

Calculet Runtime API C++ 开发文档

系统和应用

Exported on 07/10/2026

Table of Contents

1	安装	6
1.1	编译环境	6
1.2	安装步骤	6
1.3	快速上手	6
2	API 参考	9
2.1	模块	9
2.1.1	配置	9
2.1.1.1	加载calbin文件	9
2.1.1.2	获取模型 – 按照名字	9
2.1.2	设备管理	10
2.1.2.1	创建设备	10
2.1.2.2	创建虚拟设备	10
2.1.2.3	重置设备	10
2.1.2.4	设置设备电源模式	10
2.1.2.5	清除设备配置数据	11
2.1.2.6	获得设备信息	11
2.1.2.7	获得设备运行状态	11
2.1.3	Buffer	11
2.1.3.1	创建缓冲	11
2.1.3.2	获得缓冲信息	12
2.1.3.3	获得并修改tensor张量信息	12
2.1.3.4	获得并修改当前超参数信息	12
2.1.3.5	等待推理完成并读取结果	13
2.1.3.6	相关buffer指定Tensor切片	13
2.1.3.7	重置Tensor设置	13
2.1.3.8	获取传输输入数据的时间开销	14
2.1.3.9	获取传输输出数据的时间开销	14

2.1.3.10 获取推理时间.....	14
2.1.3.11 动态设置Tensor地址.....	14
2.1.4 推理.....	15
2.1.4.1 推理接口.....	15
2.1.5 Calbin.....	15
2.1.5.1 创建calbin.....	15
2.1.5.2 获得calbin文件信息.....	16
2.1.5.3 获得模型信息.....	16
2.1.5.4 获得LLM 信息.....	16
2.1.5.5 打印kv-cache specs.....	16
2.1.6 内存管理.....	16
2.1.6.1 注册设备内存.....	17
2.1.6.2 分配内存.....	17
2.1.6.3 拷贝用户内存到设备内存.....	18
2.1.6.4 拷贝用户数据到设备指定chip.....	18
2.1.6.5 拷贝指定chip内存到用户.....	19
2.1.6.6 拷贝设备内存到用户内存.....	19
2.1.6.7 写设备寄存器.....	19
2.1.6.8 读设备寄存器.....	20
2.1.6.9 释放设备内存.....	20
2.1.7 错误处理.....	21
2.1.7.1 CALRT_CHECK.....	21
2.1.7.2 REPORT_CALRT_ERROR.....	21
2.1.7.3 REPORT_CALRT_ERROR_IF.....	21
2.1.7.4 CALRT_LOG.....	21
2.1.8 Bug Replay.....	22
2.1.8.1 设置重现或debug方式.....	22
2.2 数据结构.....	22
2.2.1 结构体.....	22

2.2.1.1	CalrtCalbin	22
2.2.1.2	CalbinModel	23
2.2.1.3	CalbinSection_s.....	23
2.2.1.4	CalbinLLM_s.....	24
2.2.1.5	KV_Cache_s.....	25
2.2.1.6	CalbinTensorInfo_s	25
2.2.1.7	CalrtDevBuf_s.....	26
2.2.1.8	CalrtBufferInfo_s	26
2.2.1.9	TaskInfo_s	27
2.2.1.10	CalrtDeviceId_s	27
2.2.1.11	CalrtDeviceInfo_s	27
2.2.1.12	ModelHyperParameters_s.....	28
2.2.2	类.....	28
2.2.2.1	Calbin	28
2.2.2.2	CalrtInputBuf	28
2.2.2.3	CalrtOutputBuf	28
2.2.2.4	CalrtDevice	28
2.2.2.5	CalrtEmuDevice.....	28
2.2.2.6	CalrtPcieDevice	28
2.2.2.7	VirtualDevice	29
2.2.2.8	CalrtJobEngine.....	29
2.2.2.9	CalrtAllocator	29
2.2.2.10	CalrtDriver.....	29
2.2.2.11	CalrtJob	29
2.2.2.12	CalrtTensor.....	29
2.3	数据类型	29
2.3.1	枚举	29
2.3.1.1	CalDevAccType_e	29
2.3.1.2	ModelChipMode_e	30

2.3.1.3	CalbinSectionPlace_e	30
2.3.1.4	PrimitiveType	32
2.3.1.5	CalrtBufferDirection_e	34
2.3.1.6	TaskType_e	34
2.3.1.7	CalJobAlloStatus_e.....	35
2.3.1.8	CalrtError_e.....	35
2.3.1.9	CalrtDeviceType_e	38
2.3.1.10	CalrtOutputBufStatus_e.....	38
2.3.1.11	CalrtLogVerbosity_e.....	39
2.3.1.12	PowerMode	39
2.3.1.13	DebugOps_e	39
3	修改历史 Changing Log	41

1 安装

1.1 编译环境

- Linux 系统 (AlmaLinux7 或更高版本)
- C++17 编译器

1.2 安装步骤

1. 下载 Calculet Runtime API 源代码 (后续应该会改为提供镜像网站，不提供源码)
 - a. 提供public header files
 - b. cmake文件
 - c. .so文件

2. 解压缩源代码包

- a. 后续改为镜像网站后，则只需要在运行自己的cmakelist时候加入

```
cmake -DCMAKE_PREFIX_PATH=https://mirror.company.com/calrt/v1.0.0 ..
```

