地平线
Horizon Robotics

天工开物 J6算法工具链

模型板端部署详解-UCP

UCP简介-功能架构

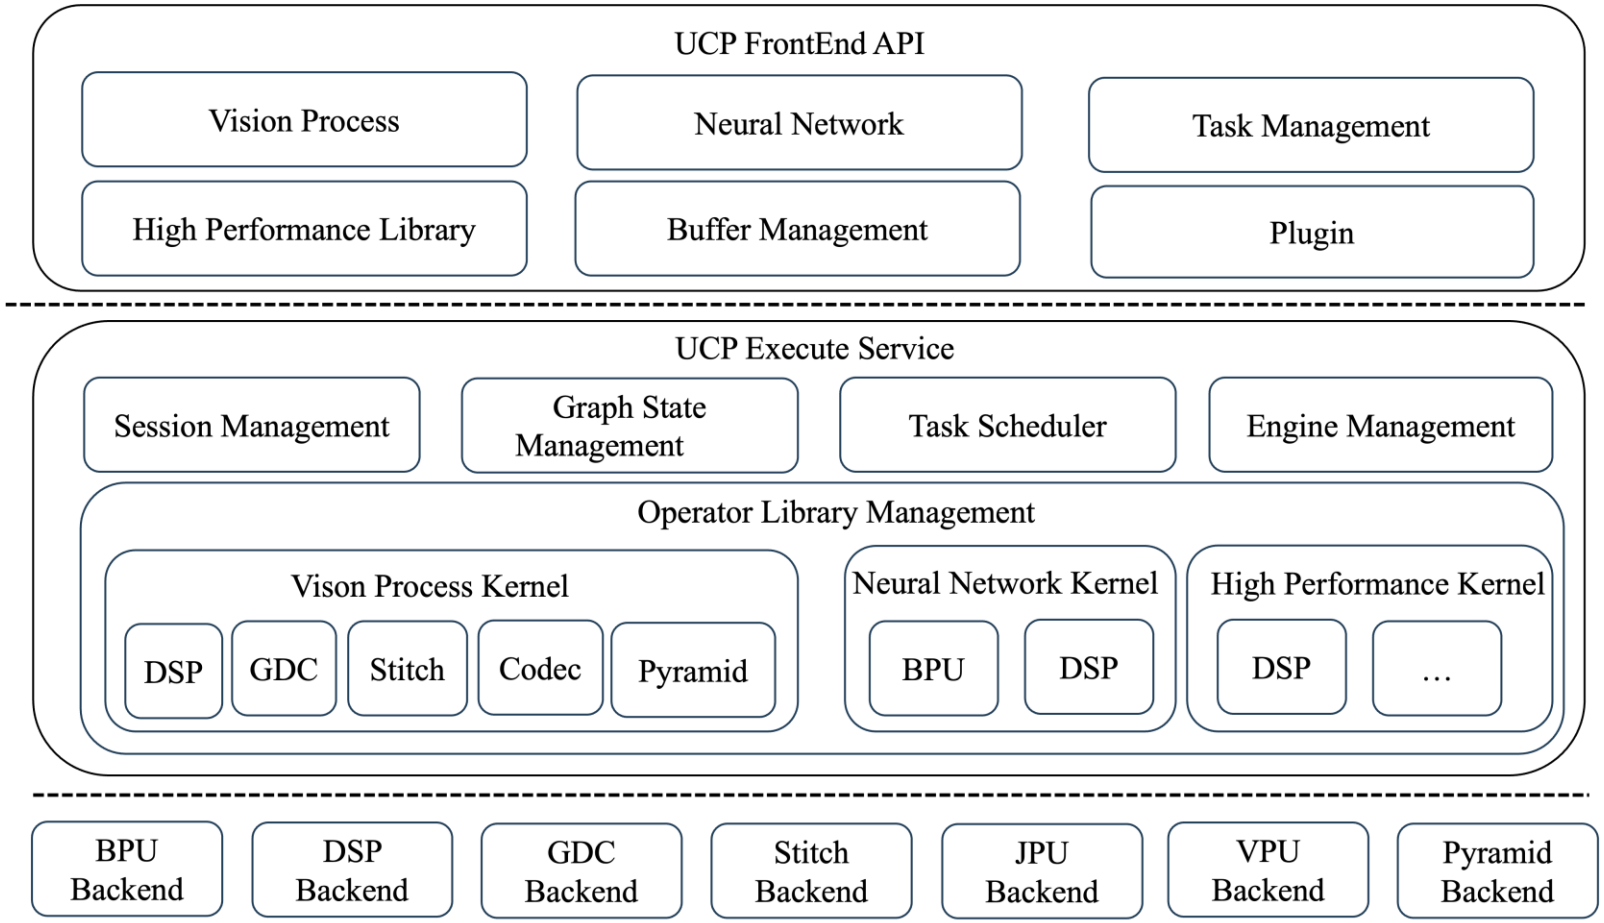

统一计算平台（Unify Compute Platform，以下简称 UCP）定义了一套高度抽象和集成的统一异构编程接口， 提供API实现对SoC上所有资源的调用。UCP将SoC上的功能硬件抽象出来并进行封装，对外提供基于功能的API，用于创建相应的UCP任务（如VP算子任务、模型推理任务等），并支持设置硬件Backend提交至UCP调度器，UCP可基于硬件资源，完成SoC上任务的统一调度。具体提供了以下几个功能：视觉处理(Vision Process)、神经网络模型推理（Neural Network）、高性能计算库（High Performance Library）、自定义算子插件开发（开发中）。

UCP简介-Backend

Backend	描述
BPU	Brain Process Unit，地平线神经网络计算单元
DSP	Digital Signal Processor，数字信号处理器，是一个可编程的硬件单元
GDC	Geometric Distortion Correction，是ARM上的一个硬件IP，可将输入图像进行视角变换、畸变矫正、图像仿射变换等操作
STITCH	stitch是J6的一个IP单元，可对输入的图像进行裁剪，拼接，拼接模式分别有：alpha融合、alpha beta融合、直接拷贝
JPU	JPEG Processing Unit，主要用以完成JPEG的编解码功能
VPU	Video Processing Unit，是一种专用的视觉处理单元
PYRAMID	全称Image Pyramid，是一个硬件处理模块，可对整幅原始图像进行缩小

Backend是指UCP任务执行时的后端计算硬件，当前UCP支持的Backend包括BPU、DSP、GDC、STITCH、JPU、VPU、PYRAMID。

UCP简介-交付物

地平线 Horizon Robotics

开发环境：

环境/工具	支持版本
操作系统	Linux
开发板	J6开发板
开发语言	C++11
交叉编译器	Linaro 11.4.0
工具链DSP	Cadence Vsion Q8 2021.7

OE包示例：

```
samples/ucp_tutorial/ # UCP示例
├── deps_aarch64 # aarch64依赖库
├── deps_x86 # x86仿真依赖库
├── dnn # 神经网络模型推理（Neural Network）推理示例
│   ├── ai_benchmark
│   └── basic_samples
├── hpl # 高性能计算库算子示例
│   ├── README.md
│   ├── code
│   └── hpl_samples
├── tools # 工具目录，包含hrt_model_exec、hrt_ucp_monitor、trace工具
│   ├── hrt_model_exec
│   ├── monitor
│   └── trace
└── vp # 视觉处理算子示例
    ├── code
    └── vp_samples
```

注：x86端UCP仿真使用Docker镜像自带的编译器环境即可

注：当前为试用版本内容，正式版本将会有更丰富内容。

地平线
Horizon Robotics

模型板端部署详解-UCP

神经网络模型推理 | 视觉处理 | 高性能计算库 | UCP工具

神经网络模型推理-注意事项

由于J6工具链编译器架构和硬件对齐规则发生了比较大的变化，模型的板端部署方式相比以前版本例如J5发生了改变，体现在模型部署侧有以下几点：

- Pyramid输入和Resizer输入需沿Batch维度拆分，例如1个Batch 8输入分支将拆分为8个Batch 1的输入分支；
- Pyramid输入的stride信息存在动态维度，Resizer输入的valid shape和stride信息存在动态维度，需指定具体数值（使用hrt_model_exec工具通过input_valid_shape和input_stride参数传入），并且stride需32位对齐。此外原来的aligned shape信息需通过valid shape和stride解析，无法直接从properties获取，并且aligned shape会在后期废弃；
- Pyramid输入的nv12数据将拆分为y和uv两个分量输入；Resizer输入的nv12数据将拆分为y、uv和roi三个分量输入，需分别准备输入数据，例如1个Batch 8 Pyramid单输入的模型，部署时模型的输入分支将是16个。

stride的计算方式如右图：

$$stride[idx] >= stride[idx+1] * validShape.dimensionSize[idx+1]$$

以y分量为例：

valid shape为(1, 224, 224, 1)，stride为(-1, -1, 1, 1)，stride[0]和stride[1]为动态，因此

stride[1] = ALIGN_32(stride[2] * validShape.dimensionSize[2]) = ALIGN_32(1 * 224) = 224

stride[0] = ALIGN_32(stride[1] * validShape.dimensionSize[1]) = ALIGN_32(224 * 224) = 50176

神经网络模型推理-基本流程

神经网络模型推理-示例解读

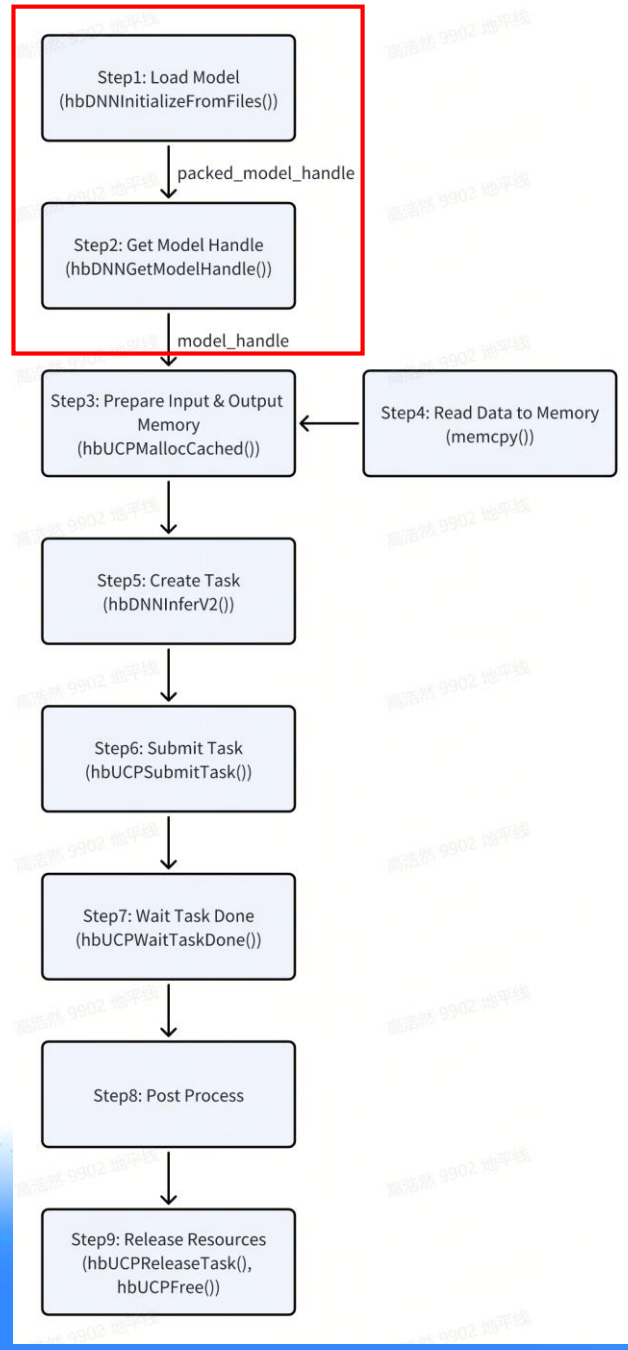

我们以samples/ucp_tutorial/dnn/basic_samples/code/00_quick_start为例，使用ResNet50进行单张图片模型推理和结果解析：

```
int main(int argc, char **argv) {
  // Parsing command line arguments
  gflags::SetUsageMessage(argv[0]);
  gflags::ParseCommandLineFlags(&argc, &argv, true);
  std::cout << gflags::GetArgv() << std::endl;

  // Init logging
  hobot::hlog::HobotLog::Instance()->SetLogLevel(
      "DNN_BASIC_SAMPLE", hobot::hlog::LogLevel::log_info);

  hbDNNPackedHandle_t packed_dnn_handle;
  hbDNNHandle_t dnn_handle;
  const char **model_name_list;
  auto modelFileName = FLAGS_model_file.c_str();
  int model_count = 0;
  // Step1: get model handle
  {
    HB_CHECK_SUCCESS(
        hbDNNInitializeFromFiles(&packed_dnn_handle, &modelFileName, 1),
        "hbDNNInitializeFromFiles failed");
    HB_CHECK_SUCCESS(hbDNNGetModelNameList(&model_name_list, &model_count,
                                           packed_dnn_handle),
                     "hbDNNGetModelNameList failed");
    HB_CHECK_SUCCESS(
        hbDNNGetModelHandle(&dnn_handle, packed_dnn_handle, model_name_list[0]),
        "hbDNNGetModelHandle failed");
  }
```

