



# **Tina V853 NPU Yolact 模型部署实战**

**版本号: 1.0**

**发布日期: 2021.07.21**

## 版本历史

| 版本号 | 日期         | 制/修订人 | 内容描述              |
|-----|------------|-------|-------------------|
| 1.0 | 2021.07.21 | PDC   | NPU Yolact 模型部署实战 |



# 目 录

|                    |          |
|--------------------|----------|
| <b>1 前言</b>        | <b>1</b> |
| 1.1 读者对象           | 1        |
| 1.2 约定             | 1        |
| 1.2.1 符号约定         | 1        |
| <b>2 正文</b>        | <b>2</b> |
| 2.1 NPU 开发简介       | 2        |
| 2.2 开发流程           | 2        |
| 2.3 获取 YOLACT 原始模型 | 3        |
| 2.4 模型部署工作目录结构     | 3        |
| 2.5 导入模型           | 3        |
| 2.6 创建 YML 文件      | 3        |
| 2.7 量化             | 4        |
| 2.8 预推理            | 5        |
| 2.9 导出代码和 NBG 文件   | 5        |
| 2.10 模型算力测量        | 6        |
| 2.11 后处理验证         | 7        |
| 2.12 结束            | 9        |

## 插 图

|                                |   |
|--------------------------------|---|
| 2-1 npu_1.png . . . . .        | 2 |
| 2-2 npu_workspace . . . . .    | 3 |
| 2-3 npu_import . . . . .       | 3 |
| 2-4 npu_yaml . . . . .         | 4 |
| 2-5 npu_scale . . . . .        | 4 |
| 2-6 npu_quantilize . . . . .   | 4 |
| 2-7 npu_inf . . . . .          | 5 |
| 2-8 npu_export . . . . .       | 6 |
| 2-9 npu_nbg . . . . .          | 6 |
| 2-10 npu_measure . . . . .     | 6 |
| 2-11 npu_gerit . . . . .       | 7 |
| 2-12 npu_post . . . . .        | 7 |
| 2-13 npu_postprocess . . . . . | 7 |
| 2-14 npu_tensor . . . . .      | 7 |
| 2-15 npu_exepost . . . . .     | 8 |
| 2-16 npu_yolact . . . . .      | 8 |
| 2-17 npu_yolact_ok . . . . .   | 9 |

# 1 前言

## 1.1 读者对象

本文档（本指南）主要适用于以下人员：

- 技术支持工程师
- 软件开发工程师
- AI 应用案客户

## 1.2 约定

### 1.2.1 符号约定

本文中可能出现的符号如下：



**警告**

**警告**



**技巧**

1. 技巧
2. 小常识



**说明**

**说明**

## 2 正文

### 2.1 NPU 开发简介

- 支持 int8/uint8/int16 量化精度，运算性能可达 1TOPS.
- 相较于 GPU 作为 AI 运算单元的大型芯片方案，功耗不到 GPU 所需要的 1%.
- 可直接导入 Caffe, TensorFlow, Onnx, TFLite, Keras, Darknet, pyTorch 等模型格式.
- 提供 AI 开发工具：支持模型快速转换、支持开发板端侧转换 API、支持 TensorFlow, TF Lite, Caffe, ONNX, Darknet, pyTorch 等模型.
- 提供 AI 应用开发接口：提供 NPU 跨平台 API.

