



北京大學

PEKING UNIVERSITY



The Legend of a Picture

报告人：李畅 李思哲 王珮衡



图像风格化——架构

- 论文summary
- 参数调整
- 不同风格的对比



图像风格化——应用

- 服饰纹理设计
- 图像风格统一化



图像风格化——拓展

- 视频风格迁移
- UI界面的设计
- 实时风格迁移

以下是Peggy的笔记 可以应用在衔接中

1、首先论文提及了一种无参的转化方式

2、其次提到许多很厉害的人用各种各样方法做风格转换

但是，都有limitation：用了低水平的图像特征处理纹理转换

提出要求即小目标：**能够获得content的语义信息 用style的方式表示出来**

故而

思路：用已经训练完成的网络分别独立处理content与style

将style transfer任务转化为一个最优解问题 即用一个神经网络最优化loss的问题

对于图片的处理大致分为两部分：

1) content: find image representation

- 这一部分在处理手写数据集等里面已经有很好的研究与方法

2) style

Content Representation:

一层 N_l 个大小为 M_l 的卷积 生成一个 $N_l * M_l$ 的响应

计算新生成图片与原图之间的Loss

$$\text{Loss}(\vec{p}, \vec{x}, \vec{l}) = \frac{1}{2} \sum_{ij} (F_{ij}^l - P_{ij}^l)^2$$

$$\frac{\partial \mathcal{L}_{\text{content}}}{\partial F_{ij}^l} = \begin{cases} (F^l - P^l)_{ij} & \text{if } F_{ij}^l > 0 \\ 0 & \text{if } F_{ij}^l < 0 \end{cases}$$

代码中即为mse_loss()

高阶的layer能捕获更高级的content特征

选择在conv_4处计算得content_loss

Style Representation:

Consisting of the correlations between the different filter responses

一层 N_l 个大小为 N_l 的卷积 生成一个 $N_l * N_l$ 的响应

生成Gram Matrix $G^l \in R^{N_l \times N_l}$ 记录内积

$$G_{ij}^l = \sum F_{ik}^l F_{jk}^l$$

用白噪音梯度下降 minimize mse_loss

各层权重论文中均取1/5 暂不作研究

$$\mathcal{L}_{total} = \alpha \mathcal{L}_{content}(\vec{p}, \vec{x}) + \beta \mathcal{L}_{style}(\vec{a}, \vec{x})$$

α , β 为各自权重

```
def get_input_optimizer(input_img):  
    # 以梯度为参数  
    optimizer = optim.LBFGS([input_img.requires_grad_()])  
    return optimizer
```

采用L-BFGS算法找到最优解

L-BFGS 在有限内存中进行BFGS算法

牛顿迭代 -> 泰勒展开Hessi矩阵 -> 通过迭代逼近矩阵

初始化时需要:

将content与style转化为同样大小图片 在load_image()函数中处理

注: Image.LANCZOS 多相位插值放缩

整个过程中

论文给出的结论是 content 与 style 是完全独立的

其中，整个方法中对于最终风格迁移效果可能产生影响的**可调参部分**为：

- 1) $\alpha/\beta = \text{content weight} / \text{style weight}$
- 2) 获取 content loss 层数
- 3) 用以初始化 output 的图片 (content / style / white noise)

整个过程中

论文给出的结论是 content 与 style 是完全独立的

其中，整个方法中对于最终风格转换效果可能产生影响的可调参部分为：

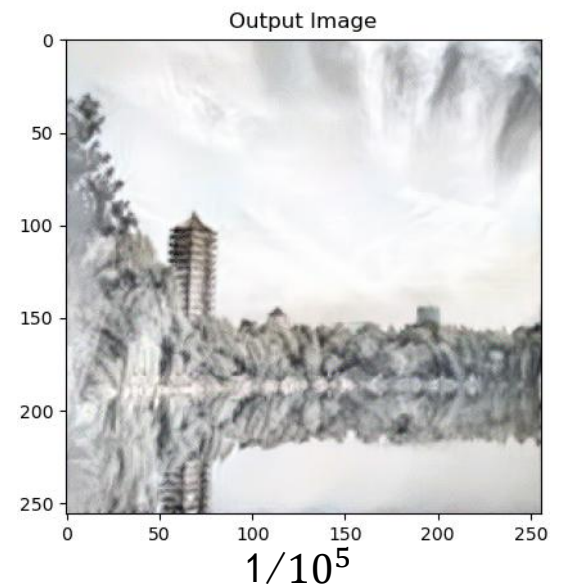
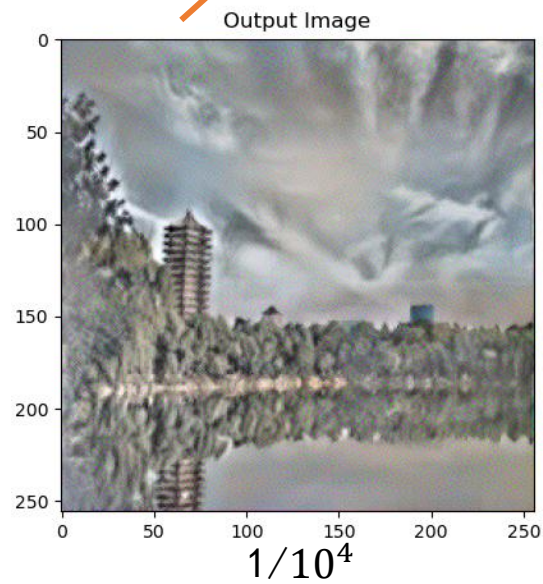
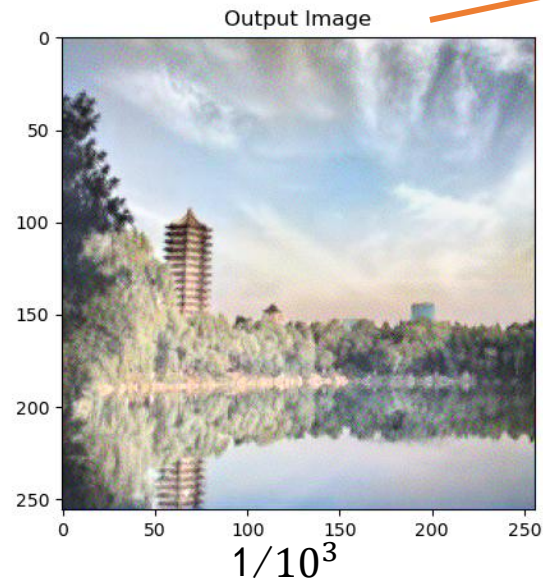
- 1) $\alpha/\beta = \text{content weight} / \text{style weight}$
- 2) 获取 content loss 层数
- 3) 用以初始化 output 的图片 (content / style / white noise)