神经网络模型推理-示例解读

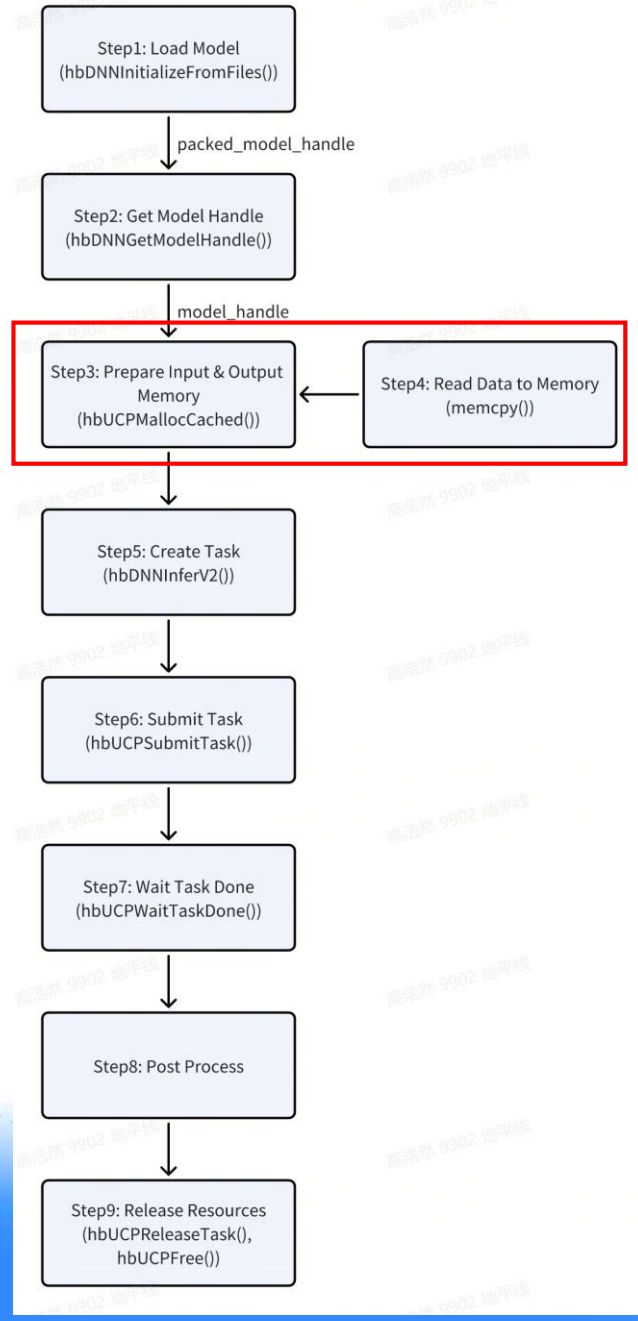

我们以samples/ucp_tutorial/dnn/basic_samples/code/00_quick_start为例，使用ResNet50进行单张图片模型推理和结果解析：

```
std::vector<hbDNNTensor> input_tensors;
std::vector<hbDNNTensor> output_tensors;
int input_count = 0;
int output_count = 0;
// Step2: prepare input and output tensor
{
  HB_CHECK_SUCCESS(hbDNNGetInputCount(&input_count, dnn_handle),
                   "hbDNNGetInputCount failed");
  HB_CHECK_SUCCESS(hbDNNGetOutputCount(&output_count, dnn_handle),
                   "hbDNNGetOutputCount failed");
  input_tensors.resize(input_count);
  output_tensors.resize(output_count);
  prepare_tensor(input_tensors.data(), output_tensors.data(), dnn_handle);
}

// Step3: set input data to input tensor
{
  // read a single picture for input_tensor[0], for multi_input model, you
  // should set other input data according to model input properties.
  HB_CHECK_SUCCESS(
      read_image_2_tensor_as_nv12(FLAGS_image_file, input_tensors.data()),
      "read_image_2_tensor_as_nv12 failed");
  LOGI("read image to tensor as nv12 success");
}
```

神经网络模型推理-示例解读

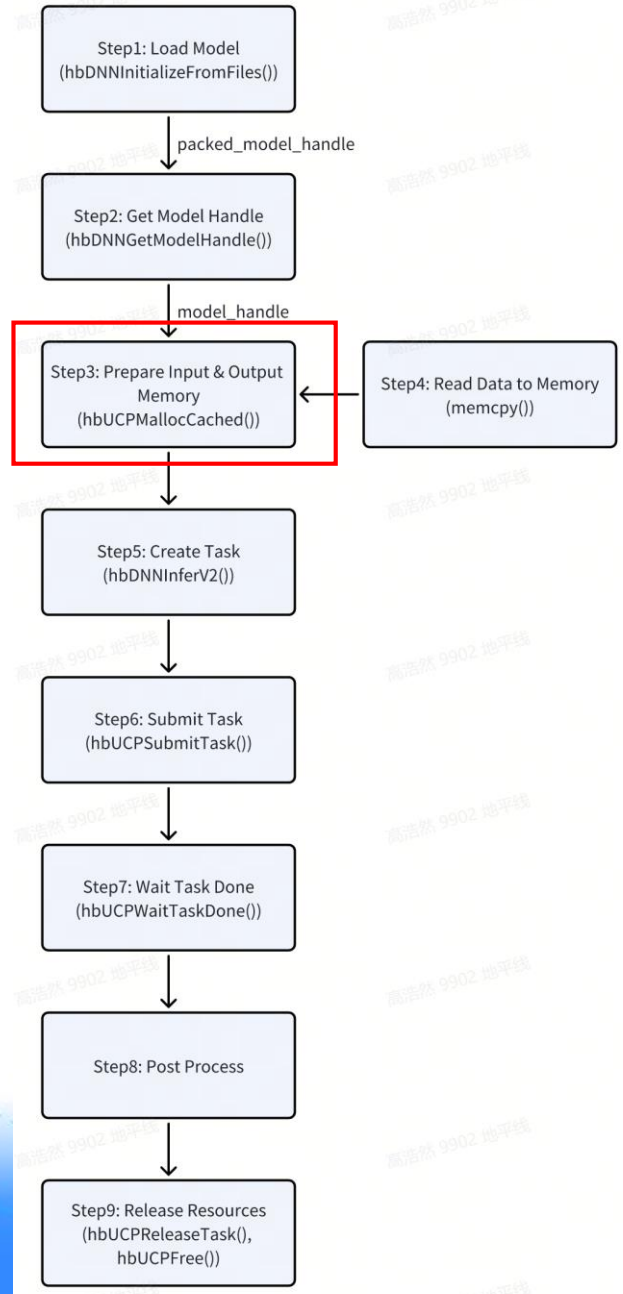

我们以samples/ucp_tutorial/dnn/basic_samples/code/00_quick_start为例，使用ResNet50进行单张图片模型推理和结果解析：

```
int prepare_tensor(hbDNNTensor *input_tensor, hbDNNTensor *output_tensor,
  /** Tips:
   * *   output_memSize = output[i].properties.alignedByteSize
   */
  hbDNNTensor *input = input_tensor;
  for (int i = 0; i < input_count; i++) {
    HB_CHECK_SUCCESS(
        hbDNNGetInputTensorProperties(&input[i].properties, dnn_handle, i),
        "hbDNNGetInputTensorProperties failed");

    /** Tips:
     * For input tensor, usually need to pad the input data according to stride obtained
     * but here for dynamic stride of y and uv, user needs to specify a value which shoul
     * */
    auto dim_len = input[i].properties.validShape.numDimensions;
    for (int32_t dim_i = dim_len - 1; dim_i >= 0; --dim_i) {
      if (input[i].properties.stride[dim_i] == -1) {
        auto cur_stride =
            input[i].properties.stride[dim_i + 1] *
            input[i].properties.validShape.dimensionSize[dim_i + 1];
        input[i].properties.stride[dim_i] = ALIGN_32(cur_stride);
      }
    }

    int input_memSize = input[i].properties.stride[0] *
                        input[i].properties.validShape.dimensionSize[0];
    HB_CHECK_SUCCESS(hbUCPMallocCached(&input[i].sysMem[0], input_memSize, 0),
                     "hbUCPMallocCached failed");
```

神经网络模型推理-示例解读

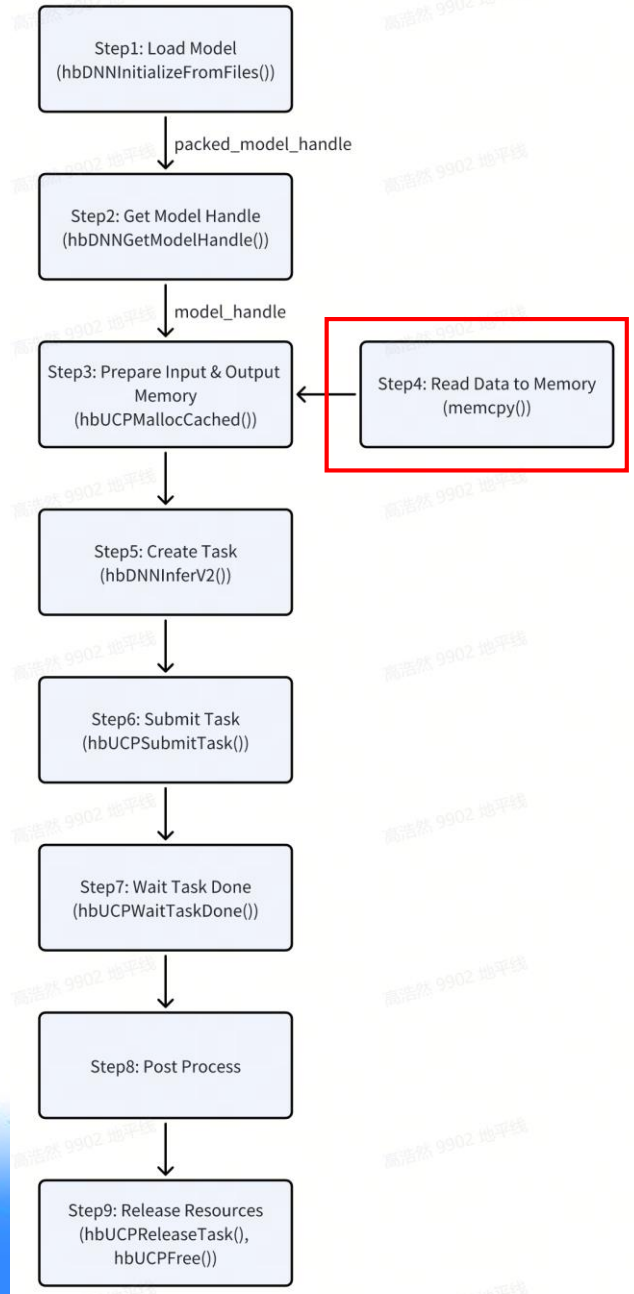

我们以samples/ucp_tutorial/dnn/basic_samples/code/00_quick_start为例，使用ResNet50进行单张图片模型推理和结果解析：

```
int32_t read_image_2_tensor_as_nv12(std::string &image_file,
  if (input_h % 2 || input_w % 2) {
  }
  cv::Mat yuv_mat;
  cv::cvtColor(mat, yuv_mat, cv::COLOR_BGR2YUV_I420);
  uint8_t *yuv_data = yuv_mat.ptr<uint8_t>();
  uint8_t *y_data_src = yuv_data;

  // copy y data
  uint8_t *y_data_dst =
      reinterpret_cast<uint8_t *>(input_tensor[0].sysMem[0].virAddr);
  for (int32_t h = 0; h < input_h; ++h) {
    memcpy(y_data_dst, y_data_src, input_w);
    y_data_src += input_w;
    // add padding
    y_data_dst += input_tensor[0].properties.stride[1];
  }

  // copy uv data
  int32_t uv_height = input_tensor[1].properties.validShape.dimensionSize[1];
  int32_t uv_width = input_tensor[1].properties.validShape.dimensionSize[2];
  uint8_t *uv_data_dst =
      reinterpret_cast<uint8_t *>(input_tensor[1].sysMem[0].virAddr);
  uint8_t *u_data_src = yuv_data + input_h * input_w;
  uint8_t *v_data_src = u_data_src + uv_height * uv_width;
```