### 2.2 开发流程

NPU 开发完整的流程如下图所示：

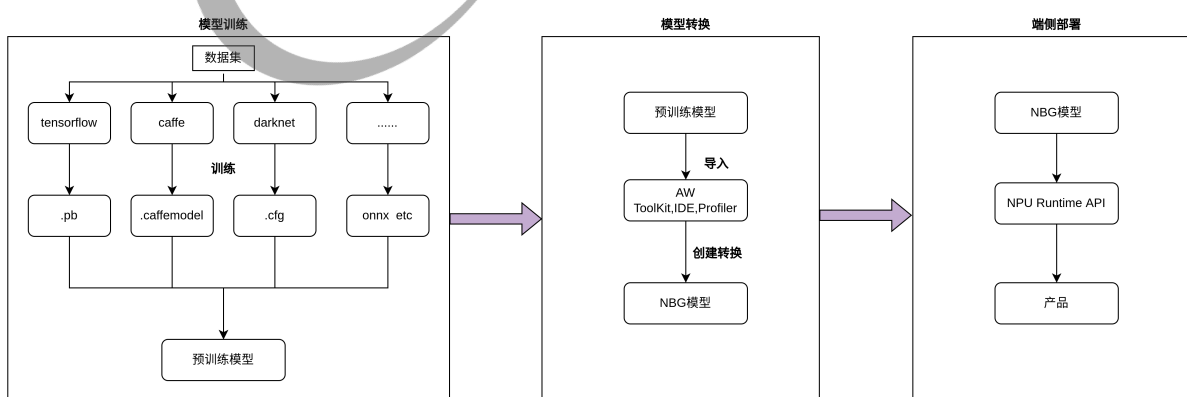


图 2-1: npu\_1.png

## 2.3 获取 YOLACT 原始模型

YOLACT 模型获取方式有很多种，可以基于项目 <https://github.com/dbolya/yolact> 产生 onnx 格式的 yolact 模型，本文档假设你已经产生了 yolact.onnx 模型

## 2.4 模型部署工作目录结构

yolact-sim.onnx 有 120M，还是蛮大的。

```
(vip) caozilong@AwExdroid-AI:~/Workspace/yolact-develop-20220218$ tree
.
├── data
│   ├── dog.jpg
│   ├── dataset.txt
│   └── yolact-sim.onnx
└── 1 directory, 3 files
(vip) caozilong@AwExdroid-AI:~/Workspace/yolact-develop-20220218$ cat dataset.txt
./data/dog.jpg
(vip) caozilong@AwExdroid-AI:~/Workspace/yolact-develop-20220218$
```

图 2-2: npu\_workspace

## 2.5 导入模型

```
pegasus import onnx --model yolact-sim.onnx --output-model yolact-sim.json --output-data yolact-sim.data
```

导入模型的目的是将开放模型转换为符合 VIP 模型网络描述文件 (.json) 和权重文件 (.data)

```
caozilong@AwExdroid-AI:~/Workspace/yolact-develop-20220218$ git status
On branch master
Untracked files:
  (use "git add <file>..." to include in what will be committed)
    yolact-sim.data
    yolact-sim.json
nothing added to commit but untracked files present (use "git add" to track)
(vip) caozilong@AwExdroid-AI:~/Workspace/yolact-develop-20220218$
```

图 2-3: npu\_import

## 2.6 创建 YML 文件

YML 文件对网络的输入和输出进行描述，比如输入图像的形状，归一化系数 (均值，零点)，图像格式，输出 tensor 的输出格式，后处理方式等等，命令如下：

```
pegasus generate inputmeta --model yolact-sim.json --input-meta-output yolact-sim-inputmeta.yml
```

```
pegasus generate postprocess-file --model yolact-sim.json --postprocess-file-output yolact-sim-postprocess-file.yml
```

```
(vip) caozilong@uexdroid-AI:~/Workspace/yolact-develop-20220210$ git status .
On branch master
Untracked files:
  (use "git add <file>..." to include in what will be committed)

    yolact-sim-inputmeta.yml
    yolact-sim-postprocess-file.yml

nothing added to commit but untracked files present (use "git add" to track)
(vip) caozilong@uexdroid-AI:~/Workspace/yolact-develop-20220210$
(vip) caozilong@uexdroid-AI:~/Workspace/yolact-develop-20220210$
(vip) caozilong@uexdroid-AI:~/Workspace/yolact-develop-20220210$
(vip) caozilong@uexdroid-AI:~/Workspace/yolact-develop-20220210$
```

