MegFlow

MegEngine

2022 年 01 月 10 日

how to build and run

Please select a specific version of the document in the lower left corner of the page.

CHAPTER 1

Building with docker

docker build 方式能够“可复现地”生成运行环境、减少依赖缺失的痛苦

1.1 下载模型包

docker 运行方式，建议把模型包下好，解压备用。下载地址

1.2 编译 Docker 镜像

```
$ cd MegFlow
$ docker build -t megflow -f Dockerfile.github-dev .
```

稍等一段时间（取决于网络和 CPU）镜像构建完成并做了基础自测

> 注意：**不要移动 Dockerfile 文件的位置**。受 EAR 约束，MegFlow 无法提供现成的 docker 镜像，需要自己 build 出来，这个过程用了相对路径。

```
$ docker images
REPOSITORY            TAG          IMAGE ID       CREATED             SIZE
megflow               latest       c65e37e1df6c   18 hours ago        5.05GB
```

直接用 ${IMAGE ID} 进入开始跑应用，挂载上之前下载好的模型包

```
$ docker run  -p 18081:8081 -p 18082:8082 -v ${DOWNLOAD_MODEL_PATH}:/megflow-runspace/
↪flow-python/examples/models -i -t  c65e37e1df6c /bin/bash
```

1.3 Python Built-in Applications

接下来开始运行好玩的 Python 应用

- 猫猫围栏运行手册
  - 图片注册猫猫
  - 部署视频围栏，注册的猫离开围栏时会发通知
  - 未注册的不会提示
- 电梯电瓶车告警
  - 电梯里看到电瓶车立即报警
- *quickstart*
  - 问答式创建自己的应用

CHAPTER 2

Building from Source

2.1 一、安装依赖

2.1.1 安装 Rust

```
$ sudo apt install curl
$ curl --proto '=https' --tlsv1.2 https://sh.rustup.rs -sSf | sh
```

成功后，cargo 应该可以正常执行

```
$ cargo --version
cargo 1.56.0 (4ed5d137b 2021-10-04)
```

如果不成功，提示 Command 'cargo' not found，可以按照提示加载一下环境变量 (重新连接或打开终端也可以):

```
source $HOME/.cargo/env
```

> cargo 是 Rust 的包管理器兼编译辅助工具。类似 Java maven/go pkg/C++ CMake 的角色，更易使用。

2.1.2 安装 python3.x （推荐 conda）

打开 miniconda 官网 下载 miniconda 安装包，修改权限并安装。

```
$ wget https://repo.anaconda.com/miniconda/Miniconda3-latest-Linux-x86_64.sh
$ chmod a+x Miniconda3-latest-Linux-x86_64.sh
$ ./Miniconda3-latest-Linux-x86_64.sh
```

安装时接受 conda 修改默认.bashrc 环境变量（zsh 用户还需自行修改.zshrc 中的 conda initialize 配置）。成功后 `conda` 可正常运行

```
$ conda --version
conda 4.10.3
```

创建一个 Python3.x（这里以 3.8 为例）的环境，激活。

```
$ conda create --name py38 python=3.8
$ conda activate py38
```

2.1.3 安装基础依赖库

megflow 的构建需要一些基础依赖库, 下面以 ubuntu 系统为例:

```
$ sudo apt update
$ sudo apt install -y wget yasm clang git build-essential
$ sudo apt install -y libssl-dev
$ sudo apt install -y pkg-config --fix-missing
```

2.2 二、编译

编译并安装 Python 包到当前用户下

```
$ git clone --recursive https://github.com/MegEngine/MegFlow --depth=1
$ cd MegFlow/flow-python
$ python3 setup.py install --user
```

编译成功后，在 Python `import megflow` 正常。

2.3 三、Python“开机自检”

```
$ cd examples
$ megflow_run -p logical_test
```

`logical_test` 是 examples 下最基础的计算图测试用例，运行能正常结束表示 MegFlow 编译成功、基本语义无问题。

`megflow_run` 是计算图的实现。编译完成之后不再需要 `cargo` 和 `Rust`，使用者只需要

- `import megflow` 成功
- `megflow_run -h` 正常

2.4 四、编译选项

CHAPTER 3

aarch64 源码编译

aarch64 源码编译方式和 源码编译 相同，此处只说明差异。

3.1 环境差异

如果是华为鲲鹏 ARM 服务器 CentOS 系统，gcc 需要 >= 7.5 版本，系统默认的 `aarch64-redhat-linux-gcc 4.8.5` 缺 `__ARM_NEON` 会导致大量异常。

```
$ yum install -y centos-release-scl
$ yum install -y devtoolset-8-gcc devtoolset-8-gcc-c++
$ source /opt/rh/devtoolset-8/enable
$ gcc --version
gcc (GCC) 8.3.1 20190311 (Red Hat 8.3.1-3)
...
```

3.2 软件差异

conda 建议使用 `archiconda`，目前（2021.12.06）miniconda aarch64 官网版本在 KhadasVIM3/JetsonNao 上均会崩溃。`archiconda` 安装：

```
$ wget https://github.com/Archiconda/build-tools/releases/download/0.2.3/Archiconda3-
↪0.2.3-Linux-aarch64.sh
$ chmod +x Archiconda3-0.2.3-Linux-aarch64.sh && ./Archiconda3-0.2.3-Linux-aarch64.sh
```

CHAPTER 4

Build on win10

4.1 下载模型包

docker 运行方式，建议把模型包下好，解压备用。下载地址

4.2 安装 wsl2

安装文档 已经非常详细，核心是安装 Linux 内核更新包。完成后第 6 步中的 Linux 分发应该可以正常运行。

4.3 安装 docker

下载 windows docker 客户端 并安装。docker 依赖 wsl2，Docker Desktop 启动正常没有报 fail 即可。

4.4 安装 git

下载安装 git 客户端 并运行 Git Bash。

```
$ pwd
/c/Users/username
$ cd /d  # 切换到合适的盘符
$ git clone https://github.com/MegEngine/MegFlow
```

(下页继续)

(续上页)

```
...
$ cd MegFlow
$ docker build -t megflow .
... # 等待镜像完成，取决于网络和 CPU
```

注意：**不要移动 Dockerfile 文件的位置**。受 EAR 约束，MegFlow 无法提供现成的 docker 镜像，需要自己 build 出来，这个过程用了相对路径。

4.5 运行

```
$ docker images
REPOSITORY            TAG           IMAGE ID       CREATED             SIZE
megflow               latest        c65e37e1df6c   18 hours ago        5.05GB
```

直接用 ${IMAGE ID} 进入开始跑应用，挂载上之前下载好的模型包

```
$ docker run  -p 18081:8081 -p 18082:8082 -v ${DOWNLOAD_MODEL_PATH}:/megflow-runspace/
↪flow-python/examples/models -i -t  c65e37e1df6c /bin/bash
```