3. 使用Cmakelist工具生成lib。在hostrt目录下执行

install .so file

```
cmake -S . -B build -DBUILD_SHARED_LIBS=ON
cmake --build build --config Release -j #开发版本不需要加入 “--config Release”
cmake --install build (在PLD中，需sudo执行)
```

4. 在你的project的 CMakeLists.txt中加入如下命令。
 - a. 如果安装在系统默认环境路径中，即没有-DCMAKE_INSTALL_PREFIX=PATH。

```
find_package(calrt REQUIRED)
```

- b. 如果安装在自定义路径下，

```
find_package(calrt REQUIRED PATHS "path")
```

1.3 快速上手

更多例子可访问 [原粒半导体](https://calculet.com/cn/)¹

¹ <https://calculet.com/cn/>

example

```

#include "calrt.hpp"

#include <memory>
#include <thread>
#include <vector>

void inference(calrt::VirtualDevice *vDev, calrt::CalbinModel *model,
calrt::CalrtInputBuf* inputBuffer, calrt::CalrtOutputBuf* outputBuffer)
{
    calrt::infer(vDev, model, inputBuffer, outputBuffer);
    outputBuffer->wait();
}

void threadFunc(calrt::VirtualDevice *vDev, calrt::CalbinModel &model)
{
    std::unique_ptr<calrt::CalrtInputBuf> pIbuf = calrt::createInputBuf(model);
    std::unique_ptr<calrt::CalrtOutputBuf> pObuf = calrt::createOutputBuf(model);
    uint32_t input[1024]; // Example input buffer size, adjust as needed

    for(auto &tensor : pIbuf->GetTensors())
    {
        // Fill input data here
        uint32_t *data = (uint32_t*)tensor.GetDataPtr(); // char * to uint32_t *

        for(size_t i = 0; i < 1024; i++)
        {
            data[i] = input[i]; // Assuming input is filled with appropriate data
        }
    }

    inference(vDev, &model, pIbuf.get(), pObuf.get());
}

int main()
{
    auto pCalbin = calrt::Calbin::CreateParser("...");

    auto vdevice = calrt::VirtualDevice::CreateVDevice();
    calrt::configure(vdevice.get(), pCalbin.get());

    std::vector<calrt::CalbinModel> models = pCalbin->GetAllModels();
    calrt::CalbinModel modelA = models[0];
    std::unique_ptr<std::thread> threads[2];
    for(int i = 0; i < 2; i++)
    {
        threads[i] = std::make_unique<std::thread>(&threadFunc, vdevice.get(),
std::ref(modelA));
    }
}

```

```
for(int i = 0; i < 2; i++)
{
    if(threads[i]->joinable())
    {
        threads[i]->join();
    }
}

return 0;
}
```

2 API 参考

这部分由3部分构成: [模块](#), [数据结构](#) (see page 22) and [数据类型](#) (see page 29)

2.1 模块

2.1.1 配置

2.1.1.1 加载calbin文件

```
CalrtError_e configure(VirtualDevice *vDev, Calbin *pParser)
```

```
CalrtError_e configure(std::unique_ptr<VirtualDevice> &vDev, Calbin *pParser)
```

配置calbin配置信息 (模型参数等) 到设备上

2.1.1.1.1 参数

vDev – calculet 设备指针。指针类型可为 [VirtualDevice](#) (see page 29) and [CalrtDevice](#) (see page 28)

2.1.1.1.2 返回值

[CalrtSuccess](#) (see page 35), [CalrtErrorInvalidConfiguration](#) (see page 35)

2.1.1.1.3 描述

返回值 [CalrtSuccess](#) 如果配置成功

2.1.1.2 获取模型 – 按照名字

```
CalbinModel* GetModelByName(std::string_view modelName)
```

根据模型名字获取模型相关信息。

2.1.1.2.1 参数

modelName – 模型名字

2.1.1.2.2 返回值

[CalbinModel](#) (see page 23)

2.1.2 设备管理

这一部分描述如何管理Calculet设备。通过 [CalrtDevice](#) (see page 28) 提供的接口即可完成相应的操作。

2.1.2.1 创建设备

```
static std::unique_ptr<CalrtDevice> CreateDevice()  
static std::unique_ptr<CalrtDevice> CreatePCIEDevice()
```

创建CalrtDevice类，映射为一个实体设备。

2.1.2.1.1 返回值

[std::unique_ptr<CalrtDevice>](#) (see page 28) –unique pointer 描述的CalrtDevice对象

2.1.2.2 创建虚拟设备

```
static std::unique_ptr<VirtualDevice> CreateVDevice() #创建当前可用设备，优先选择PCIe设备  
static std::unique_ptr<VirtualDevice> CreateVDevice(CalrtDeviceType_e type) #创建指定类型设备
```

创建VirtualDevice类，

2.1.2.2.1 返回值

[std::unique_ptr<VirtualDevice>](#)

2.1.2.3 重置设备

```
void Reset()
```

重置设备为出场模式。

2.1.2.4 设置设备电源模式

```
void SetPowerMode(PowerMode power)
```

设置设备电源模式。暂不支持

2.1.2.4.1 参数

[PowerMode](#) (see page 39)

