

Réseaux de neurones

# IFT 780

## Visualisation

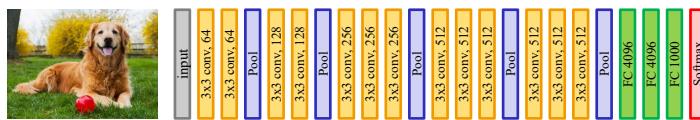
Par

Pierre-Marc Jodoin

1

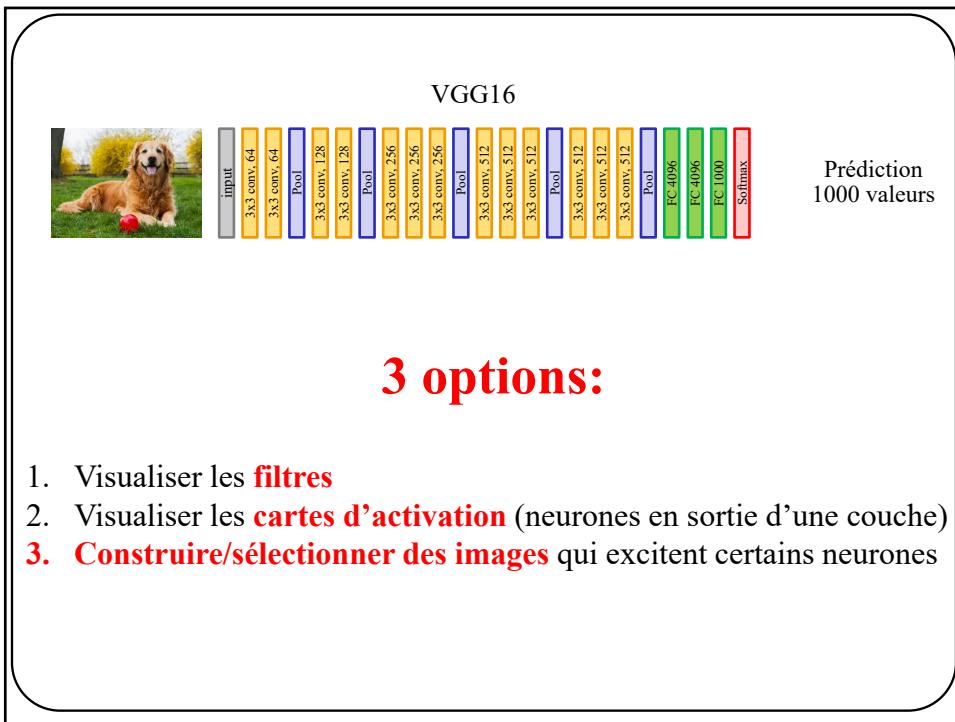
**Comment visualiser ce qu'un réseau a appris?**

VGG16



2

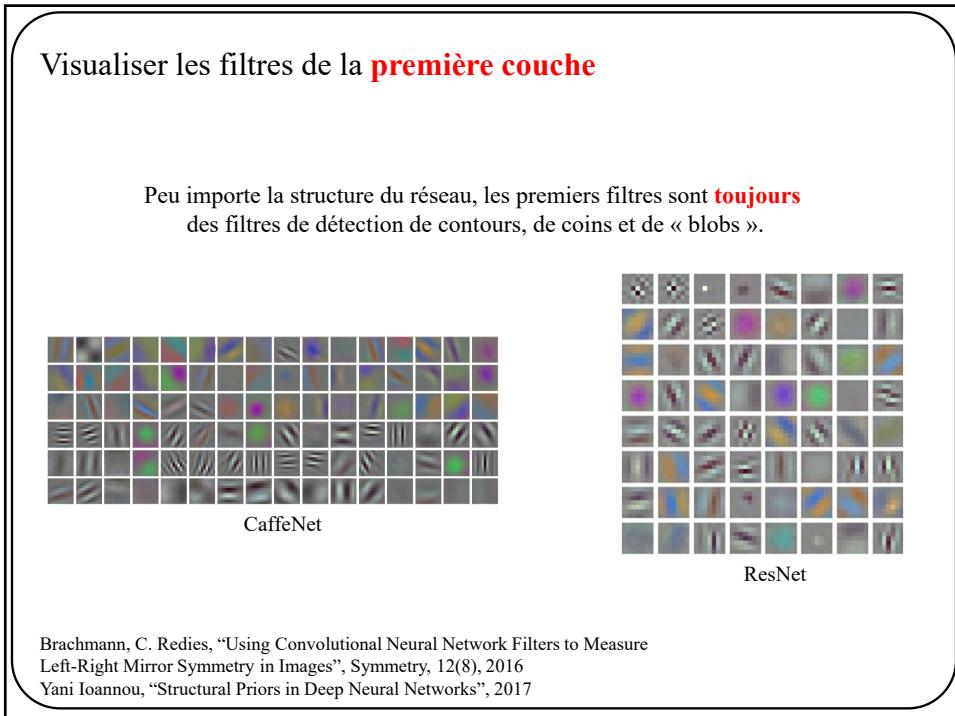
1



3

## 3 options:

1. Visualiser les **filtres**
2. Visualiser les **cartes d'activation** (neurones en sortie d'une couche)
3. **Construire/sélectionner des images** qui excitent certains neurones



4

Visualiser les **autres couches** n'est pas très intéressant

**Filtre couche 2**  
combine les 16 cartes  
d'activation de la  
couche précédente

**Interprétation difficile**

[cs231n.github.io](https://cs231n.github.io)  
[cs.stanford.edu/people/karpathy/convnetjs/demo/cifar10.html](https://cs.stanford.edu/people/karpathy/convnetjs/demo/cifar10.html)

Couche 1  
16 filtres de taille  
7x7x3

Couche 2  
20 filtres de taille  
7x7x16

Couche 3  
20 filtres de taille  
7x7x20

5

On tire rarement grand-chose à visualiser des  
filtres. Il faut donc une autre solution:

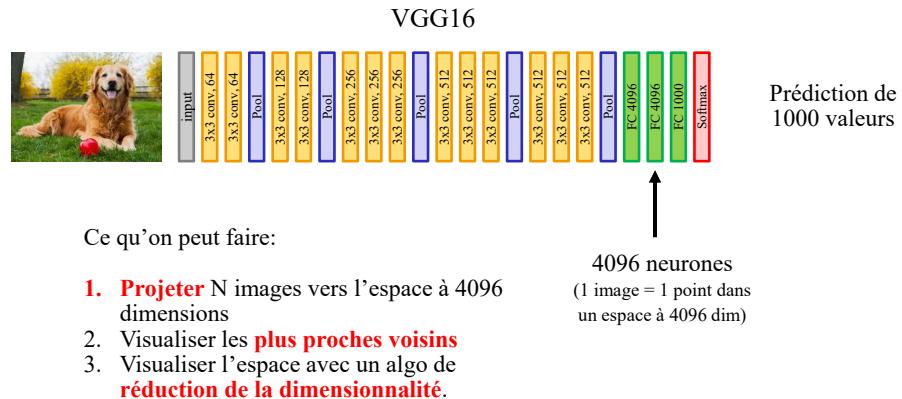
## Options restantes:

1. Visualiser les **filtres**
2. Visualiser les **cartes d'activation** (neurones en sortie d'une couche)
3. **Construire/sélectionner une image** qui excite certains neurones

6

3

Visualiser les neurones de l'avant-dernière couche.