CHAPTER 5

创建 rtsp 流地址

5.1 视频解析概要

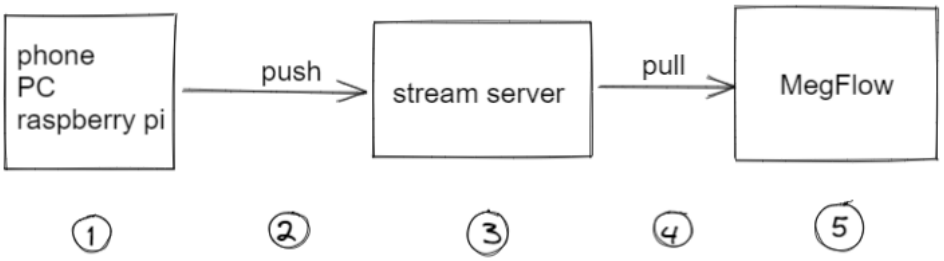

workflow

1. 前端采集。录制的视频需要用 `ffmpeg` 转到.ts/.h264/.h265 格式，**不能直接推.mp4**
2. 推流。`ffmpeg` 命令发数据包给流服务器
3. 流服务器。github 有许多开源实现

```
本文使用 `rtsp-simple-server` 作为样例
```

1. MegFlow 拉流

2. MegFlow 解码、解析

本文只说明 1 ~ 3 如何推流。

5.2 配置流服务器

下载 rtsp-simple-server 并启动

```
$ wget https://github.com/aler9/rtsp-simple-server/releases/download/v0.17.2/rtsp-
↪simple-server_v0.17.2_linux_amd64.tar.gz
$
$ tar xvf rtsp-simple-server_v0.17.2_linux_amd64.tar.gz && ./rtsp-simple-server
...
2021/08/19 18:08:00 I [0/0] [RTSP] TCP listener opened on :8554
...
```

5.3 笔记本推本地视频文件

如果是手机录制的.mp4，先转成.ts。移除音频（可选）。

```
$ ffmpeg -i  test.mp4 -s 640x480  -q:v 2 -vcodec copy -an  test.ts
```

推.ts 文件上去

```
$ ffmpeg -re -stream_loop -1 -i test.ts -c copy -f rtsp rtsp://127.0.0.1:8554/test
```

5.4 笔记本推本地摄像头

```
ffmpeg -framerate 25 -video_size 640x480 -i /dev/video0 -vcodec h264 -f rtsp rtsp://
↪127.0.0.1:8554/test
```

参数说明 | 选项 | 含义 | | - | - | | -framerate | 每秒帧数量（FPS）| | -video_size | 采集视频宽高 | | -i | 设备文件描述符 | | -f | format 格式，如 rtsp/flv 等 | | -q:v | 图像品质，2 表示最好 | | -an | 移除音频 | | -vcodec copy | 拷贝流 |

5.5 树莓派实时推流

1. 参照官方文档，推流前检查摄像头是否正常运行
2. ffmpeg 推流

```
ffmpeg -framerate 25 -video_size 640x480 -i /dev/video0 -vcodec h264 -f rtsp rtsp://
↪127.0.0.1:8001/test
```

1. 常见问题

- ffmpeg 进程被 kill：`Out of memory: killed process: pid` GPU 显存不足导致，树莓派最多支持设置 512M 显存
- USB camera 推流卡顿、帧率低。应该换树莓派专用 camera

5.6 检查流地址是否可用

打开 VLC 媒体播放器 - “网络串流”，地址输入“rtsp://127.0.0.1:8554/test”正常播放即可。

CHAPTER 6

Run in 15 minutes

6.1 安装 python3.x （推荐 conda）

打开 miniconda 官网 下载 miniconda 安装包，修改权限并安装。

```
$ wget https://repo.anaconda.com/miniconda/Miniconda3-latest-Linux-x86_64.sh
$ chmod a+x Miniconda3-latest-Linux-x86_64.sh
$ ./Miniconda3-latest-Linux-x86_64.sh
```

安装时接受 conda 修改默认.bashrc 环境变量（zsh 用户还需自行修改.zshrc 中的 conda initialize 配置）。成功后 `conda` 可正常运行

```
$ conda --version
conda 4.10.3
```

创建一个 Python3.x（这里以 3.8 为例）的环境，激活。

```
$ conda create --name py38 python=3.8
$ conda activate py38
```

6.2 安装 Prebuilt 包

从 MegFlow release 下载对应 python 版本的.whl 包，安装

```
$  python3 -m pip install megflow-0.1.0-py38-none-linux_x86_64.whl  --force-reinstall
```

完成后应该可以 `import megflow`

```
$ python3
Python 3.8.3 (default, May 19 2020, 18:47:26)
[GCC 7.3.0] :: Anaconda, Inc. on linux
Type "help", "copyright", "credits" or "license" for more information.
>>> import megflow
```

.whl 提供了 `megflow_run` 命令，某些环境可能要 `export PATH=~/.local/bin/:${PATH}`

```
$ apt install build-essential -y
$ megflow_run -h
megflow_run 1.0
megvii
...
```

6.3 Python “开机自检”

6.3.1 下载 MegFlow 源码（需要使用到 flow-python/examples 中文件）

```
$ git clone https://github.com/MegEngine/MegFlow.git
```

6.3.2 运行 “开机自检”

```
$ cd ${MegFlow_PATH}/flow-python/examples  # 这行必须
$ megflow_run -p logical_test
```

`logical_test` 是 examples 下最基础的计算图测试用例，运行能正常结束表示 MegFlow 编译成功、基本语义无问题。目前版本输出为 logical_test pass 即为正确

`megflow_run` 是计算图的实现。使用者不需要关心 Rust/cargo，只需要

- `import megflow` 成功
- `megflow_run -h` 正常

  工作原理：megflow 仅是一层接口，由 megflow_run “注入” 建图/调度/优化等实现。

6.4 Python Built-in Applications

接下来开始运行好玩的 Python 应用

- 猫猫围栏运行手册
  - 图片注册猫猫
  - 部署视频围栏，注册的猫离开围栏时会发通知
  - 未注册的不会提示
- 电梯电瓶车告警
  - 电梯里看到电瓶车立即报警
- *quickstart*
  - 问答式创建自己的应用

CHAPTER 7

模型下载

MegFlow 所有模型都压缩成了单个 models.zip 。

取最新的 models_xxx.zip，解压、软链为 examples/models

```
$ wget  ${URL}/modes.zip
$ cd flow-python/examples
$ ln -s ${DOWNLOAD_DIR}/models models
```

如果有 MegFlow-models repo，可以直接

```
$ cd MegFlow-models
$ git-lfs update
$ git lfs pull
```