2.1.2.5 清除设备配置数据

```
void ClearAllDevMem()
```

清除设备所有配置数据，即清除设备上的calbin

2.1.2.6 获得设备信息

```
std::string GetDevInfo()
```

获得设备信息，如内存使用情况，核心频率等

2.1.2.7 获得设备运行状态

```
CalrtError_e Status()
```

获得设备运行状态

2.1.2.7.1 返回值

[CalrtSuccess](#) (see page 35), [CalrtErrorDeviceBusy](#) (see page 35)

2.1.3 Buffer

这一部分描述跟缓冲相关的runtime内容。其主要用于推理和携带数据信息

2.1.3.1 创建缓冲

```
std::unique_ptr<CalrtInputBuf> createInputBuf(const CalbinModel &model)
std::unique_ptr<CalrtOutputBuf> createOutputBuf(const CalbinModel &model)
```

创建输入缓冲或输出缓冲

2.1.3.1.1 参数

`model` – [CalbinModel](#) (see page 23) 从 [Calbin](#) (see page 15) 对象中获得

2.1.3.1.2 返回值

`std::unique_ptr<CalrtInputBuf>` ([see page 28](#))

`std::unique_ptr<CalrtOutputBuf>` ([see page 28](#))

2.1.3.2 获得缓冲信息

```
const CalrtBufferInfo_s& GetBufferInfo() const
```

获取 i/o 缓冲的信息

2.1.3.2.1 返回值

[CalrtBufferInfo_s](#) (see page 26)

2.1.3.3 获得并修改tensor张量信息

```
std::vector<CalrtTensor>& GetTensors()
```

获取i/o 缓冲中张量信息，并可以拷贝相应 形状的数据到张量中。

2.1.3.3.1 返回值

[CalrtTensor](#) (see page 29)

2.1.3.3.2 描述

With `CalrtTensor.GetDataPtr()`, it return a `char *` for input data or get output data.

2.1.3.4 获得并修改当前超参数信息

```
ModelHyperParameters_s &GetCurHyperParam()
```

获得并修改当前超参数信息。

2.1.3.4.1 返回值

[ModelHyperParameters_s](#) (see page 28)

2.1.3.4.2 注意

在CNN模型下该结构体为无效结构体。此接口只在 `CalrtInputBuf` 中提供。

2.1.3.5 等待推理完成并读取结果

```
CalrtError_e Wait()
```

阻塞接口，用于提交推理任务后，等待推理完成并读回推理结果。

2.1.3.5.1 注意

此接口只在 `CalrtOutputBuf` 中提供。

2.1.3.5.2 返回值

[CalrtSuccess](#) (see page 35)

2.1.3.6 相关buffer指定Tensor切片

```
CalrtError_e SliceTensorByName(void *src, const std::string &tensorName, uint64_t offset, uint64_t size)
```

可截短tensor传输数据大小和数据所在tensor的位置。以减少数据传输的时间开销。

2.1.3.6.1 注意

参数offset永远会以tensor中buffer起始位置做偏移。不会被之前的设置的offset影响

2.1.3.6.2 返回值

[CalrtSuccess](#) (see page 35)

2.1.3.7 重置Tensor设置

```
void ResetTensorByName(const std::string &tensorName)
```

重置tensor的传输size跟offset值为默认值。

2.1.3.8 获取传输输入数据的时间开销

| `float GetInputTransferTime()`

获取input传输数据时间开销。返还单位为 ms

2.1.3.8.1 注意

只有CalrtInputBuf类提供该接口

2.1.3.9 获取传输输出数据的时间开销

| `float GetOutputTransferTime()`

获取output传输数据时间开销。返还单位为 ms

2.1.3.9.1 注意

只有CalrtOutputBuf类提供该接口

2.1.3.10 获取推理时间

| `float GetWaitTime()`

获取纯推理时间。（考虑改名为 GetInferTime更为贴切）。返还单位为 ms

2.1.3.10.1 注意

只有CalrtOutputBuf类提供该接口

2.1.3.11 动态设置Tensor地址

| `CalrtError_e RelocateTensorAddress(const std::string &tensorName, uint64_t altAddr)`

重新设置相关buffer的指定tensor在设备上的地址。需要通过 VirtualDevice类的接口

`uint64_t AllocDevMem(uint64_t size, uint32_t alignLog2Byte=0)` 来动态开设备内存空间。或者 CalrtDevice类的接口

`uint64_t CreateBuf(uint64_t size, uint32_t alignLog2Byte=2)`来动态开设备空间内存

2.1.3.11.1 返回值

[CalrtSuccess](#) (see page 35)

2.1.4 推理

这一部分描述推理相关的接口

2.1.4.1 推理接口

```
void infer(std::unique_ptr<VirtualDevice> &vDev, CalbinModel *model,
CalrtInputBuf* inputBuffer, CalrtOutputBuf* outputBuffer);
```

2.1.4.1.1 参数

vDev – [VirtualDevice](#) (see page 29) virtual device manages one or multiple physical device.

model – [CalbinModel](#) (see page 23) try to infer specific model

inputBuffer – [CalrtInputBuf](#) (see page 28) runtime input buffer pointer

outputBuffer – [CalrtOutputBuf](#) (see page 28) runtime output buffer pointer

2.1.4.1.2 描述

非阻塞接口。用于通知单个或多个设备开始推理。通过 `CalrtOutputBuf.Wait()` 来等待推理完成并获取推理结果。

2.1.5 Calbin

这部分描述calbin对象中提供的接口。主要用于解析calbin文件和提供相关calbin中的文件信息。

2.1.5.1 创建calbin

```
static std::unique_ptr<Calbin> CreateCalbin(const std::string &path)
```