神经网络模型推理-示例解读

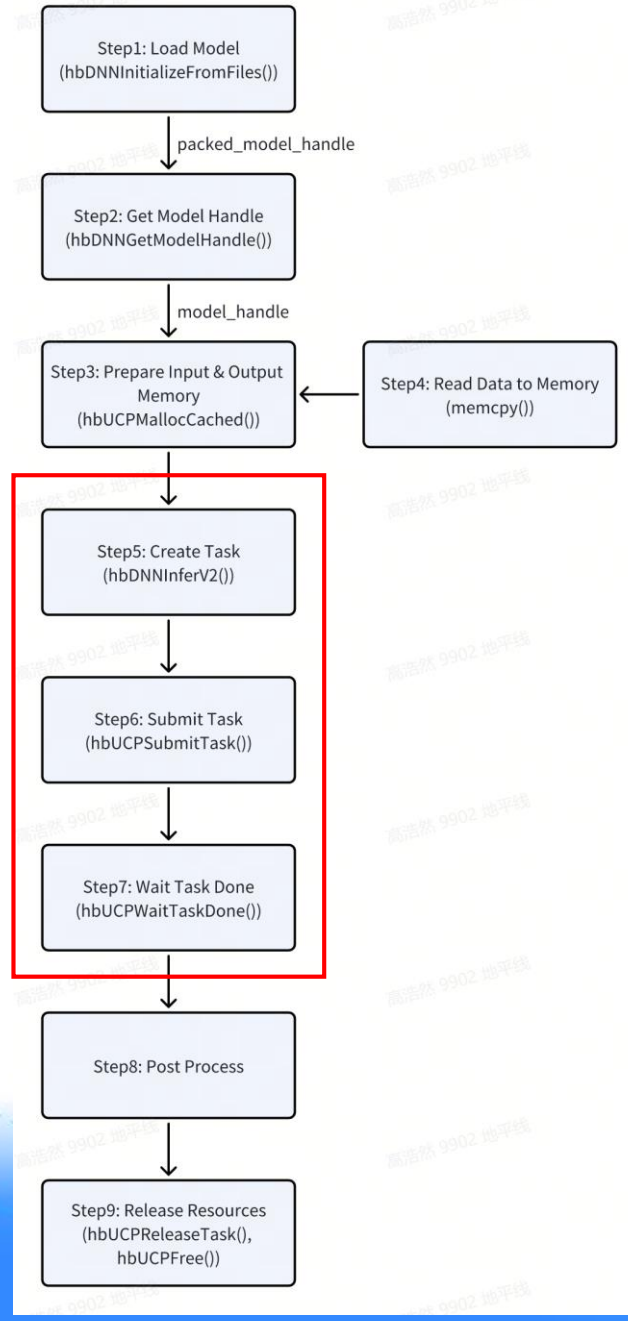

我们以samples/ucp_tutorial/dnn/basic_samples/code/00_quick_start为例，使用ResNet50进行单张图片模型推理和结果解析：

```
hbUCPTaskHandle_t task_handle{nullptr};
hbDNNTensor *output = output_tensors.data();
// Step4: run inference
{
  // make sure memory data is flushed to DDR before inference
  for (int i = 0; i < input_count; i++) {
    hbUCPMemFlush(&input_tensors[i].sysMem[0], HB_SYS_MEM_CACHE_CLEAN);
  }

  // generate task handle
  HB_CHECK_SUCCESS(
      hbDNNInferV2(&task_handle, output, input_tensors.data(), dnn_handle),
      "hbDNNInferV2 failed");

  // submit task
  hbUCPSchedParam ctrl_param;
  HB_UCP_INITIALIZE_SCHED_PARAM(&ctrl_param);
  ctrl_param.backend = HB_UCP_BPU_CORE_ANY;
  HB_CHECK_SUCCESS(hbUCPSubmitTask(task_handle, &ctrl_param),
                   "hbUCPSubmitTask failed");

  // wait task done
  HB_CHECK_SUCCESS(hbUCPWaitTaskDone(task_handle, 0),
                   "hbUCPWaitTaskDone failed");
}
```

神经网络模型推理-示例解读

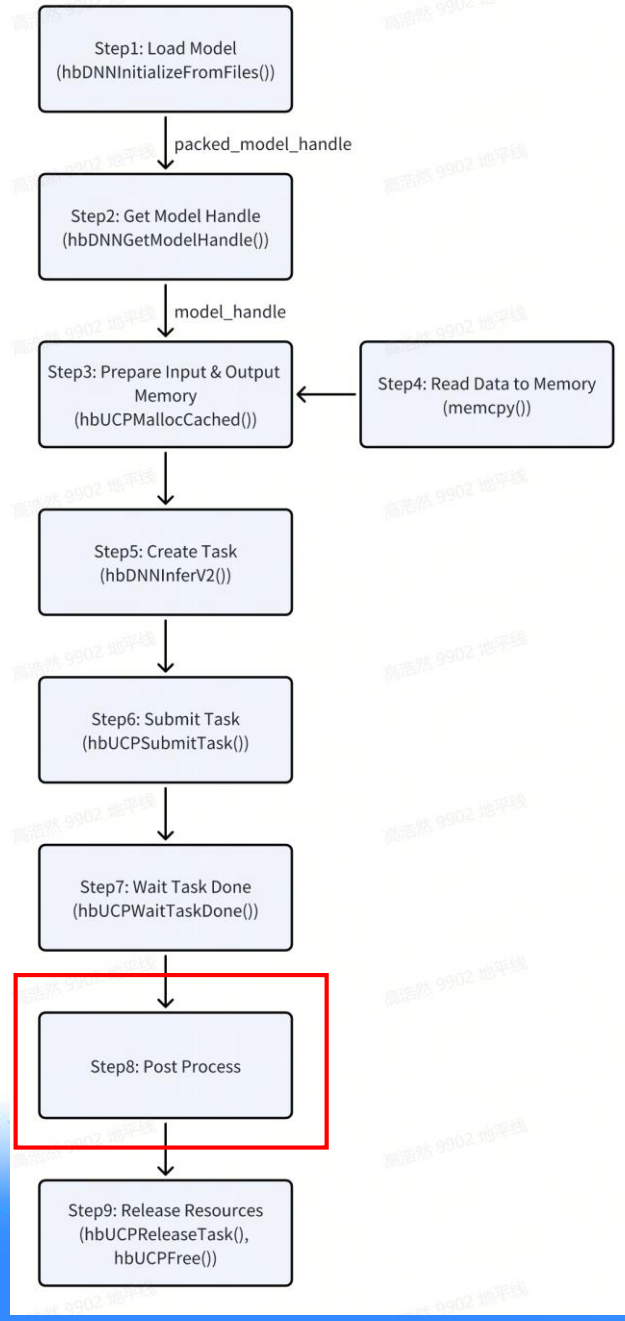

我们以samples/ucp_tutorial/dnn/basic_samples/code/00_quick_start为例，使用ResNet50进行单张图片模型推理和结果解析：

```
// Step5: do postprocess with output data
std::vector<Classification> top_k_cls;
{
  // make sure CPU read data from DDR before using output tensor data
  for (int i = 0; i < output_count; i++) {
    hbUCPMemFlush(&output_tensors[i].sysMem[0], HB_SYS_MEM_CACHE_INVALIDATE);
  }

  get_topk_result(output, top_k_cls, FLAGS_top_k);
  for (int i = 0; i < FLAGS_top_k; i++) {
    LOGI("TOP {} result id: {}", i, top_k_cls[i].id);
  }
}
```

神经网络模型推理-示例解读

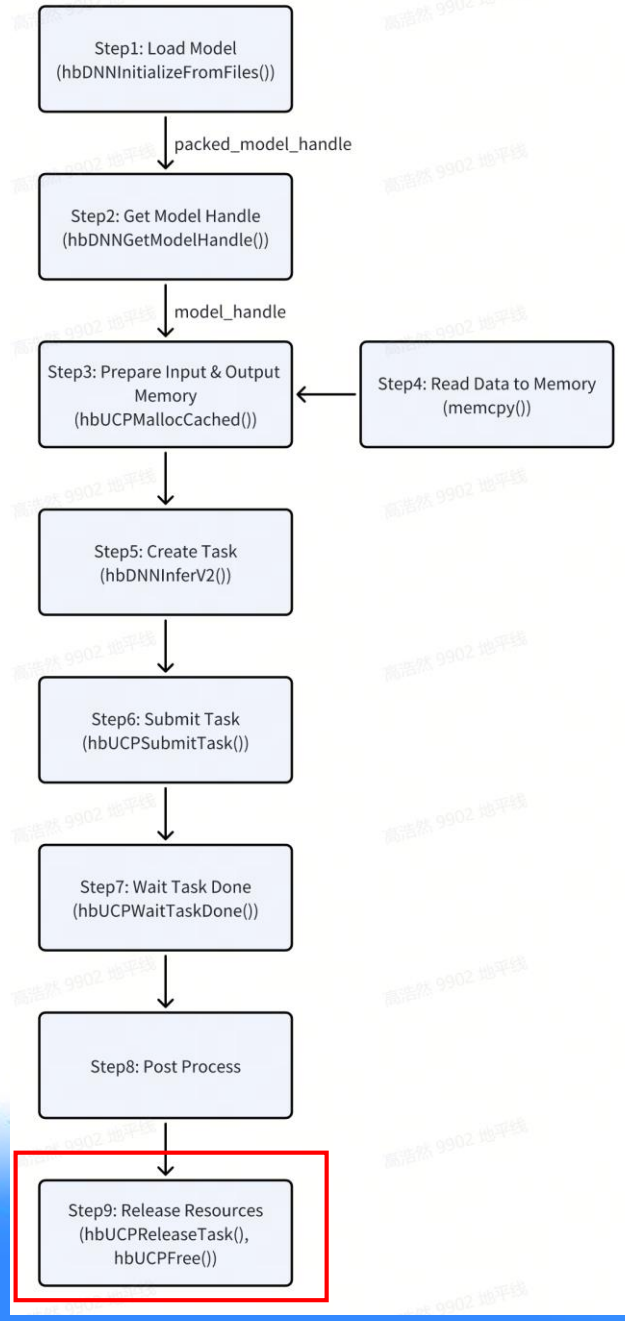

我们以samples/ucp_tutorial/dnn/basic_samples/code/00_quick_start为例，使用ResNet50进行单张图片模型推理和结果解析：

```
// Step6: release resources
{
  // release task handle
  HB_CHECK_SUCCESS(hbUCPReleaseTask(task_handle), "hbUCPReleaseTask failed");
  // free input mem
  for (int i = 0; i < input_count; i++) {
    HB_CHECK_SUCCESS(hbUCPFree(&(input_tensors[i].sysMem[0])),
                     "hbUCPFree failed");
  }
  // free output mem
  for (int i = 0; i < output_count; i++) {
    HB_CHECK_SUCCESS(hbUCPFree(&(output_tensors[i].sysMem[0])),
                     "hbUCPFree failed");
  }
  // release model
  HB_CHECK_SUCCESS(hbDNNRelease(packed_dnn_handle), "hbDNNRelease failed");
}
```

神经网络模型推理-基础示例交付物

基础示例包位于 horizon_j6_open_explorer 发布物的 samples/ucp_tutorial/dnn/basic_samples/ 路径下，主要包括以下内容：

```
basic_samples/
├── README.md
├── code # 示例源码
│   ├── 00_quick_start # 快速入门示例，用resnet50读取单张图片进行推理的示例代码
│   │   ├── CMakeLists.txt
│   │   └── src
│   ├── 01_api_tutorial
│   │   ├── CMakeLists.txt
│   │   ├── mem
│   │   ├── model
│   │   └── roi_infer
│   ├── CMakeLists.txt
│   ├── build.sh # 编译脚本
│   ├── build_aarch64.sh # 编译脚本，aarch64环境运行
│   ├── build_x86.sh # 编译脚本，x86环境运行
│   └── resolve.sh # 运行依赖获取脚本
└── runtime
    ├── model
    │   ├── README.md
    │   └── runtime -> ../../../../../model_zoo/runtime/basic_samples/
    ├── script
    │   ├── 00_quick_start
    │   ├── 01_api_tutorial
    │   └── README.md
    └── script_x86
        ├── 00_quick_start
        ├── 01_api_tutorial
        └── README.md
```

注：当前为试用版本内容，更多示例以及算子开发中。

神经网络模型推理-AI Benchmark交付物

AI Benchmark位于 horizon_j6_open_explorer 发布物的 samples/ucp_tutorial/dnn/ai_benchmark/ 路径下，主要包括以下内容：

```
ai_benchmark/
├── README.md
├── code
│   ├── CMakeLists.txt
│   ├── README.md
│   ├── build.sh
│   ├── build_ptq_j6.sh # PTQ方案程序一键编译脚本
│   ├── build_qat_j6.sh # QAT方案程序一键编译脚本
│   ├── include
│   ├── resolve.sh # 下载模型性能评测数据集的脚本
│   └── src # 示例源码
└── j6
    ├── ptq # PTQ方案模型示例
    │   ├── README.md
    │   ├── data # 模型评测数据集
    │   ├── model
    │   ├── script # 示例执行脚本
    │   └── tools # 精度评测工具
    └── qat # QAT方案模型示例
        ├── README.md
        ├── data
        ├── model
        ├── script
        └── tools
```

注：当前为试用版本内容，更多示例以及算子开发中。

地平线
Horizon Robotics

模型板端部署详解-UCP

神经网络模型推理 | 视觉处理 | 高性能计算库 | UCP工具

视觉处理

视觉处理VP模块在以NN为中心的计算方案中，主要作用于模型的前后处理环节。在地平线统一架构中，多种硬件均已搭载了图像处理的算子，而VP模块将图像处理相关的硬件调用进行了封装， 通过设置backend来选择不同的硬件方案（若不指定backend，UCP会自动适配负载更低的处理单元），从而平衡开发板负载，充分对开发板算力进行挖掘， 规避了不同硬件调用区别带来的不便

