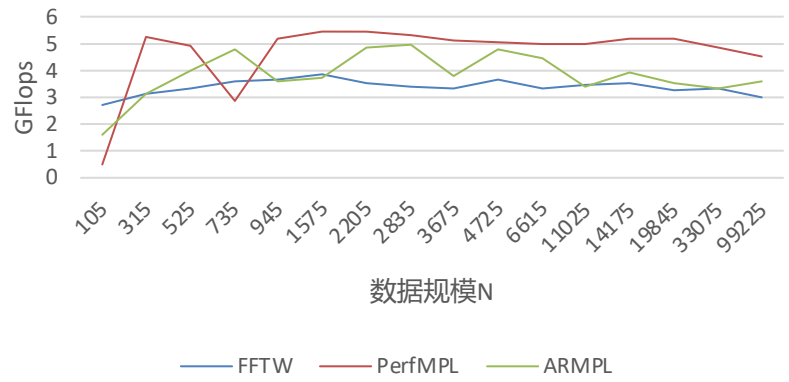


**FT-2000（ARM）**

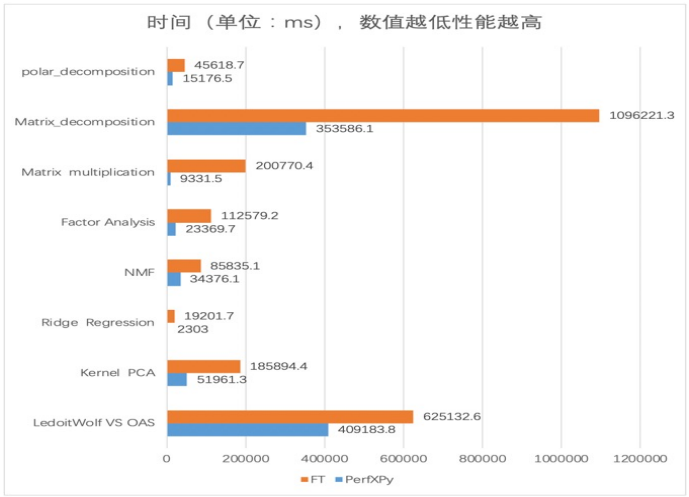


**FT-2000/4**

PerfMPL应用在PerfXPy科学计算软件上，与原生Python比较，带来性能大幅提升。

# 高性能数学库（PerfMPL）on RISC-V

优势：1）性能对标国际；2）一致精度；3）安全、可靠、稳定。

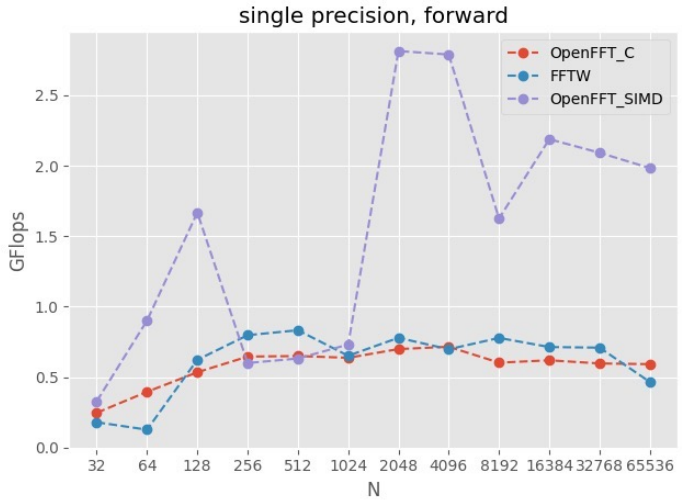