创建calbin对象。

2.1.5.1.1 参数

path –calbin文件的路径信息。

2.1.5.1.2 返回值

`std::unique_ptr<Calbin>` 一个unique_ptr Calbin类型指针。

2.1.5.2 获得calbin文件信息

`CalrtCalbin& GetCalbinBrief()`

获得calbin文件对应的结构体数据信息。

2.1.5.3 获得模型信息

`std::optional<CalbinModel> GetModelInfo(const char *modelName)`

`std::vector<CalbinModel> GetAllModels()`

两种calbin对象的成员接口均可提供calbin文件中，关于模型的相关结构体信息。不同在于，第一种可获取指定模型信息，第二种可获取全部模型信息。

2.1.5.4 获得LLM 信息

`const CalbinLLM_s &GetLLMInfo()`

获取最大batch size和最大sequence length。

2.1.5.4.1 返回值

[CalbinLLM_s](#)

2.1.5.5 打印kv-cache specs

`void Report()`

打印kv-cache 配置信息。

2.1.6 内存管理

这一部分主要描述内存管理相关的接口。所有的接口均是 [CalrtDevice](#)² 成员函数。

² https://file+.vscode-resource.vscode-cdn.net/c:/Users/YulinYang/Desktop/yulin_250731/subpage/class.md#calrtdevice

2.1.6.1 注册设备内存

```
CalrtError_e RegisterDram(uint64_t startAddr, uint64_t size)
```

注册设备动态随机存取存储器(DRAM)空间。

```
CalrtError_e RegisterSyncUnit(uint64_t startAddr, uint64_t size)
```

注册设备同步单元(sync unit)。

```
CalrtError_e RegisterSramBuf(uint64_t startAddr, uint64_t size)
```

注册设备静态随机存取存储器(SRAM)空间。

2.1.6.1.1 参数

startAddr -- 注册内存起始地址

size -- 注册内存大小。以byte为单位

2.1.6.1.2 返回值

[CalrtSuccess](#) (see page 35), [CalrtErrorMemoryAlreadyRegistered](#) (see page 35)

2.1.6.1.3 用法

```
/*CalrtDevice pointer*/ device_ptr->RegisterDram(0x1000, 32);
```

2.1.6.2 分配内存

```
uint64_t CreateBuf(uint64_t size, uint32_t alignLog2Byte=0)
```

```
uint64_t AllocDevMem(uint64_t size, uint32_t alignLog2Byte=0)
```

动态分配设备动态随机存取存储器(DRAM)空间。

```
uint64_t CreateSramBuf(uint64_t size, uint32_t alignLog2Byte=0)
```

动态分配设备静态随机存取存储器(SRAM)空间。

```
uint64_t ApplySyncUnit()
```

动态分配设备同步单元(sync unit)。

2.1.6.2.1 参数

`size` -- 申请分配空间大小。byte单位。

`alignLog2Byte` -- 位对其。在 2^n 公式中，对应n。举例：64 byte align. then n is 6。

2.1.6.2.2 返回值

`uint64_t` 内存空间起始地址。

2.1.6.2.3 注意

如何分配内存失败，则会终止程序。

2.1.6.2.4 用法

```
/*CalrtDevice pointer*/ device_ptr->CreateBuf(32, 20) // allocate 32-byte  
memory aligned to 1MB on DRAM
```

2.1.6.3 拷贝用户内存到设备内存

```
void WriteToDevice(void *srcAddr, const uint64_t devAddr, const uint64_t  
size) #CalrtDevice 接口
```

拷贝用户端内存数据到设备端

2.1.6.3.1 参数

`srcAddr` -- 客户端内存地址。

`devAddr` -- 设备端内存地址。

`size` -- 数据大小。byte单位。

2.1.6.4 拷贝用户数据到设备指定chip

```
CalrtError_e WriteRemoteChipMem(void *srcAddr, const uint64_t devAddr, const uint64_t size, uint32_t  
chipId) #CalrtDevice 接口
```

```
CalrtError_e WriteMem(void *srcAddr, const uint64_t dst, const uint64_t size, uint32_t chipId) #VirtualDevice  
接口
```

2.1.6.4.1 参数

srcAddr – 客户端内存地址
 devAddr – 设备端内存地址
 size – 数据大小。byte单位
 chipId – 指定chip id

2.1.6.5 拷贝指定chip内存到用户

*CalrtError_e ReadRemoteChipMem(void *srcAddr, const uint64_t devAddr, const uint64_t size, uint32_t chipId) #CalrtDevice 接口*

*CalrtError_e ReadMem(void *srcAddr, const uint64_t dst, const uint64_t size, uint32_t chipId) #VirtualDevice 接口*

2.1.6.5.1 参数

srcAddr – 客户端内存地址
 devAddr – 设备端内存地址
 size – 数据大小。byte单位
 chipId – 指定chip id

2.1.6.6 拷贝设备内存到用户内存

```
void ReadFromDevice(void *srcAddr, const uint64_t devAddr, const uint64_t size)
```