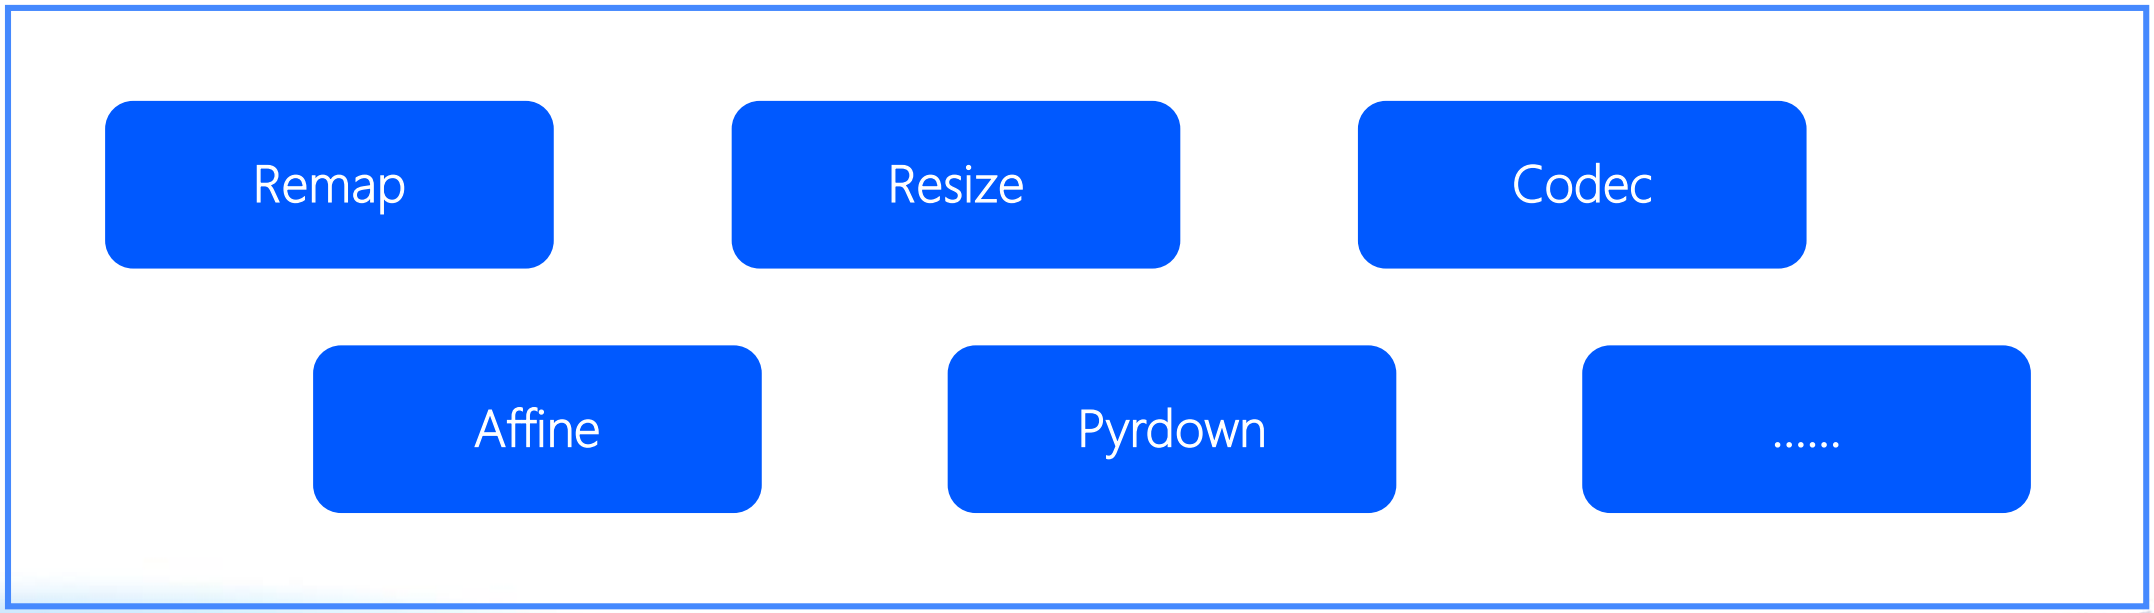

注：VP算子相关性能指标请参考用户手册

视觉处理-基本流程


申请内存用于存放图片
填充输入图片描述信息
hbVPImage
准备输入
准备输出
填充输出图片描述信息
hbVPImage
申请内存用于存放图片
设置旋转参数
创建任务
hbVPRotate
提交任务
hbUCPSubmitTask
设置调度参数
scheduleParam
等待任务完成
hbUCPWaitTaskDone
销毁任务
hbUCPReleaseTask
释放内存

视觉处理-示例解读

我们通过一个简单的算子调用展示了如何使用VP封装的算子实现图片处理的功能，使用hbVPRotate算子将图片旋转90度：


```cpp
#include <cstring>

#include "img_util.h"
#include "log_util.h"
#include "opencv2/opencv.hpp"
#include "hobot/vp/hb_vp_rotate.h"

// 读取输入图片
std::string src_img = "../../data/images/input.jpg";
cv::Mat src_mat = cv::imread(src_img.c_str(), cv::IMREAD_GRAYSCALE);
LOGE_AND_RETURN_IF(src_mat.empty(), HB_UCP_INVALID_ARGUMENT,
                   "Read image {} failed", src_img.c_str());
LOGI("Read image {} success", src_img);

const int32_t src_width = src_mat.cols;
const int32_t src_height = src_mat.rows;
const int32_t src_stride = src_width;
const int32_t dst_width = src_height;
const int32_t dst_height = src_width;
const int32_t dst_stride = dst_width;

// 初始化输入输出内存，并将图片填充到输入内存中
hbUCPSysMem src_mem, dst_mem;
hbUCPMallocCached(&src_mem, src_stride * src_height, 0);
hbUCPMallocCached(&dst_mem, dst_stride * dst_height, 0);
memcpy(src_mem.virAddr, src_mat.data, src_stride * src_height);
hbUCPMemFlush(&src_mem, HB_SYS_MEM_CACHE_CLEAN);
```

视觉处理-示例解读

我们通过一个简单的算子调用展示了如何使用VP封装的算子实现图片处理的功能，使用hbVPRotate算子将图片旋转90度：

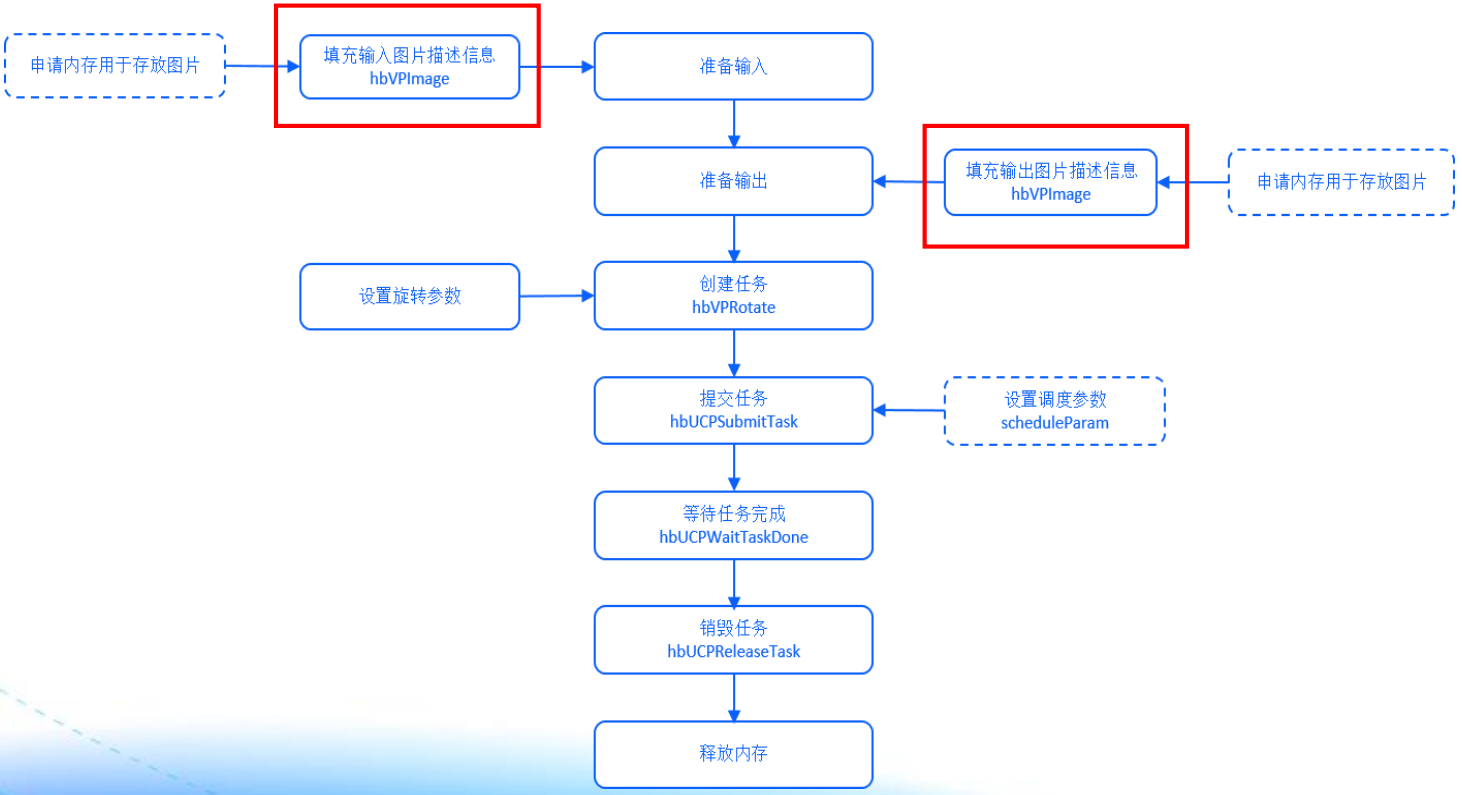


```
// 填充输入图片信息
hbVPImage src{HB_VP_IMAGE_FORMAT_Y,
              HB_VP_IMAGE_TYPE_U8C1,
              src_width,
              src_height,
              src_stride,
              src_mem.virAddr,
              src_mem.phyAddr,
              0,
              0,
              0};

// 填充输出图片信息
hbVPImage dst{HB_VP_IMAGE_FORMAT_Y,
              HB_VP_IMAGE_TYPE_U8C1,
              dst_width,
              dst_height,
              dst_stride,
              dst_mem.virAddr,
              dst_mem.phyAddr,
              0,
              0,
              0};

// 填充算子参数
int8_t rotate_code = HB_VP_ROTATE_90_CLOCKWISE;
```

视觉处理-示例解读

我们通过一个简单的算子调用展示了如何使用VP封装的算子实现图片处理的功能，使用hbVPRotate算子将图片旋转90度：

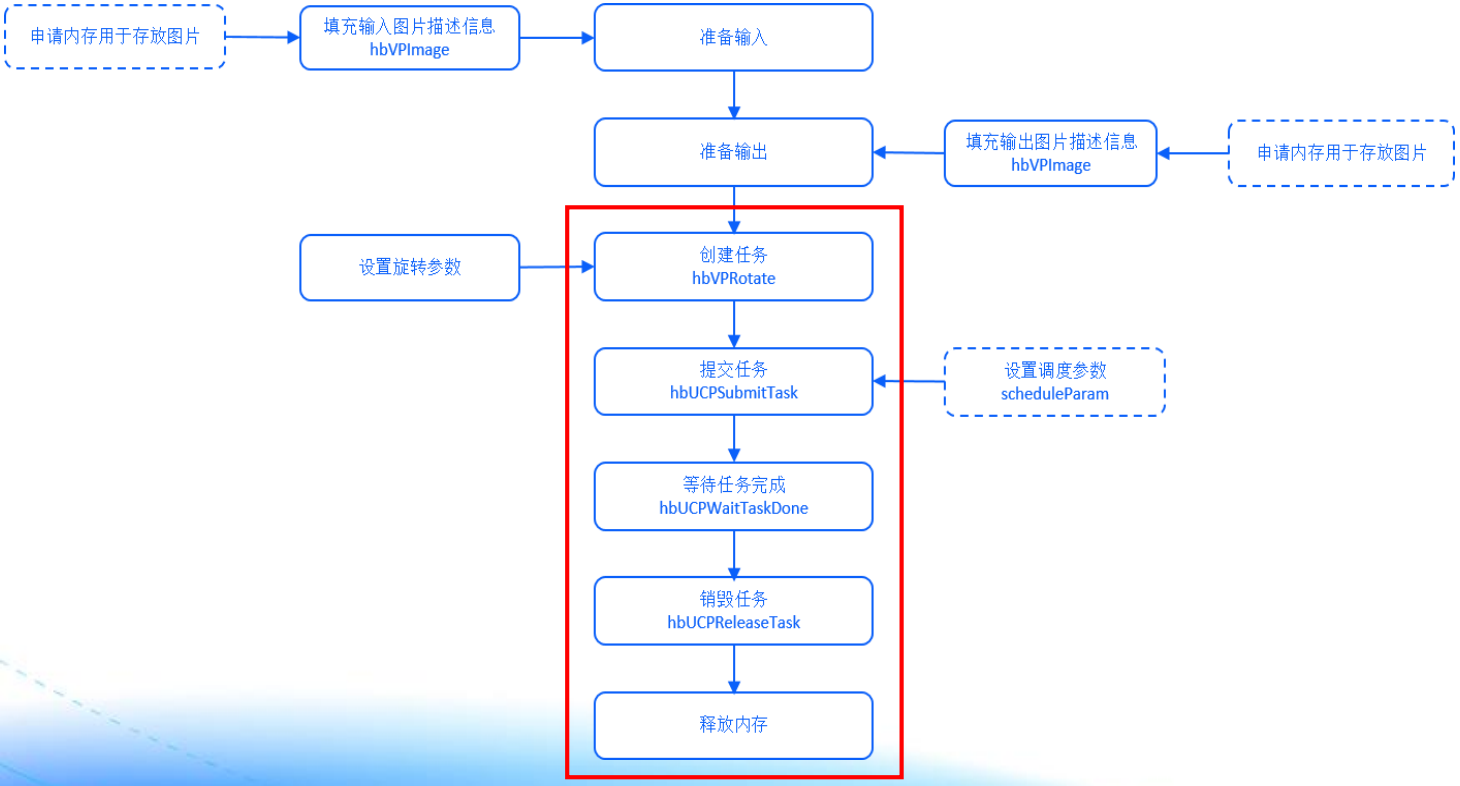


```
// 通过VP提供的算子接口创建任务，任务句柄支持设置为nullptr，使用同步模式执行此任务
hbUCPTaskHandle_t rotate_task{nullptr}; // UCP任务句柄
hbVPRotate(&rotate_task/*任务句柄*/,
           &dst/*输出图片*/,
           &src/*输入图片*/,
           rotate_code/*算子参数*/);

// 设置调度参数调整任务优先级、选择执行终端等
hbScheParam sched_param;
HB_UCP_INITIALIZE_SCHED_PARAM(&sched_param);
sched_param.backend = HB_UCP_DSP_CORE_0; /*指定执行设备ID*/

// 提交任务，sche_param 支持设置为nullptr，使用默认调度参数
hbUCPSubmitTask(rotate_task, &sched_param);/

// 等待任务完成，设置超时参数，值为0时表示一直等待
hbUCPWaitTaskDone(rotate_task, 500);

// 释放任务句柄
hbUCPReleaseTask(rotate_task);

// 释放内存资源
hbUCPFree(&src_mem);
hbUCPFree(&dst_mem);
```