CHAPTER 8

megflow_quickstart

8.1 简介

本文介绍如何使用 `megflow_quickstart` **问答式**创建应用。

目前支持 4 种用法：

- modelserving。单模型图片服务
- 图片 pipeline 服务
- 视频 pipeline
- 自定义模板

8.2 单模型服务

假设模型使用 megengine 格式且 input tensor 只有一个

```
$ megflow_quickstart
...
Welcome to MegFlow quickstart utility.
Please enter values for the following settings (just press Enter to accept a default␣
↪value, if one is given in brackets).
> Enter the root fullpath for the project. [megflow-app]
megflow-app
```

(下页继续)

(续上页)

```
> Enter project type, modelserving/image/video/custom? [modelserving]
modelserving
   fetching remote template, please wait...
> Enter model input tensor name. [data]
data
> Enter model fullpath. [model.mge]
model.mge
   Project created, read ${PROJECT_dir}/README.md to run it.
```

quickstart 会依次问几个问题，并且提供默认值：

- 项目路径
- 服务类型，这里用 modelserving
- input tensor 名称，这里用 data
- 模型所在路径。阅读此文档生成 megengine 模型

正常会提示项目创建成功，阅读 ${PROJECT_dir}/README.md 即可运行。

```
$ cd megflow-app
$ ./requires.sh  # 安装 Python 依赖
$ cd ..
$ megflow_run -p megflow-app/config.toml -p megflow-app  # 运行服务
...
# 浏览器打开 127.0.0.1:8080/docs
```

对于可恢复的错误（如模板拉取失败），quickstart 会提醒重试，对应 emoji 是

8.3 图片/视频服务

```
$ megflow_quickstart
...
Welcome to MegFlow quickstart utility.
Please enter values for the following settings (just press Enter to accept a default
↪value, if one is given in brackets).
> Enter the root fullpath for the project. [megflow-app]
megflow-app
> Enter project type, modelserving/image/video/custom? [modelserving]
image
   fetching remote template, please wait...
   Project created, read ${PROJECT_dir}/README.md to run it.
```

图片/视频创建的项目只有服务框架，可以用 `megflow_run` 直接运行，不含具体业务功能。

8.4 自定义模板

quickstart 工作原理：

- 拉取 github 上对应分支
- 检查分支里的 placeholder
- 让用户填写 placeholder 对应内容
- 替换 placeholder

此流程同样可用于自定义 repo 和分支，quickstart 提供了 `--git` 参数

```
$ megflow_quickstart --git https://github.com/user/repo
...
> Enter project type, modelserving/image/video/custom? [modelserving]
custom
...
```

`custom` 选项会问以下问题：

- 模型路径
- 类型
- 分支名称
- 如有 placeholder，应该替换成什么

placeholder 使用的正则匹配是

```
$ cat flow-quickstart/main.rs
...
    let re = Regex::new(r"##[_\-a-zA-Z0-9]*##").unwrap();
...
```

8.5 MegFlow 服务使用方式

8.5.1 WebUI 图片

浏览器打开对应端口（例如 http://127.0.0.1:8080/docs ），选择一张图“try it out”即可。

8.5.2 WebUI 视频

浏览器打开端口服务（例如 http://127.0.0.1:8080/docs ）

- 参照*如何生成 rtsp*，提供一个 rtsp 流地址
- 或者给.mp4 文件的绝对路径（文件和 8080 服务在同一台机器上）

8.5.3 命令行方式

图片服务

```
$ curl http://127.0.0.1:8080/analyze/image_name  -X POST --header "Content-Type:image/
↪*"   --data-binary @test.jpeg
```

`image_name` 是用户自定义参数，用在需要 POST 内容的场景。这里随便填即可；`test.jpeg` 是测试图片

视频服务

```
$ curl  -X POST  'http://127.0.0.1:8085/start/rtsp%3A%2F%2F127.0.0.1%3A8554%2Ftest1.ts
↪'  # start  rtsp://127.0.0.1:8554/test1.ts
start stream whose id is 2%
$ curl 'http://127.0.0.1:8085/list'   # list all stream
[{"id":1,"url":"rtsp://10.122.101.175:8554/test1.ts"},{"id":0,"url":"rtsp://10.122.
↪101.175:8554/test1.ts"}]%
```

路径中的 `%2F`、`%3A` 是 URL 的转义字符

8.5.4 Python Client 方式

图片 client 代码

```
import requests
import cv2

def test():
    ip = 'localhost'
    port = '8084'
    url = 'http://{}:{}/analyze/any_content'.format(ip, port)
    img = cv2.imread("./test.jpg")
    _, data = cv2.imencode(".jpg", img)
    data = data.tobytes()

    headers = {'Content-Length': '%d' % len(data), 'Content-Type': 'image/*'}
    res = requests.post(url, data=data, headers=headers)
```

(下页继续)

(续上页)

```
    print(res.content)

if __name__ == "__main__":
    test()
```

视频 client 代码

```
import requests
import urllib


def test():
    ip = 'localhost'
    port = '8085'
    video_path = 'rtsp://127.0.0.1:8554/vehicle.ts'
    video_path = urllib.parse.quote(video_path, safe='')
    url = 'http://{}:{}/start/{}'.format(ip, port, video_path)

    res = requests.post(url)
    ret = res.content
    print(ret)


if __name__ == "__main__":
    test()
```

8.5.5 其他语言

rweb/Swagger 提供了 http RESTful API 描述文件，例如在 http://127.0.0.1:8084/openapi.json 。`swagger_codegen` 可用描述文件生成 java/go 等语言的调用代码。更多教程见 swagger codegen tutorial 。

CHAPTER 9

串联检测和分类

本文将在 tutorial01 modelserving 的基础上扩展计算图：先检测、再扣图分类。对外提供视频解析服务。完整的代码在 flow-python/examples/simple_det_classify 目录。

9.1 移除分类预处理

见 生成带预处理的模型

9.2 准备检测模型

这里直接用现成的 YOLOX mge 模型。复用 cat_finder 的检测 或者从 YOLOX 官网 下载最新版。

9.3 配置计算图

`flow-python/examples` 增加 `simple_det_classify/video_cpu.toml`

```
$ cat flow-python/examples/simple_det_classify/video_cpu.toml

main = "tutorial_02"

# 重资源结点要先声明
```

(下页继续)

(续上页)

```
[[nodes]]
name = "det"
ty = "Detect"
model = "yolox-s"
conf = 0.25
nms = 0.45
tsize = 640
path = "models/simple_det_classify_models/yolox_s.mge"
interval = 5
visualize = 1
device = "cpu"
device_id = 0

[[nodes]]
name = "classify"
ty = "Classify"
path = "models/simple_det_classify_models/resnet18_preproc_inside.mge"
device = "cpu"
device_id = 0

[[graphs]]
name = "subgraph"
inputs = [{ name = "inp", cap = 16, ports = ["det:inp"] }]
outputs = [{ name = "out", cap = 16, ports = ["classify:out"] }]
# 描述连接关系
connections = [
  { cap = 16, ports = ["det:out", "classify:inp"] },
]

...
# ty 改成 VdieoServer
    [[graphs.nodes]]
    name = "source"
    ty = "VideoServer"
    port = 8085

...
```