2.1.6.6.1 参数

srcAddr – 客户端内存地址。
 devAddr – 设备端内存地址。
 size – 数据大小。byte单位。

2.1.6.7 写设备寄存器

```
void WriteReg(const uint64_t regAddr, uint32_t data) #CalrtDevice 接口
```

```
void WriteRegister(uint64_t regAddr, uint32_t regValue, uint32_t chipId)
#VirtualDevice接口
```

写设备寄存器。

2.1.6.7.1 参数

regAddr – 寄存器地址。

data – 写入的数据。

chipId – 指定chipId

2.1.6.8 读设备寄存器

```
void ReadReg(const uint64_t regAddr, uint32_t &data) #CalrtnDevice 接口
void ReadRegister(uint64_t regAddr, uint32_t regValue, uint32_t chipId)
#VirtualDevice接口
```

读取设备寄存器。

2.1.6.8.1 参数

regAddr – 寄存器地址。

data – 读回的数据。

chipId – 指定chipId

2.1.6.9 释放设备内存

```
void FreeBuf(uint64_t addr)
```

释放设备动态随机存取存储器(DRAM)地址空间。

```
void FreeSramBuf(uint64_t addr)
```

释放静态随机存取存储器空间(SRAM)地址空间。

```
void FreeSyncUnitByAddress(uint64_t addr)
```

释放同步单元依据地址信息。

```
void FreeSyncUnitByIndex(uint32_t idx)
```

释放同步单元依据角标信息。

2.1.7 错误处理

这一部分描述错误处理的接口。

2.1.7.1 CALRT_CHECK

```
CALRT_CHECK(CalrtError_e, msg)
```

检查错误代码是否是CalrtSuccess. 否则就会抛出错误信息

2.1.7.1.1 用法

```
CalrtError_e status = calrt::configure(device_ptr, calbin_ptr);  
CALRT_CHECK(status, "hello world. your input: %s", "hello w0rld");
```

2.1.7.2 REPORT_CALRT_ERROR

```
REPORT_CALRT_ERROR(CalrtError_e, msg)
```

反馈错误信息和错误类型

2.1.7.2.1 用法

```
REPORT_CALRT_ERROR(CalrtErrorInvalidValue, "hello world. your input: %s",  
"hello w0rld");
```

2.1.7.3 REPORT_CALRT_ERROR_IF

```
REPORT_CALRT_ERROR_IF(CalrtError_e, condition, msg)
```

反馈错误信息和错误类型，如果条件为false。

2.1.7.3.1 描述

条件判断使用跟 `assert` 逻辑相同。

2.1.7.4 CALRT_LOG

```
CALRT_LOG(verbosity, msg)
```

打印runtime信息。

2.1.7.4.1 参数

verbosity (see page 39) – log层级

2.1.8 Bug Replay

提供bug复现功能。生成运行时所需要的input 数据和output数据。

2.1.8.1 设置重现或debug方式

```
void SetFullDebug(DebugOps_e debOp, const char* path = nullptr)
```

2.1.8.1.1 参数

DebugOps_e (see page 39): debug 操作选项

path: 默认路径为当前calbin路径。可传入自定义路径，但DebugOps_e需要有对应的设置。详情查看选项描述部分。

2.2 数据结构

这一部分由两部分组成: struct (see page 22) and class (see page 28)。

2.2.1 结构体

2.2.1.1 CalrtCalbin

描述 CalrtCalbin 结构体。

2.2.1.1.1 变量

```
uint64_t name
```

Calbin文件hash名字。

```
std::vector<CalbinModel> models
```

文件描述的模型结构体。

2.2.1.2 *CalbinModel*

描述模型相关信息。

2.2.1.2.1 变量

`bool isConfigured`

描述当前模型是否配置到设备上。

`CalDevAccType_e devAccType`

[CalDevAccType_e](#) (see page 29)

`std::string modelType`

[CalbinModelType_e](#)

`std::string modelArch`

[CalbinModelArch_e](#)

`ModelChipMode_e chipMode`

[ModelChipMode_e](#) (see page 30)

`std::string modelName`

描述当前模型名字

`std::unordered_multimap<CalbinSectionType_e, CalbinSection_s> sections`

描述当前模型组成的相关组件。 [CalbinSectionType_e](#) (see page 31), [CalbinSection_s](#) (see page 23)。

`std::vector<int32_t> tarChipN`

描述当前模型部署的目标芯粒。

2.2.1.3 *CalbinSection_s*

描述模型的组件。

2.2.1.3.1 变量

`CalbinSectionPlace_e place`

描述当前组件应放置于设备区域。 [CalbinSectionPlace_e](#) (see page 30)

`CalbinSectionType_e type`

[CalbinSectionType_e](#) (see page 31)

`std::string name`

描述当前组件名字。

`std::string filePath`

描述当前组件相应二进制文件路径。

`int64_t offset`

描述当前组件.bss段 entry address。

`int64_t devAddr`

描述当前组件储存在设备的内存地址信息。

`int64_t size`

描述当前组件大小。byte单位

`int64_t progEntry`

描述当前组件相关的程序 header entry address

`std::vector<uint32_t> chipMask`

描述当前组件应放置于的目标芯粒。

`std::vector<CalbinTensorInfo_s> tensorInfos`

描述当前组件相关的张量信息。 [CalbinTensorInfo_s](#) (see page 25)