图 2-4: npu\_yml

修改 input meta 文件中的的 scale 参数为 0.0039(1/256)，和 yolov3 的改法完全一致。

```
1 # This file disallow TAB!!!
2 ---
3 # "category" allowed values: "image, frequency, undefined"
4 # "database" allowed types: "TEXT, NPY, H5PS, SQLITE, LMDB, GENERATOR"
5 # "tensor_name" only support in h5ps database
6 # "preproc_type" allowed types: "IMAGE_RGB, IMAGE_ROBBER_PLANAR, IMAGE_I420, IMAGE_NV12, IMAGE_YUV444, IMAGE_GRAY, IMAGE_BGRA, TENSOR"
7
8 input_meta:
9   databases:
10     path: dataset.txt
11     type: TEXT
12   preproc:
13     id: input_1210
14     category: image
15     dtype: float32
16     sparse: false
17     tensor_name:
18     layout: nchw
19     shape:
20       - 3
21       - 550
22       - 550
23     fitting: scale
24     preprocess:
25       reverse_channel: true
26       mean:
27         - 0
28         - 0
29         - 0
30       scale: 0.0039
31     add_preproc_node: false
32     preproc_type: IMAGE_RGB
33     preproc_perm:
34       - 0
35       - 1
36       - 2
37     redirect_to_output: false
```

图 2-5: npu\_scale

## 2.7 量化

量化命令：

```
pegasus quantize --model yolact-sim.json --model-data yolact-sim.data --batch-size 1 --device CPU
--with-input-meta yolact-sim-inputmeta.yml --rebuild --model-quantize yolact-sim.quantize --
quantizer asymmetric_affine --qtype uint8
```

命令执行后，创建了量化表文件

```
1 End quantization...
2 Dump net quantize tensor table to yolact-sim.quantize
3 Save net to yolact-sim.data
4 -----Error(0),Warning(0)-----
(vip) caozilong@uexdroid-AI:~/Workspace/yolact-develop-20220210$
(vip) caozilong@uexdroid-AI:~/Workspace/yolact-develop-20220210$ git status .
On branch master
Untracked files:
  (use "git add <file>..." to include in what will be committed)

    yolact-sim.quantize

nothing added to commit but untracked files present (use "git add" to track)
(vip) caozilong@uexdroid-AI:~/Workspace/yolact-develop-20220210$
(vip) caozilong@uexdroid-AI:~/Workspace/yolact-develop-20220210$
```

图 2-6: npu\_quantize



## 2.8 预推理

```
pegasus inference --model yolact-sim.json --model-data yolact-sim.data --batch-size 1 --dtype
quantized --model-quantize yolact-sim.quantilize --device CPU --with-input-meta yolact-sim-
inputemeta.yml --postprocess-file yolact-sim-postprocess-file.yml
```