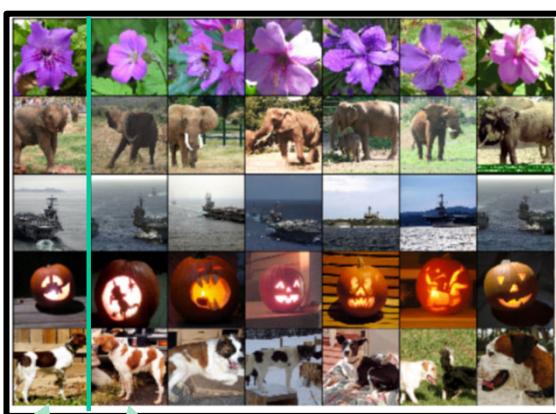
7

### AlexNet

6 plus proches voisins de 5 images de référence

Distance euclidienne dans l'espace à 4096 dim

**Conclusion :** l'espace semble être **localement linéaire**  
avec une **organisation sémantique**



Images de référence

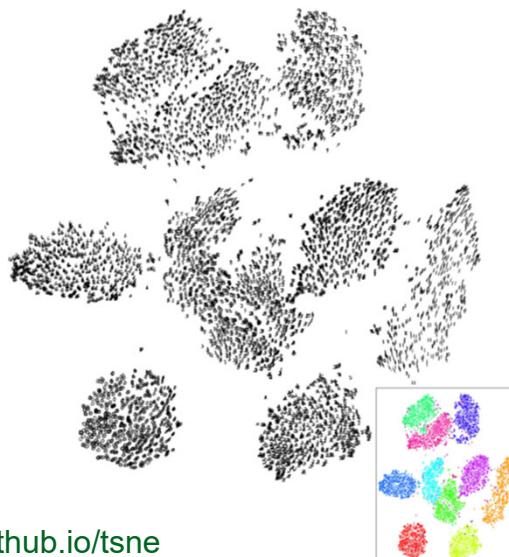
6 plus proches voisins

Krizhevsky et al, "ImageNet Classification with Deep Convolutional Neural Networks", NIPS 2012.

8

## Visualiser l'espace à 4096 dim

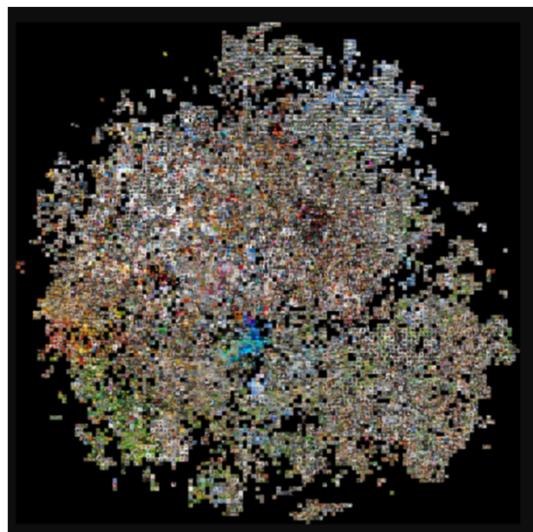
MNIST



[lvdmaaten.github.io/tsne](https://vdmaaten.github.io/tsne)

9

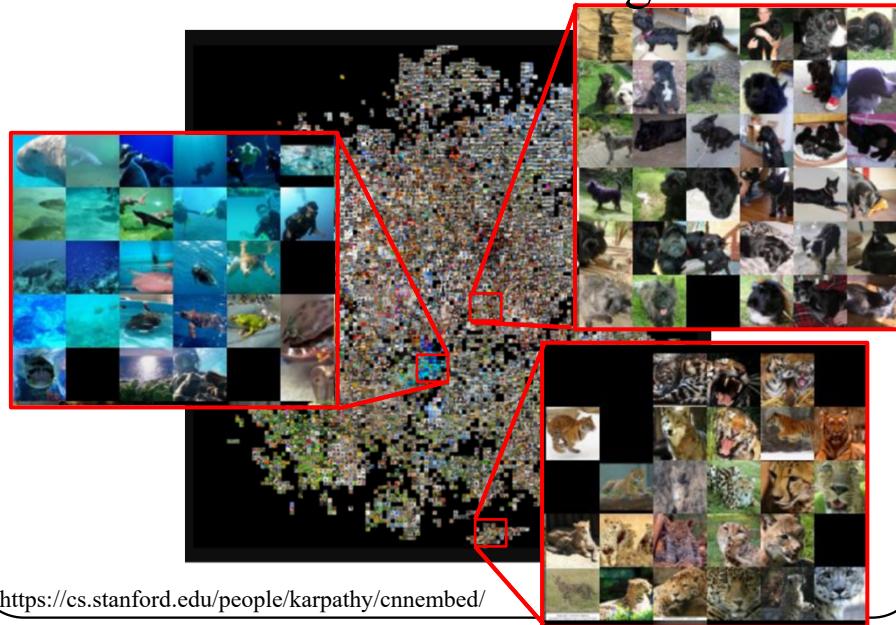
## AlexNet + tsne + ImageNet



<https://cs.stanford.edu/people/karpathy/cnnembed/>

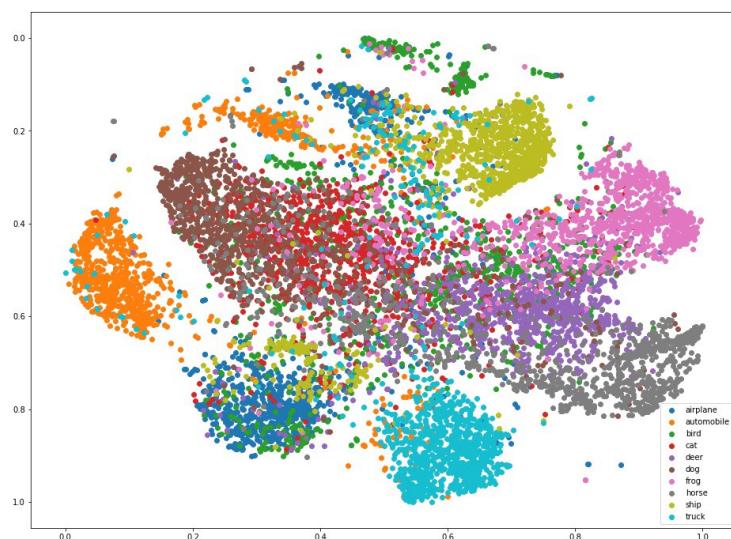
10

## AlexNet + tsne + ImageNet



11

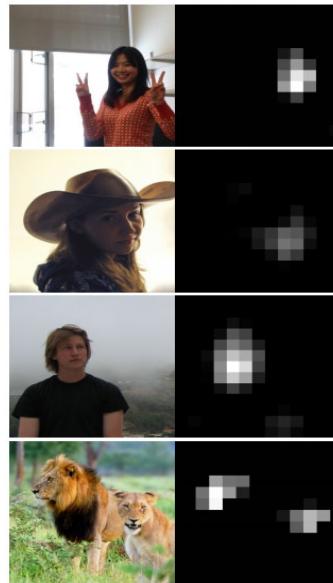
## AlexNet + tsne + CIFAR10



12

## Visualiser les cartes d'activation (entre l'entrée et la sortie)

Ici la 151<sup>e</sup> **carte d'activation** de la couche conv5 illustrées comme des images en niveau de gris de taille 13x13.



Yosinski et al., "Understanding Neural Networks Through Deep Visualization", ICML DL Workshop 2014.

Figure 2. A view of the  $13 \times 13$  activations of the 151<sup>st</sup> channel on the conv5 layer of a deep neural network trained on ImageNet, a

13

## Visualiser les cartes d'activation (entre l'entrée et la sortie)

Ici la 151<sup>e</sup> **carte d'activation** conv5 illustrée comme des images en niveau de gris de taille 13x13.

Conclusion:  
les neurones de cette carte d'activation se spécialisent dans la détection de visages



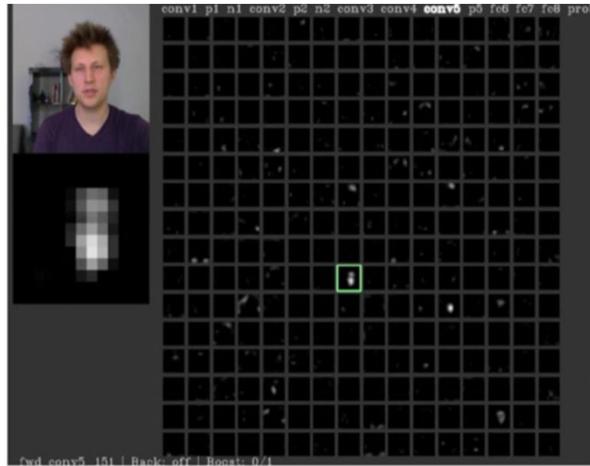
Yosinski et al., "Understanding Neural Networks Through Deep Visualization", ICML DL Workshop 2014.