2.2.1.4 CalbinLLM_s

描述当前非CNN模型的最大batch size，最大sequence length和相关的kv cache。

2.2.1.4.1 变量

`uint32_t max_batch_size`

描述当前模型支持的最大batch。

```
uint32_t max_seq_len
```

描述当前模型支持的最大sequence length。

```
KV_Cache_s kv_cache`
```

[KV_Cache_s](#) (see page 25)

2.2.1.5 KV_Cache_s

描述当前非CNN模型 kv cache信息。

2.2.1.5.1 变量

```
PrimitiveType dtype
```

描述当前数据类型。默认是 INVALID . [PrimitiveType](#) (see page 32)。

```
uint32_t layer
```

描述当前层数。

```
int64_t kv_base[2]
```

描述K cache的基地址(kv_base[0]) 和V cache的基地址(kv_base[1])。

```
int64_t size
```

描述当前kv cache 大小

```
std::vector<int32_t> shape
```

描述当前kv cache 形状。{head, batch, head_dim, d0, d2}

2.2.1.6 CalbinTensorInfo_s

描述张量相关信息。

2.2.1.6.1 变量

```
std::string name
```

描述当前张量名字。

```
std::vector<int32_t> shape
```

描述当前张量形状。

```
PrimitiveType dataType
```

描述当前张量的数据类型。 [PrimitiveType](#) (see page 32)

```
int64_t ping; int64_t pong
```

描述当前张量的ping-pong地址。

```
int64_t size
```

描述当前张量的ping-pong地址大小。

2.2.1.7 CalrtDevBuf_s

Descript [Buffer](#)³ info. Reserved.

2.2.1.8 CalrtBufferInfo_s

用于构建 `CalrtInputBuf` 和 `CalrtOutputBuf` 的结构体。描述基础buffer信息。

2.2.1.8.1 变量

```
CalrtBufferDirection_e direction
```

描述当前buffer数据流向。 [CalrtBufferDirection_e](#) (see page 34)

```
std::string name
```

描述当前buffer名字。

```
std::vector<CalbinTensorInfo_s> tensorInfos
```

描述当前buffer的储存的相关张量信息。

```
`uint64_t devAddr0; uint64_t devAddr1; uint64_t size`
```

描述当前buffer目标设备ping pong内存信息。重复出现在 `CalbinTensorInfo_s`。

³ https://file+.vscode-resource.vscode-cdn.net/c:/Users/YulinYang/Desktop/yulin_250731/subpage/class.md#calrtinputbuf

2.2.1.9 TaskInfo_s

内部 JobEgnine 使用。描述任务抽象类型。

2.2.1.10 CalrtDeviceId_s

当前设备基础id信息。

2.2.1.10.1 变量

`CalrtDeviceType_e devType`

描述当前设备类型。 [CalrtDeviceType_e \(see page 38\)](#)

`std::string devPath`

描述当前设备节点路径

`int serialNum = 0`

设备系列号

2.2.1.11 CalrtDeviceInfo_s

当前设备的详细信息。通过 `CalrtDeviceId_s` 生成。

`CalrtDeviceId_s devId`

描述当前设备 id。

`std::string name`

描述当前设备名字

`int64_t ddrSize`

描述当前设备动态随机存取存储器(DRAM)大小。

`float sramFreqMhz`

静态随机存取存储器(SRAM)频率。

`int64_t sramSizeMb`

描述当前设备静态随机存取存储器(SRAM)大小。

2.2.1.12 *ModelHyperParameters_s*

提供给上层用户 (llama, etc) 结构体。用于调整运行时的csr配置和sequence length。

```
uint32_t GetCsrValueByName(const std::string &csrName)
```

根据csr 名字来获得对应data

```
void SetCsrByName(const std::string &csrName, uint32_t value)
```

给对应csr配置data

2.2.2 类

相关类的简易说明。开发者需要更多的信息，可阅读相关头文件。 Related class brief introduction. For more details, please read header files.

2.2.2.1 *Calbin*

Calculet runtime object used for parsing calbin file and related program data.

2.2.2.2 *CalrtInputBuf*

Calculet runtime object used for carrying tensors information and related data for inference. Multi-threads friendly.

2.2.2.3 *CalrtOutputBuf*

Calculet runtime object used for carry tensors information and inference result. Multi-threads friendly.

2.2.2.4 *CalrtDevice*

Calculet runtime abstract object used for controlling physical device for either memory management or device work. Actual functionality would be override by its derived class.

2.2.2.5 *CalrtEmuDevice*

Calculet runtime object, derived class of `CalrtDevice`. Used as an emulator without physical device.

2.2.2.6 *CalrtPcieDevice*

Calculet runtime object, derived class of `CalrtDevice`. Used to map with physical PCIe device.

2.2.2.7 *VirtualDevice*

Calculet runtime abstract object. Used for managing one or multiple physical device.

2.2.2.8 *CalrtJobEngine*

Calculet runtime object. `VirtualDevice` module used for handling ping-pong task.

2.2.2.9 *CalrtAllocator*

Calculet runtime object. `CalrtDevice` module used for memory management.

2.2.2.10 *CalrtDriver*

Calculet runtime object. `CalrtPcieDevice` module used for transferring data via PCI.

2.2.2.11 *CalrtJob*

Calculet runtime object. Used for describing each inference.