$\alpha/\beta = \text{content weight} / \text{style weight}$

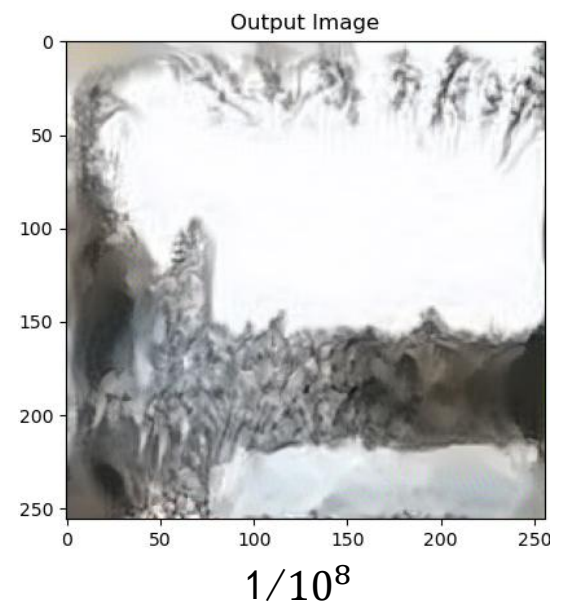
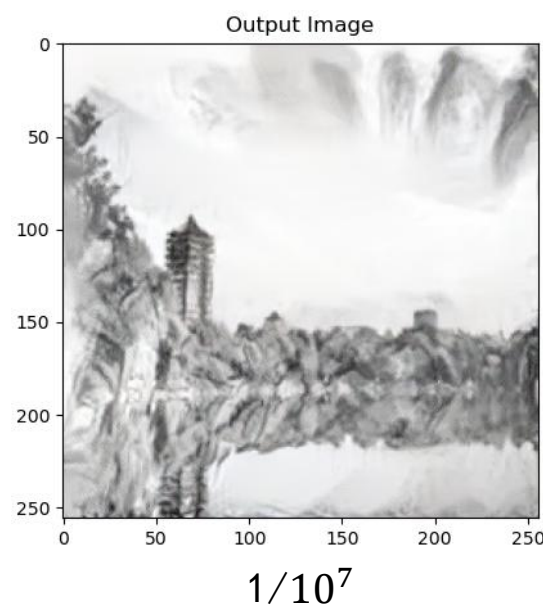
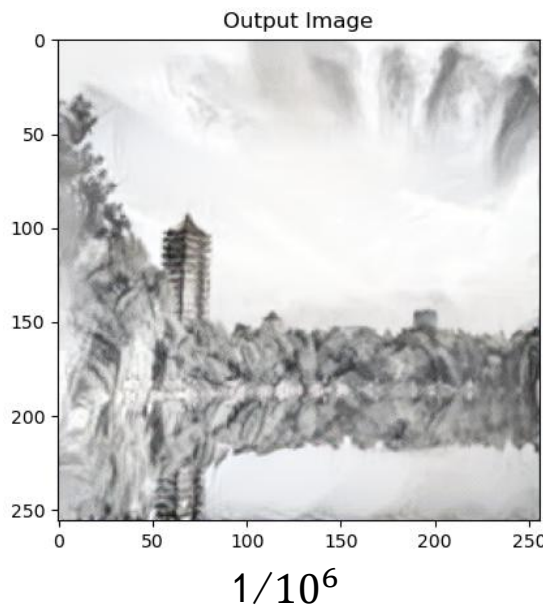
Style权重偏小
色彩保留较明显



