

**複数スタイルの融合と
部分的適用を可能とする
Multi-style Feed-forward Network の提案**

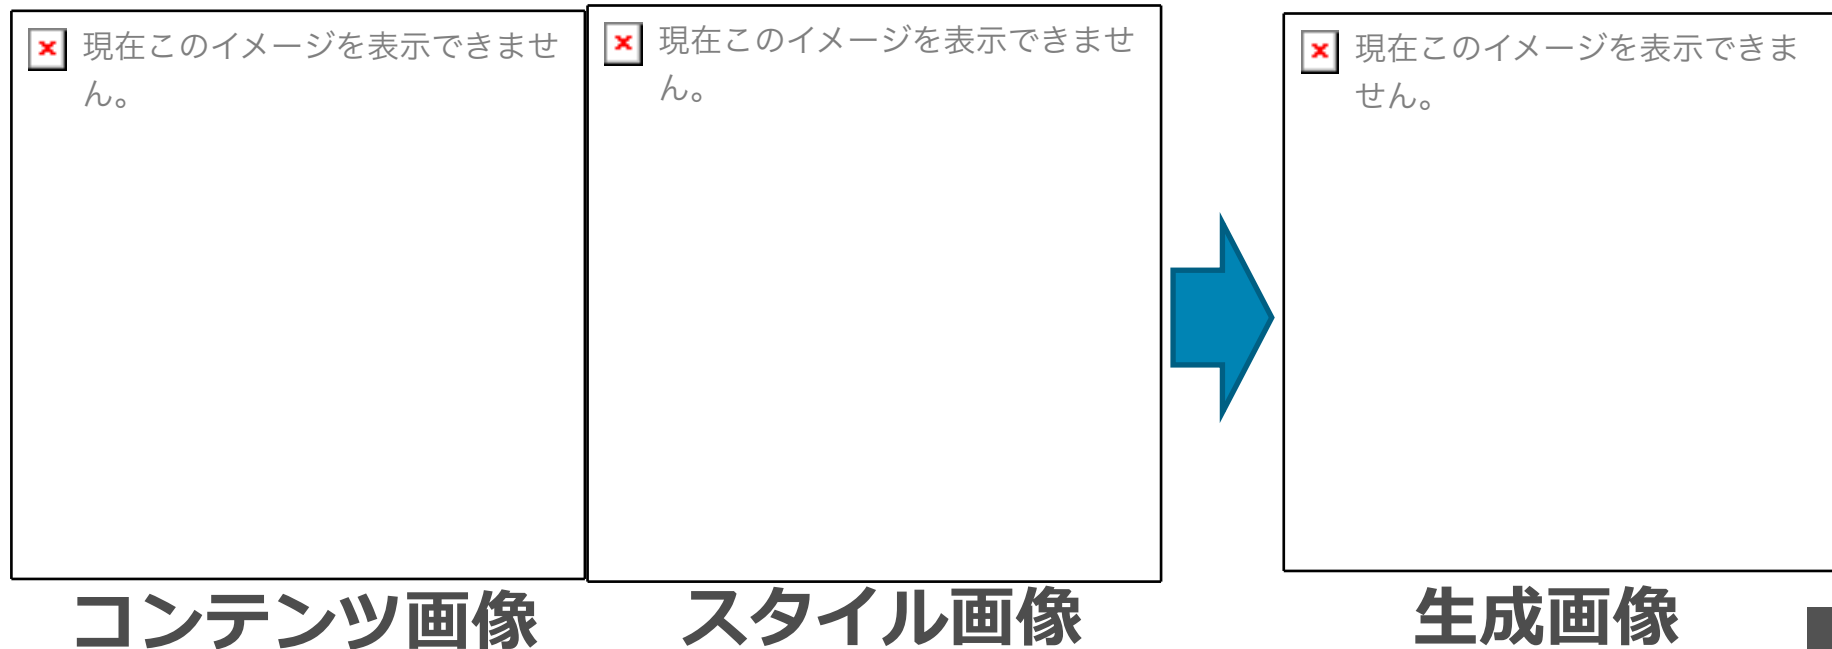
丹野 良介, 柳井 啓司

電気通信大学 大学院情報理工学研究科
情報学専攻



Style Transferとは

- 画風を変換するアルゴリズムのこと(2015年8月に公開)
 - 2枚の画像を入力として, 片方をコンテンツ画像, 片方をスタイル画像とする
 - コンテンツ画像に書かれた物体の配置をそのままにして, 画風をスタイル画像に変換した画像を生成






本研究の目的

「Neural Style Transferをモバイル上に実装」


- 既存手法

- 1つのモデルで1つのスタイル
- 学習に時間を要する
- 消費メモリの増大



- 提案手法

- 1つのモデルで複数のスタイルを変換可能
- モバイル上でのリアルタイム画風変換



関連研究

✖ 現在このイメージを表示できません。

✖ 現在このイメージを表示できません。

- Neural Style Transferを提案 [Gatys+ 2015]
 - 画像の**コンテンツ(形状)**を保持したまま,
スタイル(画風)を変化
 - AIによる**芸術的画像の生成**