**RISC-V C920**

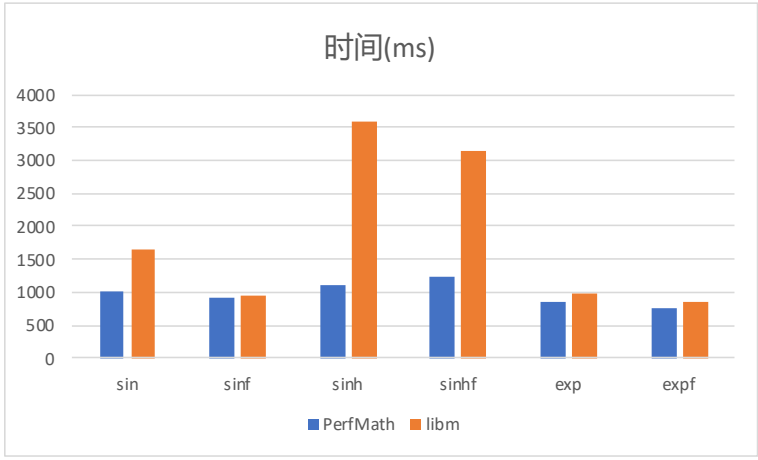


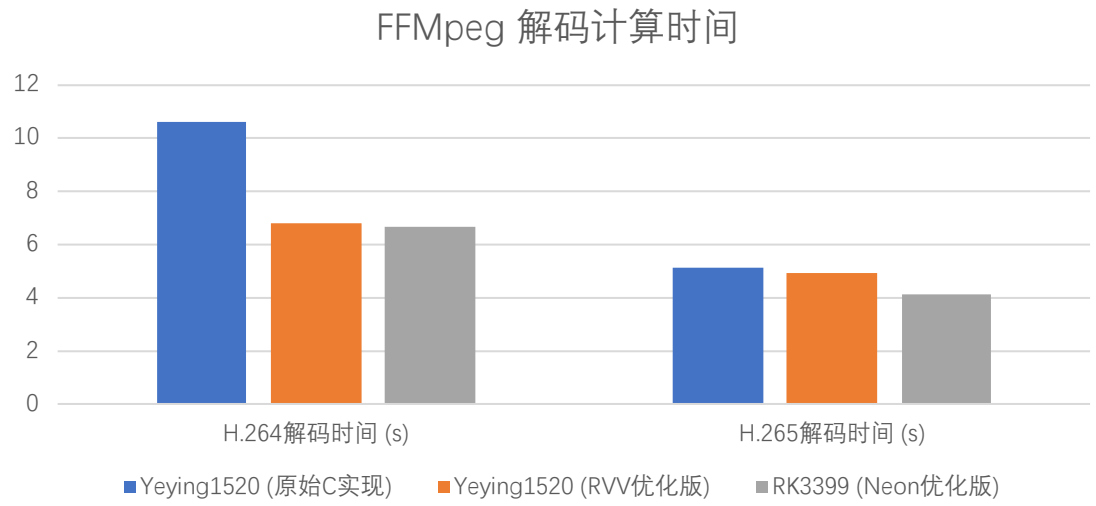


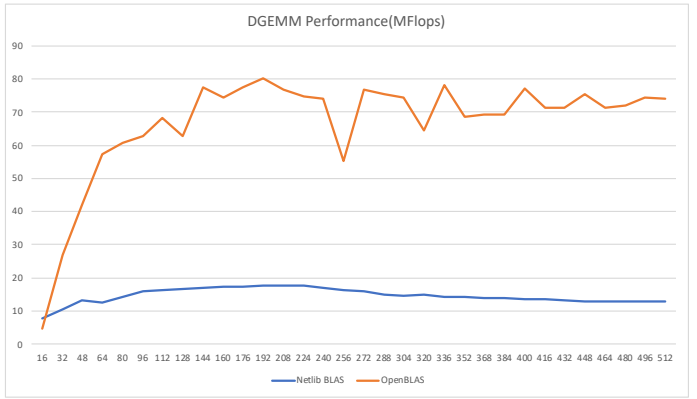

# 高性能数学库（PerfMPL）on OpenCL GPU

- GPU型号：景嘉微9230
  - 支持OpenCL 3.0
  - FP32峰值性能：1.2T FLOPS

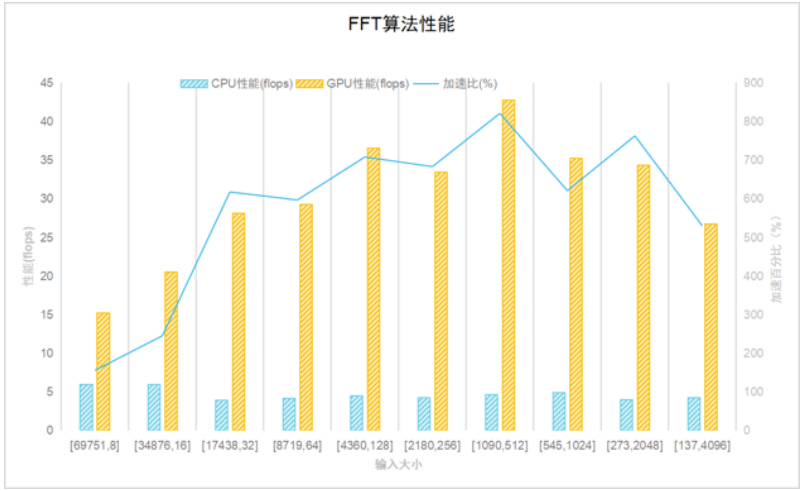


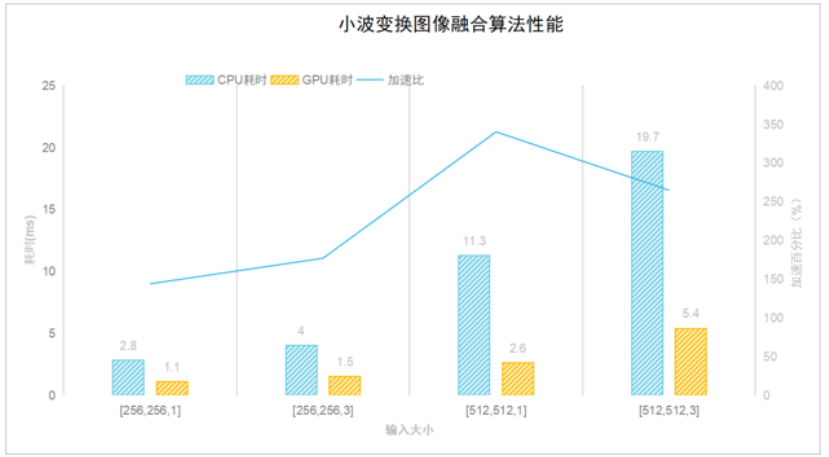