想对上一期的配置，需要关注 3 点：

- 视频流中的重资源结点，需要声明在 `[[graphs]]` 之外，因为多路视频需要复用这个结点。如果每一路都要启一个 det 结点，资源会爆掉
- `connections` 不再是空白，因为两个结点要描述连接关系

- Server 类型改成 `VideoServer`，告诉 UI 是要处理视频的

9.4 运行测试

运行服务

```
$ cd flow-python/examples
$ megflow_run -c simple_det_classify/video_cpu.toml  -p simple_det_classify
```

9.5 资源

此文档描述 graph toml 定义

此文档描述 Python node 接口定义

CHAPTER 10

批量推理和 Pipeline 级测试

本文将在 tutorial02 的基础上扩展功能：动态 batching 测试 QPS 提升。

10.1 分类模型支持动态 batch

resnet 的 dump 需要支持多 batch 输入，样例 dump_resnet.py

10.2 分类用 batch_recv 接口

新的 classify.py 改成这样：

```
$ cat flow-python/examples/simple_det_classify/classify.py
...
    def exec(self):
        # batching
        (envelopes, _) = self.inp.batch_recv(self.batch_size, self.timeout)

        if len(envelopes) == 0:
            return
...
```

这里 `batch_recv` 的参数列表

然后在 Python 层合并 data，调 `inference_batch`

```
data = np.concatenate(crops)
types = self._model.inference_batch(data)
```

10.3 Pipeline 级测试

MegFlow 支持直接输入图片集/视频列表做测试，不需要 http 服务。使用方自行实现 Validation 结点，集成进 CI 做正确性/性能测试。

10.3.1 图片集测试

以 simple_classification image_test 为例

```
...
    [[graphs.nodes]]
    name = "source"
    ty = "ImageInput"
    urls = ["/mnt/data/user/image/","/home/test_data_dir/"]
...
```

pipeline 建图等不变，新增了一种 source 叫做 `ImageInput`，调用方填 `urls` 做图片目录列表。

运行方法不变

```
$ megflow_run -c simple_classification/image_test.toml  -p simple_classification
```

10.3.2 视频列表测试

以 simple_det_classify video_test 为例：

```
...
    [[graphs.nodes]]
    name = "source"
    ty = "VideoInput"
    repeat = 1
    urls = ["rtsp://127.0.0.1:8554/test.ts", "/mnt/data/file.mp4"]
...
```

建图同样不变，新增了 `VideoInput` 结点，参数列表

使用方法不变

```
$ megflow_run  -c simple_det_classify/video_test.toml   -p simple_det_classify
```

CHAPTER 11

视频结果 Web 可视化

11.1 依赖

依赖 `ffmpeg` 命令，请确保已经安装并能正常运行。

11.2 部署图

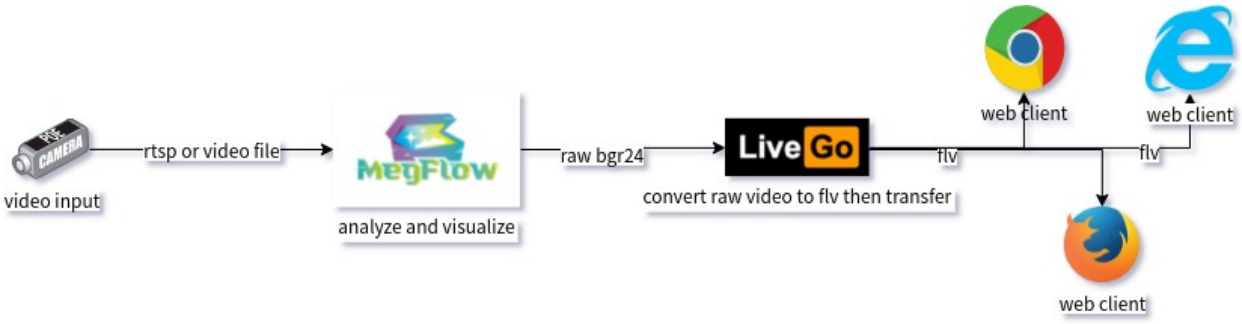

1）video input。可以是 rtsp server 或者视频文件，直接传绝对路径

2）MegFlow。解析视频，把渲染后的结果以 bgr24 格式发给下游

3）LiveGo 用于把 raw_video 转为 flv 格式。引入 LiveGo 的原因：

- 浏览器无法直接播放 rtsp 流，推荐方案是 HLS 或 http-flv
- 播放端可能不止一个，需要流量转发服务

- 生产环境中存储/点播功能是刚需，MegFlow 不具备此功能，应由其他服务完成

11.3 操作指南

1）下载启动 LiveGo

```
$ wget https://github.com/gwuhaolin/livego/releases/download/0.0.15/livego_0.0.15_
↪linux_amd64.tar.gz && tar xvf livego_0.0.15_linux_amd64.tar.gz && ./livego &
...
INFO[2021-10-27T15:44:40+08:00] HLS server enable....
INFO[2021-10-27T15:44:40+08:00] RTMP Listen On :1935
INFO[2021-10-27T15:44:40+08:00] HTTP-API listen On :8090
INFO[2021-10-27T15:44:40+08:00] HTTP-FLV listen On :7001
...
```

2）自测视频推流、播放正常

假设测试视频是 demo.flv（建议长度超过 30 秒），使用 `push_video.py` 推流到 LiveGo

```
$ cd ${MegFlow_dir}/flow-python/examples/misc/visualize_client
$ python3 push_video.py
```

浏览器打开 index.html，应能正常播放。

3）运行猫猫围栏可视化配置

猫猫围栏环境设置见 cat_finder README。运行起 video 基础版后，能够运行 video 可视化版本

```
$ cd ${MegFlow_dir}/flow-python/examples
$ megflow_run -c cat_finder/video_visualize.toml  -p cat_finder
...
```