content



style



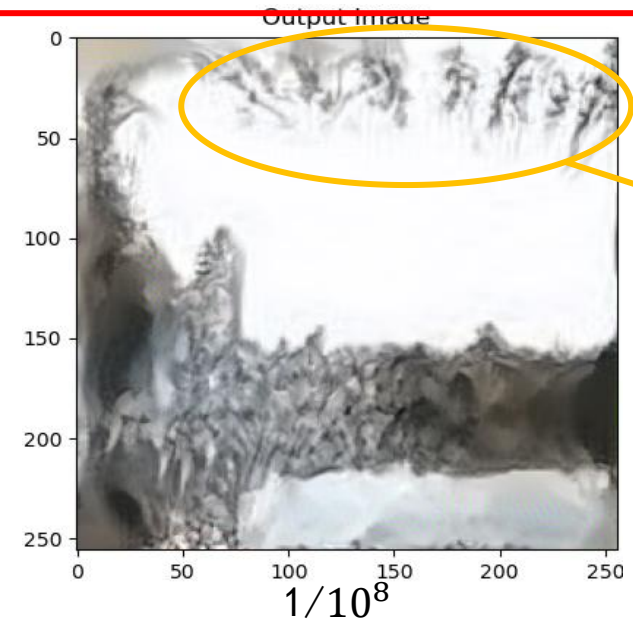



$\alpha/\beta = \text{content weight} / \text{style weight}$



content



style



Style过大
保留内容特征


$\alpha/\beta = \text{content weight} / \text{style weight}$




content



$1/10^3$




$1/10^4$



style



$1/10^5$



$1/10^6$

$\alpha/\beta = \text{content weight} / \text{style weight}$



content



$1/10^3$



$1/10^4$



style



$1/50000$



$1/10^5$




$1/10^6$

$\alpha/\beta = \text{content weight} / \text{style weight}$



content



1/5000



1/10⁴



style



1/50000



1/10⁵

$\alpha/\beta = \text{content weight} / \text{style weight}$ 总结

a. style风格笔触越小 style最终所占权重应相应调大，达到较为理想的风格保留效果


b. style 过大易导致 content 内容丢失严重 生成图片中混入较多 style 中特征



分类：水墨

特征：笔触较小 略微块状

推荐 α/β 参数： $1/10^6$



分类：工笔水彩

特征：笔触简练 线条特征

推荐 α/β 参数： $1/10^5$



分类：水粉、油画

特征：笔触较大 连贯条状

推荐 α/β 参数： $1/10^5 \sim 1/10^4$

整个过程中

论文给出的结论是 content 与 style 是完全独立的

其中，整个方法中对于最终风格转换效果可能产生影响的可调参部分为：

- 1) $\alpha/\beta = \text{content weight} / \text{style weight}$
- 2) 获取 content loss 层数
- 3) 用以初始化 output 的图片 (content / style / white noise)


content 获取特征层数




content

相同 α/β 权重下，改变获得 loss 的 content 卷积层数
可以验证论文中，从更深卷积层中获取更多的语义信息，
使得content图中信息得以保留


可以发现conv_3,conv_4,conv_5处计算效果较好



style



conv_1




conv_2



conv_3



conv_4




conv_5


采用先前得到的 $\alpha/\beta = 10^5$ 以及conv4/conv5



content



conv_4



conv_5



style


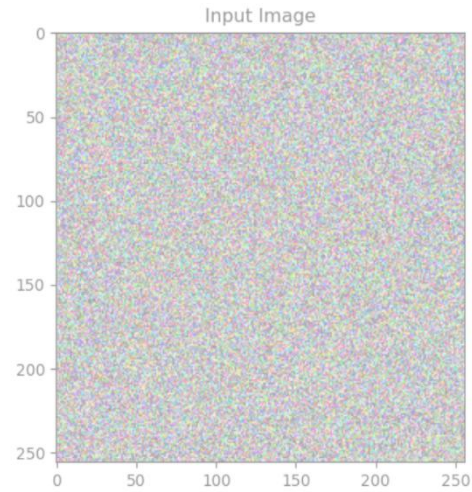
整个过程中

论文给出的结论是 content 与 style 是完全独立的


其中，整个方法中对于最终风格转换效果可能产生影响的可调参部分为：

- 1) $\alpha/\beta = \text{content weight} / \text{style weight}$
- 2) content 获取特征层数
- 3) 用以初始化 output 的图片 (content / style / white noise)

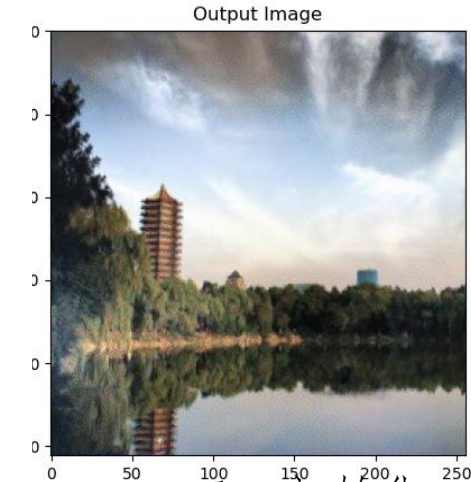
用以初始化 output 的图片 (content / style / white noise)



white noise 初始化



content 初始化



style 初始化



整个过程中

论文给出的结论是 content 与 style 是完全独立的


其中，整个方法中对于最终风格转换效果可能产生影响的可调参部分为：

- 1) $\alpha/\beta = \text{content weight} / \text{style weight}$
- 2) content 获取特征层数
- 3) 用以初始化 output 的图片 (content / style / white noise)