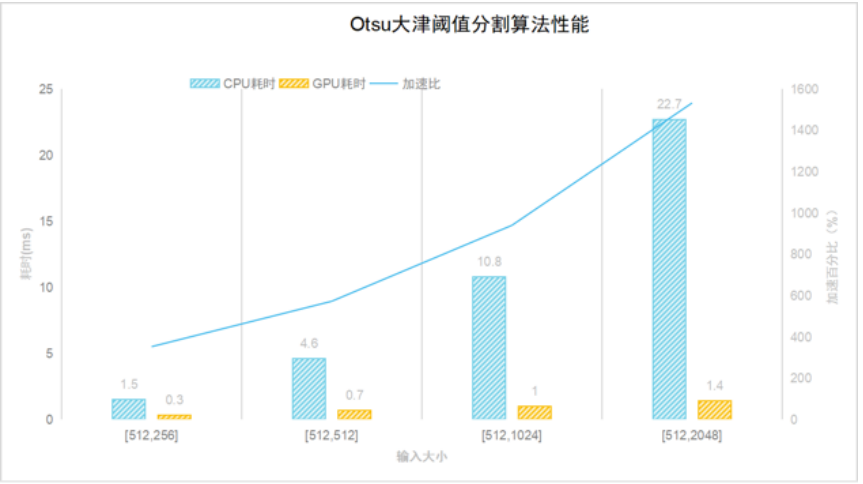


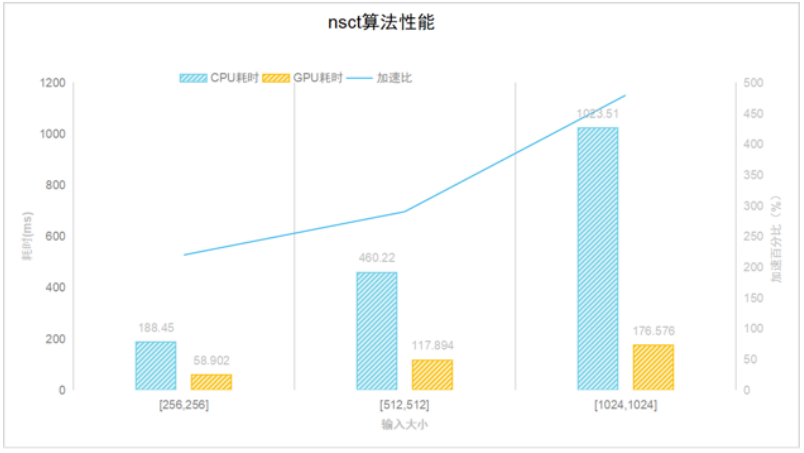


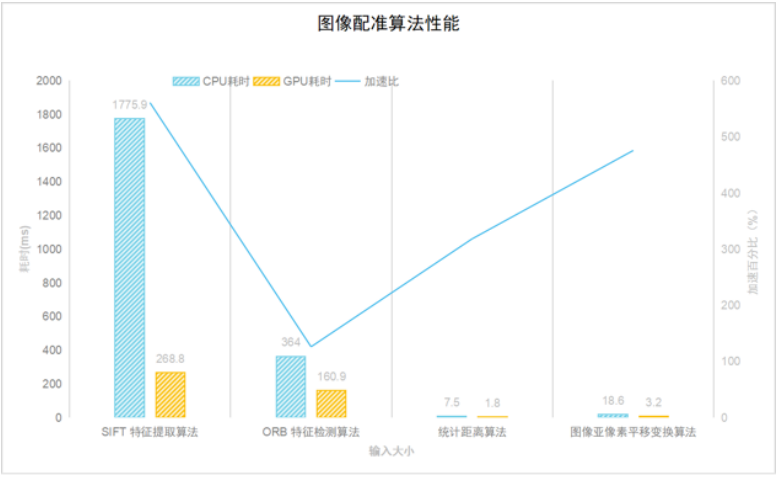

# AI推理框架 – InferXLite 基于ONNXRuntime

PerfXLab

- NPU硬件平台多样
  - 支持的算子种类不同
    - Onnx opset ?
  - 精度区别，int8? Fp16? Fp32?

- 人工参与过多
  - 模型转化工作大,学习成本高
    - 各个芯片厂商都提出一套自己的工具链
  - 手工拆分图
    - 不同子图运行到不同的NPU上
  - 支持不同的训练框架
    - PyTorch, Tensorflow, PaddlePaddle,

# ONNXRuntime介绍

PerfXLab

- 微软领导开源项目
  - https://github.com/microsoft/onnxruntime
- 跨平台
- ONNX格式
  - Opset 版本更新最快
- 已支持多种后端
  - CPU (x86, ARM)
  - GPU (NVIDIA, AMD)
  - FPGA (Xilinx Vitis AI)
  - …
- 支持新算子注册模式

