

# Réseaux de Neurones Légers Multi-Echelle pour la restauration stylisée et contrôlée d'images - journée normastic - 8 avril 2022

---

{**Thibault.Durand**, Julien.Rabin & David.Tschumperlé} @unicaen.fr

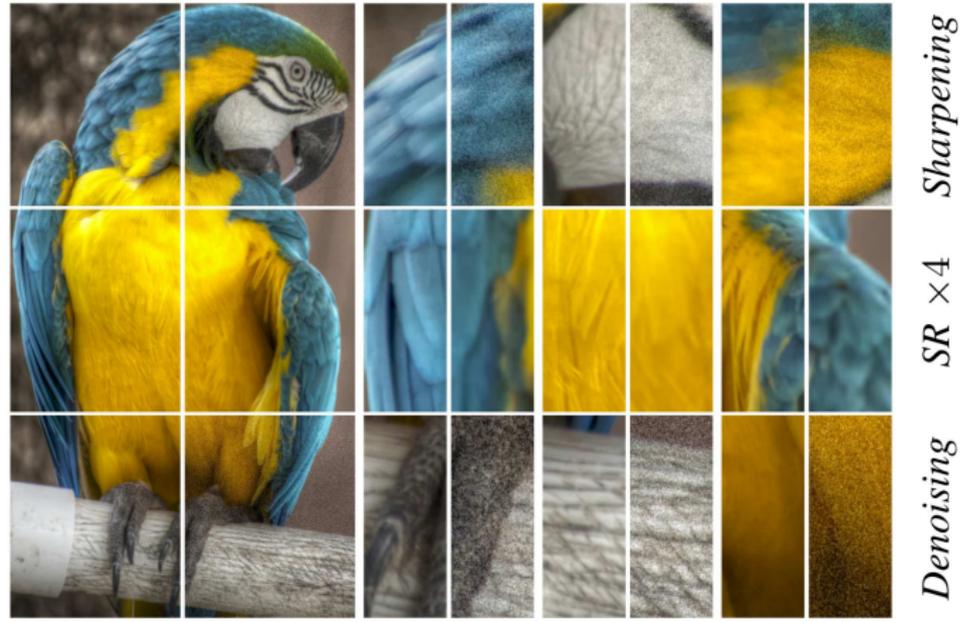
-

Normandie Université  
Equipe Image  
GREYC UMR 6072  
14000 Caen, France



- Formalisme
- Exemple: Super-Résolution(SR)
- Motivations
- Contributions
  - Présentation
  - Architecture
  - Etape1: Restauration
  - Etape2: Stylisation
- Application, exemple multi-textures
- Conclusion

## Image Before & After Degradation



Before / After

Enlarged Details (B /A)

- $X$  (resp.  $x$ )  $\in \mathbb{R}^{K \times N \times N \times 3}$  est un tenseur de  $K$  patches originaux (resp. patches dégradés) de taille  $N \times N$

- $X$  (resp.  $x$ )  $\in \mathbb{R}^{K \times N \times N \times 3}$  est un tenseur de  $K$  patches originaux (resp. patches dégradés) de taille  $N \times N$
- $x_k \in \mathbb{R}^{N \times N \times 3}$  et  $X_k \in \mathbb{R}^{N \times N \times 3}$  sont des éléments de  $X$  et  $x$ .

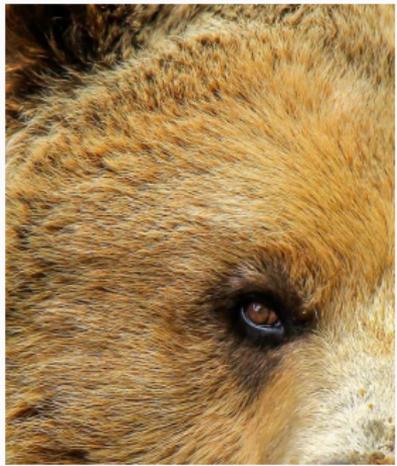
- $X$  (resp.  $x$ )  $\in \mathbb{R}^{K \times N \times N \times 3}$  est un tenseur de  $K$  patches originaux (resp. patches dégradés) de taille  $N \times N$
- $x_k \in \mathbb{R}^{N \times N \times 3}$  et  $X_k \in \mathbb{R}^{N \times N \times 3}$  sont des éléments de  $X$  et  $x$ .
- $D$  est l'opérateur de dégradation tel que  $D(X) = x$ .

- $X$  (resp.  $x$ )  $\in \mathbb{R}^{K \times N \times N \times 3}$  est un tenseur de  $K$  patches originaux (resp. patches dégradés) de taille  $N \times N$
- $x_k \in \mathbb{R}^{N \times N \times 3}$  et  $X_k \in \mathbb{R}^{N \times N \times 3}$  sont des éléments de  $X$  et  $x$ .
- $D$  est l'opérateur de dégradation tel que  $D(X) = x$ .
- $\hat{X}$  correspond à la prédiction du réseau à partir de  $x$

- $X$  (resp.  $x$ )  $\in \mathbb{R}^{K \times N \times N \times 3}$  est un tenseur de  $K$  patches originaux (resp. patches dégradés) de taille  $N \times N$
- $x_k \in \mathbb{R}^{N \times N \times 3}$  et  $X_k \in \mathbb{R}^{N \times N \times 3}$  sont des éléments de  $X$  et  $x$ .
- $D$  est l'opérateur de dégradation tel que  $D(X) = x$ .
- $\hat{X}$  correspond à la prédiction du réseau à partir de  $x$

→ Quel est l'objectif de la restauration ? Est ce de retrouver  $X$  à partir de  $x$ ?