Figure 2. A view of the  $13 \times 13$  activations of the 151<sup>st</sup> channel on the conv5 layer of a deep neural network trained on ImageNet, a

14

## Visualiser les cartes d'activation

Ici les **256 cartes d'activation** de la couche conv5 illustrées comme des images en niveau de gris de taille 13x13.



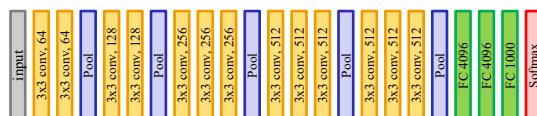
<https://www.youtube.com/watch?v=AgkfIQ4IGaM>

<https://github.com/yosinski/deep-visualization-toolbox>

Yosinski et al., "Understanding Neural Networks Through Deep Visualization", ICML DL Workshop 2014.

15

Identifier les zones de l'image qui activent au maximum les neurones d'une carte d'activation

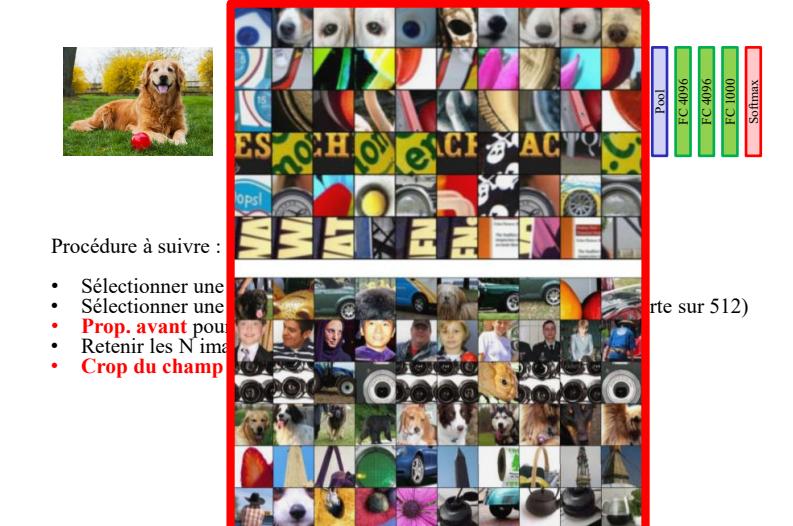


Procédure à suivre :

- Sélectionner une **couche** (ex. conv8)
- Sélectionner une **carte d'activation** de cette couche (ex.: la 20<sup>e</sup> carte sur 512)
- **Prop. avant** de plusieurs images
- Retenir les N images ayant provoqué une **activation maximale** dans cette carte
- **Crop du champ récepteur** des neurones maximalement activés

16

Identifier les zones de l'image qui activent au maximum les neurones d'une carte d'activation



Springenberg et al., "Striving for Simplicity: The All Convolutional Net", ICLR Workshop 2015

17

## Visualisation du « ZF-Net »

[Zeiler,Fergus 2014]

Même expérience mais avec le ZF-Net.

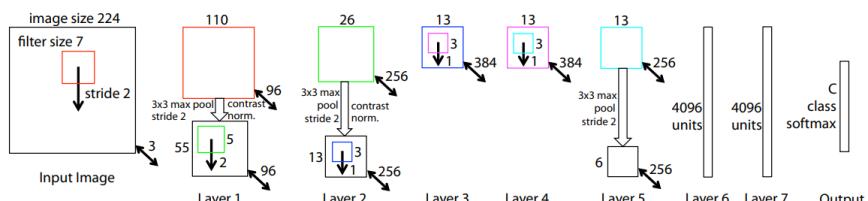


Figure 3. Architecture of our 8 layer convnet model. A 224 by 224 crop of an image (with 3 color planes) is presented as the input. This is convolved with 96 different 1st layer filters (red), each of size 7 by 7, using a stride of 2 in both x and y. The resulting feature maps are then: (i) passed through a rectified linear function (not shown), (ii) pooled (max within 3x3 regions, using stride 2) and (iii) contrast normalized across feature maps to give 96 different 55 by 55 element feature maps. Similar operations are repeated in layers 2,3,4,5. The last two layers are fully connected, taking features from the top convolutional layer as input in vector form ( $6 \cdot 6 \cdot 256 = 9216$  dimensions). The final layer is a  $C$ -way softmax function,  $C$  being the number of classes. All filters and feature maps are square in shape.

Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

18

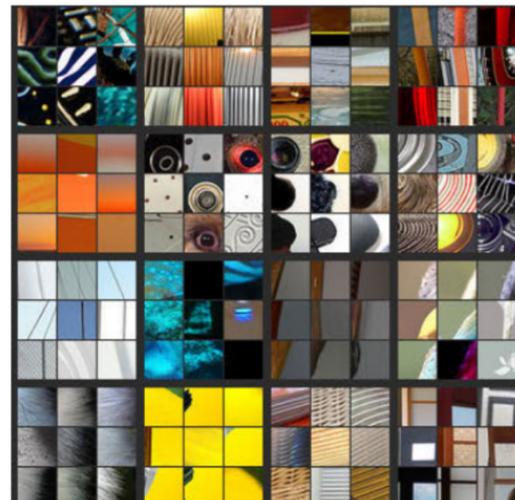
# Visualisation du « ZF-Net »

[Zeiler,Fergus 2014]

Patches qui activent au maximum les couches 1 et 2



Couche 1



Couche 1

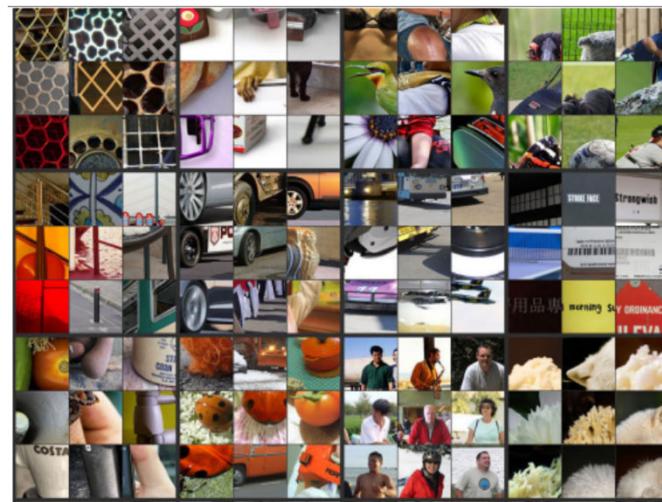
Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

19

# Visualisation du « ZF-Net »

[Zeiler,Fergus 2014]

Patches qui activent au maximum la couche 3



Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

20

10

## Visualisation du « ZF-Net »

[Zeiler,Fergus 2014]

Patches qui activent  
au maximum les  
couches 4 et 5



Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

21

## Visualisation du « ZF-Net »

[Zeiler,Fergus 2014]

Patches qui activent  
au maximum les  
couches 4

## Conclusion:

Plus les neurones sont profonds,  
plus ils détectent des  
représentations complexes



Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

22

## Visualisation par occultation

[Zeiler,Fergus 2014]

Comment identifier dans cette image ce qui permet au réseau de prédire la classe « chien »?