视觉处理-交付物

OE包示例：

```
└── vp                                  // vp示例
    ├── code                            // 示例源码目录
    │   ├── 01_basic_processing         // 基础图像处理示例
    │   ├── 02_transformation           // 图像变换示例
    │   ├── 03_feature_extraction       // 图像特征提取示例
    │   ├── 04_optical_flow             // 光流处理示例
    │   ├── 05_avm                      // 环视图像拼接示例
    │   ├── build_aarch64.sh            // aarch64示例编译脚本
    │   ├── build.sh                    // 编译vp示例最小可执行环境脚本
    │   ├── build_x86.sh                // x86仿真示例编译脚本
    │   └── CMakeLists.txt              // cmake文件
    └── vp_samples                      // vp示例最小可执行环境
        ├── data                        // 图像数据目录
        ├── script                      // aarch64示例脚本目录
        │   ├── 01_basic_processing     // 基础图像处理示例脚本目录
        │   ├── 02_transformation       // 图像变换示例脚本目录
        │   ├── 03_feature_extraction   // 图像特征提取示例脚本目录
        │   ├── 04_optical_flow         // 光流处理示例脚本目录
        │   ├── 05_avm                  // 环视图像拼接示例脚本目录
        │   ├── dsp_deploy.sh           // 部署板上的dsp运行环境脚本
        │   └── README.md               // readme文件
        └── script_x86                  // x86仿真示例脚本目录
            ├── 01_basic_processing     // 基础图像处理示例脚本目录
            ├── 02_transformation       // 图像变换示例脚本目录
            ├── 03_feature_extraction   // 图像特征提取示例脚本目录
            ├── 04_optical_flow         // 光流处理示例脚本目录
            ├── 05_avm                  // 环视图像拼接示例脚本目录
            └── README.md               // readme文件
```

OE包示例后端使用：

示例名	说明	DSP	GDC	STITCH	JPU
basic process	基础图像处理示例	Y	N	N	N
transformation	图像转换示例	Y	N	N	N
feature extraction	特征提取示例	Y	N	N	N
optical flow	光流示例	Y	N	N	Y
avm	环视图像拼接示例	Y	Y	Y	Y

注：当前为试用版本内容，更多示例以及算子开发中。

地平线
Horizon Robotics

模型板端部署详解-UCP

神经网络模型推理 | 视觉处理 | 高性能计算库 | UCP工具

高性能计算库

HPL模块在以NN为中心的计算方案中，主要作用于模型的前后处理环节。在地平线统一架构中，多种硬件均已搭载了常用的高性能的算子，而HPL模块将高性能算子相关的硬件调用进行了封装， 通过设置backend来选择不同的硬件方案（若不指定backend，UCP会自动适配负载更低的处理单元），从而平衡开发板负载，充分对开发板算力进行挖掘， 规避了不同硬件调用区别带来的不便