浏览器打开 8002 端口，提供 rtsp 地址或视频文件绝对路径，try it out。

打开 index.html，应能播放可视化结果。

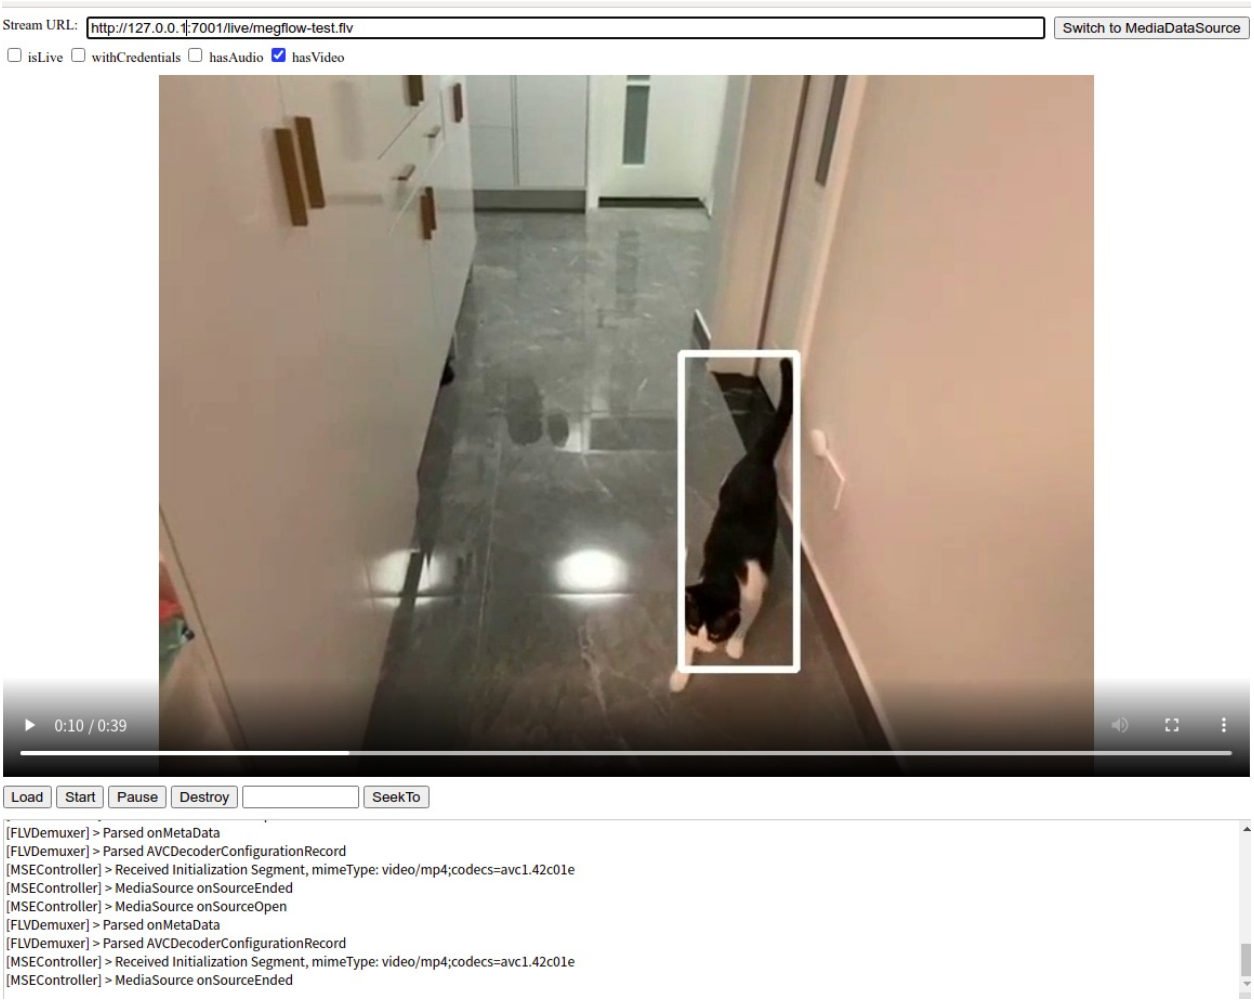

4）注意事项和常见问题

播放地址

注意 index.html 播放地址不能有多余的‘/’，例如 http://10.199.1.100/:7001/live/megflow-test.flv 是无法播放的。

视频长度

测试视频建议超过 30s。至少有 2 个 I 帧，否则影响 flv 转换。

视频尺寸

建议测试视频为标准 480p/720p/1080p。

跨域问题

web client 修改自 flv.js。如果不用 index.html、直接浏览器打开原始 demo，需自行解决跨域问题。

CHAPTER 12

Config

MegFlow 的建图描述文件使用 toml 格式。toml 注重人类可读性，学习难度约等于 markdown，看完下面 2 个例子大约就会写了。

12.1 图片范例

举个栗子，cat_finder/image_gpu.toml：

```
 // 完整的计算图的名字，叫啥都行
main = "cat_finder_image"

[[graphs]]
name = "subgraph"                                                              ␣
↪                          // 子图类型，叫啥都行。子图 == 自己写的业务
inputs = [{ name = "inp", cap = 16, ports = ["det:inp"] }]                      //␣
↪子图入口在 det 节点的 inp 端口，队列长度是 16
outputs = [{ name = "out", cap = 16, ports = ["redis_proxy:out"] }] // 子图出口是␣
↪redis_proxy 的 out 端口
connections = [                                                                ␣
↪      // 构图， A 的输出，连到 B 的输入
  { cap = 16, ports = ["det:out", "reid:inp"] },                    // det 输出接到␣
↪reid 输入
  { cap = 16, ports = ["reid:out", "redis_proxy:inp"] },     // reid 输出送给  redis_
↪proxy
```

(下页继续)

(续上页)

```
]

    [[graphs.nodes]]                  // 子图节点声明。注意 4 个空格，表示和 [[graphs]]␣
↪的层次关系
    name = "det"                        // 找 examples/xxx/ 下面的 det.py 或者 det␣
↪package
    ty = "Detect"                        // 这个 node 执行 Detect class
    model = "yolox-nano"    // 自定义参数，yolox 模型构造需要
    conf = 0.25                           //  yolox 需要的 det 阈值
    nms = 0.45                           // yolox 需要的 nms 阈值
    tsize = 640                           // yolox 需要的 inference size
    path = "models/yolox_nano.pkl" // yolox 模型相对路径

    [[graphs.nodes]]             // reid 和 det 同理
    name = "reid"
    ty = "Reid"
    thres = 1300                      // 里面用拉普拉斯计算图像清晰度，阈值写的 1300
    path = "models/aligned_reid.pkl"

    [[graphs.nodes]]           // 纯业务逻辑，name 和 ty 字段是必选，其他看需求
    name = "redis_proxy"
    ty = "RedisProxy"
    ip = "127.0.0.1"          // redis ip 地址
    port = "6379"             // redis port
    mode = "save"          // 控制此节点存特征进 redis
    prefix = "feature."  // redis key 的前缀，不然整个 redis 库乱乱的

[[graphs]]                        // 描述完整运行的计算图
name = "cat_finder_image"
connections = [
  { cap = 16, ports = ["source:out", "destination:inp"] }, // source 就是 swagger␣
↪这类 service，接收视频或图片用的。收到的数据（图像、视频、extra 字段）送进子图
  { cap = 16, ports = ["source:inp", "destination:out"] } // 子图处理完，把结果发给␣
↪http server
]

    [[graphs.nodes]]      // http server 的配置
    name = "source"
    ty = "ImageServer" // 这是个图片服务
    port = 8081                // 端口号
    response = "json"  // response Content-Type 用 application/json。不写就是默认␣
↪image/jpeg
```