- Formalisme
- Exemple: Super-Résolution (SR)
- Motivations
- Contributions
  - Présentation
  - Architecture
  - Etape1: Restauration
  - Etape2: Stylisation
- Application, exemple multi-textures
- Conclusion



$X_k$



$X_k$



Premiers réseaux convolutionnels

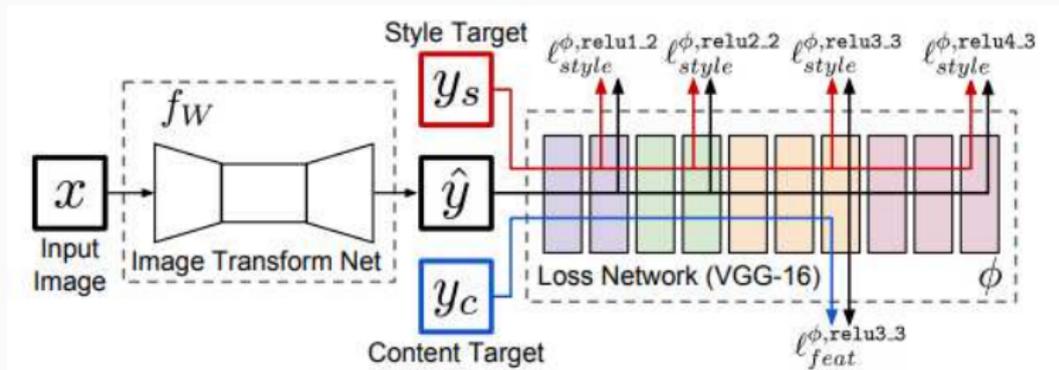
SRCNN<sup>1</sup>

( entre  $\sim 100k$  et  $\sim 400k$  paramètres )

$$\mathcal{L}_{\text{MSE}}(X, \hat{X}) = \frac{1}{K} \sum_{k=1}^K \|X_k - \hat{X}_k\|^2$$

---

<sup>1</sup>Chao Dong et al. (2014). "Learning a Deep Convolutional Network for Image Super-Resolution". In: *Computer Vision – ECCV 2014*. Ed. by David Fleet et al. Cham: Springer International Publishing, pp. 184–199. ISBN: 978-3-319-10593-2.



**Figure 1:** Fonctionnement du réseau VGG-16 pour l'extraction de caractéristiques profondes et abstraites, dites 'de style'. Source de la figure : <sup>1</sup>.

<sup>1</sup>Justin Johnson, Alexandre Alahi, and Li Fei-Fei (Oct. 2016). "Perceptual Losses for Real-Time Style Transfer and Super-Resolution". In: vol. 9906, pp. 694–711. ISBN: 978-3-319-46474-9. DOI: 10.1007/978-3-319-46475-6\_43

EDSR<sup>2</sup>

(~1500K paramètres)

$$\mathcal{L}_{\text{MSE}}(X, \hat{X}) = \frac{1}{K} \sum_{k=1}^K \|X_k - \hat{X}_k\|^2$$

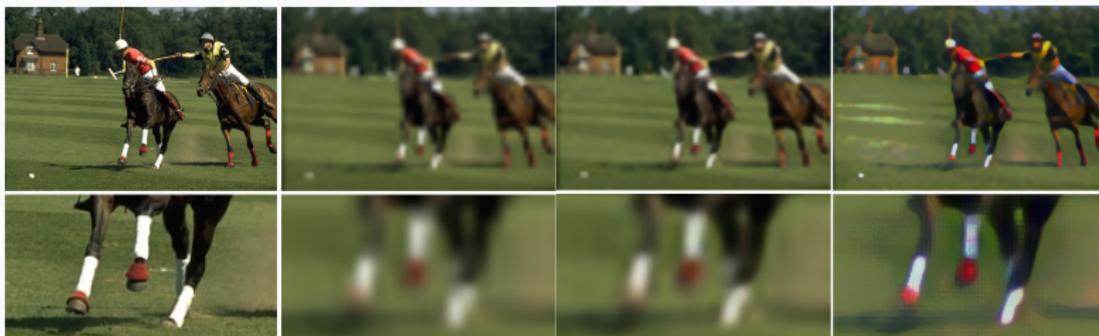
$$\mathcal{L}_{\text{Perc}}(X, \hat{X}) =$$

$$\frac{1}{K} \sum_{\ell \in L_{\text{Perc}}} \|\phi_{\ell}(X) - \phi_{\ell}(\hat{X})\|^2$$

où  $\phi_{\ell}(\cdot)$  correspond aux réponses normalisées de la  $\ell$ -ième couche d'un classifieur préentraîné

---

<sup>2</sup>Bee Lim et al. (2017). "Enhanced Deep Residual Networks for Single Image Super-Resolution". In: *2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pp. 1132–1140. DOI: 10.1109/CVPRW.2017.151.



$X_k$	$x_k$	$\hat{X}^3$	$\hat{X}^4$
<i>PSNR / SSIM</i>	22.75 / 0.5946	23.42 / 0.6168	21.90 / 0.6083

**Figure 2:** Illustration, dans le cadre du problème de Super-Résolution, de non corrélation entre le PSNR et l'évaluation subjective. Source : <sup>4</sup>

<sup>3</sup>Chao Dong et al. (2014). "Learning a Deep Convolutional Network for Image Super-Resolution". In: *Computer Vision – ECCV 2014*. Ed. by David Fleet et al. Cham: Springer International Publishing, pp. 184–199. ISBN: 978-3-319-10593-2.

<sup>4</sup>Justin Johnson, Alexandre Alahi, and Li Fei-Fei (Oct. 2016). "Perceptual Losses for Real-Time Style Transfer and Super-Resolution". In: vol. 9906, pp. 694–711. ISBN: 978-3-319-46474-9. DOI: 10.1007/978-3-319-46475-6\_43.



ESRGAN<sup>5</sup>  
(~1500K paramètres)

Pénalités adverses ;  
réseaux antagonistes

---

<sup>5</sup>Xintao Wang et al. (Sept. 2018). *ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks*.

Formalisme

Exemple: Super-  
Résolution(SR)

## Motivations

### Contributions

Présentation

Architecture

Etape1: Restauration

Etape2: Stylisation

### Application,

exemple

multi-textures

### Conclusion

- Le problème de SR est un problème double. La restauration des structures, des contours, mais aussi la restauration des textures.  
→ *Nous choisissons de résoudre le problème en deux temps*

Formalisme

Exemple: Super-  
Résolution(SR)

## Motivations

### Contributions

Présentation

Architecture

Etape1: Restauration

Etape2: Stylisation

### Application,

exemple

multi-textures

### Conclusion

- Le problème de SR est un problème double. La restauration des structures, des contours, mais aussi la restauration des textures.  
→ *Nous choisissons de résoudre le problème en deux temps*
- Les méthodes proposées sont souvent de plus en plus lourdes en nombre de paramètres.  
→ *Nous nous limitons à des réseaux légers ~ Mo*

Formalisme

Exemple: Super-  
Résolution(SR)