Answer for Project One




our output




图片由神经网络生成后
略调整饱和度得到




style





图像风格化——架构

- 论文summary
- 参数调整
- 不同风格的对比



图像风格化——应用

- 服饰纹理设计
- 图像风格统一化



图像风格化——拓展

- 视频风格迁移
- UI界面的设计
- 实时风格迁移

手稿 + 材质/纹样图片 → 该类材质/纹样的成品图

方法：将目标纹样图片作为style 手稿作为content导入




交互：手工选择需要转换的手稿区域、纹样区域 进行转换

改进：先识别出画面主体即手稿服装所在位置，仅对该位置进行风格迁移操作



Content:



+




=



《池塘·睡莲》——莫奈

Style: ?



style_loss	1	2	3	4	5	6
1	\	103	101	104	102	106
2	103	\	98	98	102	102
3	101	98	\	100	100	104
4	104	98	100	\	101	103
5	102	102	100	101	\	105
6	106	102	104	103	105	\
total_loss	516	503	503	506	510	520

$$G_{ij} = \sum_k F_{ik} \cdot F_{jk} = F \cdot F^T; \quad L_{Style} = \sum \frac{1}{w^2 \cdot h^2} (G_{ij}^1 - G_{ij}^2)^2$$



方案一：

直接用图2作为Style图片，对内容图片进行风格化。



我们需要找到一张更合适的
图片来作为Style!!




方案二：

使用图2替代图6，利用PIL的paste函数，重新拼合成与原图尺寸相同的图片作为输入的style图片。




Style输入




Output

1. 参数问题


实验发现，随style_loss的权重增大，风格统一化的效果逐渐变好。记 $\text{style_loss}/\text{content_loss} = \alpha / \beta$ 。