ORT架构图

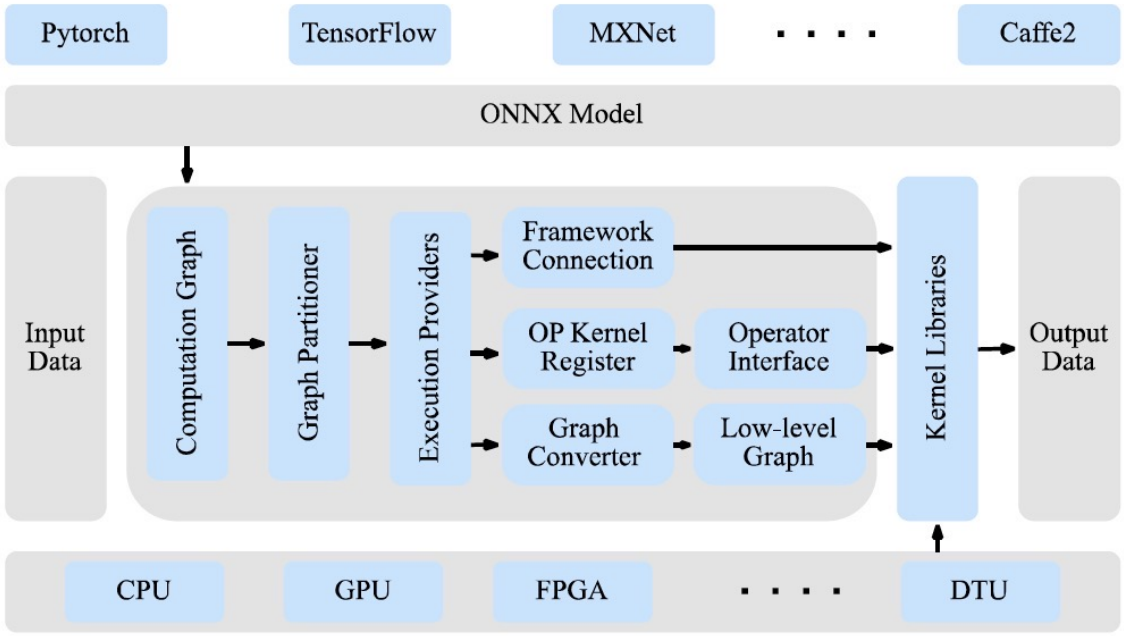

# AI推理框架 – InferXLite工作

- 支持更多国产异构硬件
  - 燧原I20（已完成）
  - 华为Atlas（已完成）
  - OpenCL GPU（初步完成）
  - 寒武纪（进行中）

- 增强易用性和性能
  - 面向异构设备的自动切图
  - 设备相关图优化等

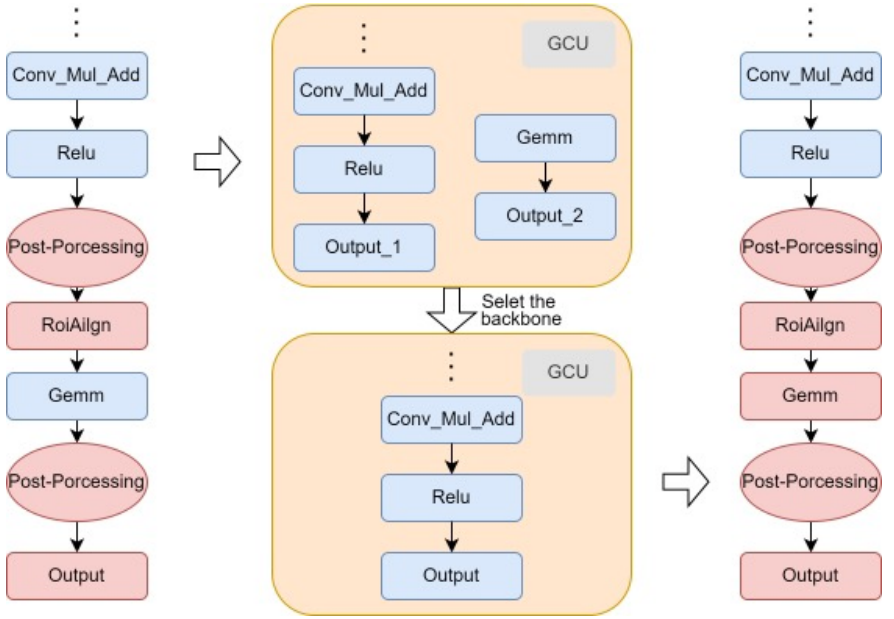


常量折叠

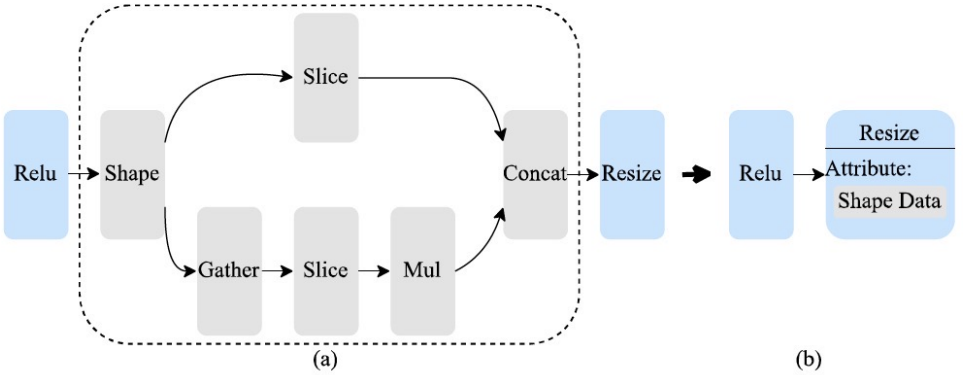

# 智能计算案例 – AI推理框架OpenCL加速

AMD V1605B APU + **InferXLite 2.0** **VS** NVIDIA TX2

- **YOLO网络性能对比**

| 网络类型 | 规模 | V1605B FP16 (单位：FPS) | V1605B FP32 (单位：FPS) | NVIDIA TX2 (单位：FPS) |
|---|---|---|---|---|
| YOLOv3 | 320*320 | 12.9 | 7.6 | 4.7 |
| | 416*416 | 9.2 | 6 | 2.9 |
| | 608*608 | 4.8 | 3.1 | 1.5 |
| YOLOv2 | 320*320 | 28 | 18.5 | 10.8 |
| | 416*416 | 16.6 | 13.8 | 6.7 |
| | 608*608 | 8.7 | 7.7 | 3.6 |
| YOLOv3-tiny | 320*320 | 70 | 43 | 24 |
| | 416*416 | 58.7 | 27 | 19 |
| | 608*608 | 25.4 | 16.7 | 10 |