## Motivations

### Contributions

Présentation

Architecture

Etape1: Restauration

Etape2: Stylisation

### Application,

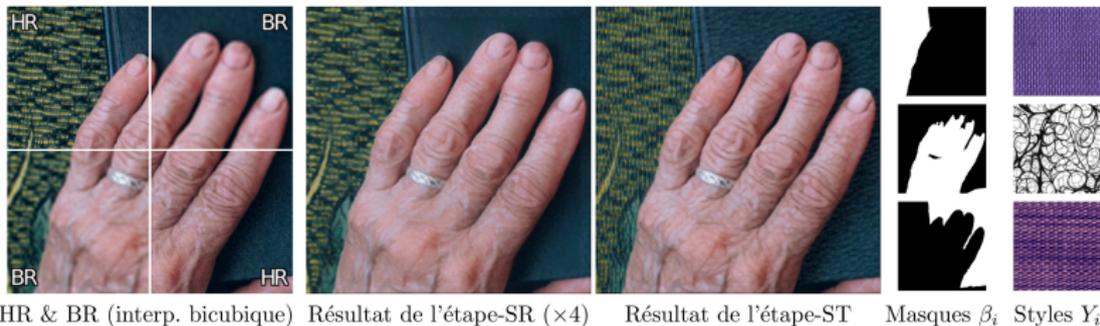
exemple

multi-textures

### Conclusion

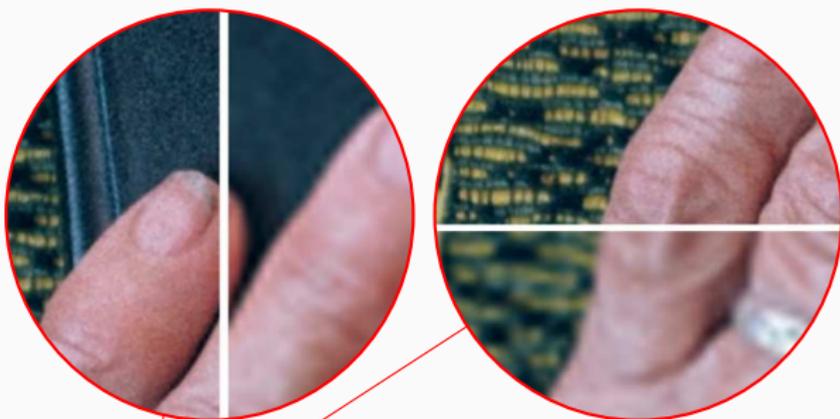
- Le problème de SR est un problème double. La restauration des structures, des contours, mais aussi la restauration des textures.  
→ *Nous choisissons de résoudre le problème en deux temps*
- Les méthodes proposées sont souvent de plus en plus lourdes en nombre de paramètres.  
→ *Nous nous limitons à des réseaux légers ~ Mo*
- Le problème de SR n'est, à priori, jamais envisagé comme un problème inverse mal posé, c'est à dire comme un problème où la solution peut (doit?) dépendre de contraintes en entrée, et où plusieurs solutions sont possibles.  
→ *Nous proposons du contrôle à l'utilisateur quant au choix des textures à insérer*

## Réseaux de neurones légers pour la restauration stylisée d'images (Ici, Super-Résolution Stylisée)



Une approche en **deux étapes** :

- Etape de Restauration (ici, étape-SR) ( $\sim 200k$  paramètres ; ordre de grandeur  $xMo$ ).  
Utilisation d'un réseau **multi-échelle** pour une bonne **reconstruction des contours, de la géométrie, sans contrôle.**



HR & BR



HR & BR (interp. bicubique)

Résultat de l'étape-SR ( $\times 4$ )

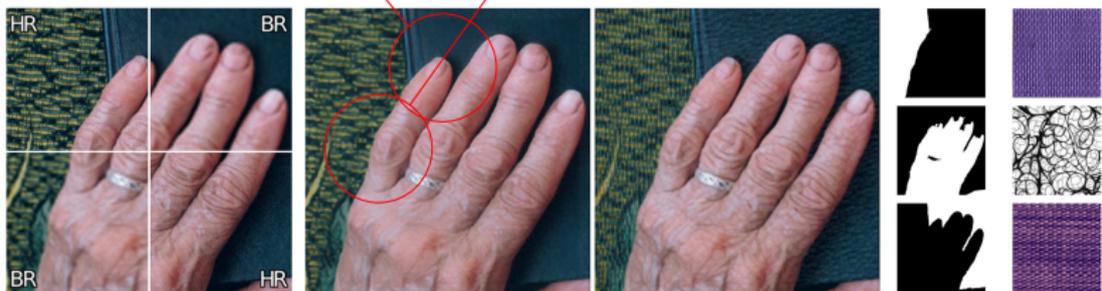
Résultat de l'étape-ST

Masques  $\beta_i$  Styles  $Y_i$



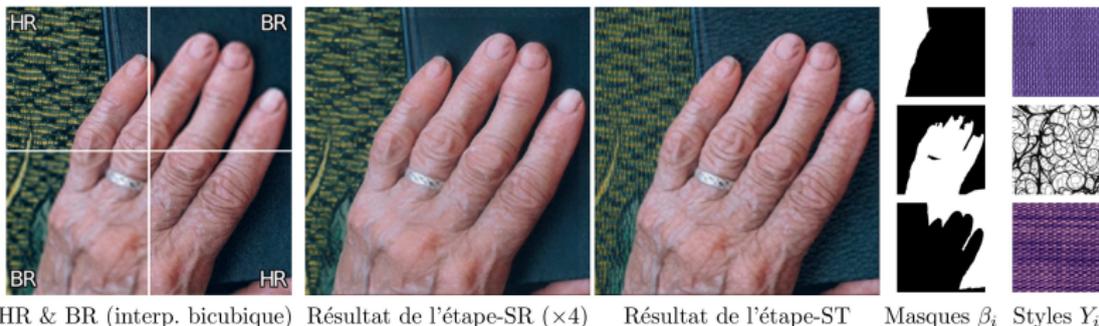


Etape 1



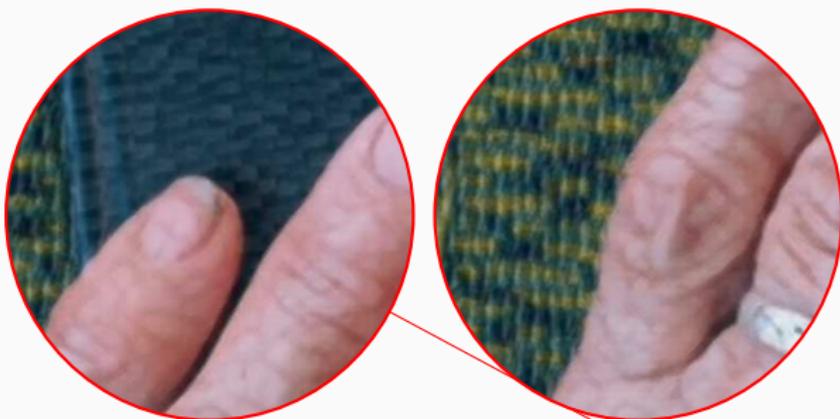
HR & BR (interp. bicubique)    Résultat de l'étape-SR ( $\times 4$ )    Résultat de l'étape-ST    Masques  $\beta_i$     Styles  $Y_i$