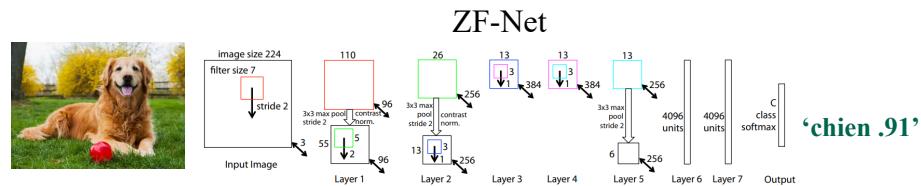
Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

23

## Visualisation par occultation

[Zeiler,Fergus 2014]

**Solution** : occulter des zones de l'image afin d'en constater l'impact



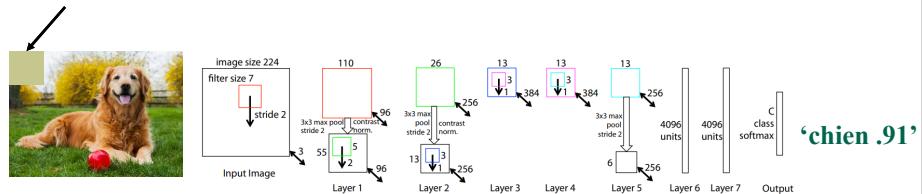
Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

24

# Visualisation par occultation

[Zeiler,Fergus 2014]

**Solution** : occulter des zones de l'image afin d'en constater l'impact



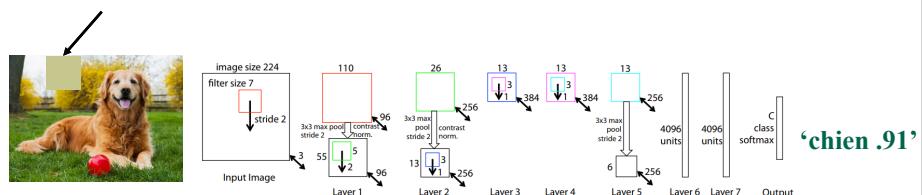
Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

25

# Visualisation par occultation

[Zeiler,Fergus 2014]

**Solution** : occulter des zones de l'image afin d'en constater l'impact



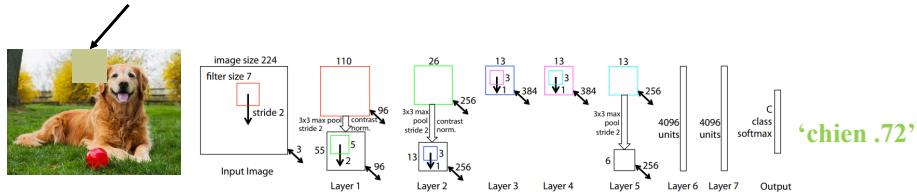
Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

26

# Visualisation par occultation

[Zeiler,Fergus 2014]

**Solution** : occulter des zones de l'image afin d'en constater l'impact



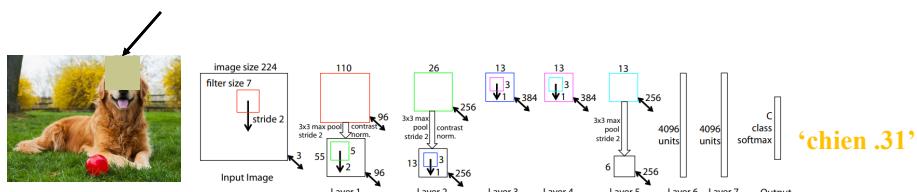
Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

27

# Visualisation par occultation

[Zeiler,Fergus 2014]

**Solution** : occulter des zones de l'image afin d'en constater l'impact



Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

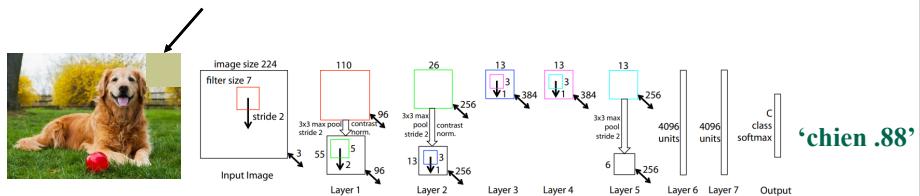
28

14

# Visualisation par occultation

[Zeiler,Fergus 2014]

**Solution** : occulter des zones de l'image afin d'en constater l'impact



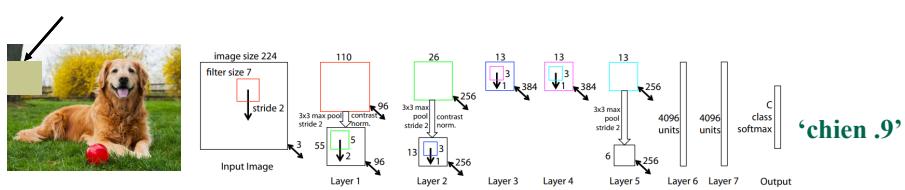
Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

29

# Visualisation par occultation

[Zeiler,Fergus 2014]

**Solution** : occulter des zones de l'image afin d'en constater l'impact



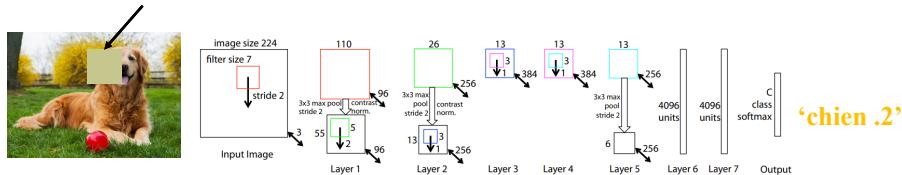
Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

30

# Visualisation par occultation

[Zeiler,Fergus 2014]

**Solution** : occulter des zones de l'image afin d'en constater l'impact



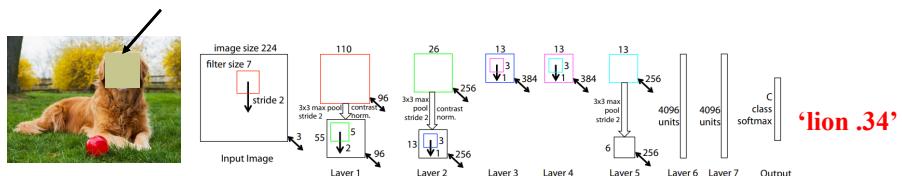
Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

31

# Visualisation par occultation

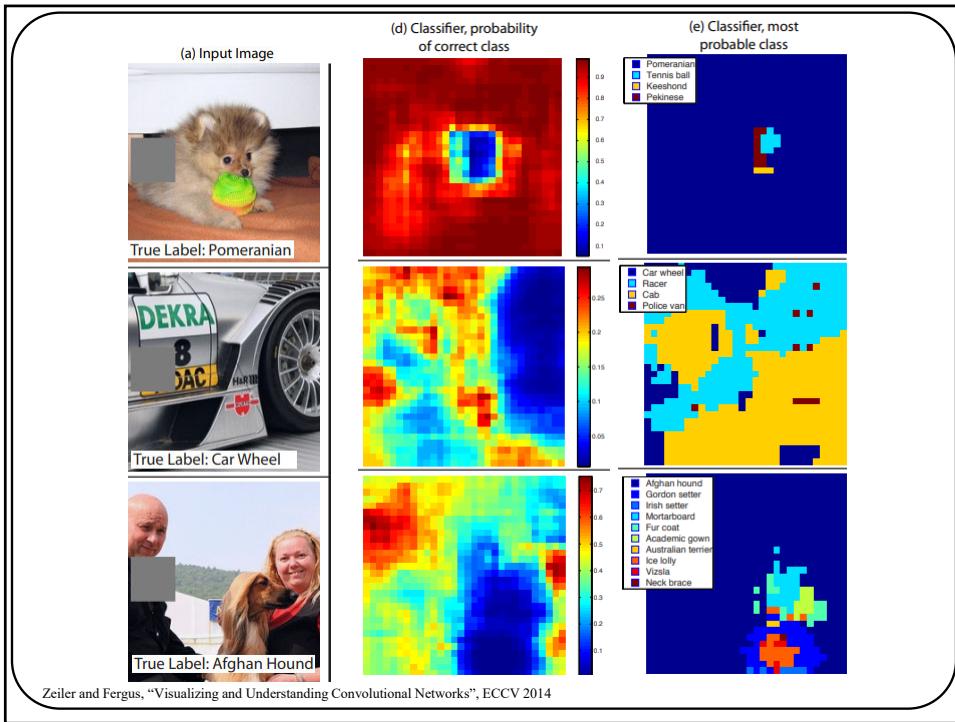
[Zeiler,Fergus 2014]

**Solution** : occulter des zones de l'image afin d'en constater l'impact



Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

32

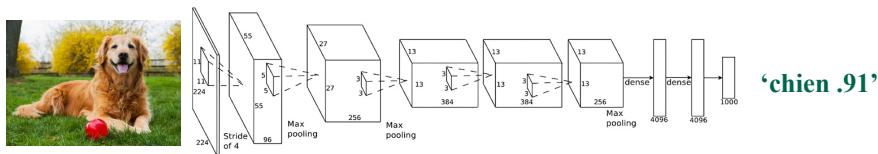


33

## Visualisation par rétropropagation

[Simonyan et al. 2014], [Zeiler-Fergus 2014], [Springenberg et al., 2015]

**Même question:** comment identifier dans cette image ce qui permet au réseau de prédire la classe « chien »?



Réseau de votre choix

JT Springenberg, A. Dosovitskiy, T. Brox, M. Riedmiller, "Striving for simplicity: the all convolutional net", ICLR 2015  
 Simonyan, Vedaldi, and Zisserman, "Deep Inside Convolutional Networks: Visualising Image Classification Models and Saliency Maps", ICLR Workshop 2014.