✖ 現在このイメージを表示できません。



各レイヤの特徴マップから画像を再構築

conv1 conv2 conv3 conv4 conv5



スタイル画像
再構築


コンテンツ画像
再構築

conv1 conv2 conv3 conv4 conv5




コンテンツ画像の特徴マップ再構築

✖ 現在このイメージを表示できません。



浅いレイヤ

- ・ 正確な元画像の情報を保持



深いレイヤ

- ・ 空間的な位置関係はそのまま
→画像が持つ重要な情報を保持.
- ・ 正確な形などの情報は弱まる



スタイル画像の特徴マップ再構築

浅いレイヤ

- ・ 画像の**細かな**パターン情報を保持

深いレイヤ

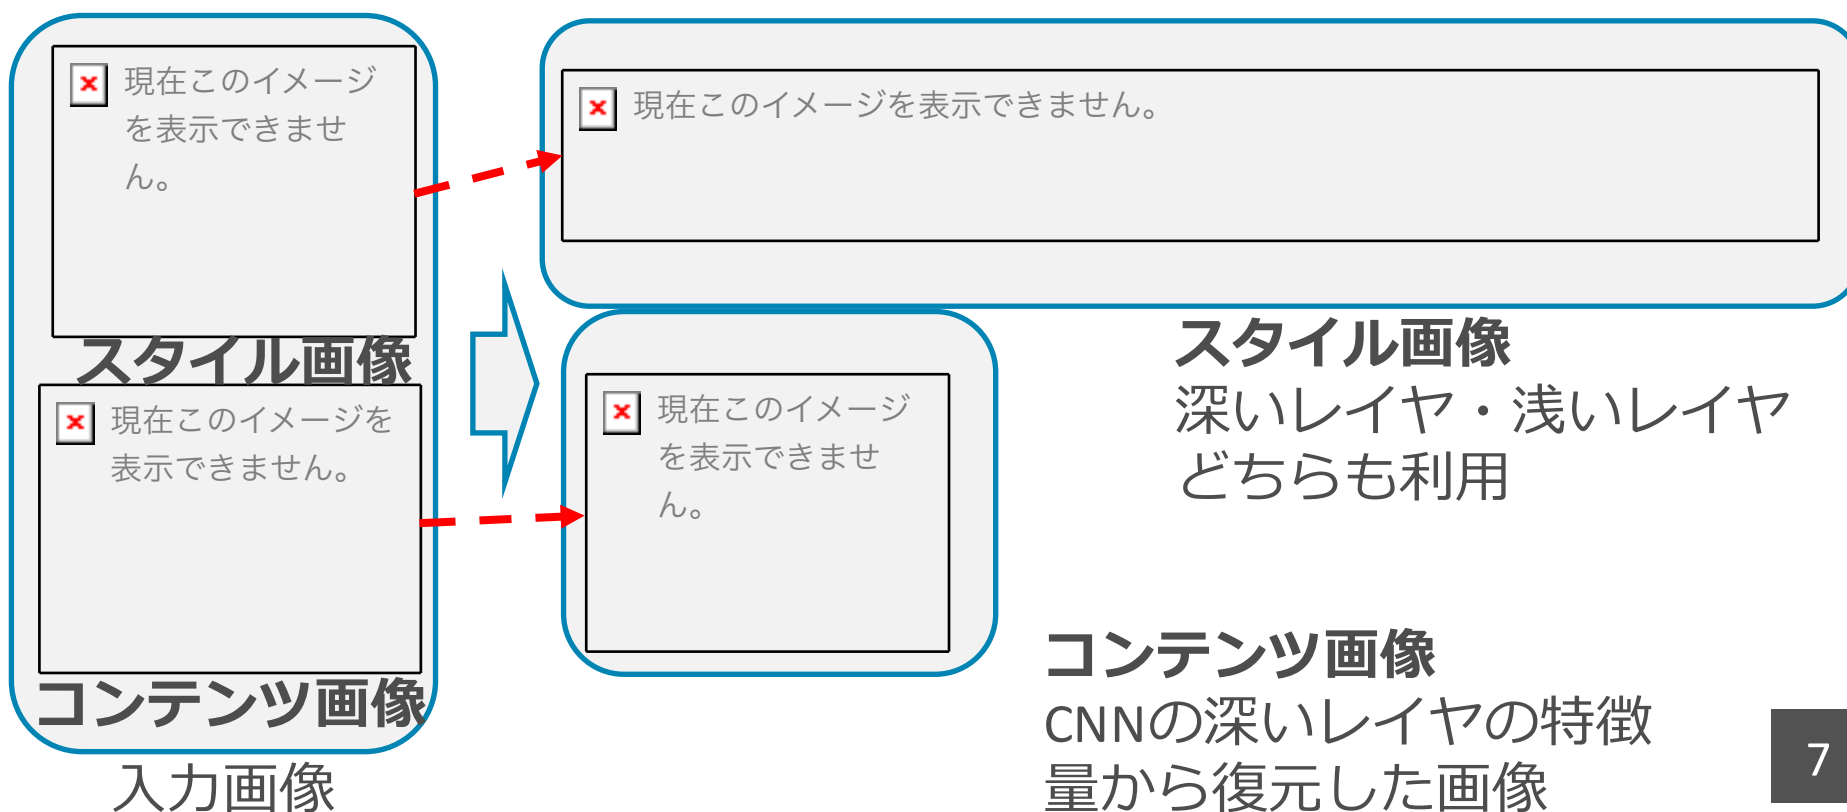
- ・ 画像の**大きめ**の空間パターンを保持






Gatysらの手法のポイント

- 情報が弱まっている部分を，別の画像の画風(スタイル)に変換すれば，コンテンツ画像の形状を保持したまま，別のスタイルに画像を変換できるのでは？





Gatysらの手法まとめ

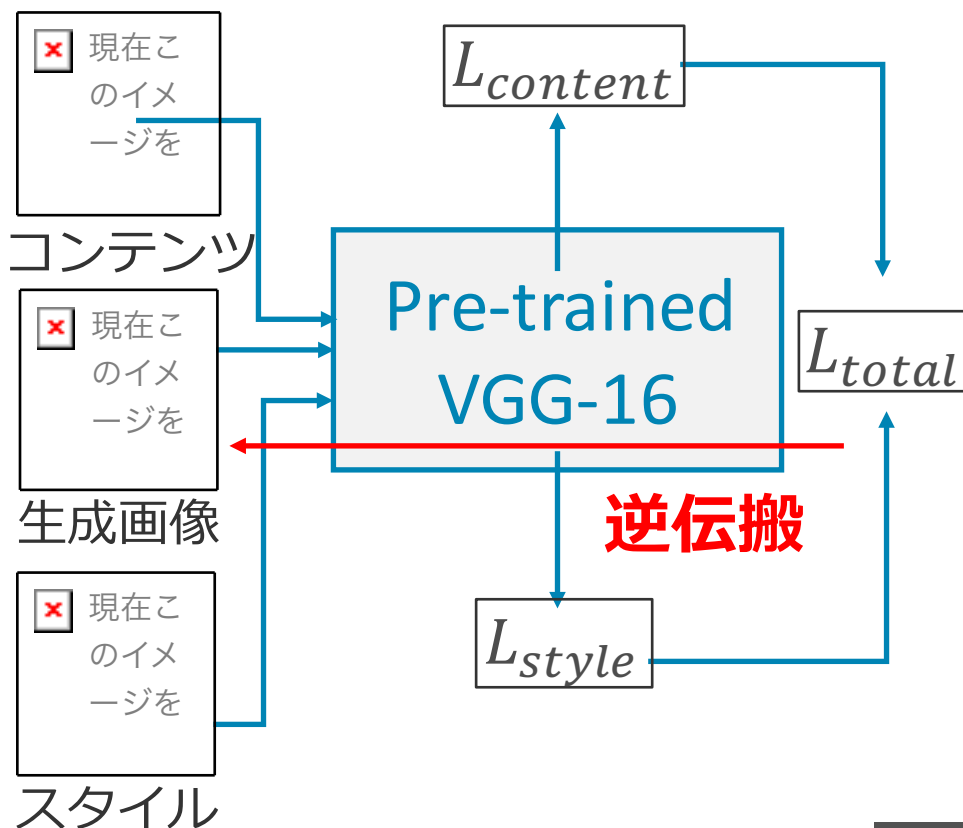


- 損失関数に学習済みCNNを利用
- 生成画像は一様乱数で初期化
- 順伝搬 & 逆伝搬を反復

- **問題点**



- 生成に**時間**がかかる
- GPU利用で**数十秒**程度



$$\operatorname{argmin} L_{total} = \alpha L_{content} + \beta L_{style}$$

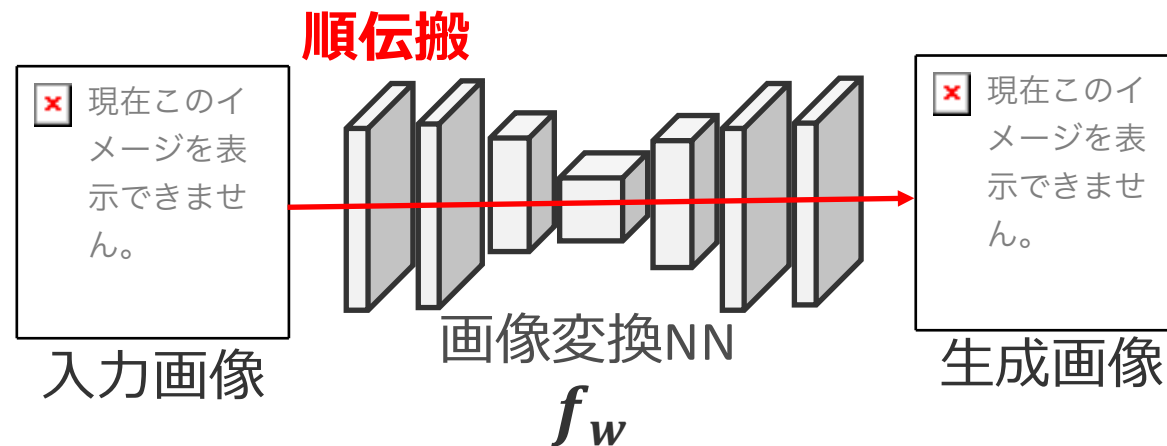


関連研究

✖ 現在このイメージを表示できません。


✖ 現在このイメージを表示できません。

- 順伝搬でスタイル変換できる手法を提案 [Johnson+ 2016]
 - 入力画像のスタイルを変換するNN (f_w) を学習
 - 生成時は順伝搬のみなので高速