图 2-7: npu\_inf

## 2.9 导出代码和 NBG 文件

```
pegasus export ovxlib --model yolact-sim.json --model-data yolact-sim.data --dtype quantized --
model-quantize yolact-sim.quantilize --batch-size 1 --save-fused-graph --target-ide-project '
linux64' --with-input-meta yolact-sim-inputemeta.yml --postprocess-file yolact-sim-postprocess-file
.yml --output-path ovxlib/yolact/yolact --pack-nbg-unify --optimize "VIP9000PICO_PID0XEE" --viv-
sdk ${VIV_SDK}
```

```
pegasus export ovxlib --model yolact-sim.json --model-data yolact-sim.data --dtype quantized --
model-quantize yolact-sim.quantilize --batch-size 1 --save-fused-graph --target-ide-project '
linux64' --with-input-meta yolact-sim-inputemeta.yml --postprocess-file yolact-sim-postprocess-file
.yml --output-path ovxlib/yolact/yolact --pack-nbg-viplite --optimize "VIP9000PICO_PID0XEE" --viv-
sdk ${VIV_SDK}
```

```
vdtpoxy -L/home/caozilong/Verisilicon/VivanteIDE5.5.0/cmdtools/vsimulator/./common/lib/ -ldtproxy /home/caozilong/Verisilicon/VivanteIDE5.5.0/cmdtools/vsimulator/./common/lib/libjpeg.a -o gen_nbg

Create Neural Network: 204ms or 204579us
Verify...
Start Graph: 60371ms or 60371600us
Run the 1 time: 6.00ms or 6004.00us
vxProcessGraph execution time:
Total 6.00ms or 6936.00us
Average 6.04ms or 6936.00us
--- Top5 ---
0: 0.000000
1: 0.000000
2: 0.000000
3: 0.000000
4: 0.000000
1 Export ovxlib case with version 1.1.34
2 Dump nbg input meta to /home/caozilong/Workspace/yolact-develop-20220218/ovxlib/yolact_nbg_viplite/nbg_meta.json
3 Save vx network source file to /home/caozilong/Workspace/yolact-develop-20220218/ovxlib/yolact_nbg_viplite/vnn_post_process.c
4 Save vx network source file to /home/caozilong/Workspace/yolact-develop-20220218/ovxlib/yolact_nbg_viplite/vnn_pre_process.h
5 Save vx network source file to /home/caozilong/Workspace/yolact-develop-20220218/ovxlib/yolact_nbg_viplite/vnn_pre_process.c
6 Save vx network source file to /home/caozilong/Workspace/yolact-develop-20220218/ovxlib/yolact_nbg_viplite/vnn_pre_process.h
7 Save vx network source file to /home/caozilong/Workspace/yolact-develop-20220218/ovxlib/yolact_nbg_viplite/main.c
8 Save vx network source file to /home/caozilong/Workspace/yolact-develop-20220218/ovxlib/yolact_nbg_viplite/yolact_vcxpro)
9 Save vx network source file to /home/caozilong/Workspace/yolact-develop-20220218/ovxlib/yolact_nbg_viplite/makefile.linux
10 Dump net to ovxlib/yolact/yolact_fused.json
11 End exporting ovxlib case
1 -----Error(0),Warning(0)-----
(vip) caozilong@xendroid-AI:~/Workspace/yolact-develop-20220218$
(vip) caozilong@xendroid-AI:~/Workspace/yolact-develop-20220218$ tree -L 2
.
├── data
│   ├── dog.jpg
│   └── dataset.txt
├── iter_0_attach_Concat_Concat_256_out0_0_out0_1_192x48_4.tensor
├── iter_0_attach_Concat_Concat_256_out0_2_out0_1_192x48_32.tensor
├── iter_0_attach_initializer_769_out0_3_out0_192x48_4.tensor
├── iter_0_attach_Softmax_Softmax_260_out0_1_out0_1_192x48_32.tensor
├── iter_0_attach_Transpose_Transpose_165_out0_4_out0_1_138_138_32.tensor
├── iter_0_input_1_219_out0_1_3_550_550.tensor
├── ovxlib
│   ├── yolact
│   │   ├── yolact_nbg_unify
│   │   ├── yolact_nbg_unify_ovx
│   │   └── yolact_nbg_viplite
│   ├── yolact-sim.data
│   ├── yolact-sim-inputmeta.yml
│   ├── yolact-sim.json
│   ├── yolact-sim.onnx
│   ├── yolact-sim-postprocess-file.yml
│   └── yolact-sim.quantize
└── 0 directories, 14 files
(vip) caozilong@xendroid-AI:~/Workspace/yolact-develop-20220218$
```

图 2-8: npu\_export

生成的 NBG 文件，可以部署到端侧：

```
(vip) caozilong@xendroid-AI:~/Workspace/yolact-develop-20220218$ sha512sum ovxlib/yolact/*-nb
4e1870730b1883f4a5ec002b9fb241d532614fb91da80a245850b09a626fc3704d2b30193b99f41bc0ff49677c2e37e2c8970f028da4182a812d08a35b61 ovxlib/yolact_nbg_unify/network_binary.nb
4e1870730b1883f4a5ec002b9fb241d532614fb91da80a245850b09a626fc3704d2b30193b99f41bc0ff49677c2e37e2c8970f028da4182a812d08a35b61 ovxlib/yolact_nbg_unify_ovx/network_binary.nb
4e1870730b1883f4a5ec002b9fb241d532614fb91da80a245850b09a626fc3704d2b30193b99f41bc0ff49677c2e37e2c8970f028da4182a812d08a35b61 ovxlib/yolact_nbg_viplite/network_binary.nb
(vip) caozilong@xendroid-AI:~/Workspace/yolact-develop-20220218$
(vip) caozilong@xendroid-AI:~/Workspace/yolact-develop-20220218$
```