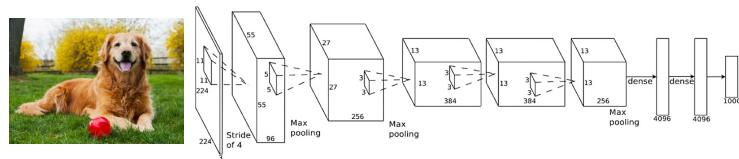
Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

34

# Visualisation par rétropropagation

[Simonyan et al. 2014], [Zeiler-Fergus 2014], [Springenberg et al., 2015]

**Étape 1:** pré-entraîner le réseau sur une grosse base de données  
(ex. ImageNet)



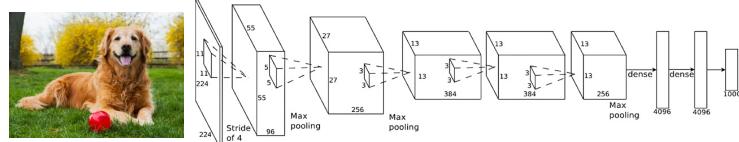
JT Springenberg, A. Dosovitskiy, T Brox, M.Riedmiller, "Striving for simplicity: the all convolutional net", ICLR 2015  
Simonyan, Vedaldi, and Zisserman, "Deep Inside Convolutional Networks: Visualising Image Classification Models and Saliency Maps", ICLR Workshop 2014.  
Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

35

# Visualisation par rétropropagation

[Simonyan et al. 2014], [Zeiler-Fergus 2014], [Springenberg et al., 2015]

**Étape 2:** prop. avant d'une image



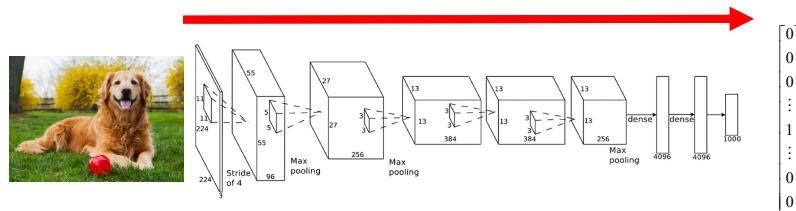
JT Springenberg, A. Dosovitskiy, T Brox, M.Riedmiller, "Striving for simplicity: the all convolutional net", ICLR 2015  
Simonyan, Vedaldi, and Zisserman, "Deep Inside Convolutional Networks: Visualising Image Classification Models and Saliency Maps", ICLR Workshop 2014.  
Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

36

## Visualisation par rétropropagation

[Simonyan et al. 2014], [Zeiler-Fergus 2014], [Springenberg et al., 2015]

**Étape 3:** forcer le score du réseau à 1 pour la class d'intérêt



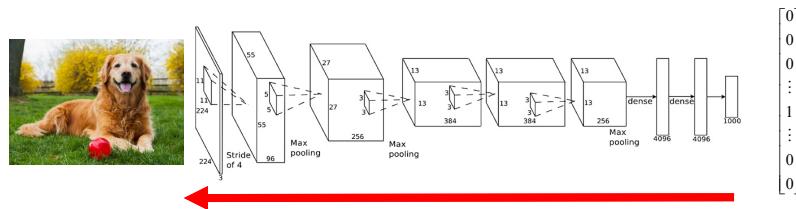
JT Springenberg, A. Dosovitskiy, T Brox, M.Riedmiller, "Striving for simplicity: the all convolutional net", ICLR 2015  
 Simonyan, Vedaldi, and Zisserman, "Deep Inside Convolutional Networks: Visualising Image Classification Models and Saliency Maps", ICLR Workshop 2014.  
 Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

37

## Visualisation par rétropropagation

[Simonyan et al. 2014], [Zeiler-Fergus 2014], [Springenberg et al., 2015]

**Étape 4:** rétro-propagation du gradient jusqu'à l'entrée  
 (chaque pixel = gradient)



JT Springenberg, A. Dosovitskiy, T Brox, M.Riedmiller, "Striving for simplicity: the all convolutional net", ICLR 2015  
 Simonyan, Vedaldi, and Zisserman, "Deep Inside Convolutional Networks: Visualising Image Classification Models and Saliency Maps", ICLR Workshop 2014.  
 Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

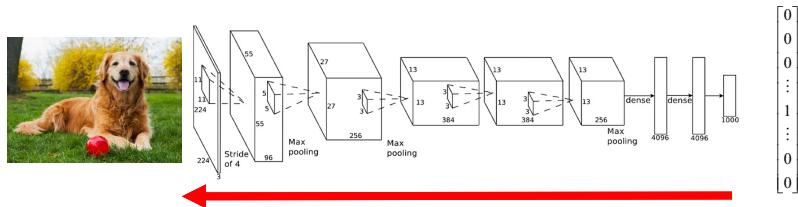
38

19

# Visualisation par rétropropagation

[Simonyan et al. 2014], [Zeiler-Fergus 2014], [Springenberg et al., 2015]

**Étape 5:** convertir les gradients en une image



JT Springenberg, A. Dosovitskiy, T Brox, M.Riedmiller, "Striving for simplicity: the all convolutional net", ICLR 2015  
Simonyan, Vedaldi, and Zisserman, "Deep Inside Convolutional Networks: Visualising Image Classification Models and Saliency Maps", ICLR Workshop 2014.

Zeiler and Fergus, "Visualizing and Understanding Convolutional Networks", ECCV 2014

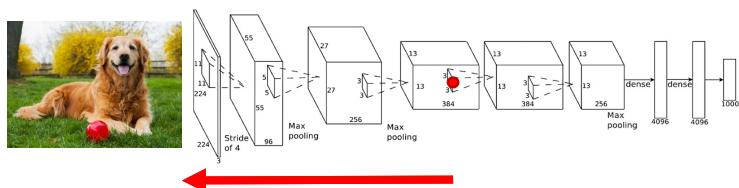
39

# Visualisation par rétropropagation

[Simonyan et al. 2014], [Zeiler-Fergus 2014], [Springenberg et al., 2015]

On peut faire la même chose pour **1 neurone** :

- Propagation avant jusqu'à la couche X
- Forcer à 0 la sortie de tous les neurones de la couche X
- Mettre à 1 la sortie du neurone d'intérêt
- Propager le gradient vers l'image d'entrée.



Simonyan, Vedaldi, and Zisserman, "Deep Inside Convolutional Networks: Visualising Image Classification Models and Saliency Maps", ICLR Workshop 2014.