$$\alpha / \beta = 10^7$$




$$\alpha / \beta = 10^9$$




$$\alpha / \beta = 10^{11}$$

2. 图片切割以及损失函数


图片切割是否是越细越好？损失函数是否合理？



2*2




3*3



4*4

3. 如何寻找更好的风格输入



Content



Style



Output

3. 如何寻找更好的风格输入




Content



Style




Output



图像风格化——架构

- 论文summary
- 参数调整
- 不同风格的对比




图像风格化——应用

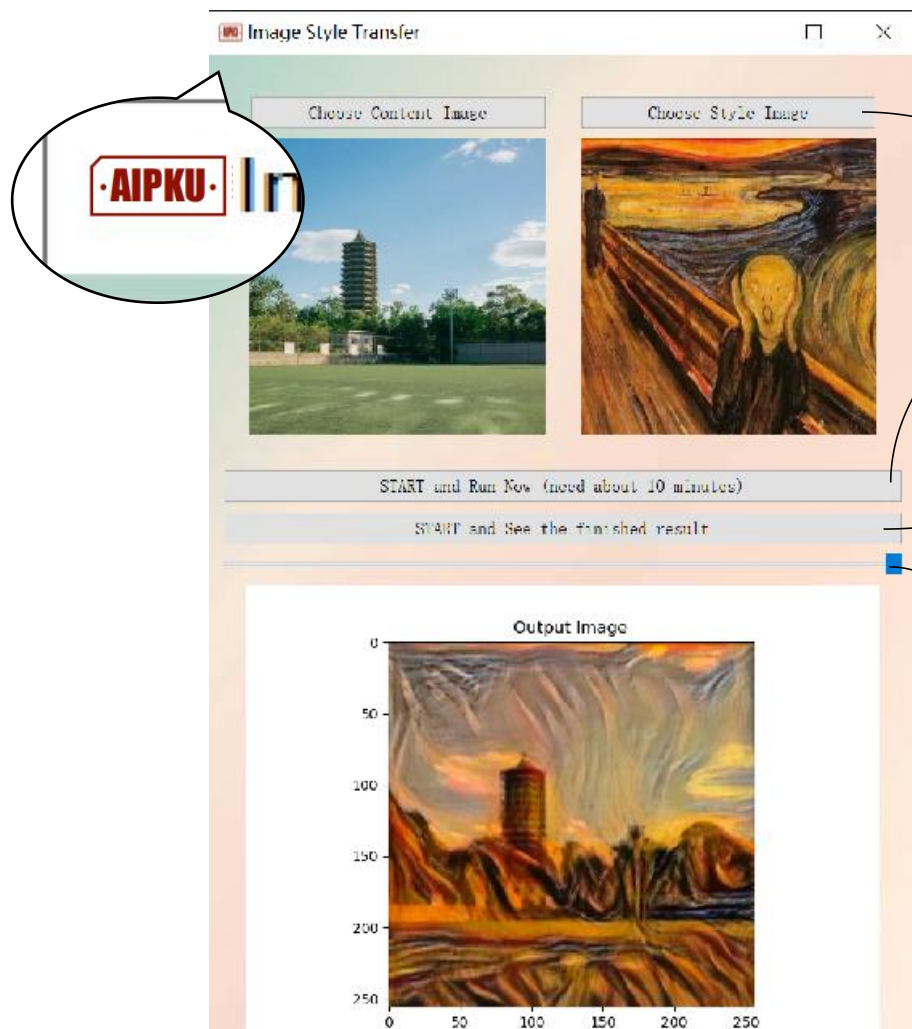
- 服饰纹理设计
- 图像风格统一化



图像风格化——拓展

- 视频风格迁移
- UI界面的设计
- 实时风格迁移





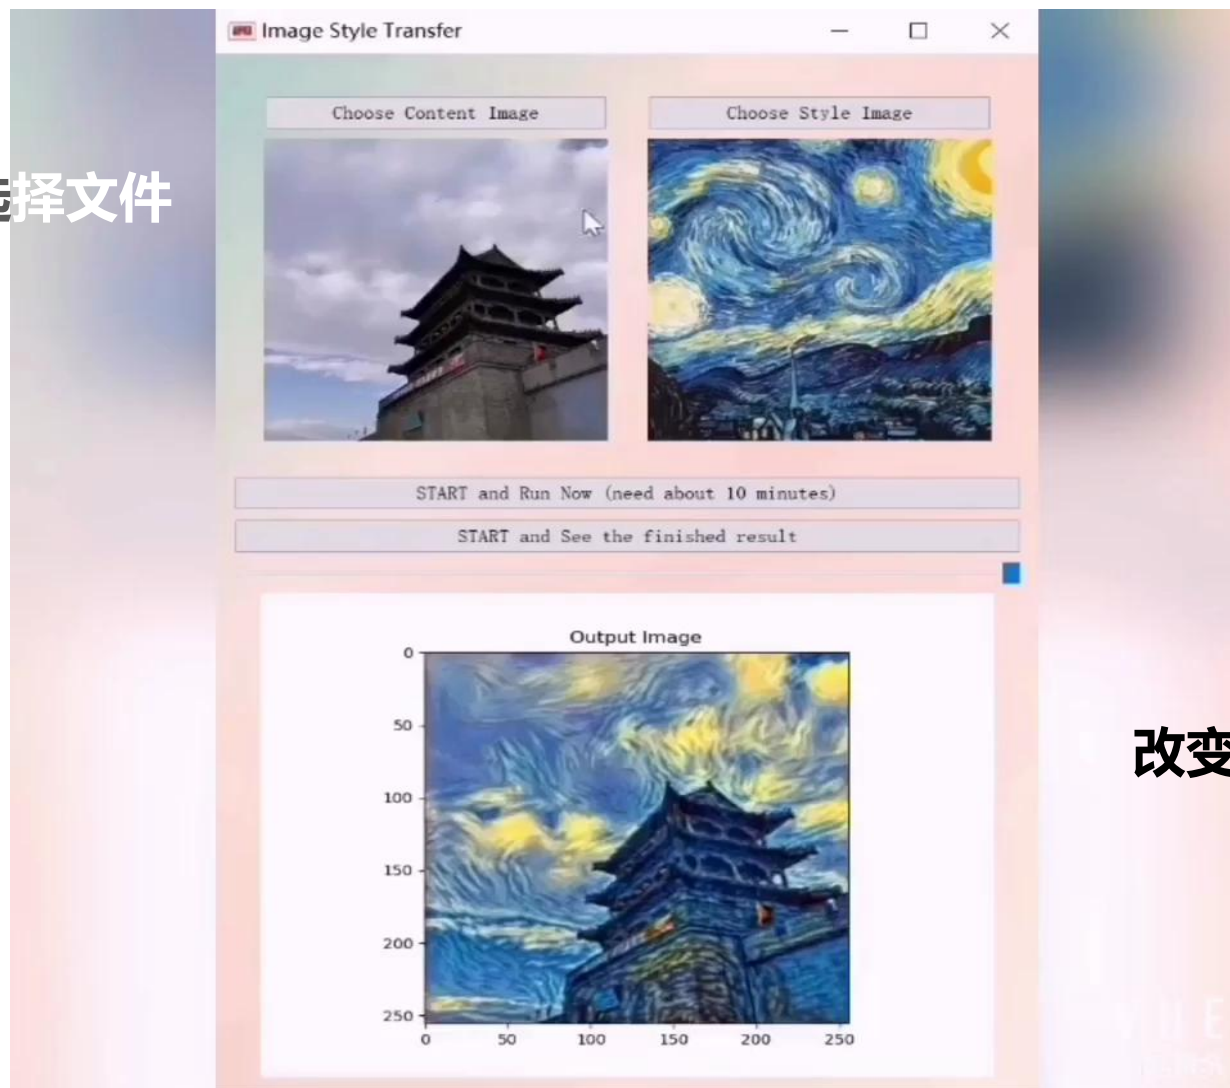
可以从本地选择文件

Start and Run now (现场运行)

See the Result (查看运行后的结果)