## Réseaux de neurones légers pour la restauration stylisée d'images (Ici, Super-Résolution Stylisée)

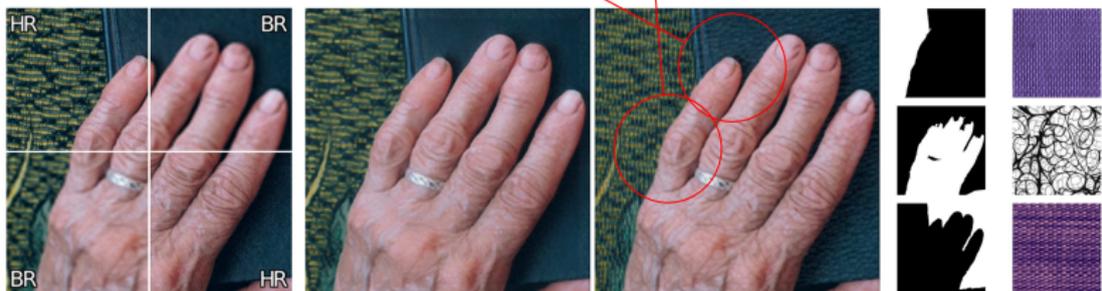


Une approche en **deux étapes** :

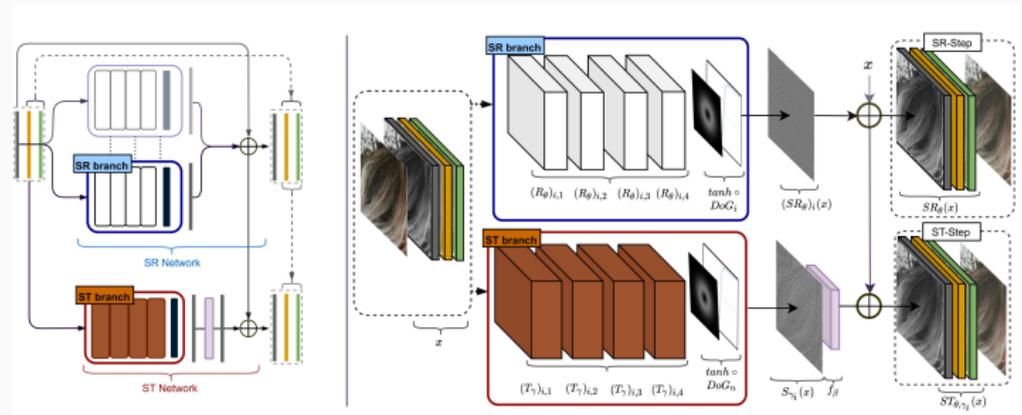
- Etape(s) de Stylisation (étape-ST) (un réseau par masque et par style, de **50k paramètres** ; ordre de grandeur  $\sim$  **x00Ko**).  
Utilisation d'un petit réseau branché en parallèle du réseau de l'Etape de Restauration et spécialisé dans **la stylisation des détails hautes fréquences**.  
Il y'a autant d'Etapes de Stylisation que de textures différentes choisies par l'utilisateur.



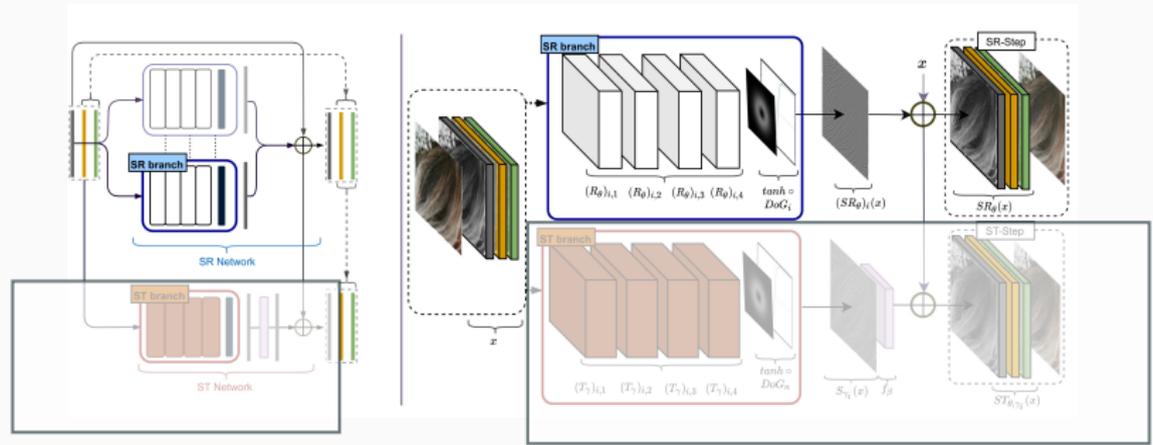
Etapes 2



HR & BR (interp. bicubique)    Résultat de l'étape-SR (x4)    Résultat de l'étape-ST    Masques  $\beta_i$     Styles  $Y_i$



**Figure 3:** Architecture construite par assemblage du réseau de restauration avec le réseau de stylisation



**Figure 4:** Architecture du Réseau de Restauration

**Etape de Restauration :** Architecture constituée de 6 branches parallèles. Chaque branche se termine par une différence de Gaussiennes (filtre passe-bande) spécialisant la branche dans une bande de fréquences donnée. La reconstruction des branches est une combinaison linéaire des contributions. ( $\sim 200k$ ) paramètres

Avec  $\theta$  les paramètres du réseau de restauration  $M_\theta$ , il s'agit de résoudre :

$$\min_{\theta} \mathcal{L}_M(X, M_\theta(x)),$$

avec

$$\mathcal{L}_M(X, Y) = \sum_{k=1}^K \|X_k - Y_k\|^2 + \lambda_M \mathcal{L}_{\text{Perc}}(X_k, Y_k).$$

où  $\|\cdot\|$  est la norme de Frobenius,

$\mathcal{L}_{\text{Perc}}(x, y) = \sum_{\ell \in L_{\text{Perc}}} \|\phi_\ell(x) - \phi_\ell(y)\|^2$  correspond au terme de 'fidélité', avec  $\phi_\ell(\cdot)$  les caractéristiques normalisées de la couche  $\ell$  du VGG-16<sup>6</sup> ( $L_{\text{Perc}} = \{5, 9, 13\}$ ).

