

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。