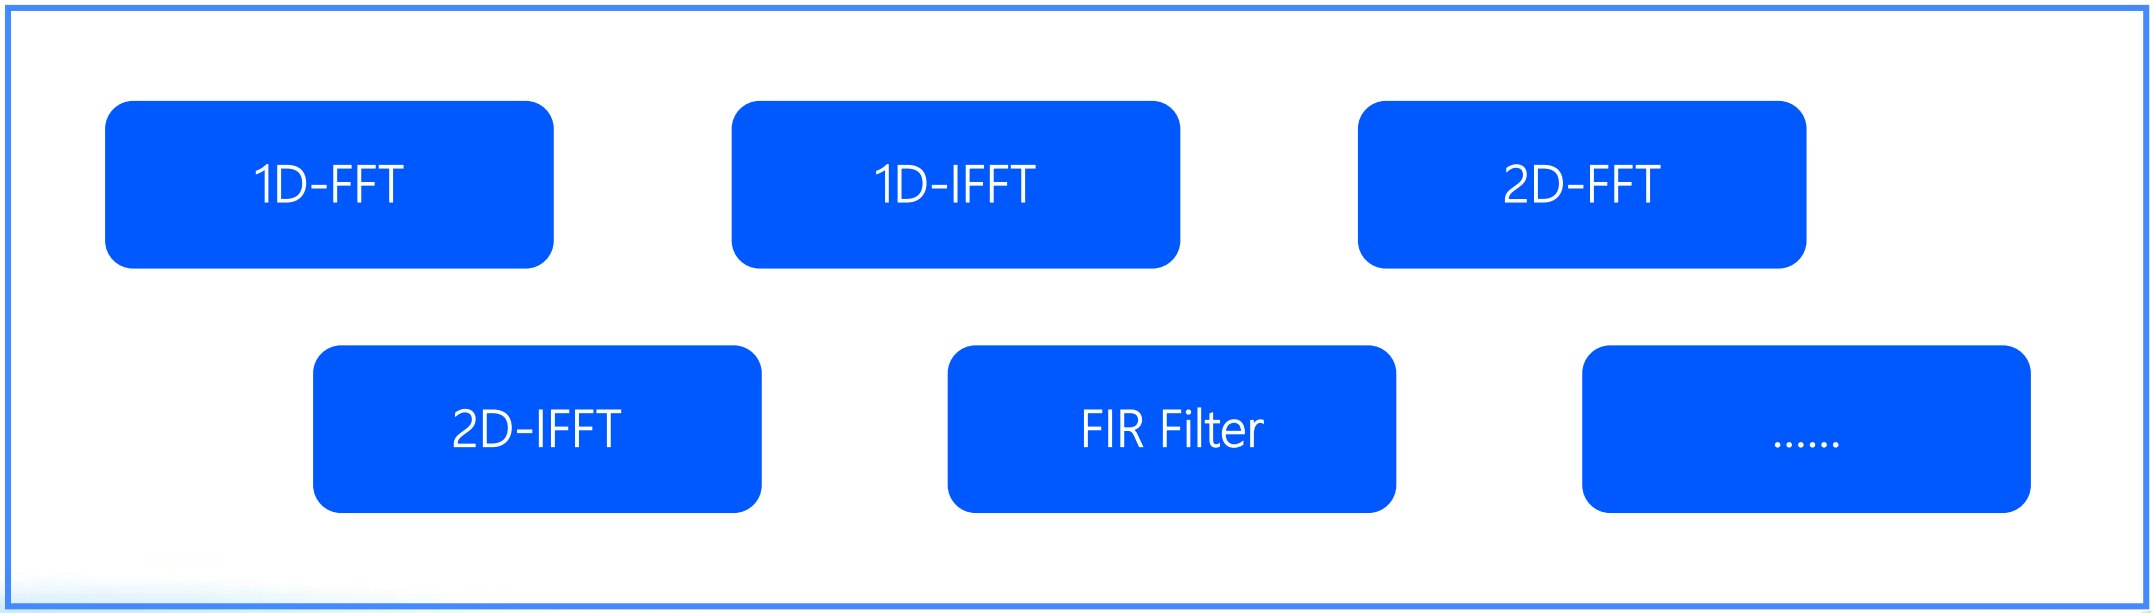

注：HPL算子相关性能指标请参考用户手册

高性能计算库-调用基本流程

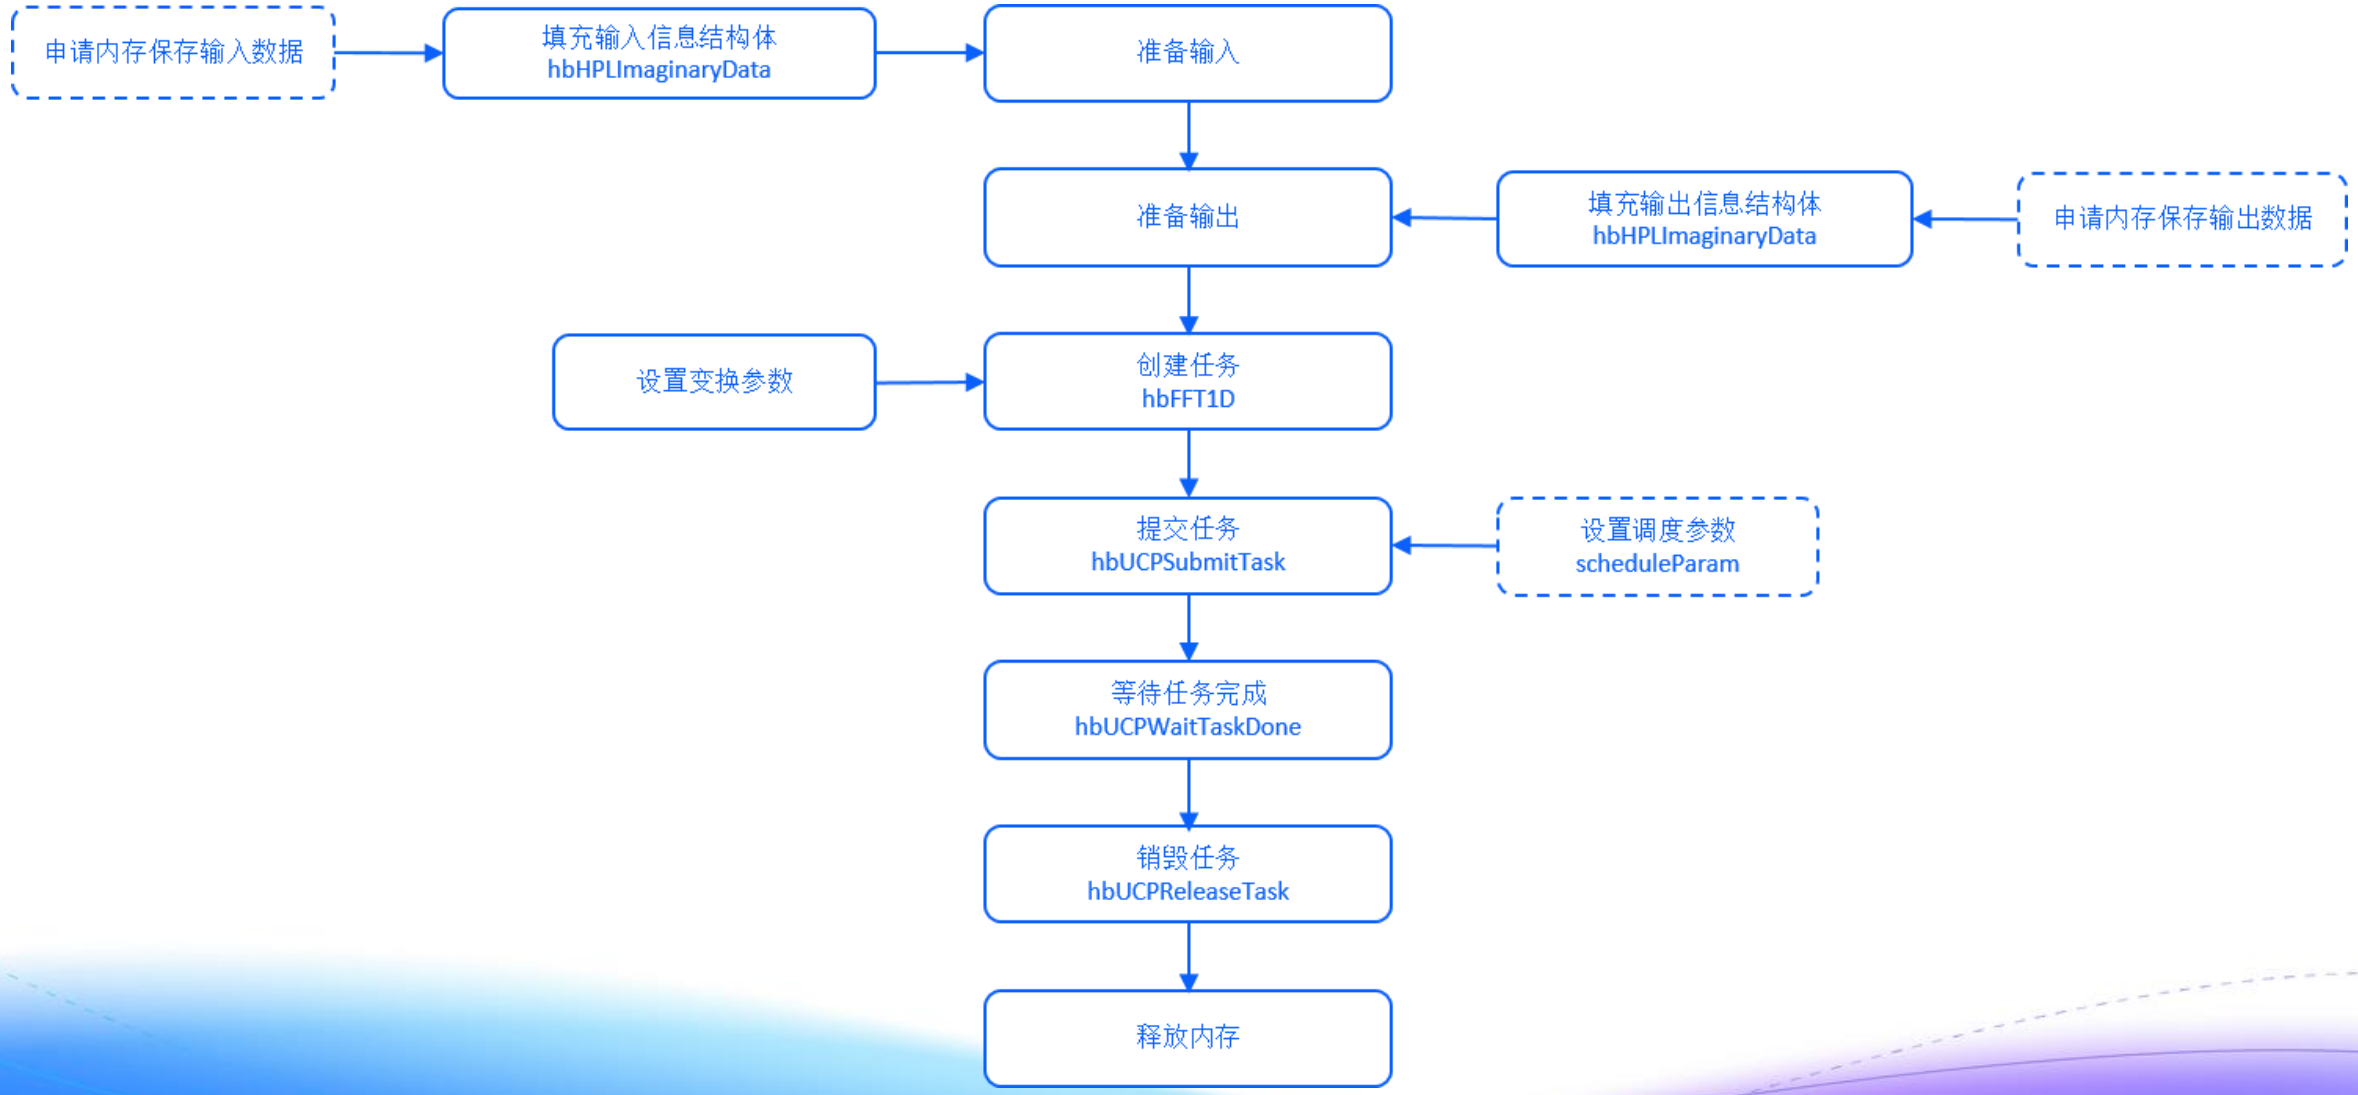

高性能计算库-示例解读

我们通过一个简单的算子调用展示如何使用HPL封装的算子实现快速傅里叶变换的功能，使用hbFFT1D算子对输入数据进行FFT变换：

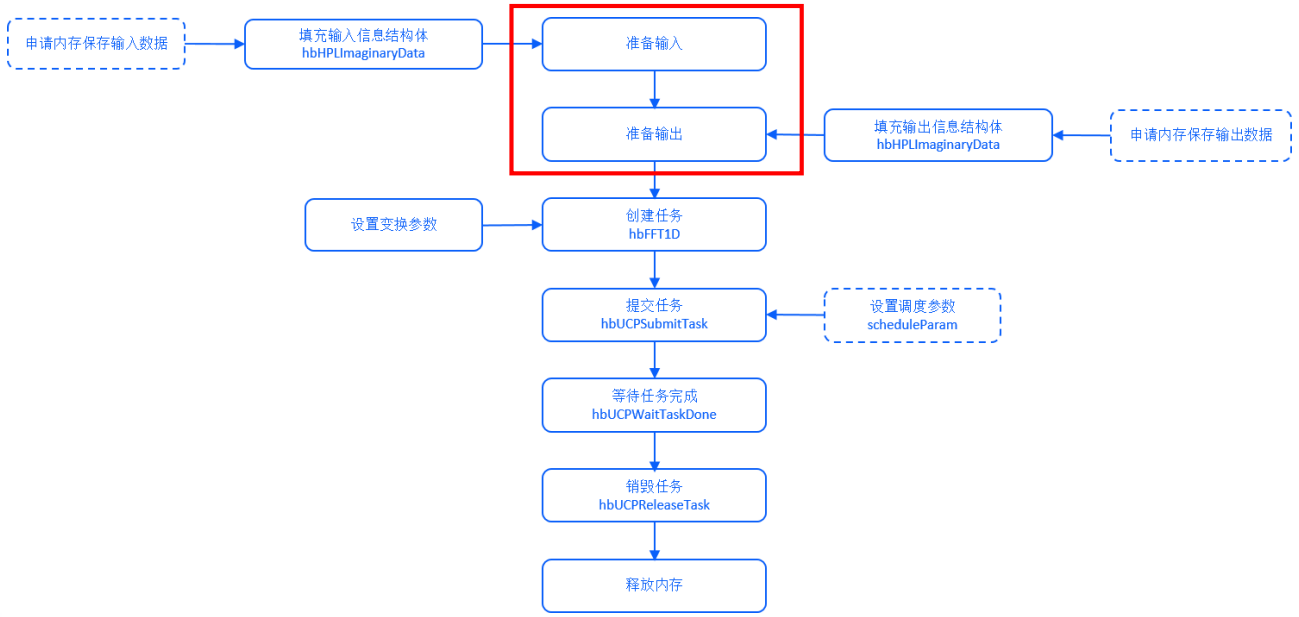


```cpp
#include <cstring>

#include "util.h"
#include "log_util.h"
#include "hobot/hpl/hb_fft.h"

// 初始化输入输出内存
hbUCPSysMem src_re_mem, src_im_mem, dst_re_mem, dst_im_mem;
int32_t src_length = 1024 * 4;
hbUCPMallocCached(&src_re_mem, src_length, 0);
hbUCPMallocCached(&src_im_mem, src_length, 0);
hbUCPMallocCached(&dst_re_mem, src_length, 0);
hbUCPMallocCached(&dst_im_mem, src_length, 0);

// 将数据填充到输入内存中
std::string src_img = "./fft_input.txt";
std::ifstream ifs(src_path, std::ios::in | std::ios::binary);
ifs.read(static_cast<char *>(src_re_mem.virAddr), src_length);
ifs.read(static_cast<char *>(src_im_mem.virAddr), src_length);
hbUCPMemFlush(&src_re_mem, HB_SYS_MEM_CACHE_CLEAN);
hbUCPMemFlush(&src_im_mem, HB_SYS_MEM_CACHE_CLEAN);
```

高性能计算库-示例解读

我们通过一个简单的算子调用展示如何使用HPL封装的算子实现快速傅里叶变换的功能，使用hbFFT1D算子对输入数据进行FFT变换：

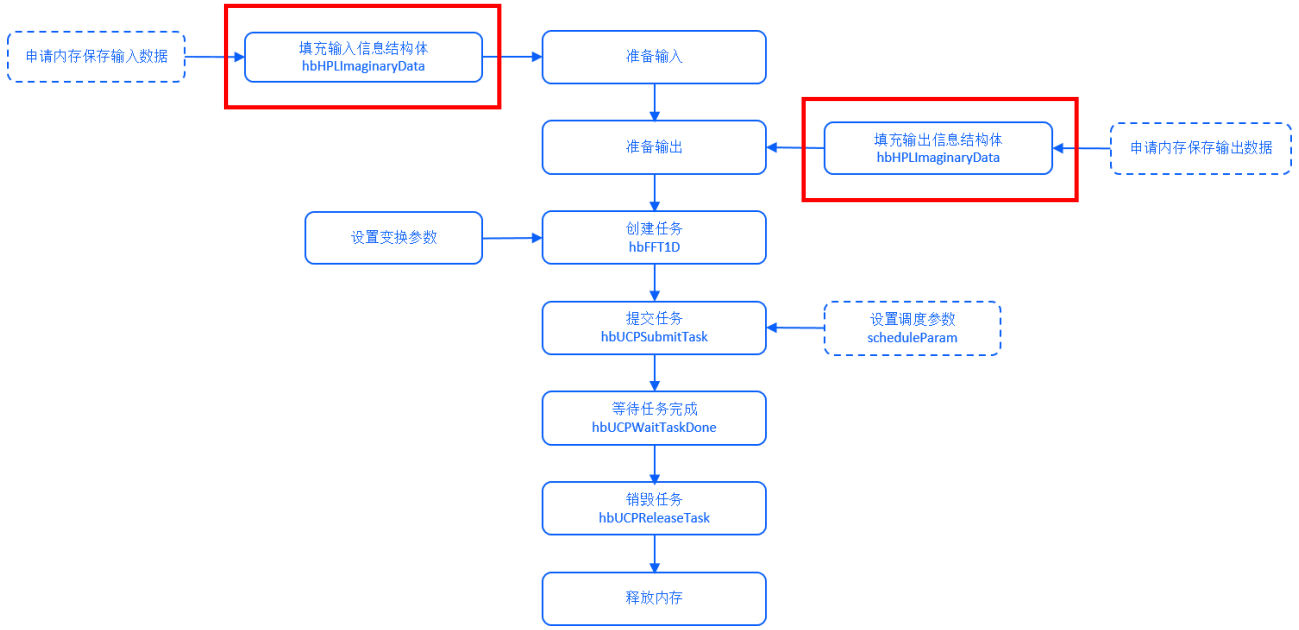


```
// 填充输入输出信息
hbHPLImaginaryData src, dst;
src.realDataVirAddr = src_re_mem.virAddr;
src.realDataPhyAddr = src_re_mem.phyAddr;
src.imDataVirAddr = src_im_mem.virAddr;
src.imDataPhyAddr = src_im_mem.phyAddr;
src.numDimensionSize = 1;
src.dataType = HB_HPL_DATA_TYPE_I16;
src.imFormat = HB_IM_FORMAT_SEPARATE;
src.dimensionSize[0] = src_length / sizeof(int16_t);

dst.realDataVirAddr = dst_re_mem.virAddr;
dst.realDataPhyAddr = dst_re_mem.phyAddr;
dst.imDataVirAddr = dst_im_mem.virAddr;
dst.imDataPhyAddr = dst_im_mem.phyAddr;
dst.numDimensionSize = 1;
dst.dataType = HB_HPL_DATA_TYPE_I16;
dst.imFormat = HB_IM_FORMAT_SEPARATE;
dst.dimensionSize[0] = src_length / sizeof(int16_t);

// 填充算子参数
hbFFTParam param;
param.pSize = HB_HPL_FFT32;
param.normalize = 0;
```

高性能计算库-示例解读

我们通过一个简单的算子调用展示如何使用HPL封装的算子实现快速傅里叶变换的功能，使用hbFFT1D算子对输入数据进行FFT变换：

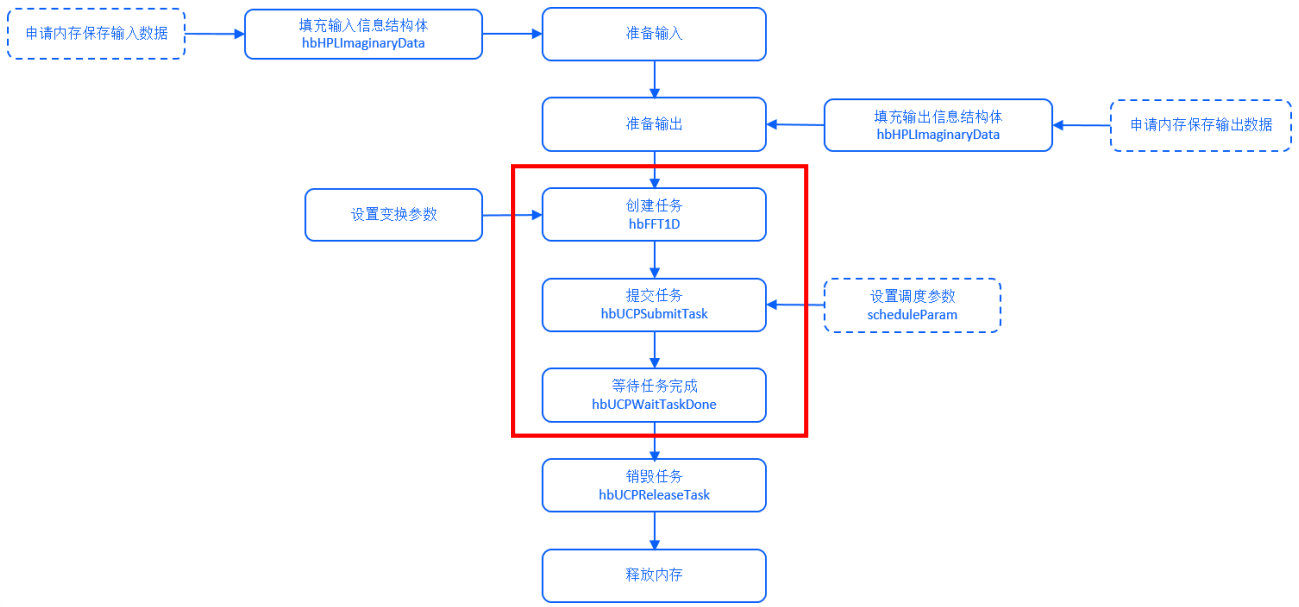


```
// 通过HPL提供的算子接口创建任务，任务句柄支持设置为nullptr，使用异步模式执行此任务
hbUCPTaskHandle_t task_handle{nullptr};

// 设置调度参数调整任务优先级、选择执行终端等参数
hbUCPSchedParam sched_param;
HB_UCP_INITIALIZE_SCHED_PARAM(&sched_param);
sched_param.backend = HB_UCP_DSP_CORE_0;  // 指定执行设备ID
sched_param.priority = 0;                 // 指定任务优先级

hbFFT1D(&task_handle,  // UCP任务句柄
        &dst,          // 输出数据
        &src,          // 输入数据
        &param         // 算子参数
        );

// 设置调度参数调整任务优先级、选择执行终端等参数
hbScheParam sched_param;
HB_UCP_INITIALIZE_SCHED_PARAM(&sched_param);
sched_param.backend = HB_UCP_DSP_CORE_0; /*指定执行设备ID*/

// 提交任务，sched_param 支持设置为nullptr，使用默认调度参数
hbUCPSubmitTask(task_handle, &sched_param);

// 等待任务完成，设置超时参数，值为0时表示一直等待
hbUCPWaitTaskDone(task_handle, 0);
```