使用滑动条调节滤镜浓度

从电脑选择文件



改变滤镜浓度



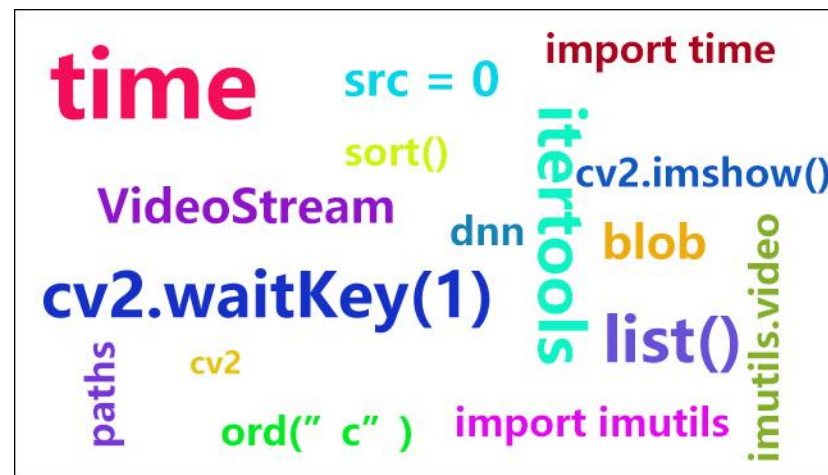
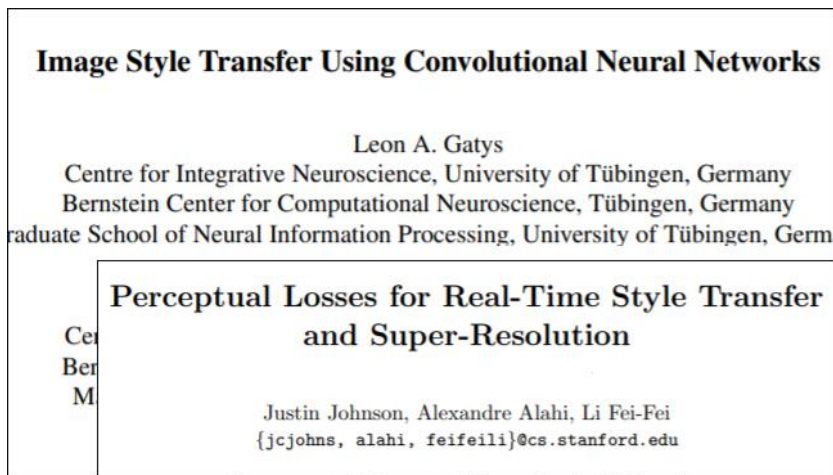
实时风格转换