| YOLOv2-tiny | 320*320 | 84.2 | 58.6 | 25 |
| | 416*416 | 62.5 | 46.5 | 20 |
| | 608*608 | 28 | 23.3 | 11.1 |

- **应用效果（视频演示）**

# PerfXPy 新一代科学计算软件

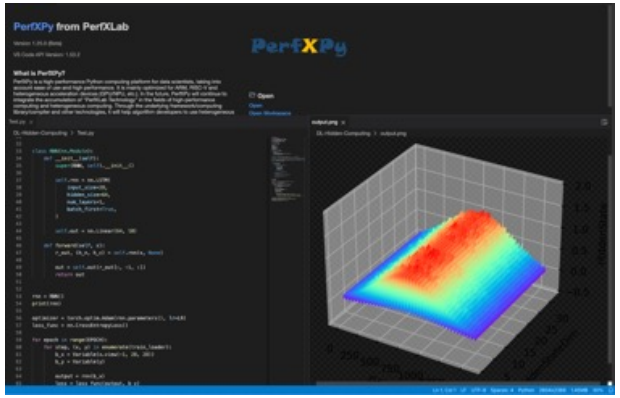

科学计算

AI计算

**PerfXPy** 是一个面向**科学家**和**算法工程师**的高性能**Python**计算平台，兼顾易用性与高性能，支持ARM、RISC-V 通用算力平台和异构加速平台。多个版本：单机版（免费），SaaS版本，集群版本。

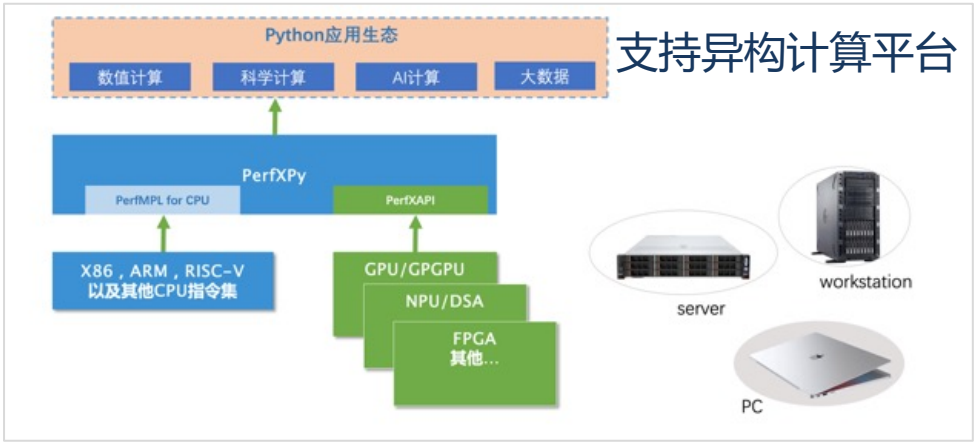


支持异构计算平台

在更多高校展开实施

**产学研新范式**

过去

PerfXPy **算法建模** MATLAB Julia ...

PerfXPy **算法实现** CUDA Python ...

PerfXPy **算法部署** CUDA Python C/C++

- 支持国产硬件
- 一键迁移，发挥极致计算性能。
- 传统科学计算工具对国产硬件基本不支持。

# 总结

- 计算软件栈
  - 芯片与上层应用（AI、工业软件）桥梁
  - 国外投入巨大，生态成熟

- 发展思路：开源 + 商业
  - 参与开源，共建生态
  - 商业发行版等

- 澎峰的工作
  - 高性能数学库PerfMPL，解决计算性能
  - 异构计算框架PerfXAPI，解决跨平台/异构
  - 高性能Python计算平台PerfXPy，解决易用性

PerfXLab

# 感谢各位

## 期待与各位交流，为计算软件生态发展贡献力量

## 欢迎全职/兼职/实习生