

## BANGC 算子与风格迁移实验手册（下）

### 一、实时风格迁移在线推理与离线部署

#### 1. 实验内容：

- a) 模型量化：将单精度模型量化为 INT8 模型。
- b) 在线推理，完成 MLU 推理代码的移植工作，分别比较三种不同模型（原始模型、PowerDifference 算子模型，Numpy 算子模型）在 CPU 和 MLU 上的性能和精度。
- c) 离线推理，完成 MLU CNRT 离线推理代码，并完成部署测试。

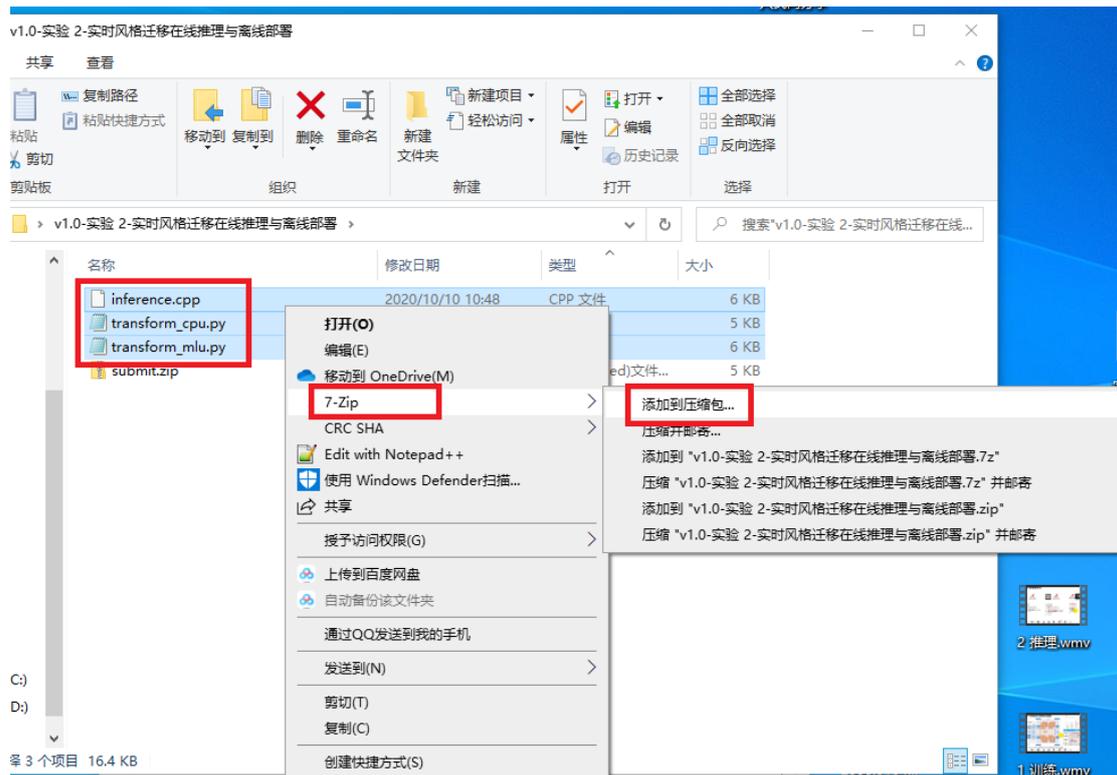
#### 2. 实验步骤：

- a) 模型量化：MLU270 对于 mlp 和 conv 等算子可使用 int 数据类型进行计算以提高效率，所以先要将原始的 float32 数据类型的 pb 模型量化成为 int 类型。在 /opt/AICSE-demo-student/demo/style\_transfer\_bcl/tools/fppb\_to\_intpb 目录中执行：python fppb\_to\_intpb.py udnie\_int8.ini。生成的模型会保存在 /opt/AICSE-demo-student/demo/style\_transfer\_bcl/models/int\_pb\_models 目录下。
- b) 在线推理程序：分别补全 /opt/AICSE-demo-student/demo/style\_transfer\_bcl/src/online\_mlu/transform\_mlu.py 和 /opt/AICSE-demo-student/demo/style\_transfer\_bcl/src/online\_cpu/transform\_cpu.py。比较多种不同推理方式的性能精度差异。
- c) 离线推理程序：在执行 MLU 在线推理时，通过配置文件生成并保存两种离线模型（原始模型、PowerDifference 算子模型）至 /opt/AICSE-demo-student/demo/style\_transfer\_bcl/models/offline\_models 文件夹下。补全 CNRT 离线推理模型代码：  
/opt/AICSE-demo-student/demo/