40

# Approche par rétropropagation

```
def generate_grad_saliency (self, input_image, target_class):  
  
    model_output = self.model(input_image)  
  
    # Init gradients à zero  
    self.model.zero_grad()  
  
    # one_hot = 00000100000, 1 sur la classe cible  
    one_hot_output = torch.FloatTensor(1, model_output.size()[-1]).zero_()  
    one_hot_output[0][target_class] = 1  
  
    # Backward pass  
    model_output.backward(gradient=one_hot_output)  
  
    # [0] pour éliminer la première dimension (1,3,224,224)  
    gradients_saliency = self.gradients.data.numpy()[0]  
  
    return gradients_saliency
```

41

## Rétropropagation à partir du score du réseau

[Simonyan et al. 2014]



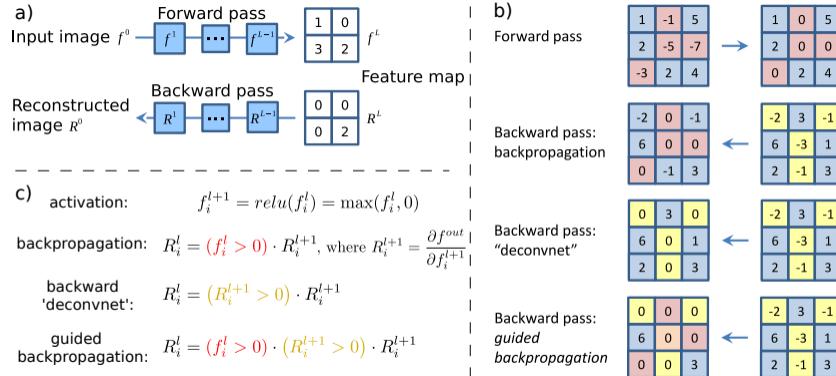
Gradient en valeur absolue

Simonyan, Vedaldi, and Zisserman, "Deep Inside Convolutional Networks: Visualising Image Classification Models and Saliency Maps", ICLR Workshop 2014.

42

## NOTE: 3 façons de rétropropager le gradient

[Simonyan et al. 2014], [Zeiler-Fergus 2014], [Springenberg et al., 2015]

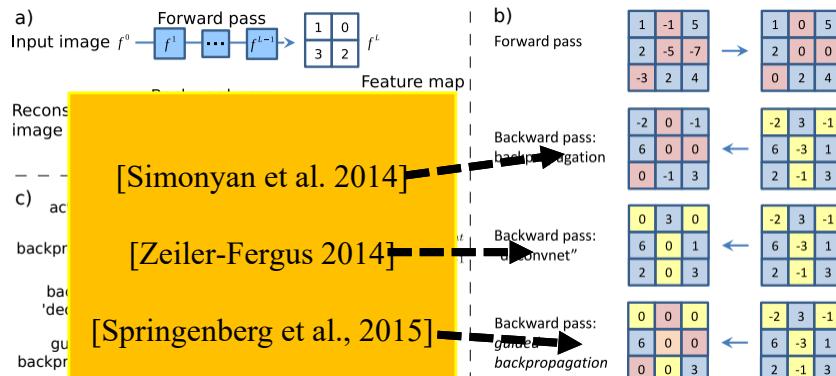


JT Springenberg, A Dosovitskiy, T Brox, M.Riedmiller, "Striving for simplicity: the all convolutional net", ICLR 2015

43

## NOTE: 3 façons de rétropopager le gradient

[Simonyan et al. 2014], [Zeiler-Fergus 2014], [Springenberg et al., 2015]

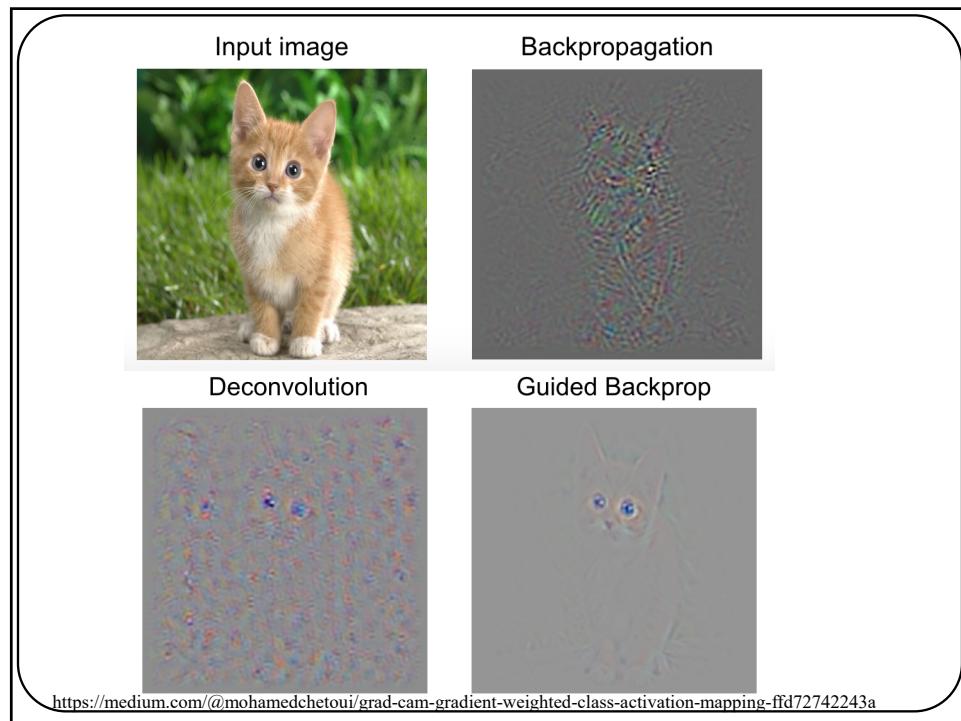


JT Springenberg, A Dosovitskiy, T Brox, M.Riedmiller, "Striving for simplicity: the all convolutional net", ICLR 2015

44

L'approche « *guided backprop* » est plus souvent utilisée car les résultats sont plus saillants et moins bruités

45

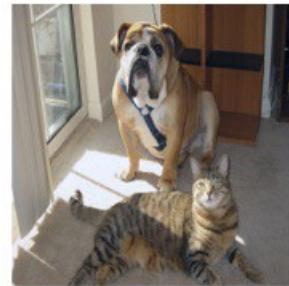
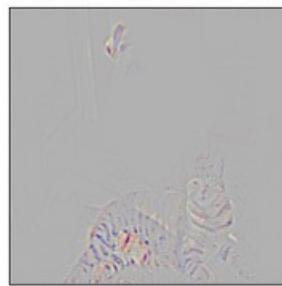


46

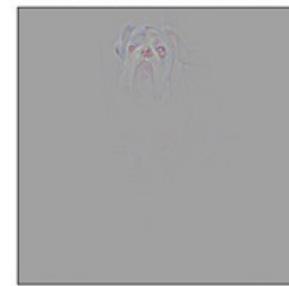
## Guided backprop

[Springenberg et al., 2015]

Guided Grad-CAM for "Cat"



Guided Grad-CAM for "Dog"

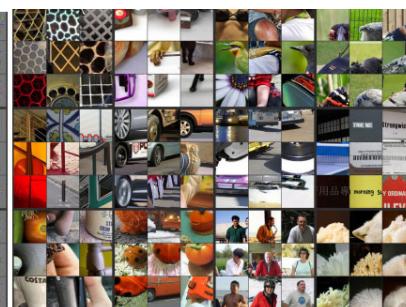
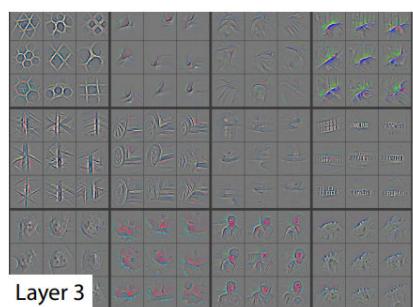
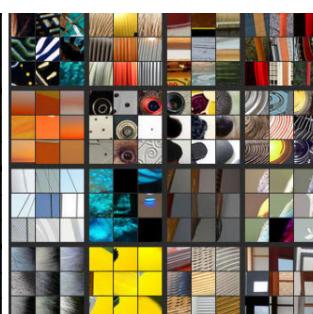
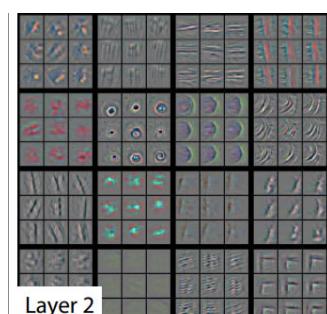