2.2.2.12 *CalrtTensor*

Calculet runtime object, Used for recoding each tensors information inside i/o buffer object

2.3 数据类型

这一部分描述Runtime相关数据类型。

2.3.1 枚举

enum items.

2.3.1.1 *CalDevAccType_e*

设备加速类型。

2.3.1.1.1 变量

`CAL_DEV_ACC_NULL = 0`

undefined acceleration type

`CAL_DEV_ACC_CPU = 1`

仅CPU加速

`CAL_DEV_ACC_CCUCU = 2`

仅CCU加速

`CAL_DEV_ACC_CPU_CCUCU = 3`

co-op CPU and CCUCU acceleration.

2.3.1.2 *ModelChipMode_e*

描述当前模型的芯粒调度指示。

2.3.1.2.1 变量

`SCHIP = 0`

单芯粒模式。

`MCHIP = 1`

多芯粒模式

`UNDEFINED_CHIP_MODE`

未知调度模式。

2.3.1.3 *CalbinSectionPlace_e*

描述calbin section在设备的位置。

2.3.1.3.1 变量

`DRAM = 0`

DRAM。

`SRAM = 1`

SRAM。

CalbinSectionType_e

Calbin section 类型。

2.3.1.3.2 变量

`CALBIN_SECTION_NULL = 0`

undefined section. 未定义部分。

`CALBIN_SECTION_CPU_CMD = 1`

a section about CPU program and related commands. 有关CPU程序和相关命令的部分。

`CALBIN_SECTION_CPU_SO = 2`

a section about shared libs used by CPU. 有关 CPU 使用的共享库的部分。

`CALBIN_SECTION_CCU_ELF = 3`

a section about CCU ELF. 关于 CCU ELF 的部分。

`CALBIN_SECTION_RODATA = 4`

a section about model parameter. 关于模型参数的部分。

`CALBIN_SECTION_IBUF = 5`

a section about input buffer. 有关输入缓冲区的部分。

`CALBIN_SECTION_OBUF = 6`

a section about output buffer. 关于输出缓冲区的部分。

`CALBIN_SECTION_MEMRSVD = 7`

a section about reserved memory for your calbin applying to Calculet device. 有关应用于设备 calbin 保留内存的部分。

`CALBIN_SECTION_KV = 8`

a section about kv cache and related information. 有关 kv cache和相关信息的部分。

`CALBIN_SECTOIN_CSR = 9`

有关CSR配置相关信息的部分。

```
CALBIN_SECTION_NUM = 10
```

the number of CalbinSectionType_e 类型数量。

2.3.1.4 PrimitiveType

Descript data type.

2.3.1.4.1 变量

```
U1=0
```

1bit

```
PRED=1
```

bool, int8

```
U8=2
```

unsigned int

```
S8=3
```

signed int

```
FP8_143=4
```

exp_bias = 8; has subnormal, no inf/nan. when biased_exp=0 it is fixed explained as unbiased_exp=-7;

```
FP8_152=5
```

exp_bias = 16; has subnormal, no inf/nan. when biased_exp=0, it is fixed explained as unbiased_exp=-15;

```
U16=6
```

16b unsigned int

```
S16=7
```

16b signed int

```
BF16=8
```

16b

| U32=9

32b unsigned integer

| S32=10

32b signed integer

| F32=11

32b float

| U4=12

4b unsigned char

| S4=13

4b signed char

| F35=14

35b float

| U64=15

not support

| S64=16

u64和s64需要保留，仅做类型转换，因为pytorch要求tensor做index时必须为 long或byte或bool。

| TF32=17

19b. not support

| F16=18

| F64=19

| C64

| C128

reserved

| TUPLE

0b

| `TOKEN`

32b

| `OPAQUE_TYPE`

32b

| `INVALID`

0b

| `TYPE_SIZE`

the number of data types

2.3.1.5 *CalrtBufferDirection_e*

描述缓冲区的数据流方向。

2.3.1.5.1 变量

| `HostToDevice = 0`

transfer data from host to device only. 仅从主机向设备传输数据。

| `DeviceToHost = 1`

transfer data from device to host only. 仅从设备向主机传输数据。

| `Both = 4`

2-ways transfer. 双向传输。

2.3.1.6 *TaskType_e*

Describe the task type. Used for ping-pong arrangement.

2.3.1.6.1 变量

| `TASK_PING = 0`

ping property task. ping 属性任务。

| `TASK_PONG = 1`

pong property task. pong 属性任务。

`UNDEFINED_TASK = 2`

undefined property task. error report purpose. 未定义的属性任务

2.3.1.7 CalJobAlloStatus_e

CalrtJobEngine [\(see page 29\)](#) 状态描述。

2.3.1.7.1 变量

`JOB_PING = 0`

ping condition job. executed by ping thread. ping 条件作业。由 ping 线程执行。

`JOB_PONG`

pong condition job. executed by pong thread. pong 条件作业。由 pong 线程执行。

`JOB_PENDING`

pending condition job. 待定条件作业。

2.3.1.8 CalrtError_e

runtime 错误代码

2.3.1.8.1 变量

`CalrtSuccess = 0`

no error. 成功。

`CalrtErrorMemoryAllocation = 1`

failed to allocate device memory. 动态分配内存空间失败。

`CalrtErrorMemoryAlreadyRegistered = 2`

failed to register(reserve) device memory due to target memory address is already taken. 由于目标内存地址已被占用，无法注册（保留）设备内存。