---

<sup>6</sup>Karen Simonyan and Andrew Zisserman (2015). "Very Deep Convolutional Networks for Large-Scale Image Recognition". In: *International Conference on Learning Representations*.

Model	# Params.	DIV2K	Set5	Set14	Bsd100
<b>Ours</b>	200K	1.02	2.22	1.36	0.76
SRCNN <sup>7</sup>	440K	0.72	1.95	0.81	0.54
EDSR <sup>8</sup>	1517K	1.54	4.71	1.86	1.24
SRGAN <sup>9</sup>	1554K	-0.50	2.00	-0.19	-0.48
RDN <sup>10</sup>	2205K	1.59	4.76	1.83	1.29

**Figure 5:** comparaison des Gains en PSNR entre notre réseau de restauration (étape-1 ; entraîné avec l'erreur quadratique moyenne comme seule pénalité, *i.e*  $\lambda_M = 0$ ) et d'autres réseaux

<sup>7</sup>Chao Dong et al. (2014). "Learning a Deep Convolutional Network for Image Super-Resolution". In: *Computer Vision – ECCV 2014*. Ed. by David Fleet et al. Cham: Springer International Publishing, pp. 184–199. ISBN: 978-3-319-10593-2.

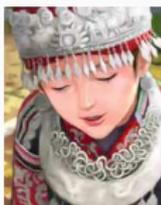
<sup>8</sup>Bee Lim et al. (2017). "Enhanced Deep Residual Networks for Single Image Super-Resolution". In: *2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pp. 1132–1140. DOI: 10.1109/CVPRW.2017.151.

<sup>9</sup>Christian Ledig et al. (July 2017). "Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network". In: pp. 105–114. DOI: 10.1109/CVPR.2017.19.

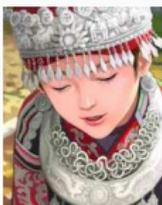
<sup>10</sup>Yulun Zhang et al. (June 2018). "Residual Dense Network for Image Super-Resolution". In: pp. 2472–2481. DOI: 10.1109/CVPR.2018.00262.



$x_k$  (bruitée)



Etape 1



$X_k$  originale



$x_k$  (floutée)



Etape 1



$X_k$  originale



$x_k$  (basse-rés.)



Etape 1



$X_k$  originale



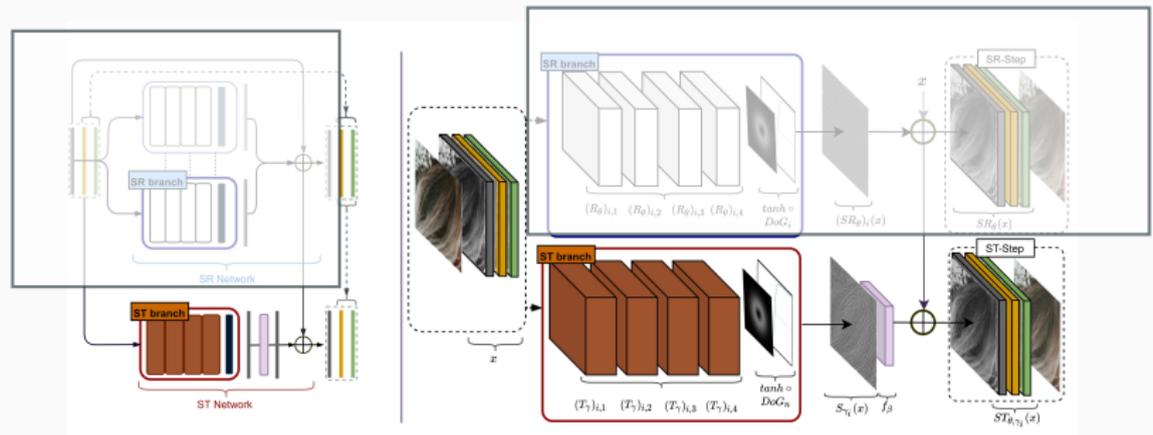
$x_k$  (inpainting)



Etape 1



$X_k$  originale



**Figure 6:** Architecture du Réseau de Stylisation

**Etapas-ST :** Architecture très légère ( $\sim 50k$  paramètres) en parallèle du réseau de restauration dont les paramètres sont gelés. Le reconstruction est additive. A la fin du réseau-ST, un filtre passe-haut suivi d'une normalisation par batch dont les paramètres affines sont contrôlés permet la génération d'un résidu haute fréquence, globalement nul et à écart type contrôlé. Un réseau-ST par style.

Avec  $\theta$  les paramètres du réseau de restauration  $M_\theta$  (paramètres gelés) et  $\gamma_i$  les paramètres du réseau  $i$  de stylisation  $ST_{\theta, \gamma_i}$  (associé au style  $Y_i$ ), il s'agit de résoudre :  $\min_{\gamma_i} \mathcal{L}_{ST}(X, Y_i, ST_{\theta, \gamma_i}(x))$

avec

$$\mathcal{L}_{ST}(X, Y_i, Z) = \sum_{k=1}^K \lambda_{ST} \mathcal{L}_{Perc}(X_k, Z_k) + \mathcal{L}_{Tex}(Y_i, Z_k).$$

où la pénalité de texture est définie à partir des matrices de gram normalisées  $G$ ,<sup>11</sup>

$$\mathcal{L}_{Tex}(x, y) = \sum_{\ell \in L_{Tex}} \|G(\phi_\ell(x)) - G(\phi_\ell(y))\|^2. \quad (1)$$

$$(L_{Tex} = \{2, 5, 9\}, L_{Perc} = \{7\})$$

---

<sup>11</sup>Leon Gatys, Alexander Ecker, and Matthias Bethge (Aug. 2015). "A Neural Algorithm of Artistic Style". In: *arXiv*. DOI: 10.1167/16.12.326.