(下页继续)

(续上页)

```
    [[graphs.nodes]]    // dest 是自己写的业务子图
    name = "destination"
    ty = "subgraph"     // 子图类型。没事儿改它干啥
```

对应可视化的计算图：

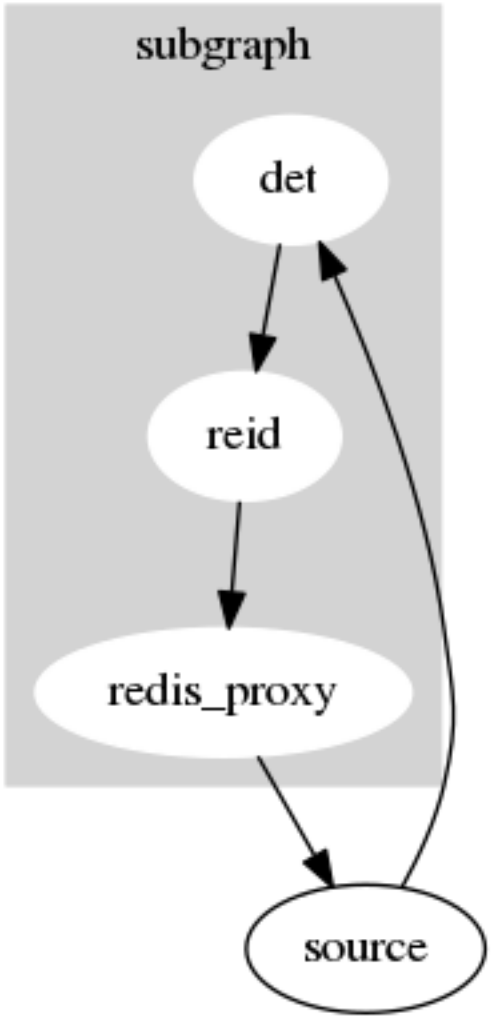

12.2 视频范例

视频和图片的唯一区别：**重资源的节点要在子图之外声明**。

MegFlow 设计上支持不同视频流跑不同业务。每创建 1 路视频就会创建 1 个子图，40 路视频就是 40 个。det/reid 这种很重的节点自然要被复用。

以 `cat_finder/video_gpu.toml` 为例：

```
main = "cat_finder_video"                // 完整计算图名字

[[nodes]]                // det 节点在子图外声明
name = "det"
ty = "Detect"
model = "yolox-tiny"
conf = 0.25
nms = 0.45
tsize = 640
path = "models/yolox_tiny.pkl"
interval = 5

[[nodes]]                // ReID 节点同样在外部声明，被共享
name = "reid_video"
ty = "ReIDVideo"
path = "models/aligned_reid.pkl"

[[nodes]]              // redis_proxy 使用了连接池，也可以看作“重资源”
name = "redis_proxy"
ty = "RedisProxy"
ip = "127.0.0.1"
port = "6379"
mode = "search"
prefix = "feature."

[[graphs]]
name = "subgraph"
inputs = [{ name = "inp", cap = 16, ports = ["det:inp"] }]
outputs = [{ name = "out", cap = 16, ports = ["redis_proxy:out"] }]
connections = [  // 描述连接关系
  { cap = 16, ports = ["det:out", "track:inp"] },
  { cap = 16, ports = ["track:out", "shaper:inp"] },
  { cap = 16, ports = ["shaper:out", "reid_video:inp"] },
  { cap = 16, ports = ["reid_video:out", "redis_proxy:inp"] },
]

    [[graphs.nodes]]     // 给每个检测目标，赋予唯一的 ID
    name = "track"
    ty = "Track"

    [[graphs.nodes]]     // 业务逻辑：ID 结束后，给个最优结果
    name = "shaper"
    ty = "Shaper"
    mode = "BEST"        // 结果类型，目前只支持 "BEST" 最优
```

(下页继续)

(续上页)

```
[[graphs]]
name = "cat_finder_video"
connections = [
  { cap = 16, ports = ["source:out", "destination:inp"] },
  { cap = 16, ports = ["source:inp", "destination:out"] }
]

    [[graphs.nodes]]
    name = "source"
    ty = "VideoServer"  // 视频服务
    port = 8082                 // 8081 做注册，8082 做解析

    [[graphs.nodes]]
    name = "destination"
    ty = "subgraph"
```