通过调用训练好的神经网络
再逐帧处理网络摄像头视频流信息实现

功能开发者：李畅



整体思路



网络的选取

采用Johnson 2017年提出的模型

网络的调用

视频流引入 逐帧处理

调用模型 切换

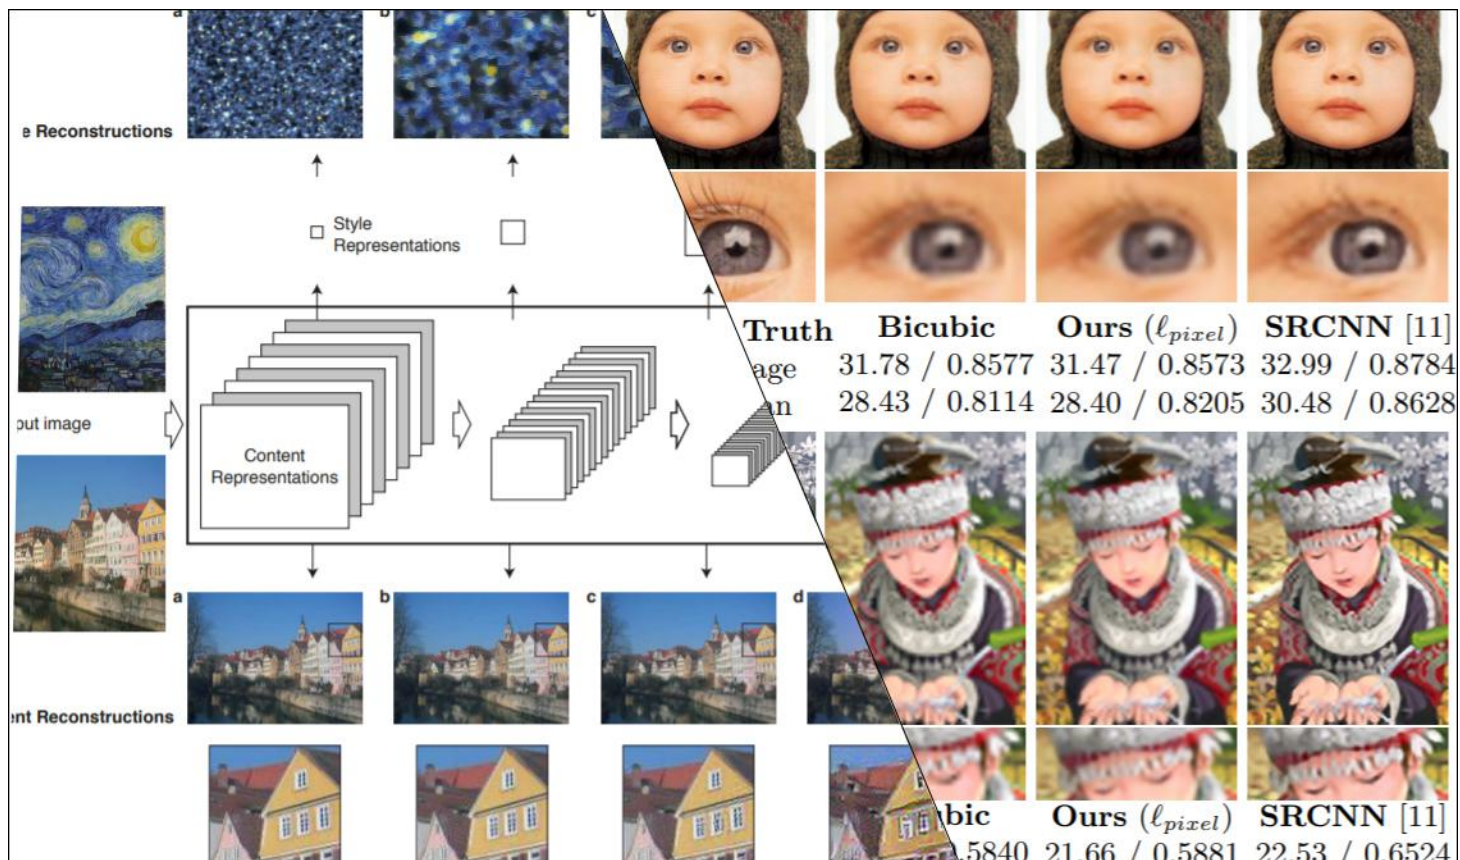
网络的选取

2016年Gatys: A Neural Algorithm of Artistic Style

最初的神经风格迁移算法

2017年Johnson: Perceptual Losses for Real-Time Style Transfer and Super-Resolution

大大提高了处理速度





```
demo_final.py ×
import cv2
import argparse
import imutils
from imutils import paths
from imutils.video import VideoStream
import itertools
import time

command = argparse.ArgumentParser()
command.add_argument('--url', type=str, required=True)

url_address = 30148411234(1234567890)

model = list(zip(range(0, len(find_models)
iterator_m = itertools.cycle(model)
(modelID, find_model) = next(iterator_m)
net = cv2.dnn.readNetFromTorch(find_model)
window_x = VideoStream(src = 0).start()
time.sleep(1.0)

while True:
    frame = window_x.read()
    frame = imutils.resize(frame, width =
    img = cv2.cvtColor(frame, cv2.COLOR_BGR2RGB)
    img = img.transpose(2, 1, 0)
    blob = cv2.dnn.blobFromImage(img, 1/255, (224, 224), (104, 117, 123.5))
    net.setInput(blob)
    probs = net.forward()
    class_ids = np.argmax(probs, axis=1).flatten()
    class_names = find_classes[class_ids]
    class_names = [class_names[i] for i in range(0, len(class_names))]
    labels = [class_names[i] + ', ' + str(round(float(class_probs[i] * 100), 2)) + '%' for i in range(0, len(class_names))]
    cv2.putText(frame, labels, (10, 10), cv2.FONT_HERSHEY_SIMPLEX, 1, (0, 255, 0), 2)
    cv2.imshow('Style Transfer', frame)
    if cv2.waitKey(1) & amp; amp; ord('q') == ord('q'):
        break
cv2.destroyAllWindows()

```

视频流引入

导入imutils库

用VideoStream.start()调用摄像头



逐帧处理

用blob函数减均值

对抗亮度变化







对output tensor进行reshape

imshow函数展示结果

减均值

reshape

展示



resize

投入网络

加回均值

resize成需要的大小

同时获取长宽信息

用setInput函数

将减均值结果投入网络

重新加回减掉的均值



模型的调用

```
from itertools
import time
and_x = argparse.ArgumentParser()
and_x.add_argument("-m", "--models", required
and_final = vars(command_x.parse_args())
_models = paths.list_files(command_final["mod
_models = sorted(list(find_models))
l = list(zip(range(0, len(find_models)), (find
ator_m = itertools.cycle(model)
elID, find_model) = next(iterator_m)
```

```
find_model) = cv2.imread(find_model)
model = list(zip(range(0, len(find_models)
iterator_m = itertools.cycle(model)
(modelID, find_model) = next(iterator_m)
net = cv2.dnn.readNetFromTorch(find_model
window_x = VideoStream(src = 0).start()
time.sleep(1.0)
while True:
    frame = window_x.read()
    frame = imutils.resize(frame, width =
```

将模型的path做成列表

利用imutils包中的list_files函数

可以将所有的模型地址导成列表

再从地址中读取网络

利用cv2.dnn.readNetFromTorch(modelpath)