图 2-9: npu\_nbg

## 2.10 模型算力测量

pegasus measure --model yolact-sim.json

```
0 Process Conv_Conv_161_22 ...
0 Acuity output shape(convolution): (1 138 138 256)
0 Tensor @Conv_Conv_161_22_out0 type: float32
0 Process Relu_Relu_162_30 ...
0 Acuity output shape(relu): (1 138 138 256)
0 Tensor @Relu_Relu_162_30_out0 type: float32
0 Process Conv_Conv_163_22 ...
0 Acuity output shape(convolution): (1 138 138 32)
0 Tensor @Conv_Conv_163_22_out0 type: float32
0 Process Relu_Relu_164_10 ...
0 Acuity output shape(relu): (1 138 138 32)
0 Tensor @Relu_Relu_164_10_out0 type: float32
0 Process Attach_Transpose_Transpose_165_out0_4 ...
0 Acuity output shape(output): (1 138 138 32)
0 Tensor @Attach_Transpose_Transpose_165_out0_4_out0 type: float32
1 Build torchjit-export complete.
1 Dump analysis to /home/caozilong/Workspace/yolact-develop-20220218/analysis.json
1 sum_macc:59.280 sum_param:34.98M sum_activation:227.32M
1 End measuring...
1 -----Error(0),Warning(0)-----
(vip) caozilong@xendroid-AI:~/Workspace/yolact-develop-20220218$
(vip) caozilong@xendroid-AI:~/Workspace/yolact-develop-20220218$
(vip) caozilong@xendroid-AI:~/Workspace/yolact-develop-20220218$
```

图 2-10: npu\_measure

对比 yolov3 的 32.99G MACC 算力和 yolov3-tiny 的 2.79G macc 的算力需求，YOLOACT 明显对算力的需求大很多。题外话，1TOPS=1000GOPS，对于 yolov3-tiny 来说，我们以 3G 的算力需求来计算，就是 0.003T，在 500M 频率下，NPU 的理论算力是 0.5T，所以，YOLOV3 的帧率为：0.5T/0.003T=166 帧。这个值和仿真值是比较接近的。

## 2.11 后处理验证

yolact 的后处理 C 代码在如下位置：




图 2-11: npu\_gerit

编译后处理模型：

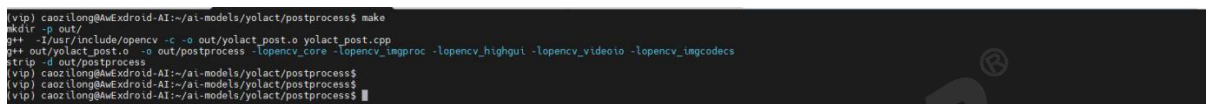


图 2-12: npu\_post

out 目录生成了 yolact 的后处理程序：



图 2-13: npu\_postprocess

yolact 模型有五个输出层,inference 阶段生成了 5 个 output tensor.

|   |                 |           |           |
|---|-----------------|-----------|-----------|
| iter_0_attach_Concat_Concat_256_out0_0_out0_1_19248_4.tensor      | 2022/2/18 16:23 | TENSOR 文件 | 1.444 KB  |
| iter_0_attach_Concat_Concat_256_out0_2_out0_1_19248_32.tensor     | 2022/2/18 16:23 | TENSOR 文件 | 11.570 KB |
| iter_0_attach_initializer_789_out0_3_out0_1_19248_4.tensor        | 2022/2/18 16:23 | TENSOR 文件 | 880 KB    |
| iter_0_attach_Softmax_Softmax_260_out0_1_out0_1_19248_81.tensor   | 2022/2/18 16:23 | TENSOR 文件 | 33.932 KB |
| iter_0_attach_Transpose_Transpose_165_out0_4_out0_1_138_32.tensor | 2022/2/18 16:23 | TENSOR 文件 | 9.622 KB  |
| iter_0_input_1_219_out0_1_3_550_550.tensor                        | 2022/2/18 16:23 | TENSOR 文件 | 16.965 KB |