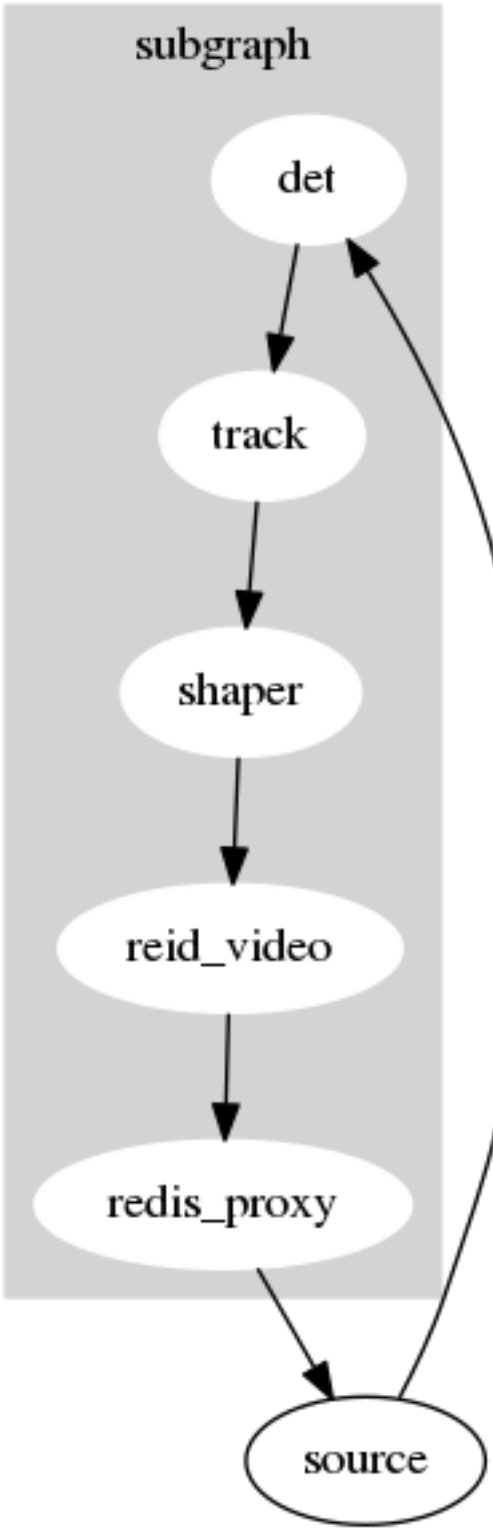

视频解析服务可视化结果和图片接近：

12.3 完整定义

TL;DR

严谨的描述文件定义如下:

```
// 节点间的连接channel
struct Connection {
    cap: usize,                    // channel容量
    ports: Vec<String>, // 连接的节点端口，格式是`节点名:端口名[:标签]`
}
// 有名channel
struct NamedConn {
    name: String,              // channel的名字
    cap: usize,                  // channel容量
    ports: Vec<String>, // 连接的节点端口，格式是`节点名:端口名[:标签]`
}
// 节点定义
struct Node {
    name: String,          // 节点名
    ty: String,                  // 节点类型
    cloned: usize,         // 表示并行度，默认值为1
    res: Vec<String>,  // 引用的资源名字列表
    ... // 其他参数，会被透传到节点的构造函数中
}
// 资源定义
struct Resource {
    name: String,           // 资源名字
    ty: String,                  // 资源类型
    ... // 其他参数，会被透传到资源的构造函数中
}

struct Graph {
    name: String,                                       // 图的名字
    resources: Vec<Resource>              // 资源声明，生命周期与该图绑定
    nodes: Vec<Node>,                           // 节点声明，生命周期与该图绑定
    inputs: Vec<NamedConn>,            // 图输入声明
    outputs: Vec<NamedConn>,         // 图输出声明
    connections: Vec<Connection>, // 节点间连接声明
}

struct Config {
    resources: Vec<Resource>             // 全局共享资源，生命周期与整个应用绑定
    nodes: Vec<Node>,                           // 全局共享节点，生命周期与整个应用绑定
    graphs: Vec<Graph>,                       // 图声明
```

(下页继续)

(续上页)

```
    main: String,                                    // 主图名字，及应用的进入点
}
```

CHAPTER 13

Python Plugins

从一个最简单的例子开始

```
import megflow
@megflow.register(name="alias", inputs=["inp"], outputs=["out"])
class Node:
    def __init__(self, name, args):
        pass
    def exec(self):
        envelope = self.inp.recv()
        msg = dowith(envelope.msg)
        self.out.send(envelope.repack(msg))
```

这其中有三部分内容: register 装饰器，Node 的构造函数，Node 的执行函数

1. register 装饰器
    - name: 若指定，则 register 所修饰插件重命名为 name，默认为 register 所修饰类的类名
    - inputs: Node 的输入列表，每个输入 `input` 都可以在 `exec` 方法中，通过 `self.input` 访问,
    - outputs: Node 的输出列表，每个输出 `output` 都可以在 `exec` 方法中，通过 `self.output` 访问
    - exclusive: 默认为 False, 调度模型是一个 thread local 的协程调度器, 若为 True, 则将该任务安排到线程池中
2. Node 的构造函数

- name: 即参数文件中 Node 的 name 字段
- args: 即参数文件中 Node 的剩余参数字段

3. Node 的执行函数
   - 一个 python 插件的执行方法必须是命名为 `exec` 的零参成员方法
   - 对于在参数文件中该插件引用的资源 `resource`, 可以在 `exec` 方法中，通过 `self.resource` 访问
   - 通过输入的 `recv` 方法取得输入消息，输入消息是 `Envelope` 对象，其 `msg` 成员即开发者真正需要读写的消息实例
   - `Envelope` 语义为在图中流转的消息的相关信息，由于这些信息需要在图中被传递，所以开发者应该保持消息与 `Envelope` 的对应关系
   - 若一个 `Envelope` 携带的消息被拆分为多个消息, 或者转换为另一个消息, 应该通过 `Envelope` 的 `repack` 方法，将 `Envelope` 与消息关联起来
   - 通过输出的 `send` 方法发送输出消息，输出消息是 `Envelope` 对象

MegFlow 也提供了一系列异步工具

1. `yield_now()`, 让出当前任务的执行权
2. `sleep(dur)`, 使当前任务沉睡 `dur` 毫秒
3. `join(tasks)`, `tasks` 参数是一个函数列表，`join` 堵塞直到 `tasks` 中的函数都执行完毕
4. `create_future(callback)`, `callback` 参数是一个函数, 默认值为 None，`create_future` 返回一个 `(Future, Waker)` 对象
   - `Future::wait`，堵塞直到 `Waker::wake` 被调用，返回 `Waker::wake(result)` 传入的 `result` 参数

CHAPTER 14

生成 MegEngine 模型

14.1 生成不带预处理的模型

Github MegEngine models 有现成的 imagenet 预训模型。这里把模型 dump 成.mge。

新增 dump.py，按 [1, 3, 224, 224] 尺寸 trace 模型，打开推理优化选项，保存为 `model.mge`。

```
$ git clone https://github.com/MegEngine/models
$ cd models
$ export PYHTONPATH=${PWD}:${PYTHONPATH}
$ cd official/vision/classification/resnet
$ python3 dump.py
$ ls -lah model.mge
...
```

`dump.py` 已经 PR 到 MegEngine/models 分类模型目录

```
$ cat dump.py
...
    data = mge.Tensor(np.random.random((1, 3, 224, 224)))  # 准备一个样例输入

    @jit.trace(capture_as_const=True)
    def pred_func(data):
        outputs = model(data)  # trace 每个 opr 的 shape
        return outputs
```

(下页继续)

(续上页)

```
    pred_func(data)
    pred_func.dump( # 保存模型
        graph_name,
        arg_names=["data"],
        optimize_for_inference=True, # 打开推理优化选项
        enable_fuse_conv_bias_nonlinearity=True, # 打开 fuse conv+bias+ReLU pass␣
↪推理更快
    )
...
```

14.2 模型单测

开发模型的推理封装，对外提供功能内聚的接口。调用方传入一张或多张图片、直接获取结果，尽量避免关心内部实现（如用何种 backbone、预处理是什么、后处理是什么）。

```
$ cat flow-python/examples/application/simple_classification/lite.py
...
    def inference(self, mat):
        img = self.preprocess(mat, input_size=(224,224), scale_im = False, mean=[103.
↪530, 116.280, 123.675], std=[57.375, 57.120, 58.395])

        # 设置输入
        inp_data =self.net.get_io_tensor("data")
        inp_data.set_data_by_share(img)

        # 推理
        self.net.forward()
        self.net.wait()

        # 取输出
        output_keys = self.net.get_all_output_name()
        output = self.net.get_io_tensor(output_keys[0]).to_numpy()
        return np.argmax(output[0])
...
$ python3 lite.py --model model.mge  --path test.jpg  # 测试
2021-09-14 11:45:02.406 | INFO     | __main__:<module>:81 - 285
```