Image originale  $X_k$     Image dégradée  $x_k$     Etape 1 ('restauration')    Etape 2 (stylisation)

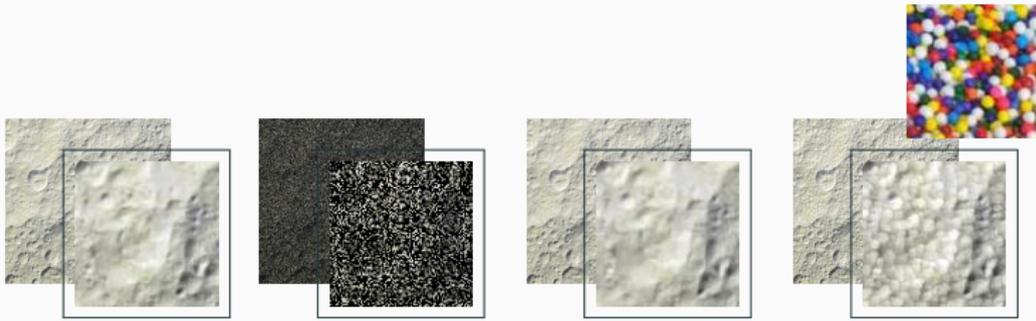


Image originale  $X_k$     Image dégradée  $x_k$     Etape 1 ('restauration')    Etape 2 (stylisation)

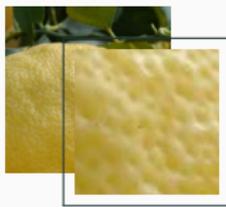
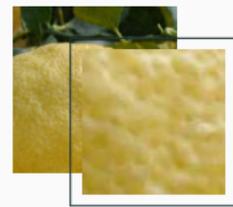


Image originale  $X_k$



Image dégradée  $x_k$



Etape 1 ('restauration')



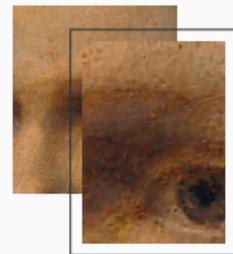
Etape 2 (stylisation)



Image originale  $X_k$



Image dégradée  $x_k$



Etape 1 ('restauration')



Etape 2 (stylisation)

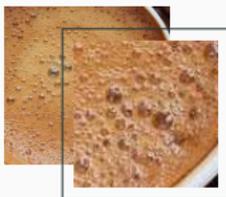
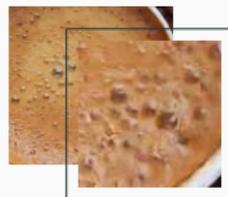


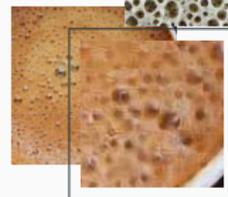
Image originale  $X_k$



Image dégradée  $x_k$



Etape 1 ('restauration')



Etape 2 (stylisation)



Image originale  $X_k$

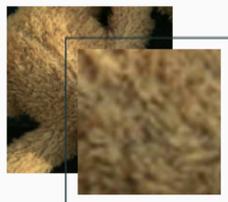
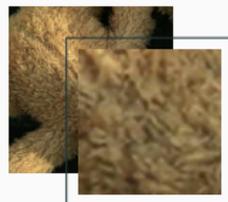
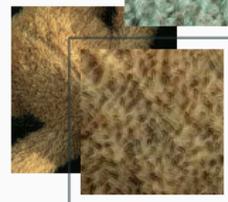


Image dégradée  $x_k$



Etape 1 ('restauration')

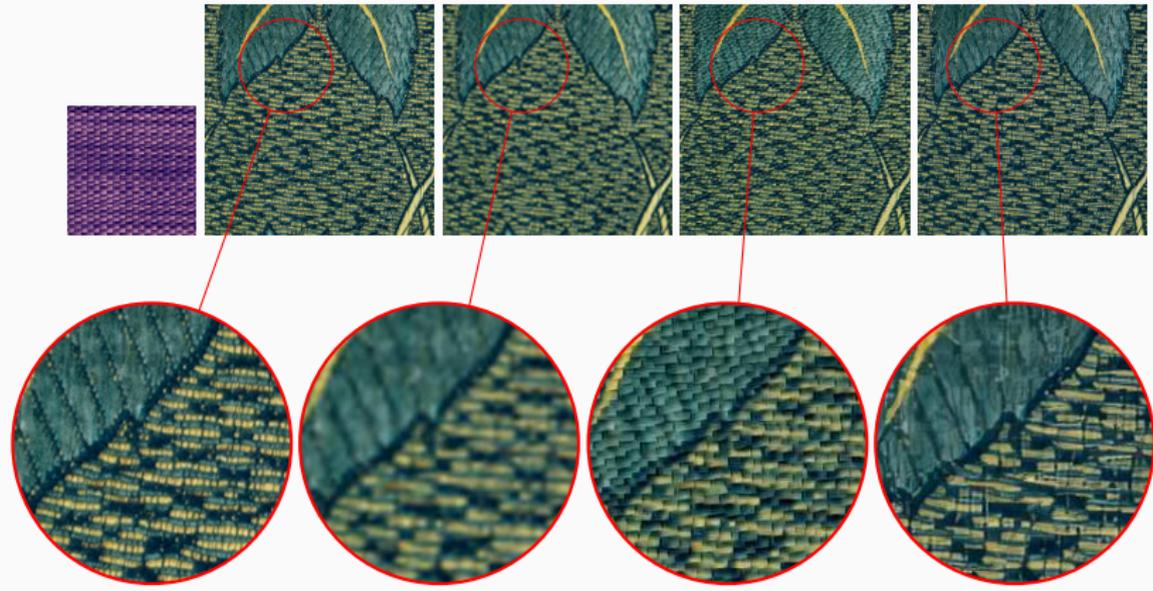


Etape 2 (stylisation)