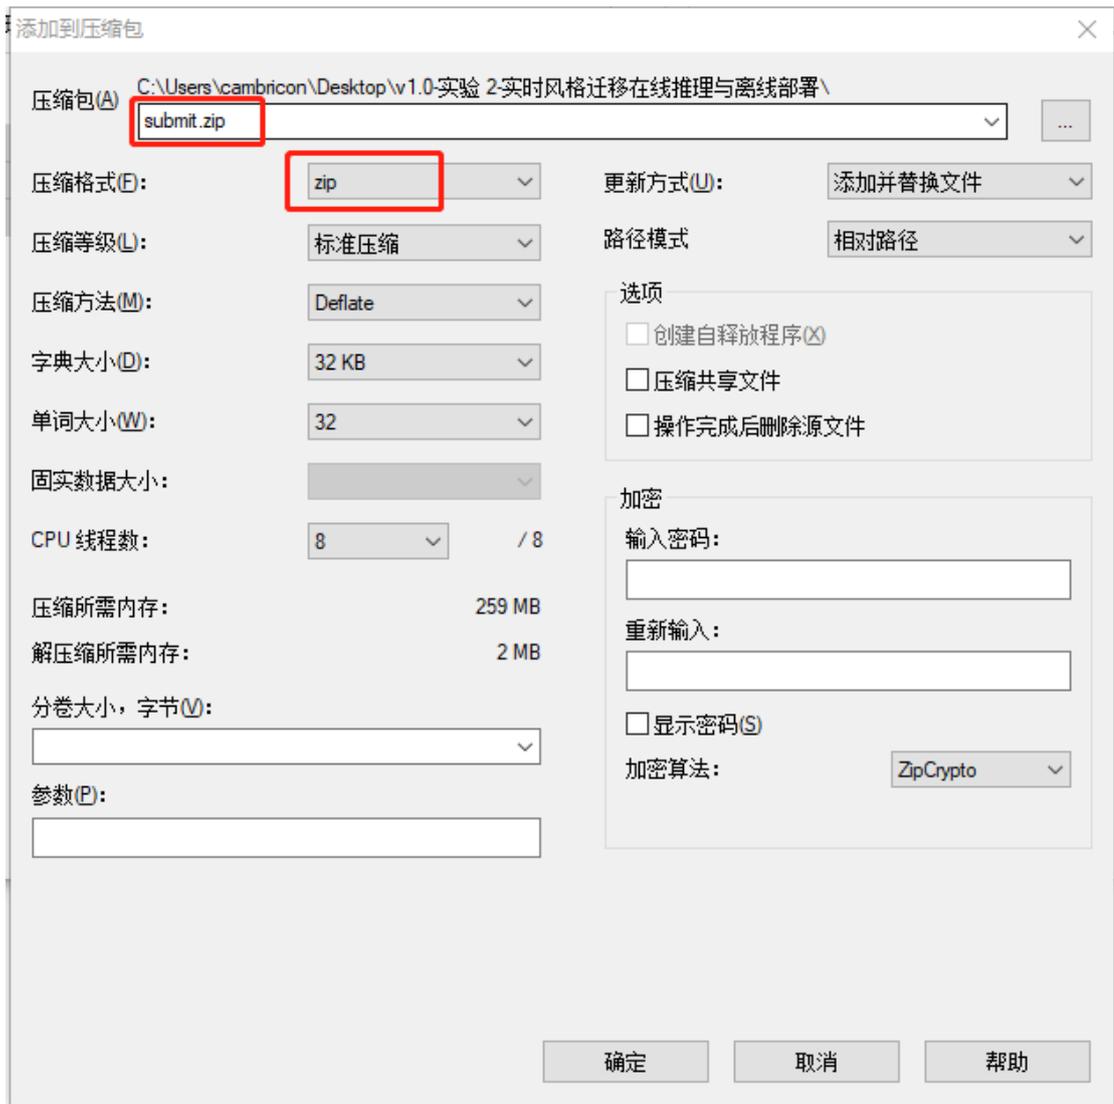
style\_transfer\_bcl/src/offline/src/inference.cpp 然后编译并执行离线推理。