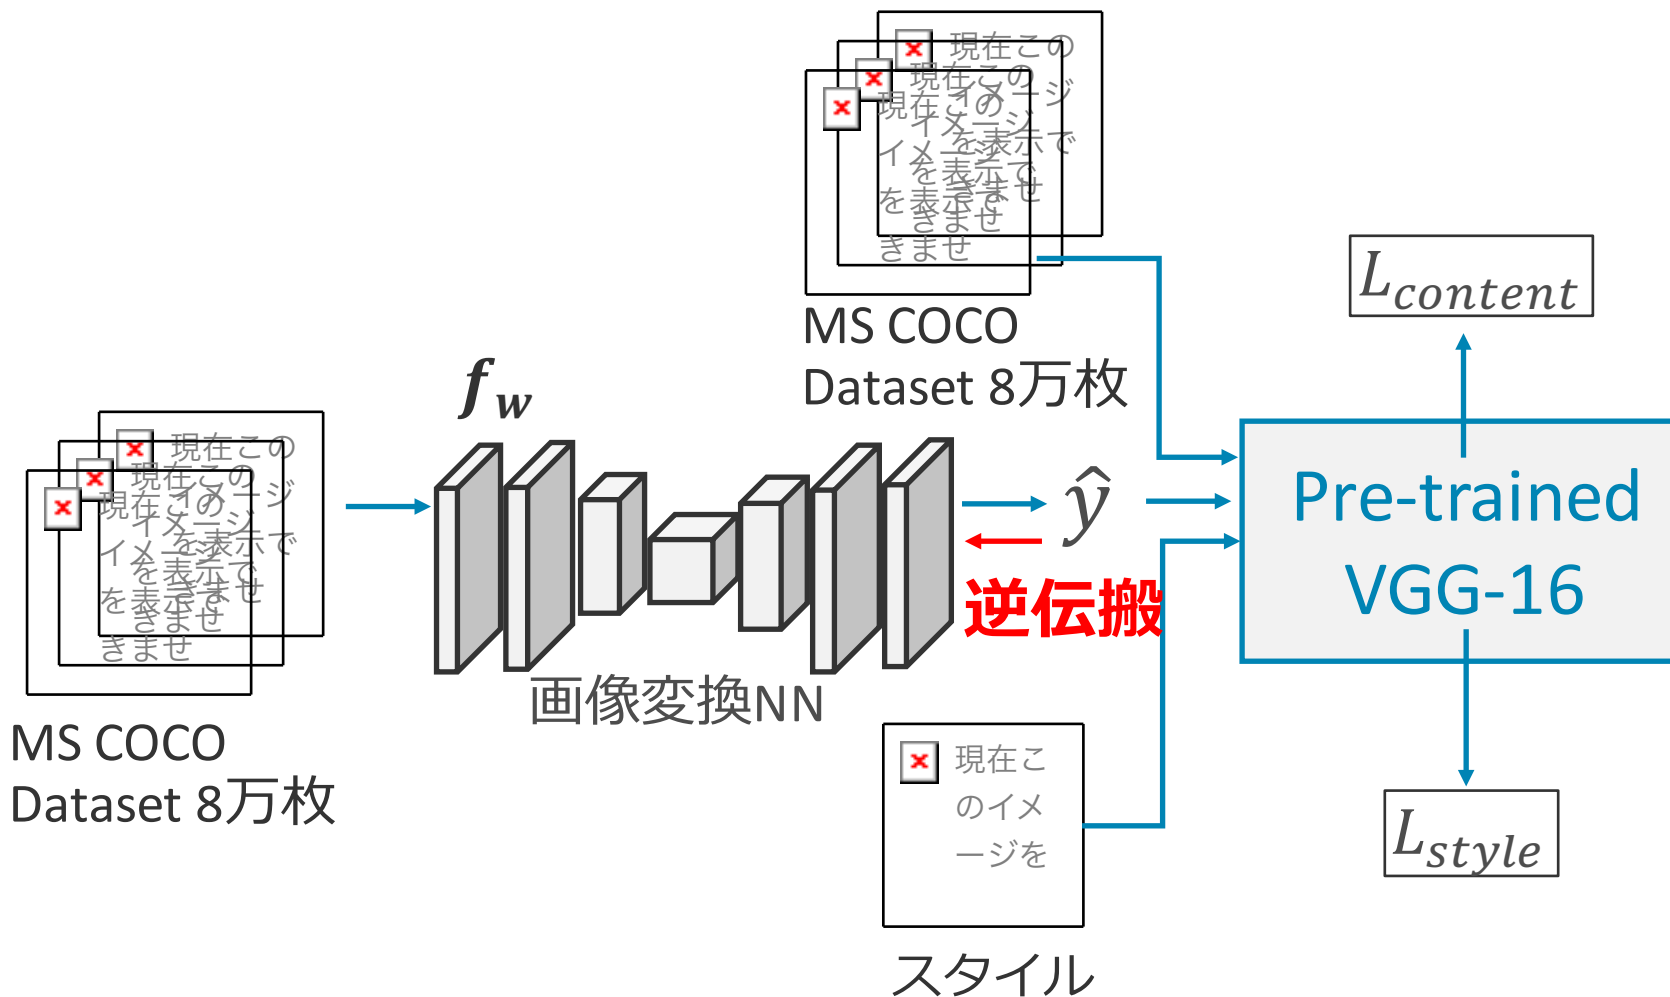




Johnsonらの手法





- MSCOCO 8万枚 + スタイル画像で f_w を学習




$$\operatorname{argmin} \hat{y} = \alpha L_{content} + \beta L_{style} + \text{正則化項}$$