285 是分类模型最后一层的 argmax，对应含义需要查 imagenet 数据集分类表，这里是“Egyptian cat”（下标从 0 开始）。

14.3 生成带预处理的模型

MegEngine 除了不需要转模型，还能消除预处理。我们修改 dump_resnet.py 把预处理从 SDK/业务代码提到模型内。这样的好处是：**划清工程和算法的边界**，预处理本来就应该由 scientist 维护，每次只需要 release mge 文件，减少交接内容

```
...
    @jit.trace(capture_as_const=True)
    def pred_func(data):
        out = data.astype(np.float32)

        output_h, output_w = 224, 224
        # resize
        print(shape)
        M = mge.tensor(np.array([[1,0,0], [0,1,0], [0,0,1]], dtype=np.float32))
        M_shape = F.concat([data.shape[0],M.shape])
        M = F.broadcast_to(M, M_shape)
        out = F.vision.warp_perspective(out, M, (output_h, output_w), format='NHWC')
        # mean
        _mean = mge.Tensor(np.array([103.530, 116.280, 123.675], dtype=np.float32))
        out = F.sub(out, _mean)
        # div
        _div = mge.Tensor(np.array([57.375, 57.120, 58.395], dtype=np.float32))
        out = F.div(out, _div)
        # dimshuffile
        out = F.transpose(out, (0,3,1,2))

        outputs = model(out)
        return outputs
...
```

具体实现是在 trace inference 里增加预处理动作，fuse opr 优化加速的事情交给 MegEngine 即可。更多 cv 操作参照 MegEngine API 文档。

因为推理输入变成了 BGR，所以 dump 模型的时候参数也应该跟着变

```
$ python3 dump.py -a resnet18 -s 1 224 224 3
```

CHAPTER 15

FAQ

Q：`megflow_run -p logical_test` 无法运行怎么办?

A1：如果报错 `message: "No such file or directory" }'`，确认是否 `cd flow-python/examples`

A2：确认安装了 python 组件，即 `cd flow-python` 再 `python3 setup.py install --user`

还不行就提 issue。

Q：视频流跑一路没事。跑多个，内存爆了/显存爆了/模型加载多次是因为啥?

A：参照 `cat_finder/video.toml`，把涉模型的 nodes 移到 `[[graphs]]` 上面，让多个子图来共享。

每启动一个视频流就会启一个子图，如果 `nodes` 放到 `[[graphs]]` 里，20 路视频就会创建 20 套 nodes。

Q：如何修改服务端口号，8080 已被占用?

A：以 `cat_finder` 为例，端口配置在 `image.toml` 的 `port` 中。

Q：如何让 ImageServer 返回 json，而不是渲染后的图?

A：ImageServer 默认返回 `envelope.msg["data"]` 图像。如果要返回 json 需要改两处：

- `image.toml` 的配置里增加 `response = "json"`
- 最终结果用 `self.out.send(envelope.repack(json.dumps(results)))` 发送出去

框架既不知道哪些字段可序列化，也不知道要序列化那几个字段，因此需要调用方序列化成 `str`。代码可参照 `examaples/cat_finder/redis_proxy.py`。

Q：视频流为什么无法停止，调用了 stop 接口还是在处理?

A：调用 stop 之后队列的 `push/put` 接口已经被关闭了，不能追加新的，但之前解好的帧还在队列里。需要把遗留的处理完、依次停止子图节点才完全结束。流不会调用 stop 即刻停止，实际上有延迟。

CHAPTER 16

如何 Debug 常见问题

一、`megflow_run` 无法启动服务，直接 core dump 报错退出

如果“Python 开机自检”的 `megflow_run -p logical_test` 能够正常结束，排查方向应该是 Python import error。调试方法举例

```
$  gdb --args ./megflow_run  -c electric_bicycle/electric_bicycle_cpu.toml   -p␣
↪electric_bicycle
...
illegal instruction
...
```

可以看到 crash 发生在哪个 import

CHAPTER 17

如何提交代码

17.1 一、fork 分支

在浏览器中打开 MegFlow, `fork` 到自己的 repositories，例如

```
https://github.com/user/MegFlow
```

clone 项目到本地，添加官方 remote 并 fetch:

```
$ git clone https://github.com/user/MegFlow && cd MegFlow
$ git remote add megvii https://github.com/MegEngine/MegFlow
$ git fetch megvii
```

对于 `git clone` 下来的项目，它现在有两个 remote，分别是 origin 和 megvii

```
$ git remote -v
origin   https://github.com/user/MegFlow (fetch)
origin   https://github.com/user/MegFlow (push)
megvii  https://github.com/MegEngine/MegFlow (fetch)
megvii  https://github.com/MegEngine/MegFlow (push)
```

origin 指向你 fork 的仓库地址；remote 即官方 repo。可以基于不同的 remote 创建和提交分支。

例如切换到官方 master 分支，并基于此创建自己的分支（命名尽量言简意赅。一个分支只做一件事，方便 review 和 revert）

```
$ git checkout MegEngine/master
$ git checkout -b my-awesome-branch
```

或创建分支时指定基于官方 master 分支：

```
$ git checkout -b fix-typo-in-document MegFlow/master
```

> `git fetch` 是从远程获取最新代码到本地。如果是第二次 pr MegFlow `git fetch megvii` 开始即可，不需要 `git remote add megvii`，也不需要修改 `github.com/user/MegFlow`。

17.2 二、代码习惯

为了增加沟通效率，reviewer 一般要求 contributor 遵从以下规则

- 不能随意增删空行
- tab 替换为 4 个空格
- 若是新增功能或平台，需有对应测试用例
- 文档放到 `docs` 目录下，中文用`.zh.md`做后缀；英文直接用`.md`后缀

开发完成后提交到自己的 repository

```
$ git commit -a
$ git push origin my-awesome-branch
```

推荐使用 `commitizen` 或 `gitlint` 等工具格式化 commit message，方便事后检索海量提交记录

17.3 三、代码提交

浏览器中打开 MegFlow pulls ，此时应有此分支 pr 提示，点击 `Compare & pull request`

- 标题**必须**是英文。未完成的分支应以 `WIP:` 开头，例如 `WIP: fix-typo`
- 正文宜包含以下内容，中英不限
  - 内容概述和实现方式
  - 功能或性能测试
  - 测试结果

回到浏览器签署 CLA，所有 CI 测试通过后通知 reviewer merge 此分支。

CHAPTER 18

打包成 Python .whl

18.1 作用

打成 whl 包，使用方直接安装即可，不再需要编译。

18.2 执行

现在使用 Dockerfile 生成各 python 版本.whl

```
$ cd ${MegFlow_dir}
$ # 构造开发环境，安装依赖。已执行过 docker 编译可以跳过此步骤
$ docker build -t megflow -f Dockerfile.github-dev .
$ # 创建结果目录
$ mkdir dist
$ # docker 打包  whl
$ # https://stackoverflow.com/questions/33377022/how-to-copy-files-from-dockerfile-to-
↪host
$ DOCKER_BUILDKIT=1 docker build -f Dockerfile.github-release --output dist .
```

注意 COPY to host 需要：

- Docker 19.03 以上版本
- 需要 DOCKER_BUILDKIT 环境变量
- 需要–output 参数