调用存储的网络



模型的切换

内部机制：迭代器

导入itertools包

迭代预先处理成列表形式存储的模型信息

外部交互：键盘键入

先用cv2.waitKey函数定义得到的信息

不同键入来进行不同操作

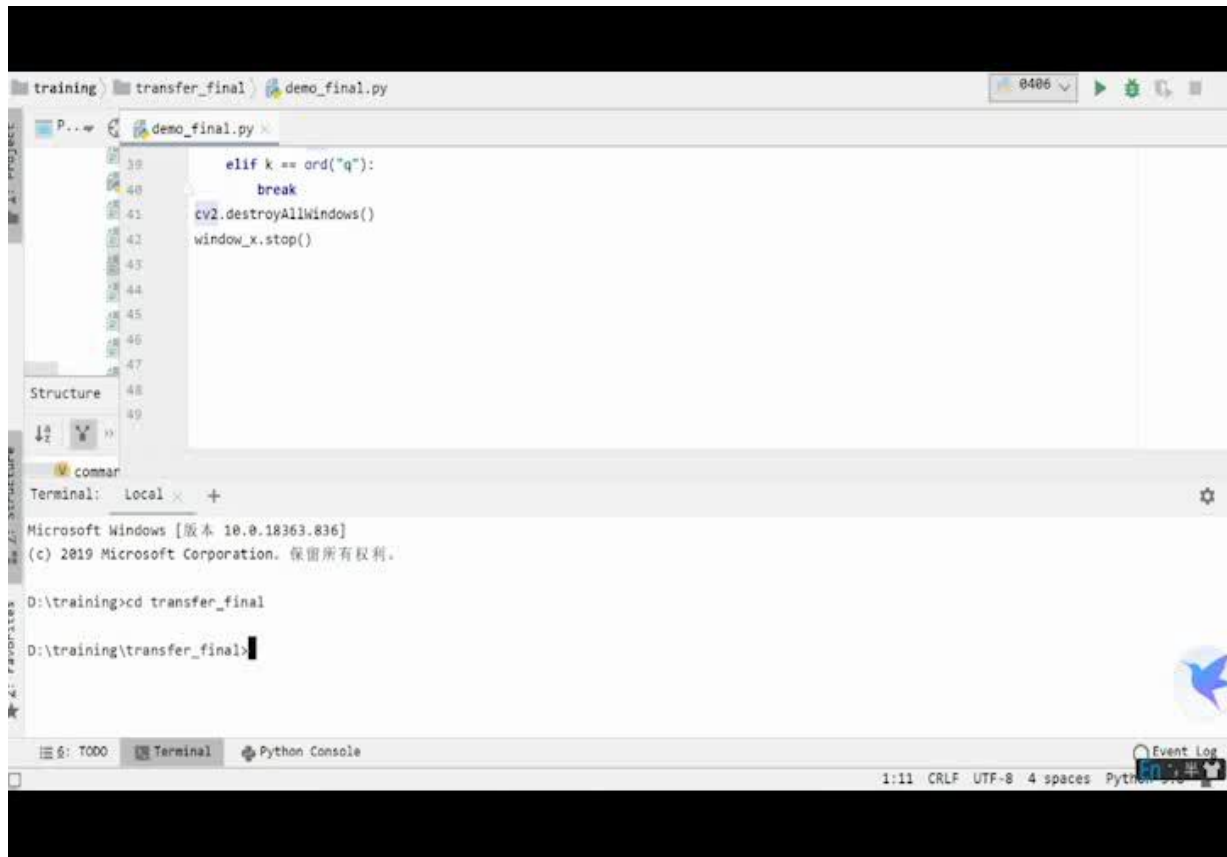
```
command_x.add_argument( '-m', '--models', required = True,
command_final = vars(command_x.parse_args())
find_models = paths.list_files(command_final["models"])
find_models = sorted(list(find_models))
model = list(zip(range(0, len(find_models)), (find_models)))
iterator_m = itertools.cycle(model)
(modelID, find_model) = next(iterator_m)
net = cv2.dnn.readNetFromTorch(find_model)
window_x = VideoStream(src = 0).start()
time.sleep(1.0)
while True:
    frame = window_x.read()
    frame = imutils.resize(frame, width = 400)
    copy_1 = frame.copy()
    (h, w) = frame.shape
    decrease_blob_size = 0.25
    output = net.blob_0_0.copy_0_0
    output = output.transpose(1, 2, 0)
    cv2.imshow("Original", frame)
    cv2.imshow("Output", output)
    k = cv2.waitKey(1) & 0xFF
    if k == ord("c"):
        (modelID, find_model) = next(iterator_m)
        net = cv2.dnn.readNetFromTorch(find_model)
    elif k == ord("q"):
        break
cv2.destroyAllWindows()
```

具体操作



具体操作

1. 命令行调用
2. 全屏
3. 键入'c'或'q'



```
training transfer_final demo_final.py 0486
demo_final.py
39     elif k == ord("q"):
40         break
41     cv2.destroyAllWindows()
42     window_x.stop()
43
44
45
46
47
48
49
Structure
comtar
Terminal: Local x +
Microsoft Windows [版本 10.0.18363.836]
(c) 2019 Microsoft Corporation. 保留所有权利。

D:\training>cd transfer_final

D:\training\transfer_final>
```



北京大學
PEKING UNIVERSITY

謝謝大家

图片、视频均来自网络，使用的人像照片均已本人同意

1、论文：模型阶段提到，将max-pooling改为average-pooling效果更佳

2、Q：第二个代码中

Why normalize?

```
def gram_matrix(input):
    a, b, c, d = input.size() # a = batch size(=1)
    # b = number of feature maps
    # (c,d) = dimensions of a f. map (N = c*d)

    features = input.view(a * b, c * d) # resize F_XL into \hat F_XL

    G = torch.mm(features, features.t()) # compute the gram product

    # we 'normalize' the values of the gram matrix
    # by dividing by the number of element in each feature maps.
    return G.div(a * b * c * d)
```

3、要再确认一下代码中方法和实际论文方法的对应

4、试试可视化style loss在最后报告中

5、为了达到input的style和content一致 运用了Image.ANTIALIAS和Image.LANCZOS 多相位插值放缩会导致一定程度数据丢失 使得最后生成图片较为模糊

6、使用的已训练网络（参数不同？）

7、关于L-BFGS

8、降噪