Johnsonらの手法まとめ



- 特定スタイルを変換可能なCNNを学習
- 順伝搬でスタイル変換可能
 - 非常に高速に画像生成可能に



- **問題点**

- **1つのモデルで1つのスタイル**

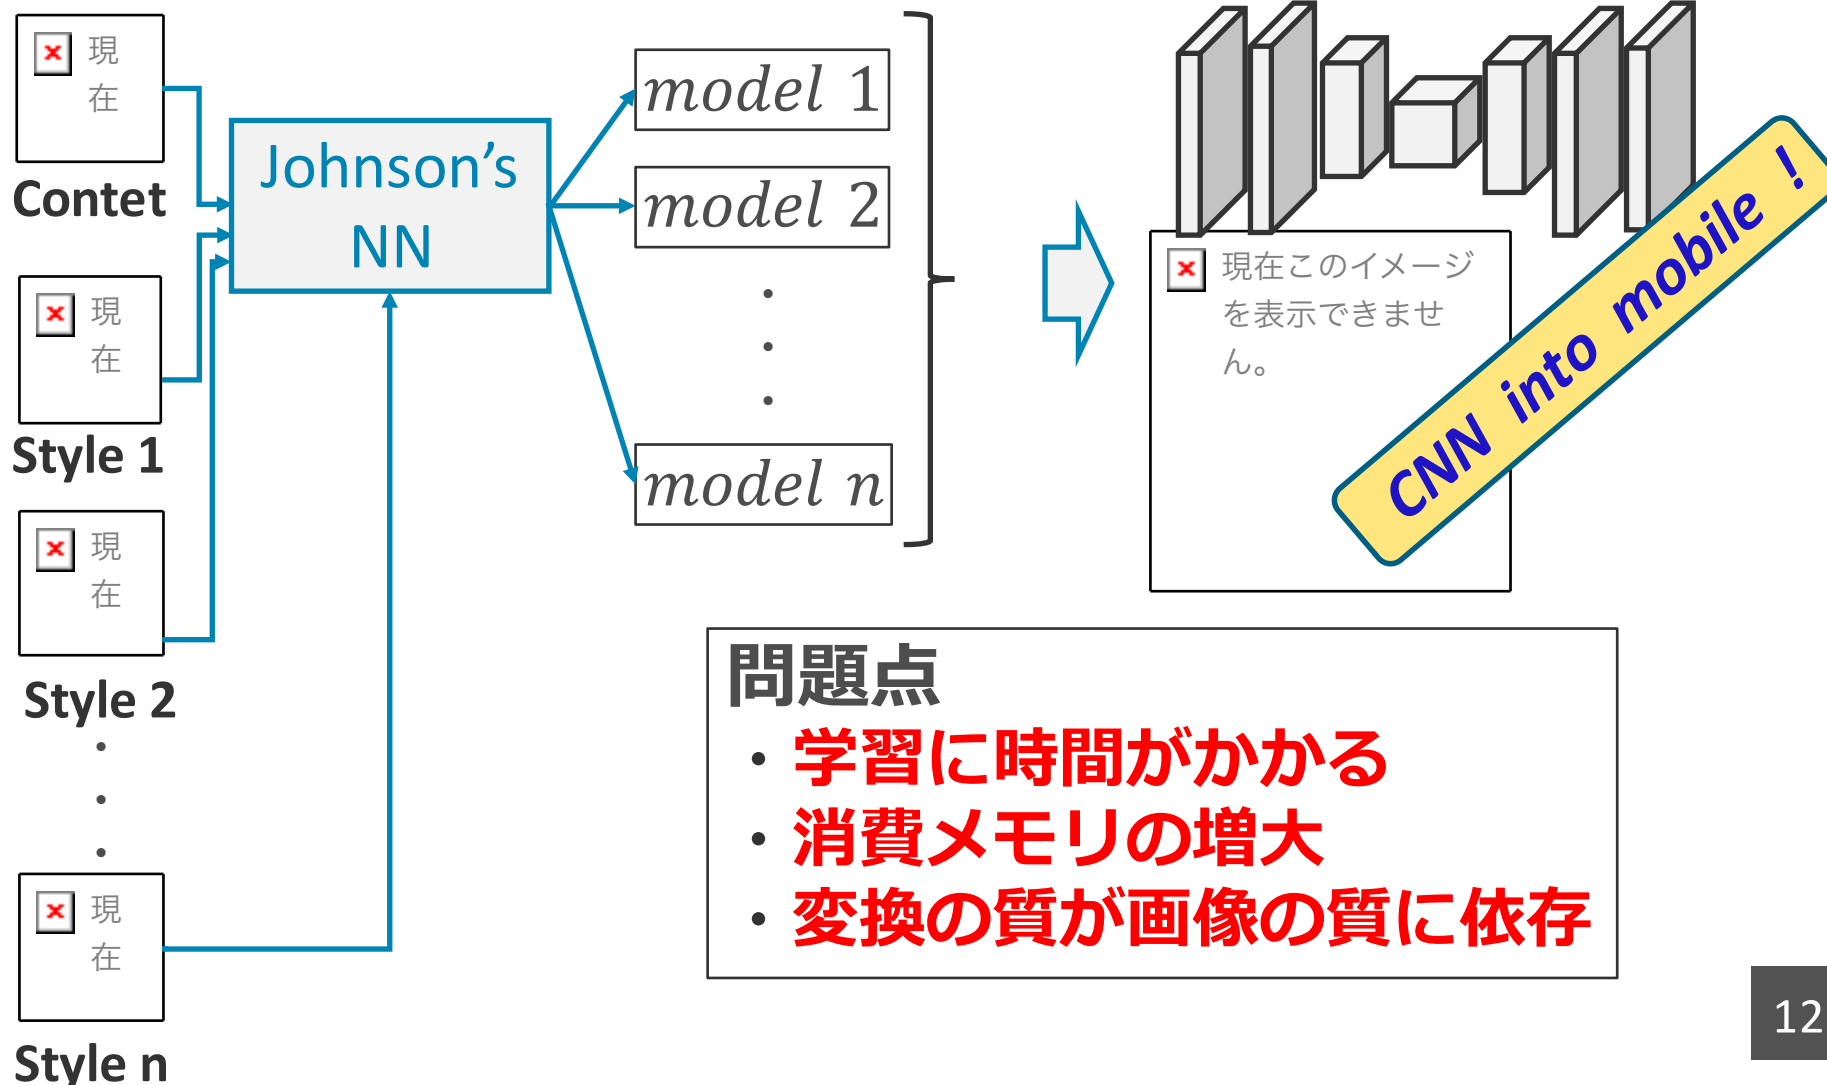


Johnsonらの手法の問題点

✗ 現在このイメージを



✗ 現在このイメージを

● 1つのモデルで1つのスタイル






Johnsonらの手法まとめ(再掲)