图 2-14: npu\_tensor

tensor之间的对应关系,0是location, 1是confidence, 2是mask, 3暂时无用, 4是maskmaps.

output0\_4\_19248\_1.dat <----> iter\_0\_attach\_Concat\_Concat\_256\_out0\_0\_out0\_1\_19248\_4.tensor

output1\_81\_19248\_1.dat<----> iter\_0\_attach\_Softmax\_Softmax\_260\_out0\_1\_out0\_1\_19248\_81.tensor

```
output2_32_19248_1.dat<---->iter_0_attach_Concat_Concat_258_out0_2_out0_1_19248_32.tensor
```

```
output3_4_19248.dat <---->iter_0_attach_Initializer_769_out0_3_out0_19248_4.tensor
```

```
output4_32_138_138_1.dat<---->iter_0_attach_Transpose_Transpose_165_out0_4_out0_1_138_138_32.tensor
```

执行后处理

```
(vip) caozilong@AwExdroid-AI:~/ai-models/yolact/postprocess$ ./out/postprocess dog.jpg  
time : 0.035 Sec  
2 = 0.96443 at 99.48 111.53 478.22 x 329.83  
17 = 0.76052 at 128.47 212.00 196.70 x 339.42  
17 = 0.70652 at 130.96 150.66 341.01 x 358.92  
8 = 0.52484 at 472.83 76.51 207.34 x 92.95  
3 = 0.52384 at 472.83 75.79 207.34 x 94.07  
(vip) caozilong@AwExdroid-AI:~/ai-models/yolact/postprocess$
```

图 2-15: npu\_exepost

后处理结果：




图 2-16: npu\_yolact

图中识别除了两只 dog, 有两个狗的信息, 其他都能很好的输出结果, dog 70.7% 不应该出现的, 大概率是量化导致输出结果精度精度降低。

修改归一化参数后重新部署, 得到的结果如下, 可以看到, 之前的问题消失:




图 2-17: npu\_yolact\_ok

至此，yoloact 模型导入完成。

## 2.12 结束






## 著作权声明

版权所有 © 2022 珠海全志科技股份有限公司。保留一切权利。

本文档及内容受著作权法保护，其著作权由珠海全志科技股份有限公司（“全志”）拥有并保留一切权利。

本文档是全志的原创作品和版权财产，未经全志书面许可，任何单位和个人不得擅自摘抄、复制、修改、发表或传播本文档内容的部分或全部，且不得以任何形式传播。

## 商标声明

、、**全志科技**、（不完全列举）均为珠海全志科技股份有限公司的商标或者注册商标。在本文档描述的产品中出现的其它商标，产品名称，和服务名称，均由其各自所有人拥有。

## 免责声明

您购买的产品、服务或特性应受您与珠海全志科技股份有限公司（“全志”）之间签署的商业合同和条款的约束。本文档中描述的全部或部分产品、服务或特性可能不在您所购买或使用的范围内。使用前请认真阅读合同条款和相关说明，并严格遵循本文档的使用说明。您将自行承担任何不当使用行为（包括但不限于如超压，超频，超温使用）造成的不利后果，全志概不负责。

本文档作为使用指导仅供参考。由于产品版本升级或其他原因，本文档内容有可能修改，如有变更，恕不另行通知。全志尽全力在本文档中提供准确的信息，但并不确保内容完全没有错误，因使用本文档而发生损害（包括但不限于间接的、偶然的、特殊的损失）或发生侵犯第三方权利事件，全志概不负责。本文档中的所有陈述、信息和建议并不构成任何明示或暗示的保证或承诺。

本文档未以明示或暗示或其他方式授予全志的任何专利或知识产权。在您实施方案或使用产品的过程中，可能需要获得第三方的权利许可。请您自行向第三方权利人获取相关的许可。全志不承担也不代为支付任何关于获取第三方许可的许可费或版税（专利税）。全志不对您所使用的第三方许可技术做出任何保证、赔偿或承担其他义务。