高性能计算库-示例解读

我们通过一个简单的算子调用展示如何使用HPL封装的算子实现快速傅里叶变换的功能，使用hbFFT1D算子对输入数据进行FFT变换：

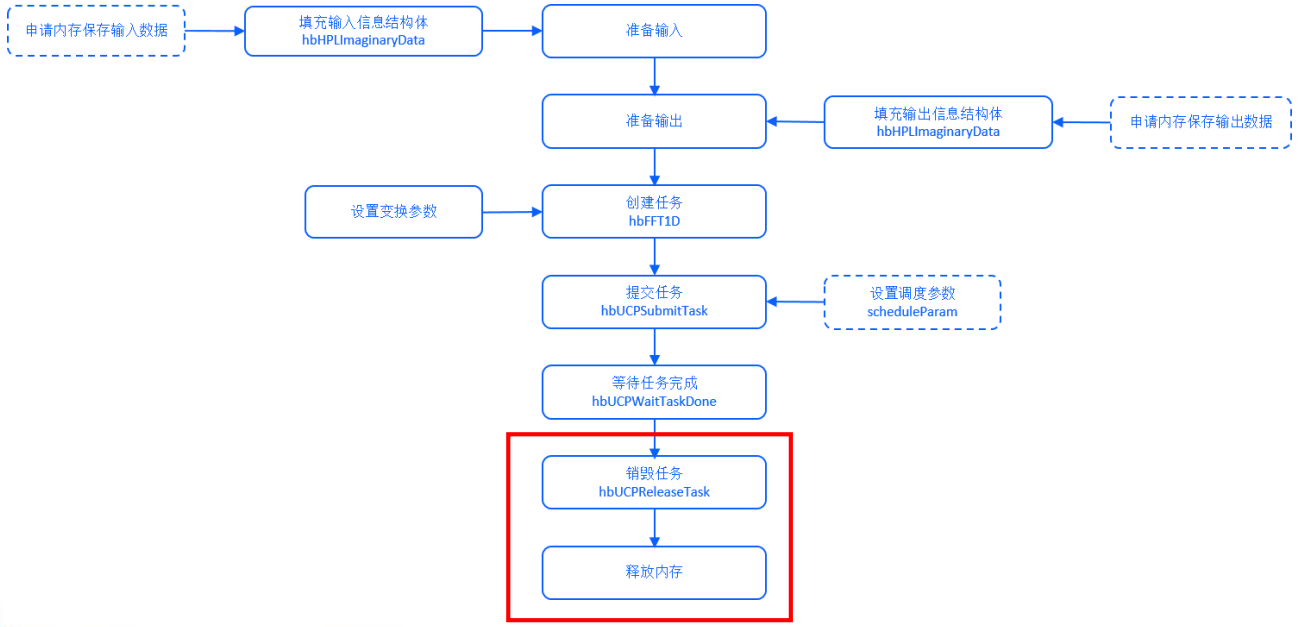


```
// 释放任务句柄
hbUCPReleaseTask(task_handle);

// 释放内存资源
hbUCPFree(&src_re_mem);
hbUCPFree(&src_im_mem);
hbUCPFree(&dst_re_mem);
hbUCPFree(&dst_im_mem);
```

高性能计算库

地平线 Horizon Robotics

OE包示例：

```
└── hpl                                  // hpl示例
    ├── code                             // 示例源码目录
    │   ├── 01_fft_ifft_transform        // fft ifft转换示例
    │   ├── util                         // 公共代码目录
    │   ├── build_aarch64.sh             // aarch64示例编译脚本
    │   ├── build.sh                     // 编译hpl示例最小可执行环境脚本
    │   ├── build_x86.sh                 // x86仿真示例编译脚本
    │   └── CMakeLists.txt               // cmake文件
    └── hpl_samples                      // hpl示例最小可执行环境
        ├── data                         // 数据目录
        ├── script                       // aarch64示例脚本目录
        │   ├── 01_fft_ifft_transform    // 示例脚本目录
        │   └── dsp_deploy.sh            // 部署板上的dsp运行环境脚本
        └── script_x86                   // x86仿真示例脚本目录
            ├── 01_fft_ifft_transform    // 示例脚本目录
            └── README.md                // readme文件
```

OE包示例后端使用：

算子名	说明	DSP
Fast Fourier Transform	快速傅里叶变换	Y
Inverse Fast Fourier Transform	快速傅里叶逆变换	Y
Fast Fourier Transform 2D	二维快速傅里叶变换	Y
Inverse Fast Fourier Transform 2D	二维快速傅里叶逆变换	Y

注：当前为试用版本内容，更多示例以及算子开发中。

地平线
Horizon Robotics

模型板端部署详解-UCP

神经网络模型推理 | 视觉处理 | 高性能计算库 | UCP工具

UCP工具-hrt_model_exec

hrt_model_exec工具可以帮助用户快速了解模型的实际上板性能，同时可以帮助用户获取模型信息以及推理模型。工具参数说明可以运行hrt_model_exec -h查看

编号	子命令	说明
1	model_info	获取模型信息，如：模型的输入输出信息等。
2	infer	执行模型推理，获取模型推理结果。
3	perf	执行模型性能分析，获取性能分析结果。

UCP工具-hrt_model_exec

运行hrt_model_exec工具查看Pyramid和Resizer输入的模型信息model_info时，终端打印信息如下：

```
[model name]: resnet50
[model desc]: TODO
input[0]:
name: input_y
input source: HB_DNN_INPUT_FROM_DDR
valid shape: (1,224,224,1,)
aligned shape: (0,0,0,0,)
aligned byte size: -1
tensor type: HB_DNN_TENSOR_TYPE_U8
tensor layout: HB_DNN_LAYOUT_NONE
quanti type: NONE
stride: (-1,-1,1,1,)

input[1]:
name: input_uv
input source: HB_DNN_INPUT_FROM_DDR
valid shape: (1,112,112,2,)
aligned shape: (0,0,0,0,)
aligned byte size: -1
tensor type: HB_DNN_TENSOR_TYPE_U8
tensor layout: HB_DNN_LAYOUT_NONE
quanti type: NONE
stride: (-1,-1,2,1,)

output[0]:
name: output
valid shape: (1,1,1,1000,)
aligned shape: (1,1,1,1000,)
aligned byte size: 1024
tensor type: HB_DNN_TENSOR_TYPE_S8
tensor layout: HB_DNN_LAYOUT_NONE
quanti type: SCALE
stride: (1000,1000,1000,1,)
scale data: 0.00787402,
zero_point data: ,
op_type: HB_DNN_OUTPUT_OPERATOR_TYPE_UNKNOWN
```

输入源为Pyramid，输入数据格式为nv12，默认y和uv分量拆开

J6支持更灵活的数据排布，Layout概念取消

-1为占位符，表示该维度为动态维度，需在推理前指定具体值

aligned shape建议根据valid shape和stride来解析：
(1, stride[0]/stride[1], stride[1]/stride[2], stride[2]/stride[3])

反量化节点被删除，保留反量化参数

```
input[0]: 输入源为Resizer
name: data_y_imageY
input source: HB_DNN_INPUT_FROM_DDR
valid shape: (1,-1,-1,1,) 动态valid
aligned shape: (0,0,0,0,) shape
aligned byte size: -1
tensor type: HB_DNN_TENSOR_TYPE_U8
tensor layout: HB_DNN_LAYOUT_NONE
quanti type: NONE
stride: (-1,-1,1,1,)

input[1]:
name: data_uv_imageUV
input source: HB_DNN_INPUT_FROM_DDR
valid shape: (1,-1,-1,2,)
aligned shape: (0,0,0,0,)
aligned byte size: -1
tensor type: HB_DNN_TENSOR_TYPE_U8
tensor layout: HB_DNN_LAYOUT_NONE
quanti type: NONE
stride: (-1,-1,2,1,)

input[2]:
name: data_roi_imageRoi
input source: HB_DNN_INPUT_FROM_DDR
valid shape: (1,4,)
aligned shape: (1,4,)
aligned byte size: 16
tensor type: HB_DNN_TENSOR_TYPE_S32
tensor layout: HB_DNN_LAYOUT_NONE
quanti type: NONE
stride: (16,4,)
```

UCP工具-hrt_model_exec

执行hrt_model_exec perf可以在板端评测模型的动态性能，其中指标Latency是指单流程推理模型所耗费的平均时间，重在表示在资源充足的情况下推理一帧的平均耗时，体现在上板运行是单核单线程统计；FPS是指多流程同时进行模型推理平均一秒推理的帧数，重在表示充分使用资源情况下模型的吞吐，体现在上板运行为单核多线程。耗时统计在代码中的位置如下图：

```
// Load model and prepare input and output tensor
  ...

  // Loop run inference and get latency
  {
    int32_t const loop_num{1000};
    start = std::chrono::steady_clock::now();
    for(int32_t i = 0; i < loop_num; i++){
        hbUCPSchedParam sched_param{};
        HB_UCP_INITIALIZE_SCHED_PARAM(&sched_param);
        // create task
        hbDNNInferV2(&task_handle, output_tensor, input_tensor, dnn_handle);
        // submit task
        hbUCPSubmitTask(task_handle, &sched_param);
        // wait task done
        hbUCPWaitTaskDone(task_handle, 0);
        // release task handle
        hbUCPReleaseTask(task_handle);
        task_handle = nullptr;
    }
    end = std::chrono::steady_clock::now();
    latency = (end - start) / loop_num;
  }

  // release tensor and model
  ...
```

UCP工具-hrt_model_exec

hrt_model_exec工具源码和编译脚本路径如左图，执行编译脚本编译后的生成物如右图

```
samples/ucp_tutorial/tools/hrt_model_exec/
├── CMakeLists.txt
├── README.md
├── build.sh # 工具编译脚本
├── build_aarch64.sh # aarch64工具编译脚本
├── build_x86.sh # x86工具编译脚本
├── include # 头文件
│   └── util
├── script # aarch64工具运行脚本
│   └── run_hrt_model_exec.sh
├── script_x86 # x86工具运行脚本
│   └── run_hrt_model_exec.sh
└── src # 工具源码
    ├── cnpy
    ├── main.cpp
    └── util
```

```
# 运行aarch64工具编译脚本后
output_shared_J6_aarch64/
├── aarch64
│   ├── bin
│   └── lib
└── script
    └── run_hrt_model_exec.sh
# 运行x86工具编译脚本后
output_shared_J6_x86/
├── script_x86
│   └── run_hrt_model_exec.sh
└── x86
    ├── bin
    └── lib
```

UCP工具-hrt_ucp_monitor

hrt_ucp_monitor 是一个监控硬件 IP 占用率的工具，支持的 IP 包括BPU，DSP，GDC，STITCH，PYM，ISP，Codec（VPU 和 JPU），将OE开发包samples/ucp_tutorial/tools/monitor路径下的可执行文件拷贝至板端，执行./hrt_ucp_monitor -h可查看参数说明

运行hrt_ucp_monitor时，如果不指定参数，则使用默认参数运行。默认开启所有硬件IP监控，以交互模式运行， BPU 和 DSP 每秒采样 500 次，硬件 IP 占用率每 1000ms 刷新一次

```
Monitor 1.0.0
+-----------------------------------------+
|          IP              %LOADING       |
|          BPU0              0.0          |
|          DSP0              0.0          |
|          GDC0              0.0          |
|          ISP0              0.0          |
|          ISP1              0.0          |
|          JPU0              0.0          |
|          PYM0              0.0          |
|          PYM1              0.0          |
|          PYM2              0.0          |
|          STITCH0           0.0          |
|          VPU0              0.0          |
+-----------------------------------------+
```

UCP工具-trace

UCP trace 通过在 UCP 执行的关键路径上嵌入 trace 记录（任务记录和算子记录），提供深入分析 UCP 应用程序调度逻辑的能力。在出现性能异常时，可以通过分析UCP trace，快速找到异常发生的时间点。UCP trace 提供了两种 trace 后端选项：Perfetto Trace 和 Chrome Trace。您可以通过设置环境变量，在这两者之间进行选择，以满足您特定的性能跟踪需求：

- Perfetto Trace可以获取到 UCP 记录的 trace，以及系统状态， ftrace 等信息；
- Chrome Trace只能获取 UCP 记录的 trace ，主要用于分析 UCP 本身的调度逻辑。

UCP trace 工具和配置文件位于 samples/ucp_tutorial/tools/trace 路径下，目录结构为：

```
└── trace                          # trace工具
    ├── catch_trace.sh             # chrome trace捕获脚本
    ├── configs                    # 参考配置文件
    │   ├── ucp_in_process.cfg     # in_process模式的perfetto配置文件
    │   ├── ucp_in_process.json    # in_process模式的ucp配置文件
    │   ├── ucp_system.cfg         # system模式的perfetto配置文件
    │   └── ucp_system.json        # system模式的ucp配置文件
    ├── perfetto                   # 触发trace抓取的工具
    ├── traced                     # trace服务程序
    └── traced_probes              # trace数据抓取程序
```