- 特定スタイルを変換可能なCNNを学習
- 順伝搬でスタイル変換可能
 - 非常に高速に画像生成可能に



- 問題点


- 1つのモデルで1つのスタイル
- 学習に時間を要する
- 消費メモリの増大




目的

- Johnsonらの手法を拡張し, 1つのモデルで**複数**のスタイルの同時学習を可能に
 - 学習時間の削減
 - 消費メモリの削減

従来手法



提案手法






本研究の貢献

- ① 単一のモデルで複数のスタイルを任意の重みで合成
- ② リアルタイムで合成したスタイルを画像に転送
- ③ モバイルアプリとして実装




提案手法


- ① 複数のスタイルを同時に学習できるように拡張



- ② モバイル実装のためにConvDeconvNetを縮小



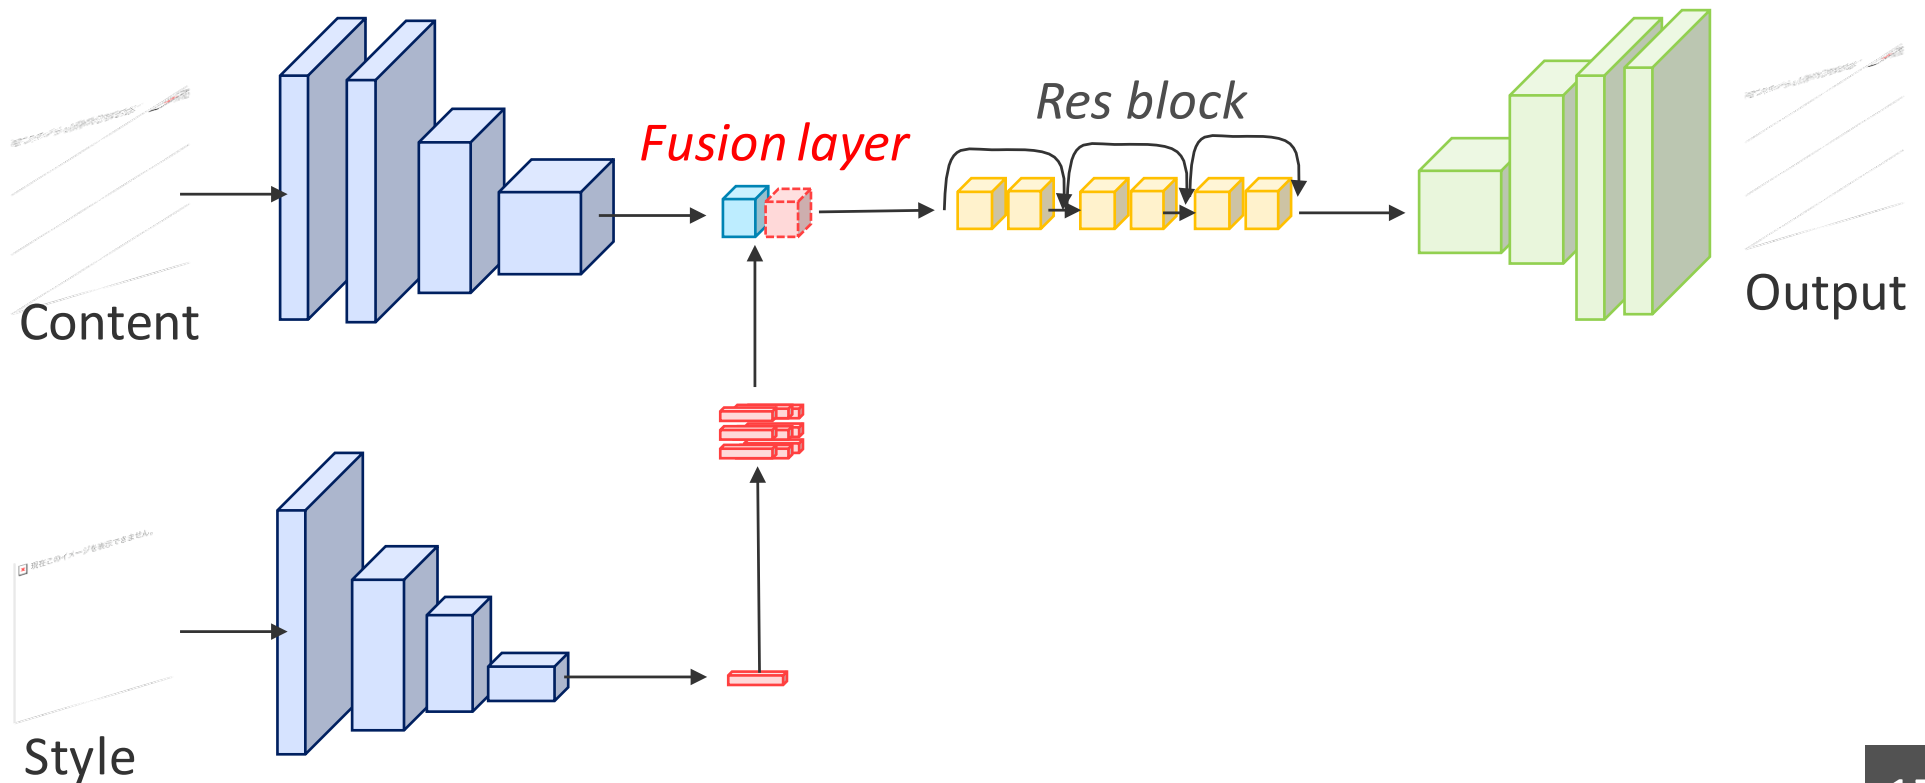
- ③ モバイル上での効率的なCNN実装及び工夫





提案手法①

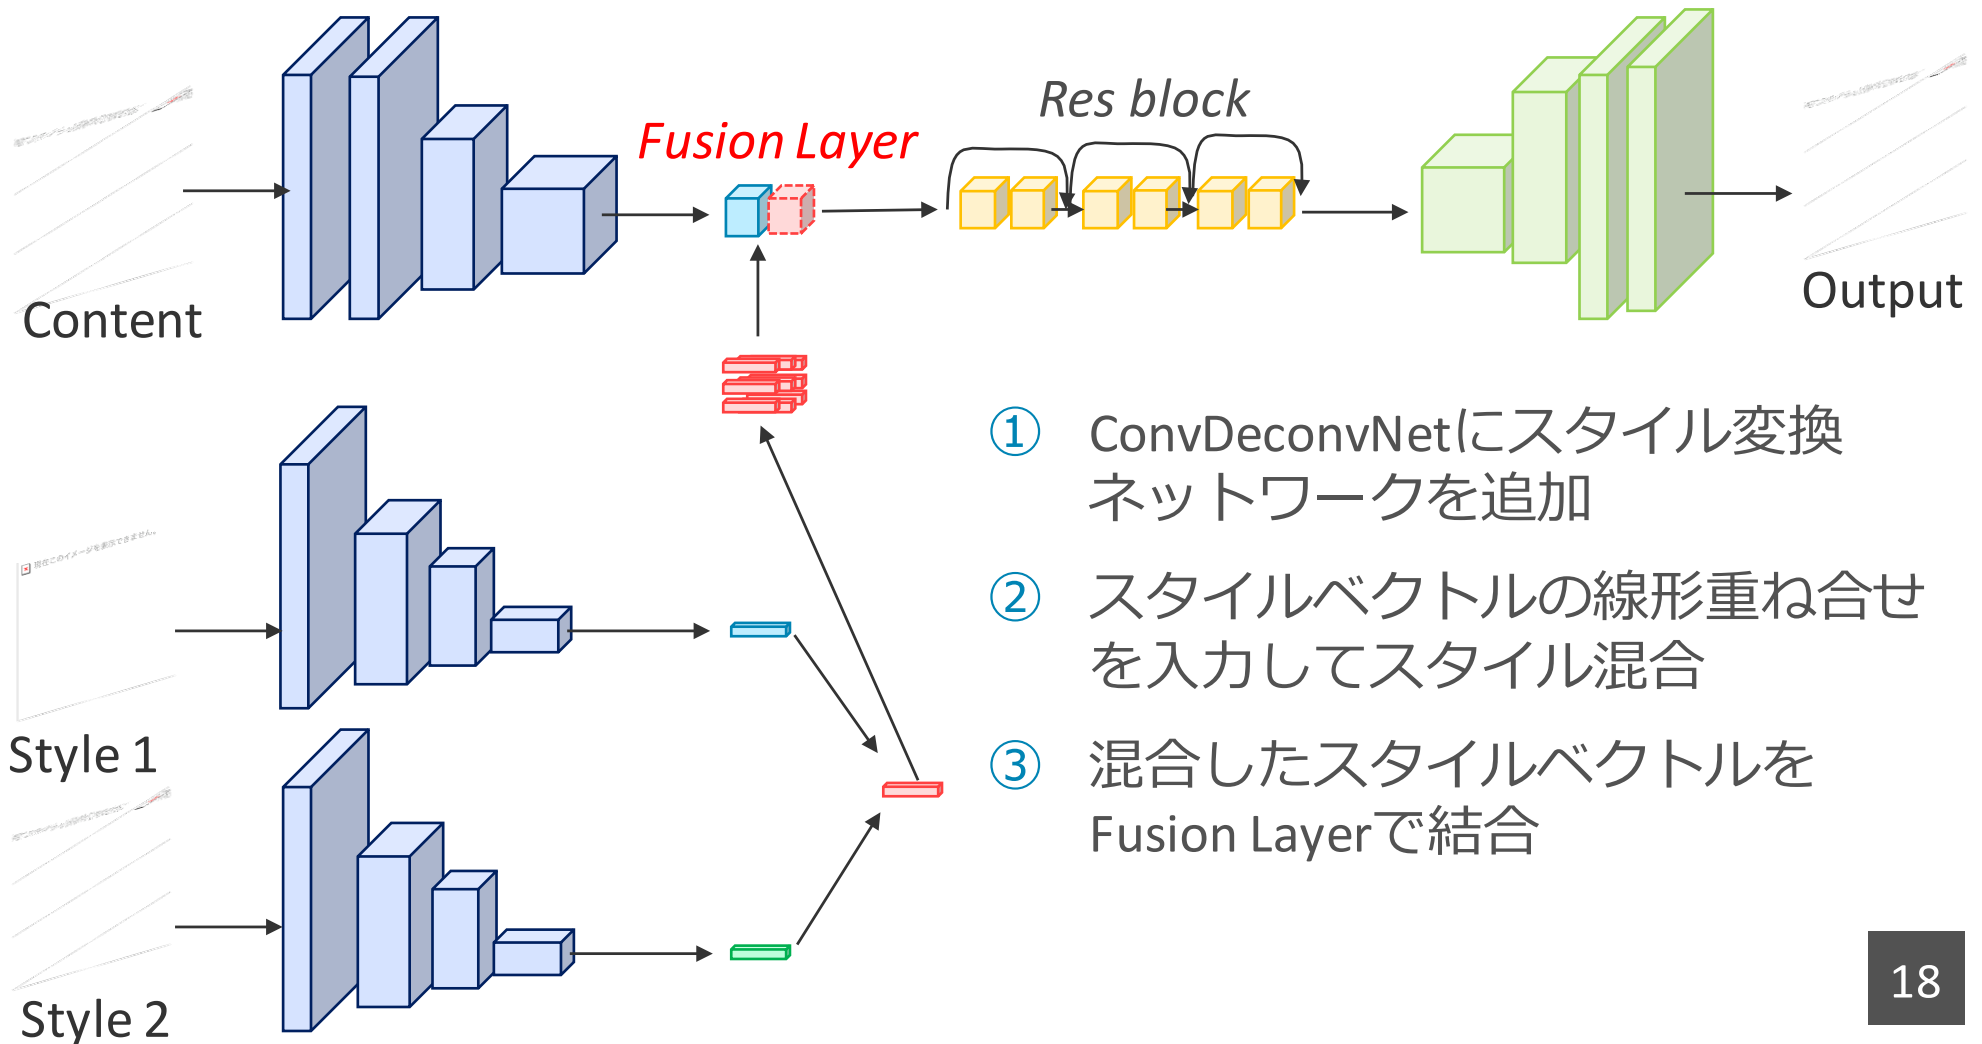
- 複数のスタイルを同時に学習できるように拡張
 - Fusion Layerの追加
 - 複数の任意重みを合成可能