### 3. 上传自动评测平台

- a) 将程序按以下文件列表整理，打包成压缩文件。请注意文件名和图中保持一致。



- b) 压缩文件格式为 zip 格式。文件名命名为 submit.zip



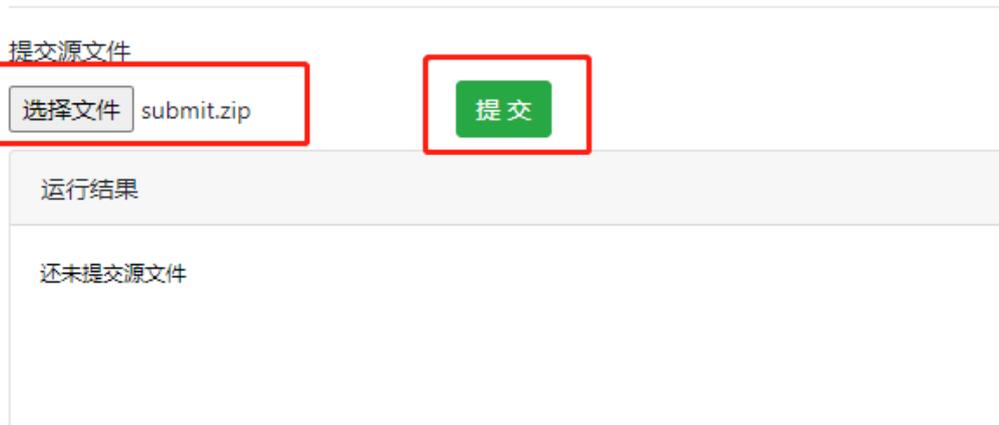
c) 将 submit.zip 上传到评测平台。选择文件并点击提交。

### 3. 评分标准

60分 标准：完成模型量化与TensorFlow在线推理程序，输出CPU端、MLU端 精度正确的风格迁移图片，输出

80分 标准：在60分的基础上，完成离线推理程序的编写，执行离线推理时 风格迁移图片精度正常；

100分标准：在80分基础上，执行离线推理时在图片精度正常的同时使用 BangC 实现 PowerDifference 等相比使用纯 CNML 算子库生成的离线模型，推理时延时更低，性能更好。



d) 上传之后请等待系统评测。

60分 标准：完成模型量化与TensorFlow在线推理程序，输出CPU端、MLU端 精度正确的风格迁移图片，输出  
80分 标准：在60分的基础上，完成离线推理程序的编写，执行离线推理时 风格迁移图片精度正常  
100分标准：在80分基础上，执行离线推理时在图片精度正常的同时使用 BangC 实现 PowerDifi  
相比使用纯 CNML 算子库生成的离线模型，推理时延时更低，性能更好。



e) 评测结束之后会自动显示评测结果。

提交源文件

选择文件 submit.zip

提交

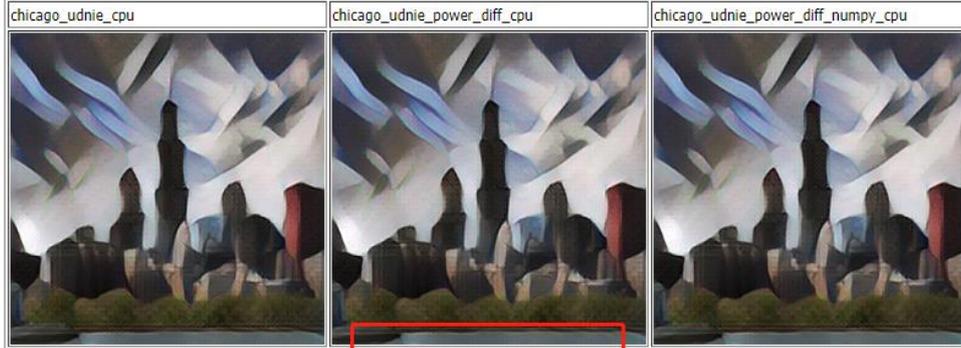
运行结果

下载源文件

得分80.00 最后一次提交时间:2020-10-19 20:10:28

Accept

### CPU推理输出图



### MLU推理输出图