<https://medium.com/@mohamedchetoui/grad-cam-gradient-weighted-class-activation-mapping-fd7742243a>

47

## « Deconv net »

[Zeiler-Fergus 2014]

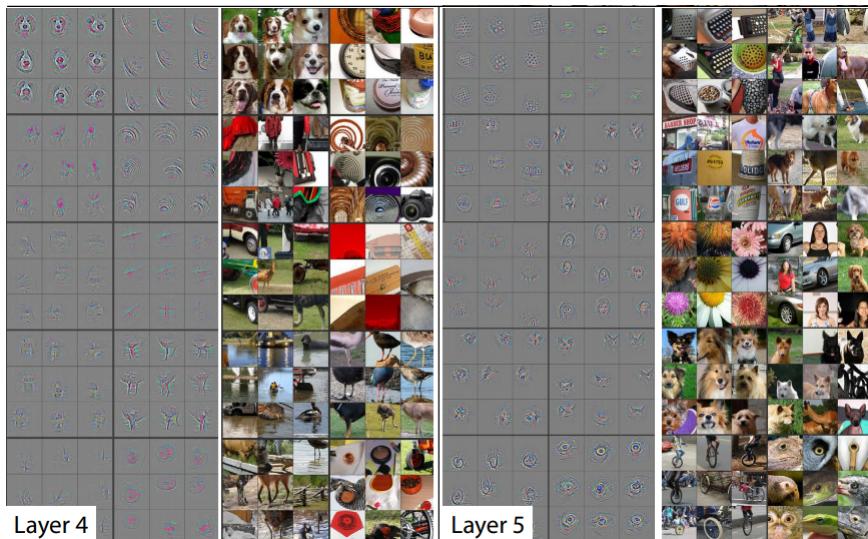


48

24

## « Deconv net »

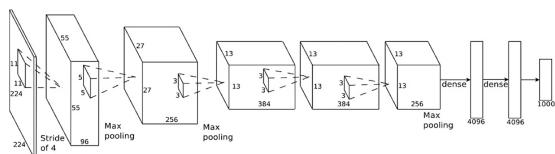
[Zeiler-Fergus 2014]



49

On peut « fabriquer » une image qui activera  
maximalemennt un neurone

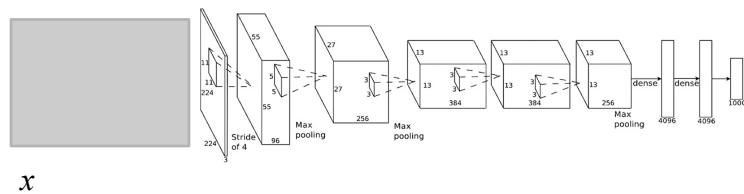
**Étape 1:** Préentraîner le réseau avec une grosse BD (ex. ImageNet)



50

On peut « fabriquer » une image qui activera  
maximalemen t un neurone

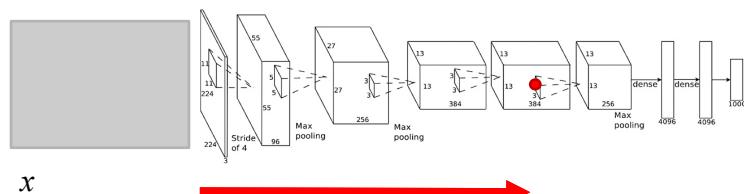
**Étape 2:** Initialiser une image avec des valeurs 0



51

On peut « fabriquer » une image qui activera  
maximalemen t un neurone

**Étape 2:** propagation avant jusqu'au neurone d'intérêt

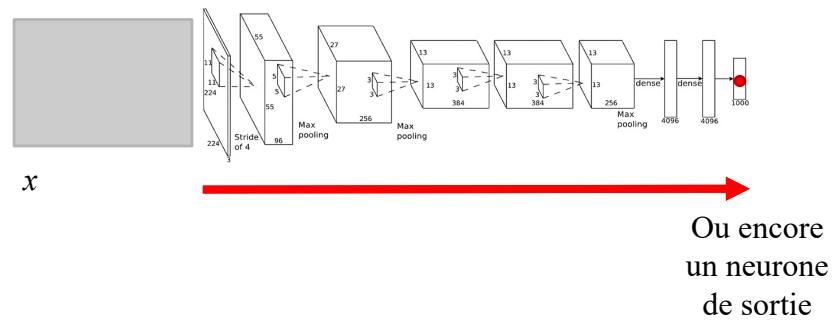


Peut être un  
neurone d'une  
couche intermédiaire

52

On peut « fabriquer » une image qui activera  
maximalemen t un neurone

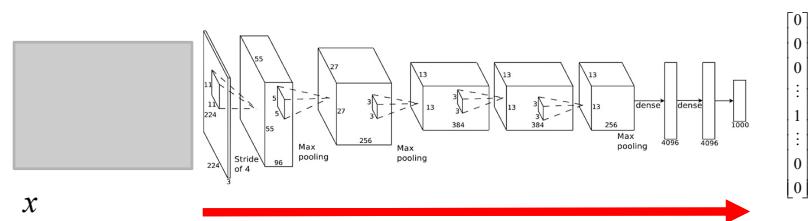
**Étape 2:** propagation avant jusqu’au neurone d’intérêt



53

On peut « fabriquer » une image qui activera  
maximalemen t un neurone

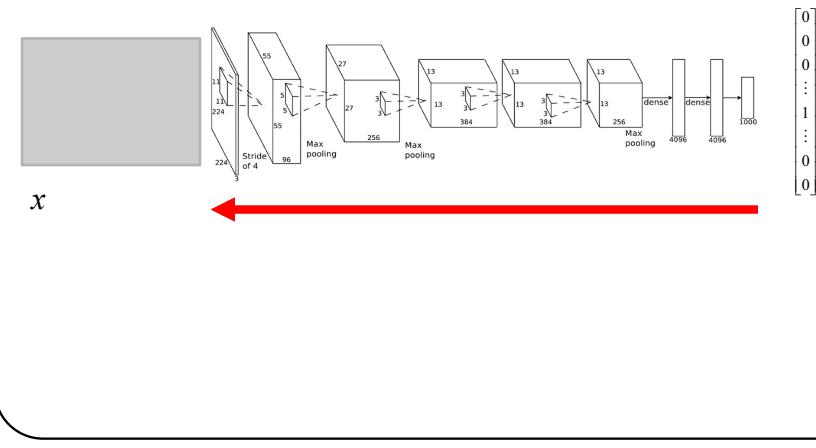
**Étape 3:** forcer le neurone d’intérêt à 1 et les autres à 0



54

On peut « fabriquer » une image qui activera maximalement un neurone

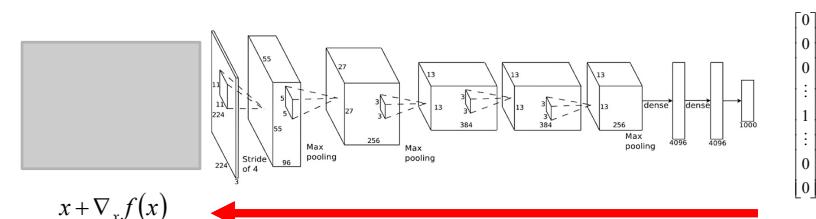
**Étape 4:** rétro propager le gradient jusqu'à l'image  $x$



55

On peut « fabriquer » une image qui activera maximalement un neurone

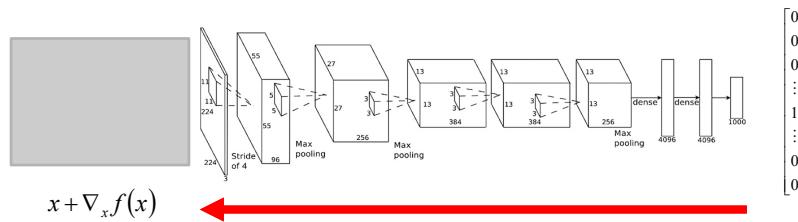
**Étape 5:** ajouter le gradient à l'image  $x$  : ascension du gradient