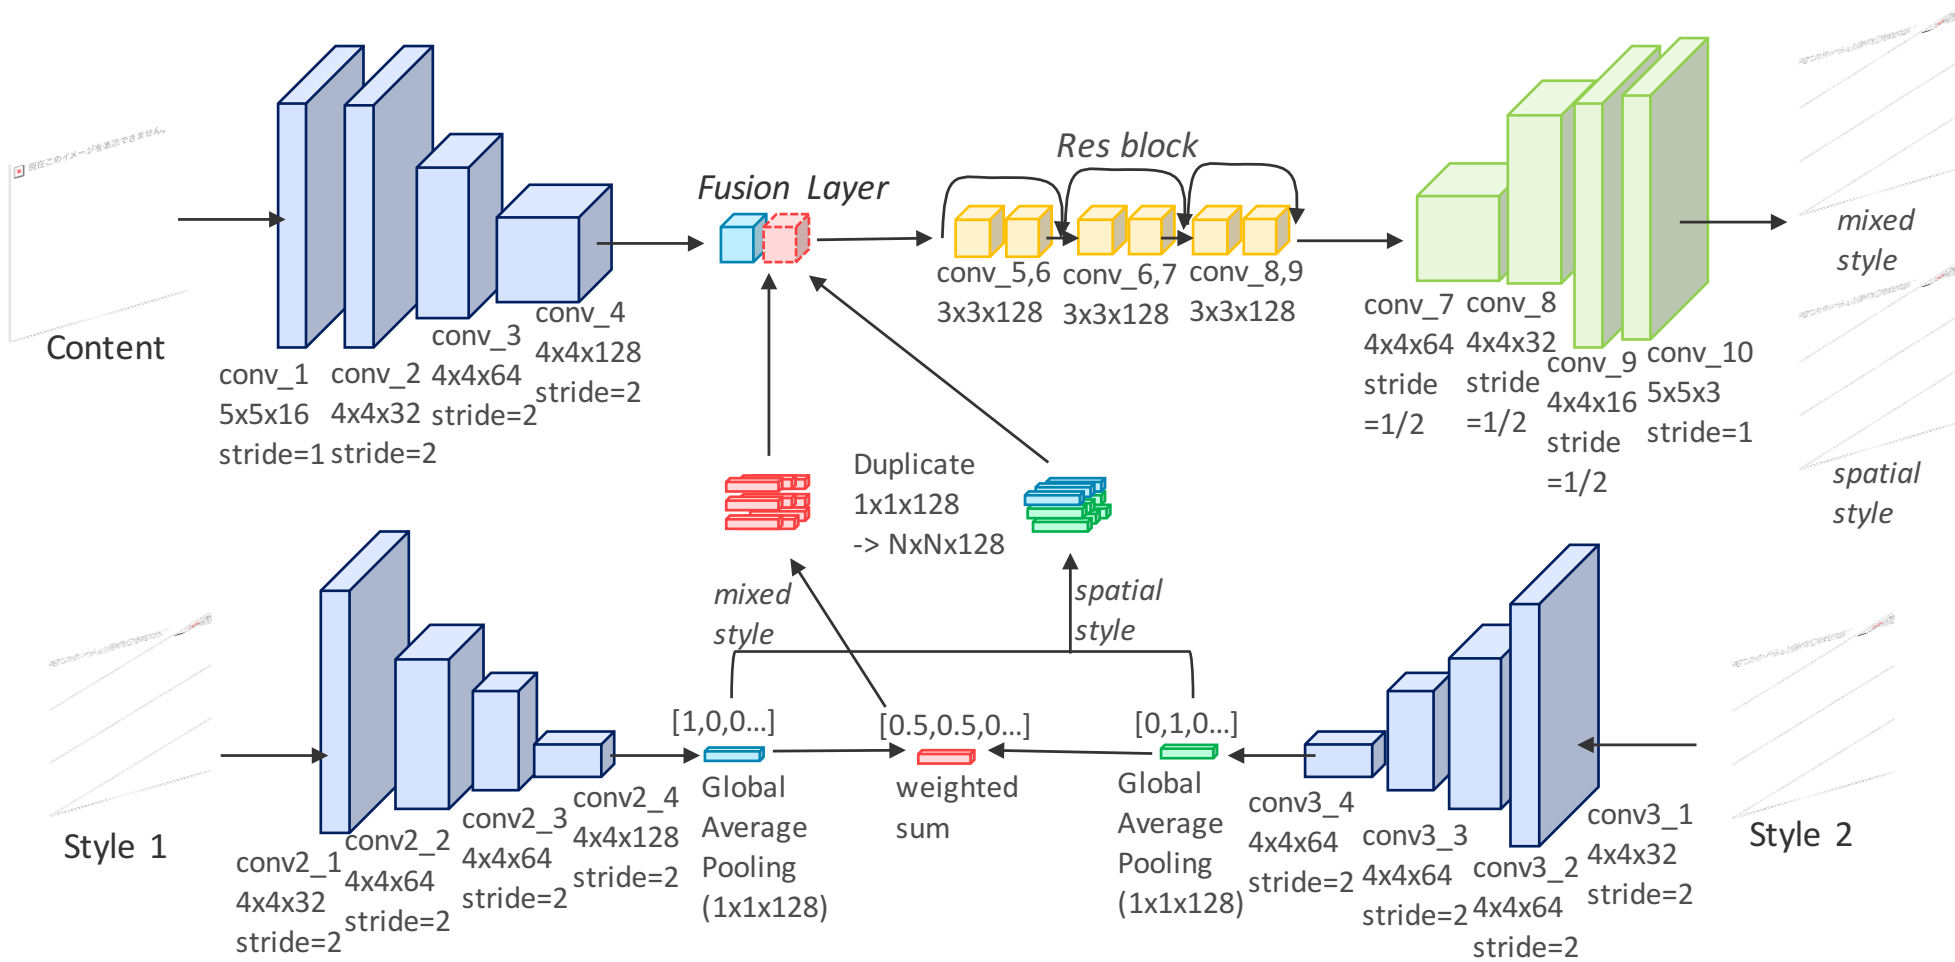


提案手法①

- 複数のスタイルを同時に学習できるように拡張



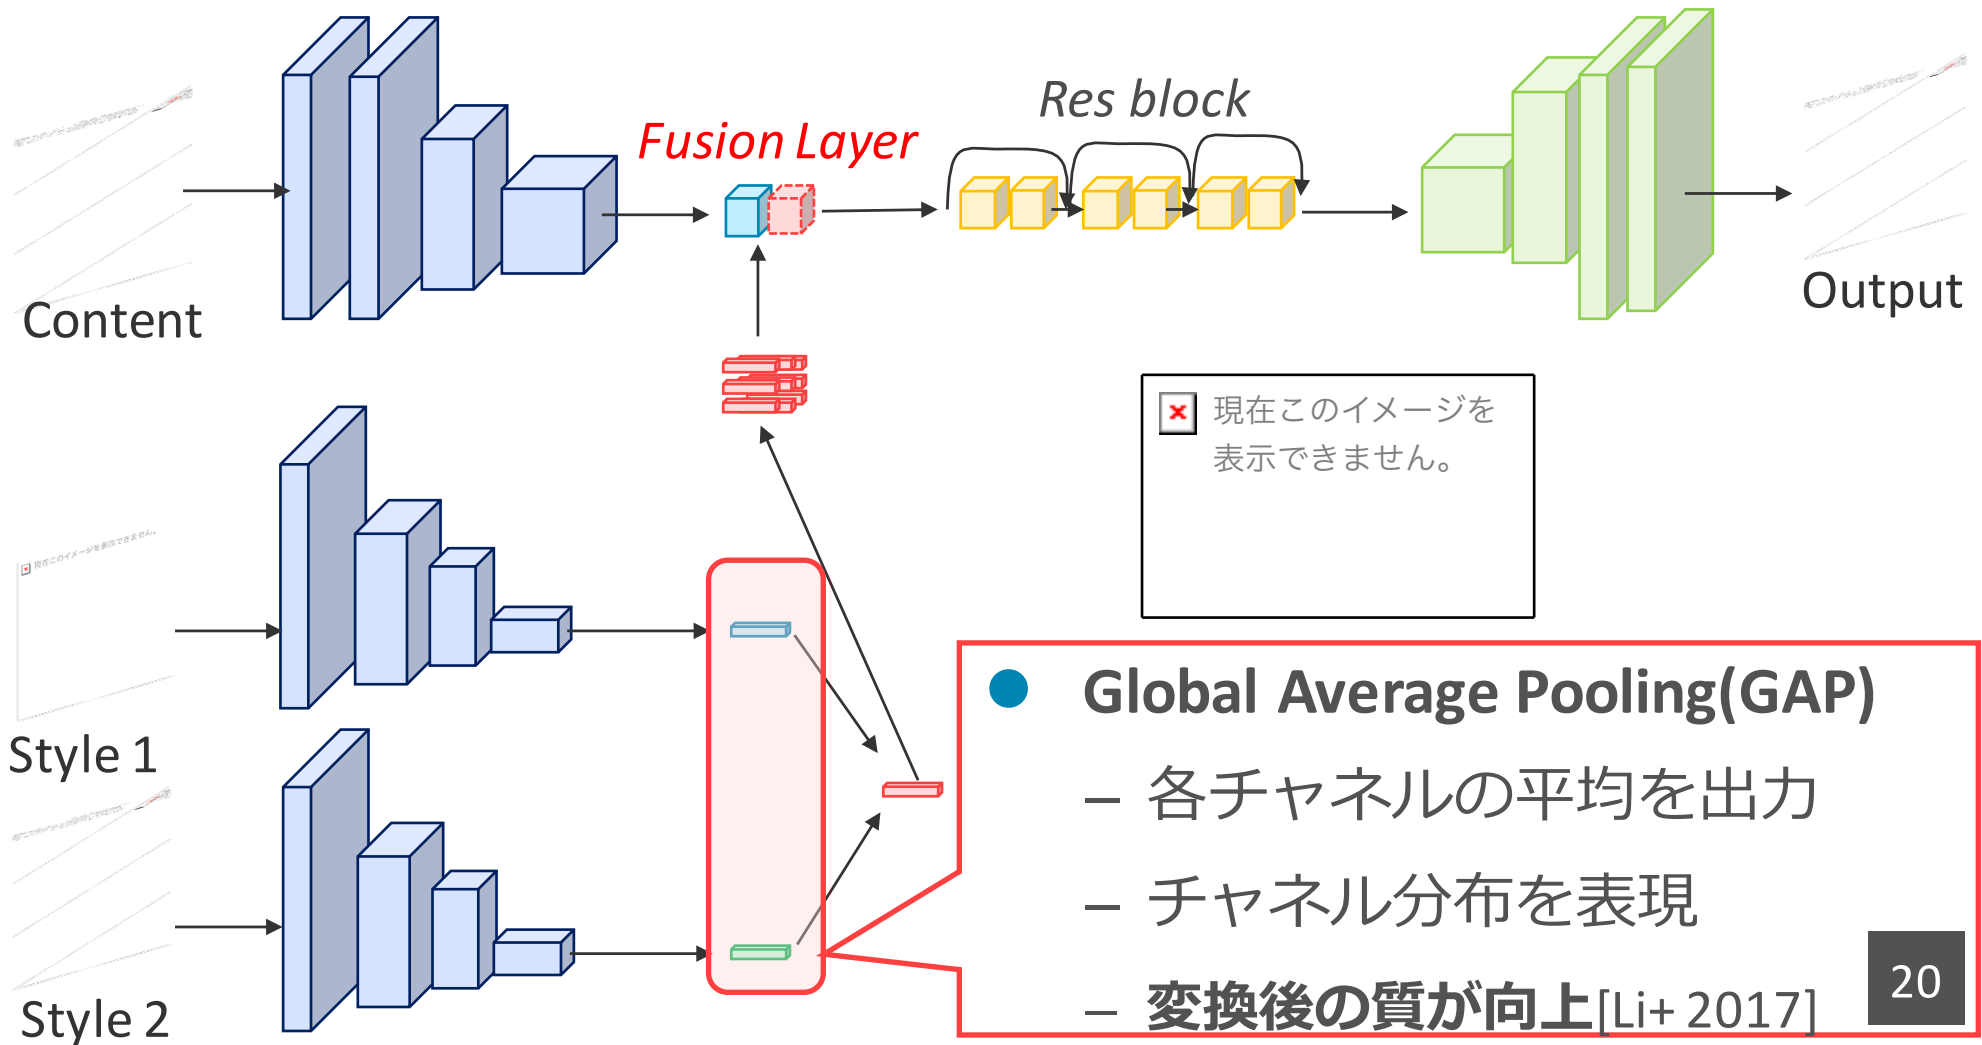
- ① ConvDeconvNetにスタイル変換ネットワークを追加
- ② スタイルベクトルの線形重ね合せを入力してスタイル混合
- ③ 混合したスタイルベクトルをFusion Layerで結合