`CalrtErrorAssert = 3`

runtime assert error.

```
CalrtErrorInvalidValue = 4
```

invalid parameters paased to runtime API. 传递给运行时 API 的参数无效。

```
CalrtErrorInvalidConfiguration = 5
```

indicate that the current model or Calbin file is invalid to be configured on device. 表示当前模型或 Calbin 文件无效，无法在设备上配置。

```
CalrtErrorNoDevice = 6
```

indicate there is no valid calculet device detected. 表示没有检测到有效的 calculet 设备。

```
CalrtErrorAlreadyConfigured = 7
```

indicate the current calbin file is already configured on device. 表示当前 calbin 文件已在设备上配置

```
CalrtErrorIncompatibleDriver = 8
```

update device driver. too old to be supported by runtime. 更新设备驱动程序太旧，runtime不支持。

```
CalrtErrorRequireNewerRT = 9
```

update runtime library. too old to be compatible with current device. 更新runtime库。太旧，与当前设备不兼容。

```
CalrtErrorFileNotFound = 10
```

indicate the target file cannot be found. 表示找不到目标文件。

```
CalrtErrorBrokenFile = 11
```

failed to read or write the target file. 无法读取或写入目标文件。

```
CalrtErrorInvalidELF = 12
```

ELF version is invalid. ELF 版本无效。

```
CalrtErrorTimeout = 13
```

indicate connection between host and device is timeout. 表示主机与设备之间的连接超时。

```
CalrtErrorOutOfRange = 14
```

indicate the passed argument is out of range. 表示传递的参数超出范围。

```
CalrtErrorNotExpected = 15
```

indicate the feedback or result is not expected. 表示反馈或结果不及预期。

`CalrtErrorMissConfiguration = 16`

indicate the current model is not configured on the current device. 表示当前设备上未配置当前型号。

`CalrtErrorDeviceBusy = 17`

indicate the current device is still connected and connection is not timeout. But it is too busy to execute the new request. 表示当前设备仍处于连接状态，且连接未超时，但太忙，无法执行新的请求。

`CalrtErrorDeviceUnavailable = 18`

device disconnected, PCIe loose contact, power supply low. 设备断开连接、PCIe接触不良、电源电压低。

`CalrtErrorInvalidCalbin = 19`

indicate that calbin file is invalid to parse any valid data for configure models on the current device. 表明 calbin 文件无效，无法解析当前设备上配置模型的任何有效数据。

`CalrtErrorUnknown = 20`

indicate unknown error. 指示未知错误。

`CalrtErrorInvalidDataType`

表明非法数据类型

`CalrtErrorInvalidDataShape`

表明非法数据shape

`CalrtErrorInvalidLibDep`

表明库依赖出错

`CalrtErrorDeviceMapBroken`

表明设备列表失效

`CalrtErrorFailedSoftReset`

表明设备软重置失败

`CalrtErrorFailedConnectServer`

表明断开连接服务器

`CalrtErrorDeviceUnsupport`

表明设备不支持当前操作

`CalrtErrorCCUExecFailed`

表明设备CCU执行错误

| *CalrtErrorWrongDirection*

表明数据传输方向错误

2.3.1.9 *CalrtDeviceType_e*

描述当前设备类型。.

2.3.1.9.1 变量

| `NO_TYPE = 0`

当前设备为未知类型。

| `PCIE = 1`

the current device is the PCIe device. 当前设备是PCIe设备。

| `USB = 2`

the current device is an USB device. 当前设备是一个USB设备。

| *EMU*

当前设备是一个模拟器

2.3.1.10 *CalrtOutputBufStatus_e*

描述当前输出缓冲区的工作状态。

2.3.1.10.1 变量

| `CALRT_OBUF_STATUS_DEFAULT = 0`

闲置。

| `CALRT_OBUF_STATUS_PENDING = 1`

在软件启动队列中，尚未启动。

| `CALRT_OBUF_STATUS_RUNNING = 2`

正在推理中，输出数据还没准备好

`CALRT_OBUF_STATUS_DONE = 3`

在软件完成队列中，准备将数据读回主机。

2.3.1.11 *CalrtLogVerbosity_e*

描述log信息层级

2.3.1.11.1 变量

`INFO = 0`

打印runtime消息

`WARNING = 1`

打印警告消息和runtime消息

`ERROR = 2`

打印错误消息，警告消息和runtime消息

`DEBUG = 3`

打印更详细的消息，包括文件名和出错位置

`TRACE = 4`

输出log文件。

2.3.1.12 *PowerMode*

描述设备电源模式

2.3.1.12.1 变量

`BALANCE = 1`

`HIGH_PERFORMANCE = 2`

2.3.1.13 *DebugOps_e*

描述bug 复现的选项

2.3.1.13.1 变量

| `DEB_DISABLE = 0`

关闭debug功能

| `DEB_DEFUALT = 1`

按默认方式debug，dump运行时的数据。infer index递增，文件输出路径为calbin路径。

| `DEB_ALTPATH = 2`

infer index递增，但文件输出路径为自定义路径。会自动创建多层目录。但要有读写权限。

| `DEB_RSTALT = 3`

infer index重置，不再递增；同时文件输出路径为自定义路径。会自动创建多层目录。但要有读写权限。

3 修改历史 Changing Log