# Contributions - comparaison état de l'art (Reference-based SR)

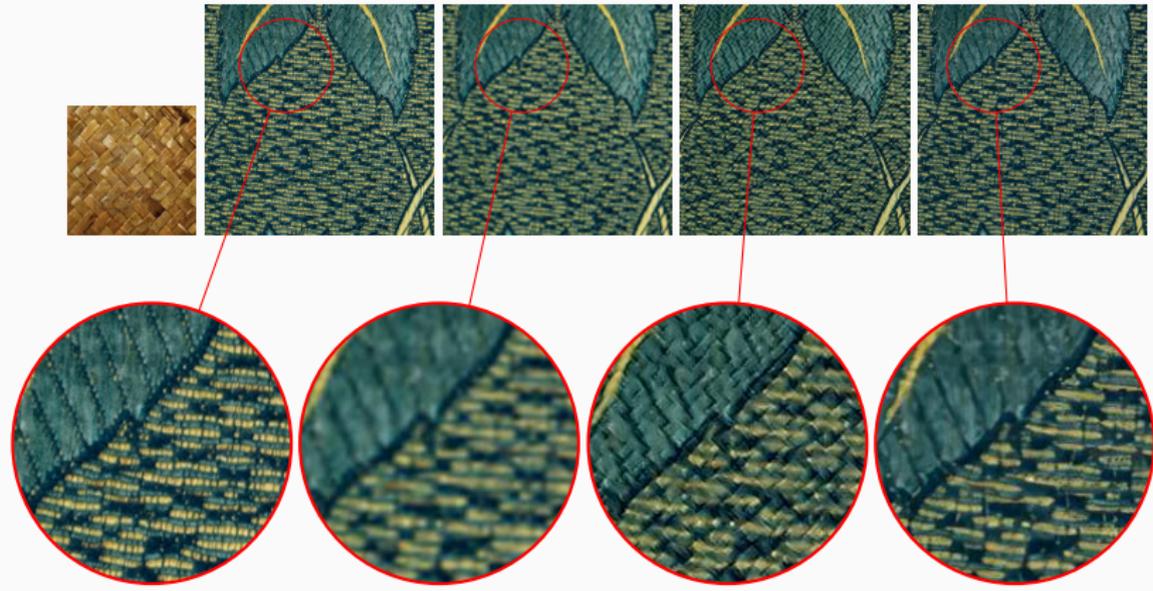
Style ; Haute-Rés. ; Basse-Rés. & SR stylisée (250k params) & Résultat TTSR<sup>12</sup> (9000k params)



<sup>12</sup>Fuzhi Yang et al. (2020). "Learning Texture Transformer Network for Image Super-Resolution". In: *CVPR*.

# Contributions - comparaison état de l'art (Reference-based SR)

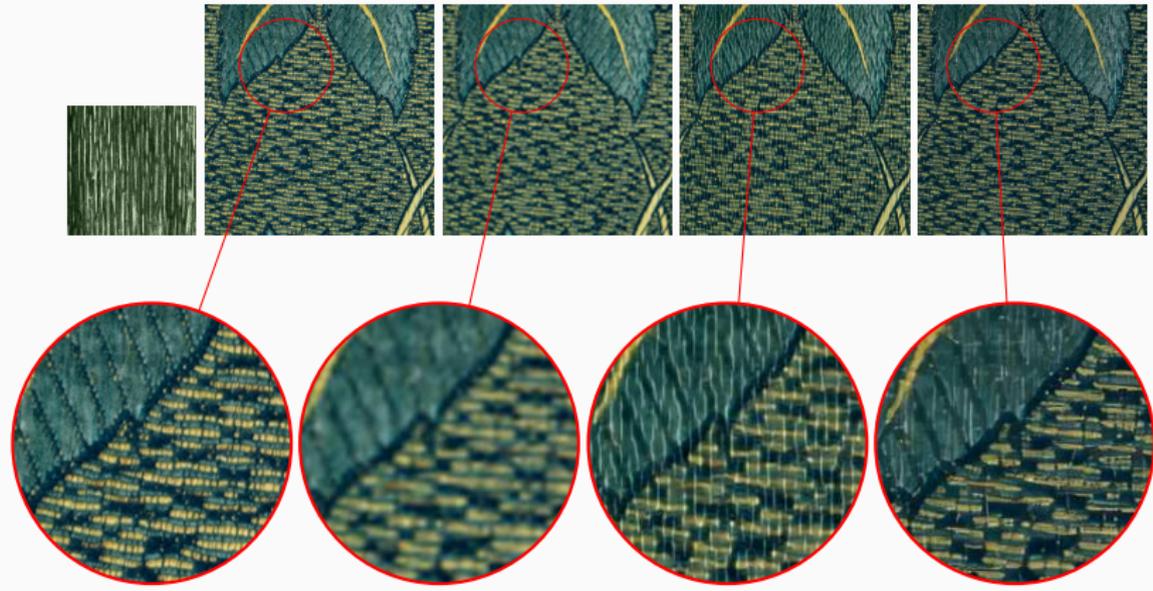
Style ; Haute-Rés. ; Basse-Rés. & SR stylisée (250k params) & Résultat TTSR<sup>13</sup> (9000k params)



<sup>13</sup>Fuzhi Yang et al. (2020). "Learning Texture Transformer Network for Image Super-Resolution". In: *CVPR*.

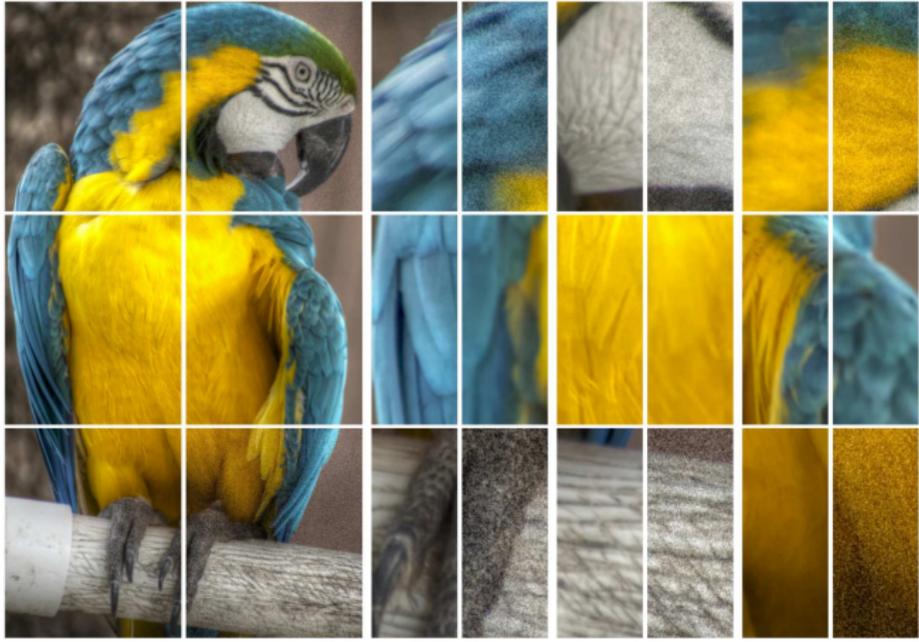
# Contributions - comparaison état de l'art (Reference-based SR)

Style ; Haute-Rés. ; Basse-Rés. & SR stylisée (250k params) & Résultat TTSR<sup>14</sup> (9000k params)



<sup>14</sup>Fuzhi Yang et al. (2020). "Learning Texture Transformer Network for Image Super-Resolution". In: *CVPR*.