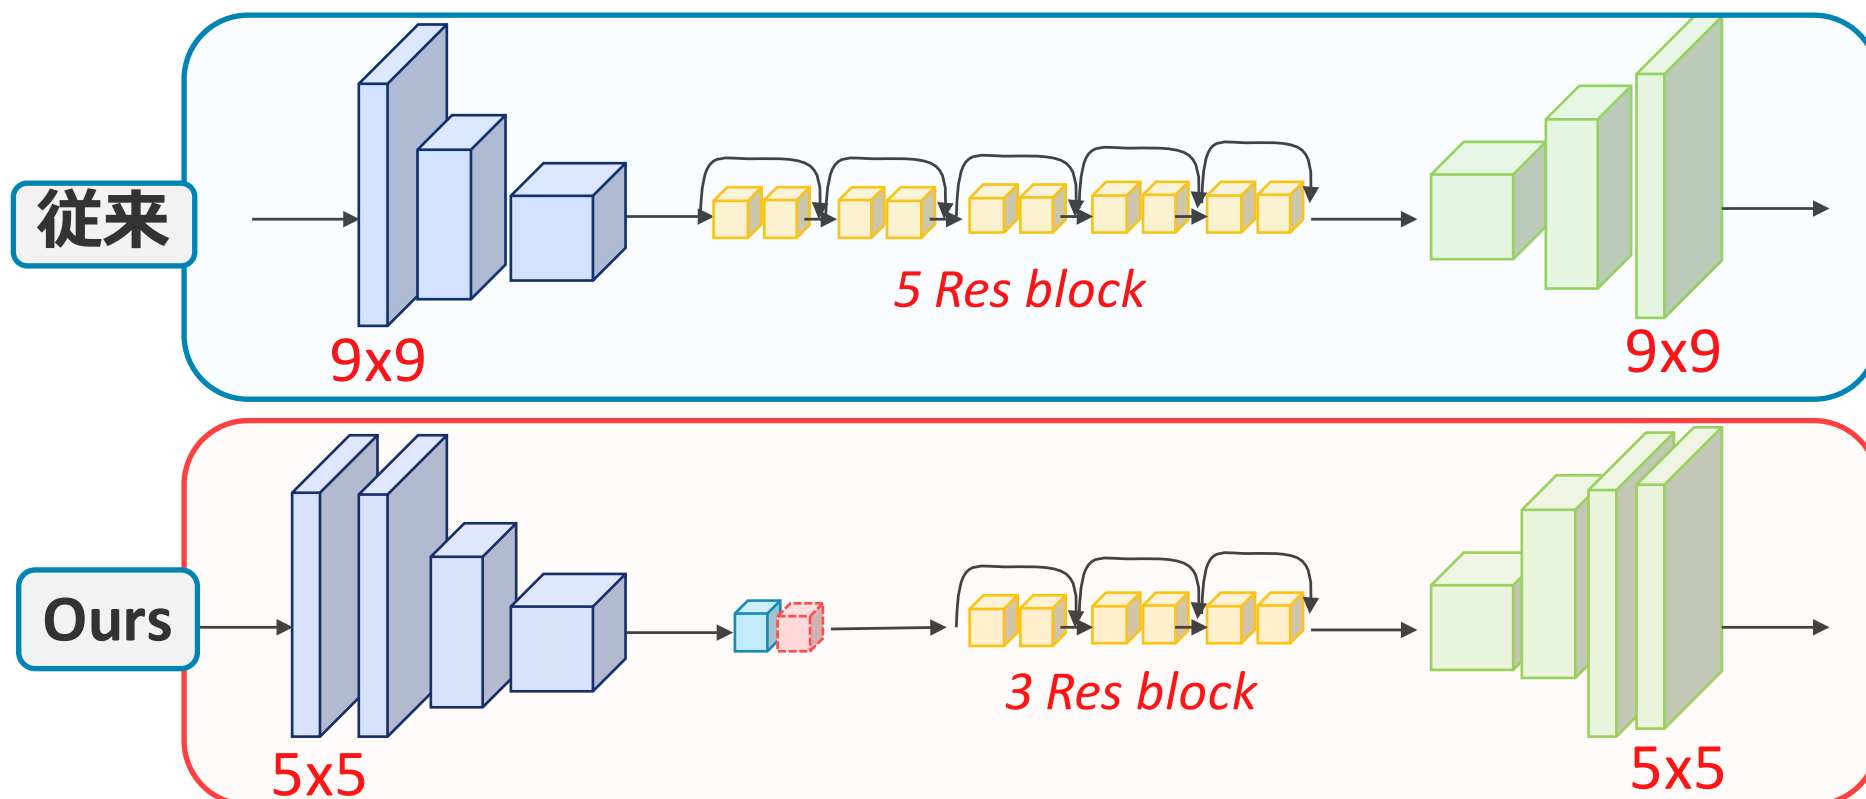
提案手法①

- 複数のスタイルを同時に学習できるように拡張



提案手法②


- モバイル実装のためにConvDeconvNetを縮小
 - 最初と最後のConv Layerのカーネルを $9 \times 9 \rightarrow 5 \times 5$ に変更
 - Residual Elementsを $5 \rightarrow 3$ に変更





提案手法③

- モバイル上での効率的なCNN実装及び工夫




- ① DNNを直接Cコードに変換(コンパイラ的に実行)
- ② Multithread化によるNEON / BLAS の効率的な利用
- ③ CNNに掛かる演算の可能な限りの事前計算の実行
- ④ **Unpooling+Conv -> 1/2 strideを実現**
 - ✓ Deconvolutional layerの代替