性能评测实操

实操要求

获取ResNet50模型的ONNX文件，使用hb_compile --fast-perf工具快速完成转换编译得到可以板端运行且性能最优的hbm模型，进行静态（PC端）和动态（板端）的性能评测。

实操提示

1. 运行启动docker脚本进入开发环境，需指定挂载的本地数据集路径和cpu/gpu docker：sh run_docker.sh /home/data gpu；
2. 我们实操选取ResNet50，了解模型快速评测的流程以及对生成物进行解读，模型示例路径为samples/ai_toolchain/horizon_model_convert_sample/03_classification/03_resnet50，首先运行00_init.sh脚本获取原始onnx模型，默认下载保存在samples/ai_toolchain/horizon_model_convert_sample/01_common/model_zoo/mapper/classification/resnet50路径下，拷贝至samples/ai_toolchain/horizon_model_convert_sample/03_classification/03_resnet50；
3. 执行命令hb_compile --fast-perf --model resnet50.onnx --march nash-m，进行PTQ快速模型转换，获取可部署的性能最优模型（不可用作精度验证），查看model_output路径下生成物静态性能评测数据。

实操提示

4. 将hbm模型拷贝至开发板端，配置PATH链接推理库：

```
#!/bin/sh
export PATH=/map/env_setup/runtime_env:${PATH}
export LD_LIBRARY_PATH=/map/env_setup/runtime_env/oe3017:${LD_LIBRARY_PATH}
export _HB_UCP_PROFILER_LOG_PATH_=./
```

5. 执行命令hrt_model_exec -h验证推理环境是否已正确配置；

6. 执行命令hrt_model_exec model_info --model_file resnet50.hbm查看模型信息；

7. 执行板端动态Perf的命令为hrt_model_exec perf --model_file resnet50.hbm --thread_num 8 --input_stride “50176,224,1,1;25088,224,2,1” --frame_count 200评测吞吐率，查看当前路径下生成的BPU和CPU耗时统计信息。

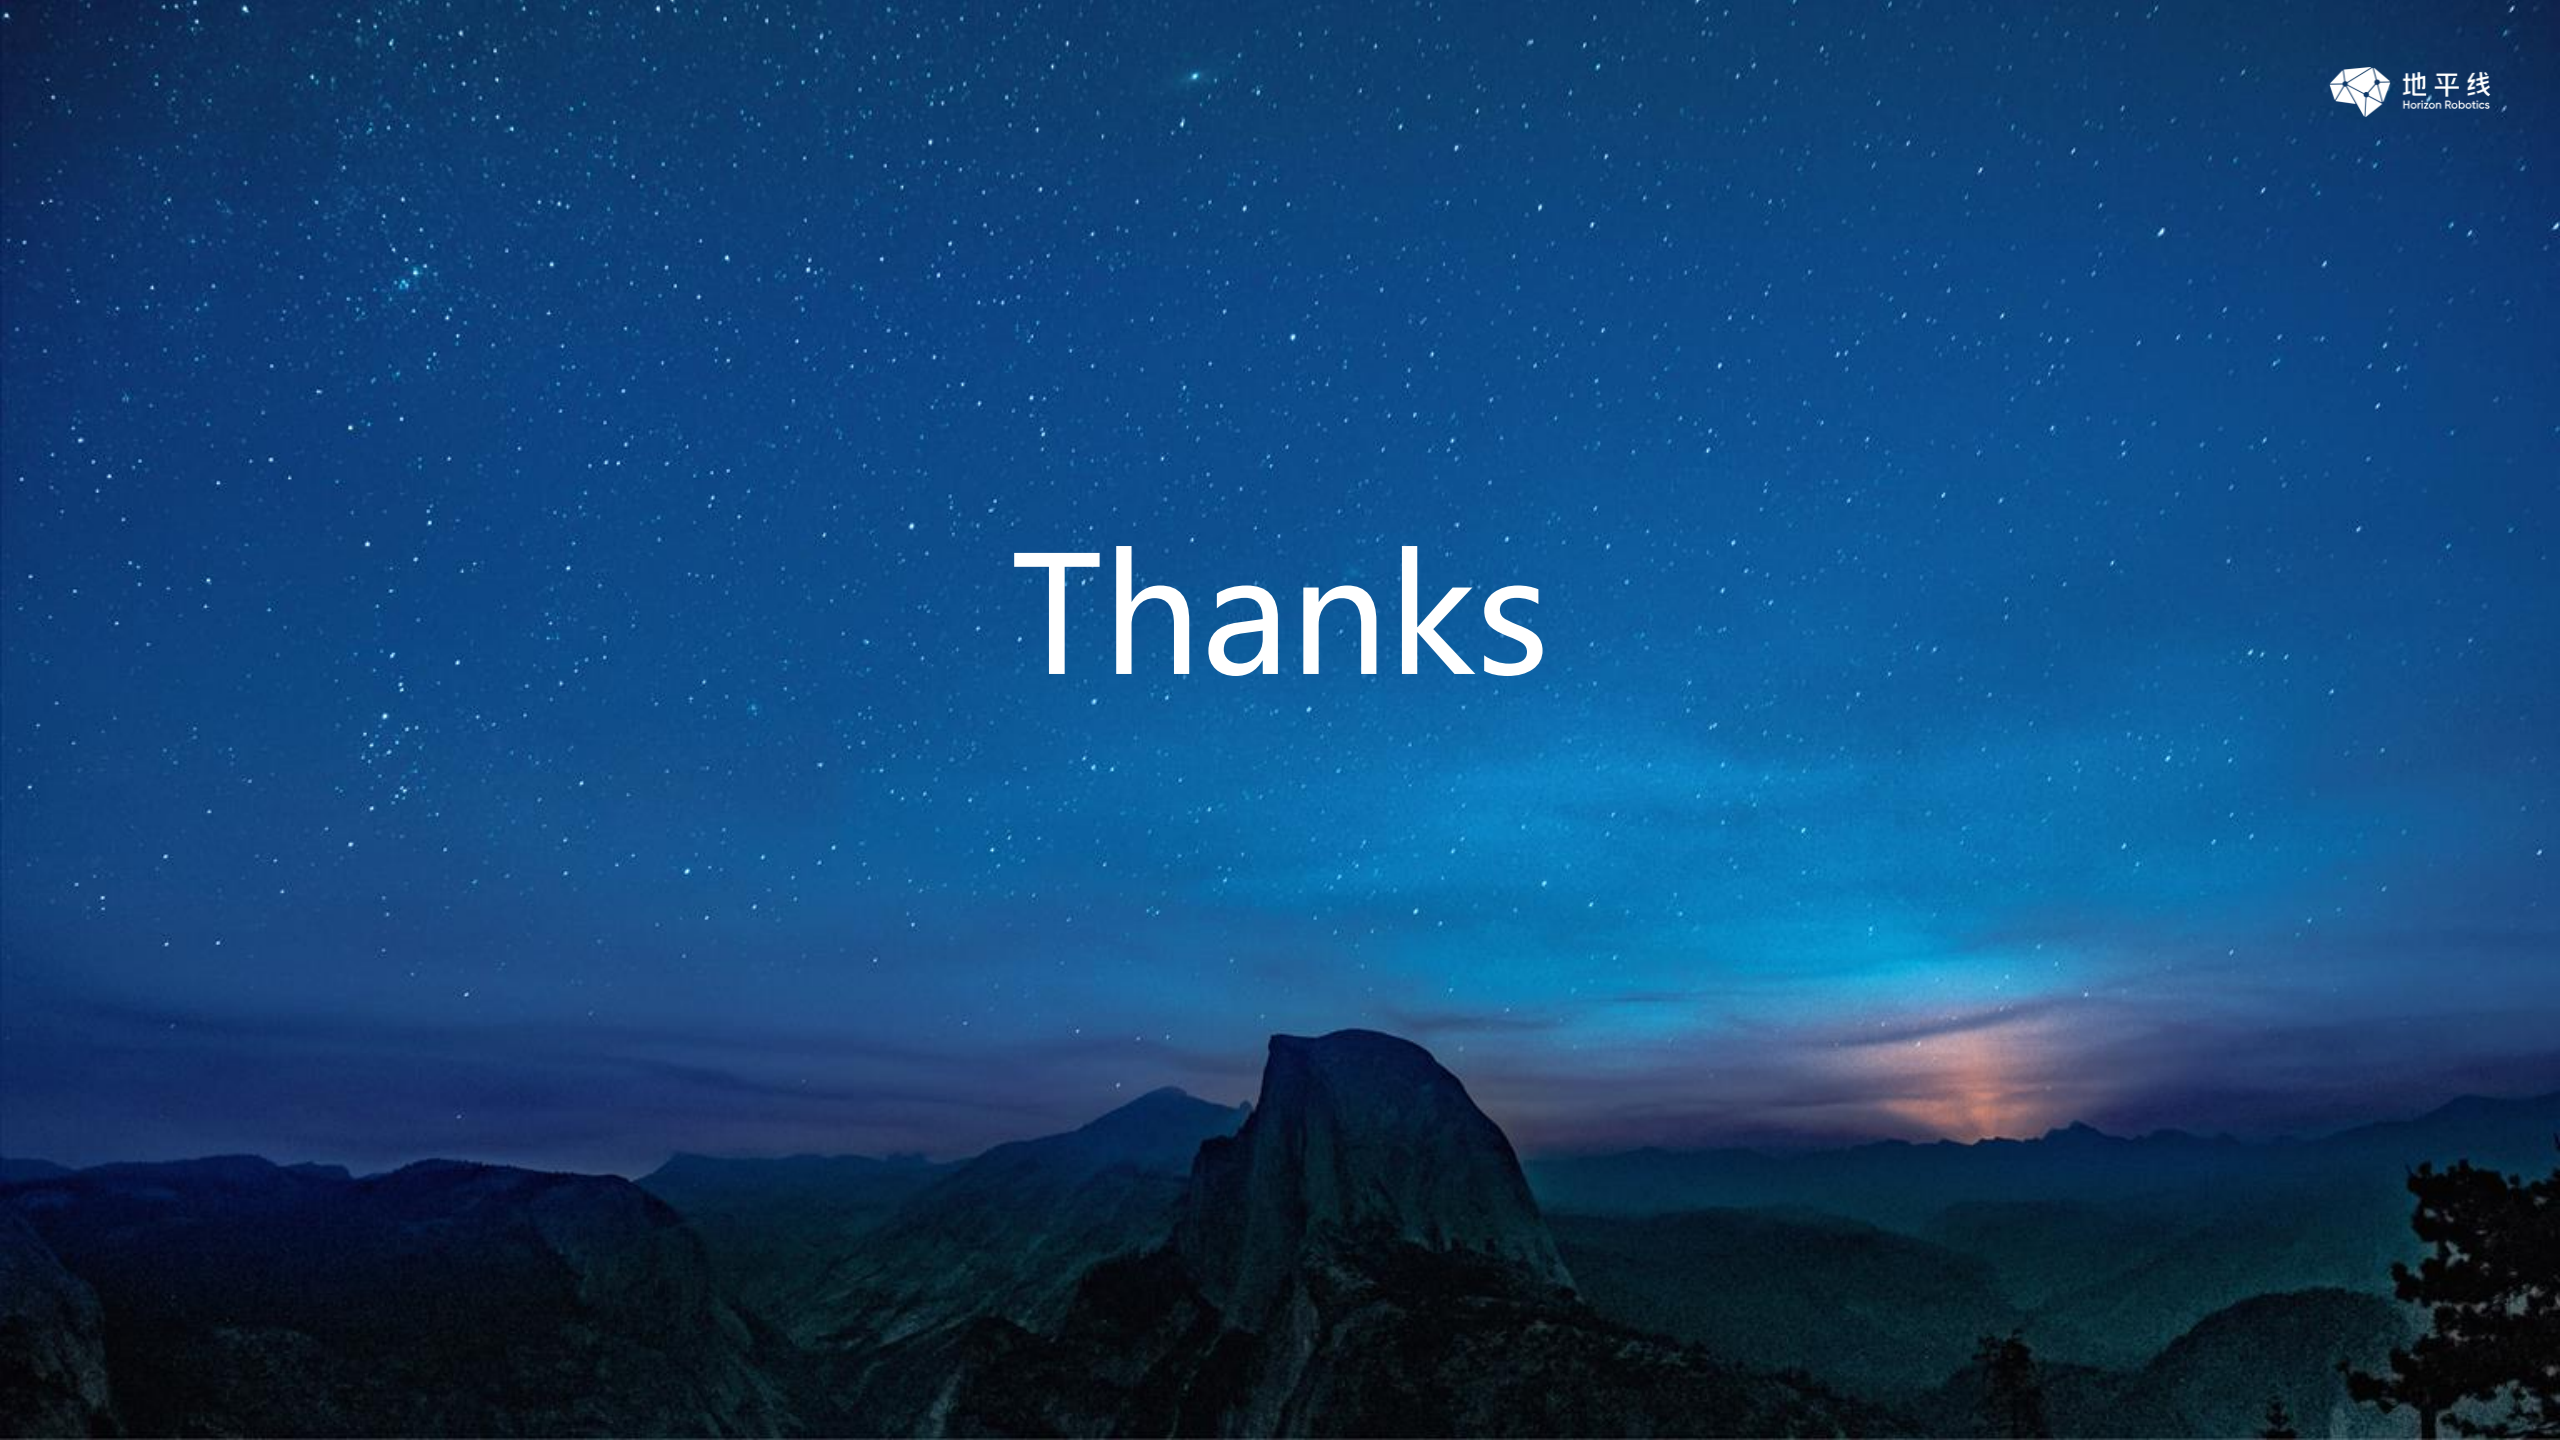
地平线
Horizon Robotics
Thanks