## Image Before & After Degradation

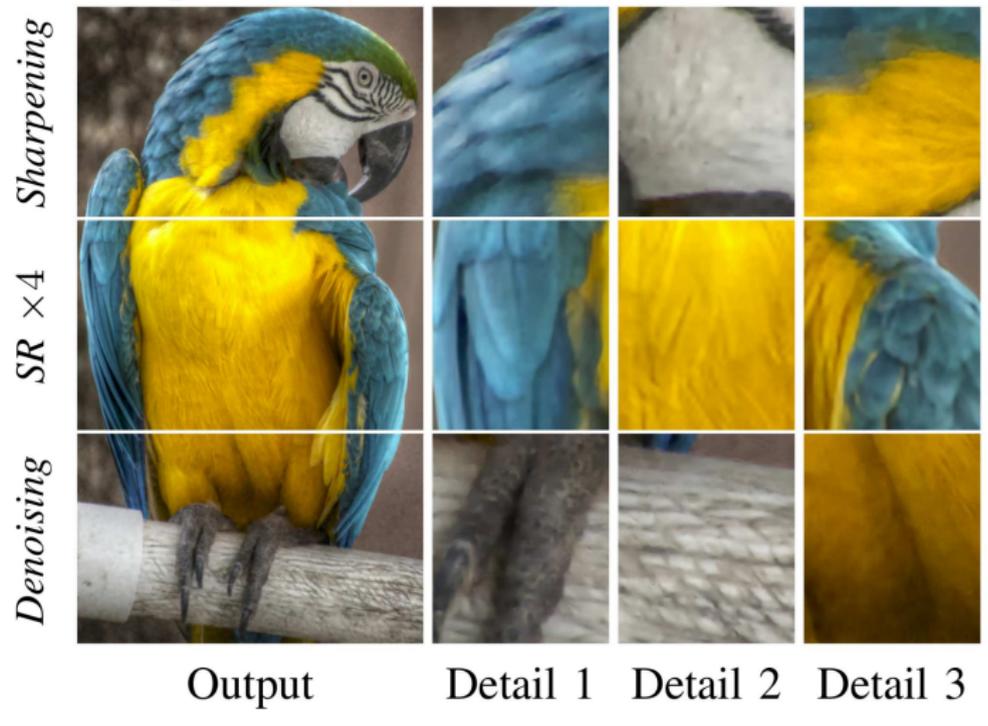


*Sharpening*  
*SR ×4*  
*Denoising*

Before / After

Enlarged Details (B /A)

## Step 1 – Multi-Scale Restoration Network



## Image Editing Example I.

Styles I

a b c d

e d e e g h f

Styles I e f g h

Sharpening

$SR \times 4$

Denoising

## Image Editing Example II.

<i>Denoising</i>					<p>Styles II</p>
	<i>SR × 4</i>				
	<i>Sharpening</i>				

								<p>Styles II</p>

Merci pour votre attention, des questions ?



Dong, Chao et al. (2014). “Learning a Deep Convolutional Network for Image Super-Resolution”. In: *Computer Vision – ECCV 2014*. Ed. by David Fleet et al. Cham: Springer International Publishing, pp. 184–199. ISBN: 978-3-319-10593-2.



Gatys, Leon, Alexander Ecker, and Matthias Bethge (Aug. 2015). “A Neural Algorithm of Artistic Style”. In: *arXiv*. DOI: 10.1167/16.12.326.



Johnson, Justin, Alexandre Alahi, and Li Fei-Fei (Oct. 2016). “Perceptual Losses for Real-Time Style Transfer and Super-Resolution”. In: vol. 9906, pp. 694–711. ISBN: 978-3-319-46474-9. DOI: 10.1007/978-3-319-46475-6\_43.



Ledig, Christian et al. (July 2017). “Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network”. In: pp. 105–114. DOI: 10.1109/CVPR.2017.19.



Lim, Bee et al. (2017). “Enhanced Deep Residual Networks for Single Image Super-Resolution”. In: *2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pp. 1132–1140. DOI: 10.1109/CVPRW.2017.151.



Simonyan, Karen and Andrew Zisserman (2015). "Very Deep Convolutional Networks for Large-Scale Image Recognition". In: *International Conference on Learning Representations*.



Wang, Xintao et al. (Sept. 2018). *ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks*.



Yang, Fuzhi et al. (2020). "Learning Texture Transformer Network for Image Super-Resolution". In: *CVPR*.



Zhang, Yulun et al. (June 2018). "Residual Dense Network for Image Super-Resolution". In: pp. 2472–2481. DOI: 10.1109/CVPR.2018.00262.

# Bi-Scale Style Transfer

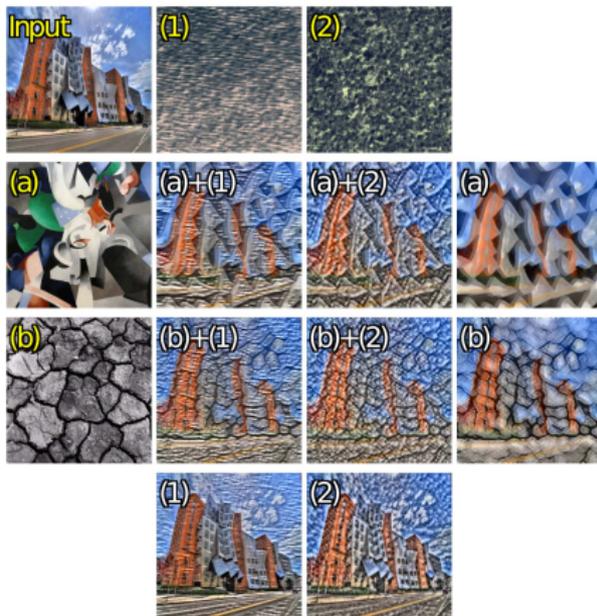


FIGURE 1 – Résultats du transfert de styles à deux échelles. L'image de contenu Input est stylisée avec les styles **a** and **b** combinés aux textures **1** and **2** et ce à l'aide de réseaux légers et modulables. Le transfert de style pour les réseaux pris individuellement correspond à a,b,1, 2.