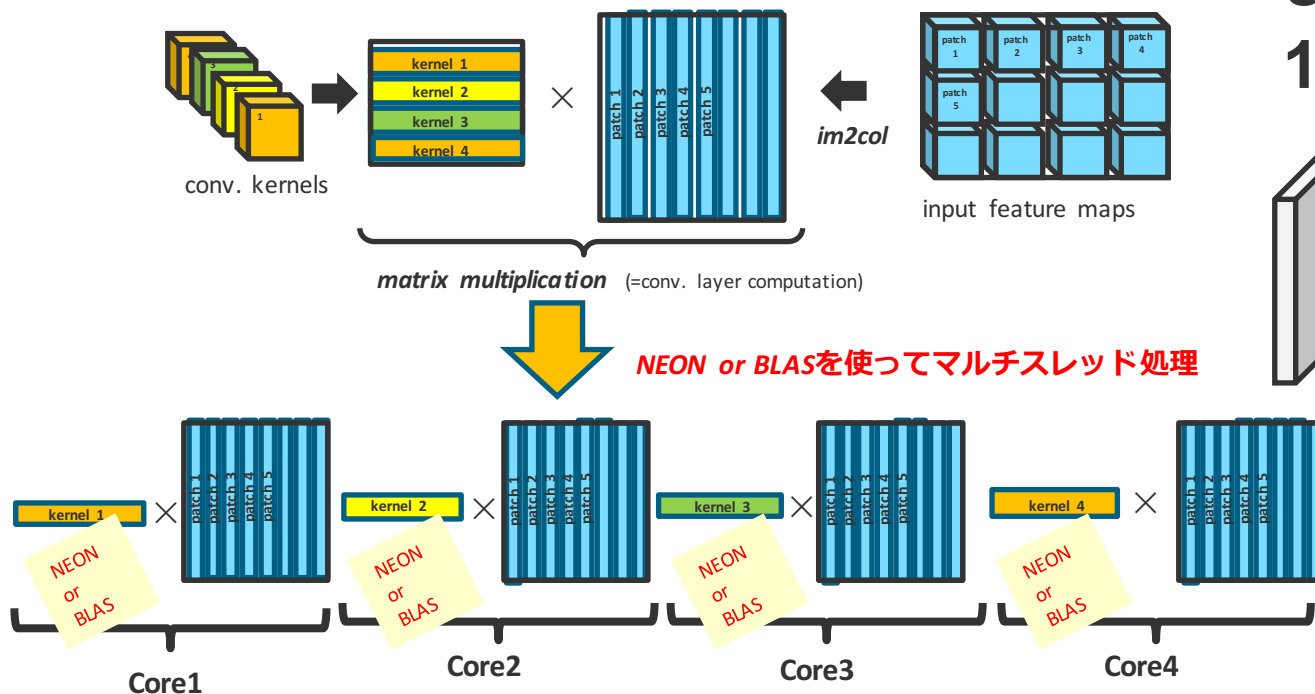

Unpooling + Conv -> 1/2 strideを実現

- Convの逆演算を行うDeconvをConvで表現したい...
 - 高速GEMM演算(BLAS)を利用したい

- **Unpoolingで縦横2倍に拡大 -> Conv**



Unpooling =
1/2 stride Conv





デモ動画

入力: 250x250

演算: 13億回


時間: 175ms(iphone 7+)



✖ 現在このイメージを表示できません。



考察



● 変換ネットワーク

- Res block 3個は過剰？
- skip connectionの追加

● モバイル実装

- 画像の解像度を上げたい -> Conv処理を高速化必須
- 明示的にGPUを利用？


✖ 現在このイメージを表示できません。



まとめ

- 目的
 - 「Neural Style Transferをモバイル上に実装」
- 既存手法
 - 1つのモデルで1つのスタイル
 - 学習に時間を要する
 - 消費メモリの増大
- 提案手法
 - 1つのモデルで複数のスタイルを変換可能
 - モバイル上でのリアルタイム画風変換
- 今後の課題
 - 線画のモバイル上でのリアルタイム着色

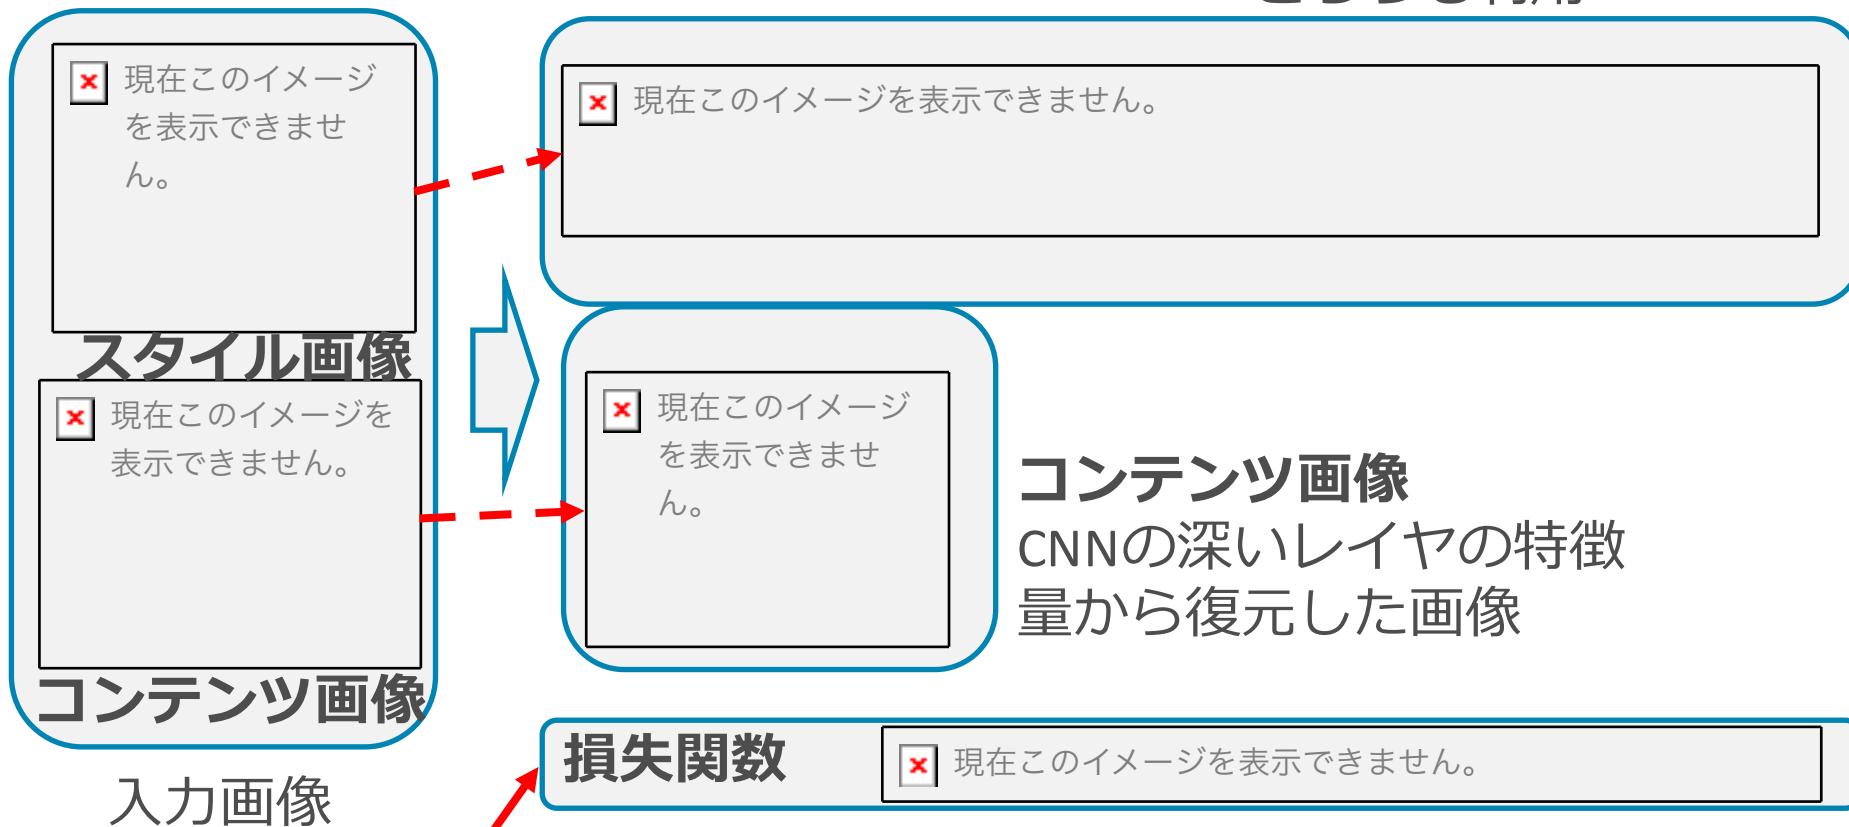
✖ 現在このイメージを表示できません。

 ご清聴ありがとうございました。



損失関数

スタイル画像
深いレイヤ・浅いレイヤ
どちらも利用



コンテンツ画像の外形を保持しつつ、スタイルを変換したい...

コンテンツ画像
CNNの深いレイヤの特徴量から復元した画像

最小化