56

On peut « fabriquer » une image qui activera maximalement un neurone

**Étape 5:** ajouter le gradient à l'image  $x$  : ascension du gradient



$$x^* = \arg \max f(x)$$

57

On peut « fabriquer » une image qui activera maximalement un neurone

**Étape 5:** ajouter le gradient à l'image  $x$  : ascension du gradient

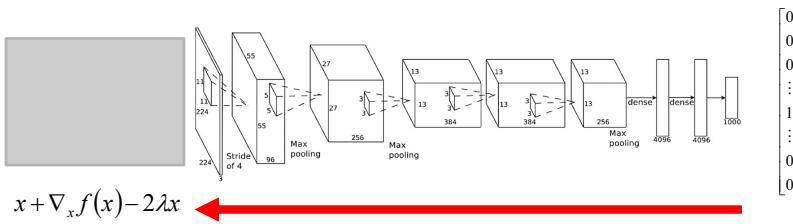
Afin de s'assurer que l'image produite soit lisse, on rajoute un terme de régularisation, souvent de type L2

$$x^* = \arg \max f(x) - \lambda \|x\|^2$$

58

On peut « fabriquer » une image qui activera maximalement un neurone

**Étape 5:** ajouter le gradient à l'image  $I$ : ascension du gradient

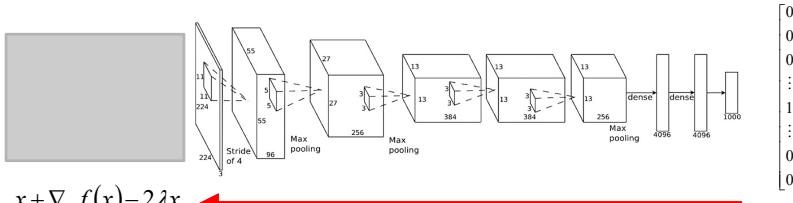


$$x + \nabla_x f(x) - 2\lambda x$$

$$x^* = \arg \max f(x) - \lambda \|x\|^2$$

59

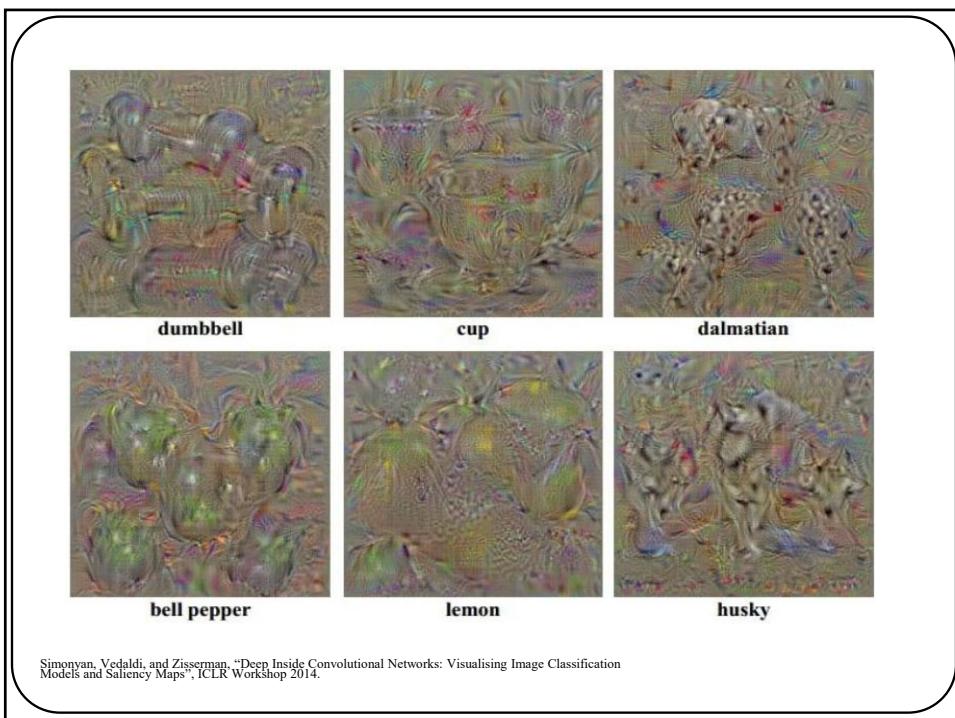
On peut « fabriquer » une image qui activera maximalement un neurone



$$x + \nabla_x f(x) - 2\lambda x$$

**NOTE IMPORTANTE:** pour cette opération, les poids du réseau sont gelés seule l'image d'entrée est modifiée

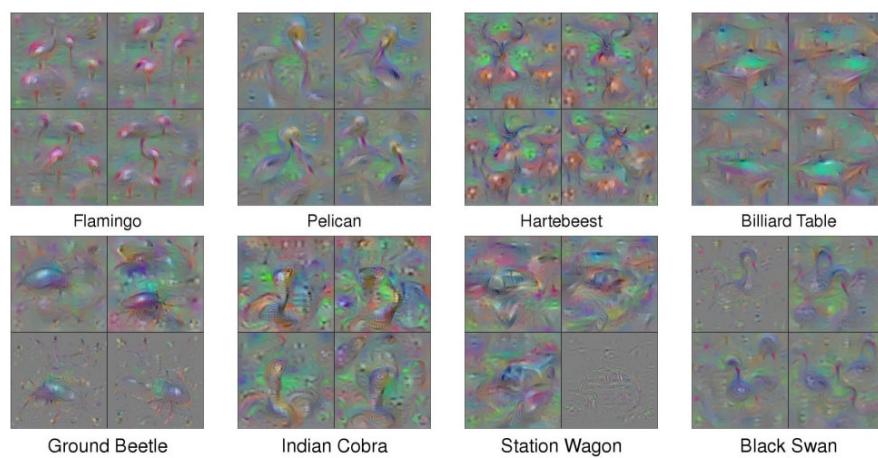
60



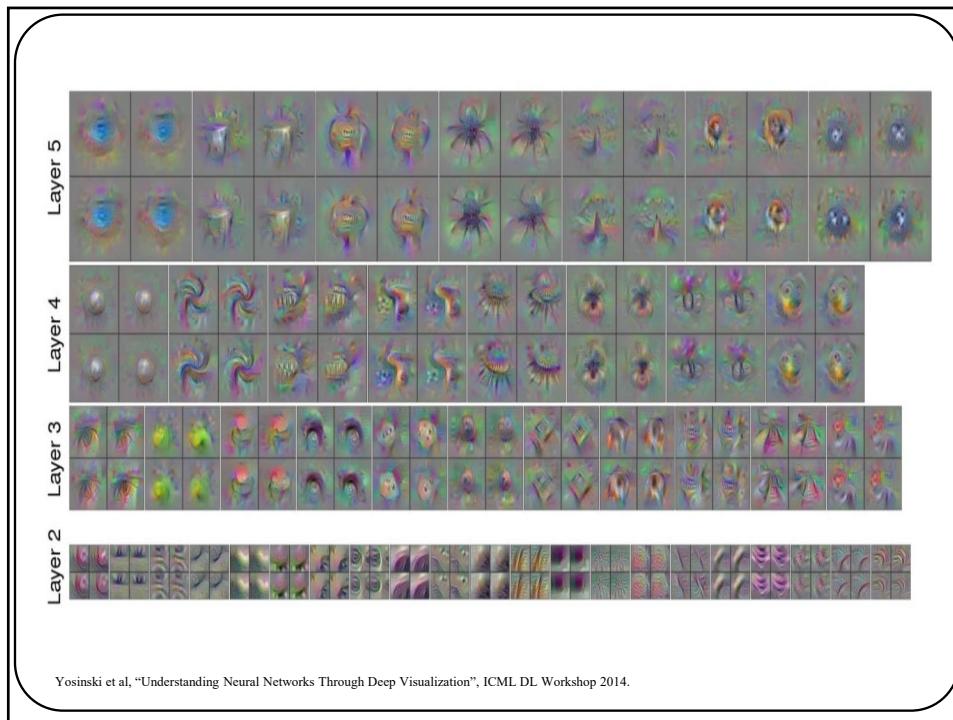
61

On peut améliorer les résultats. À chaque itération:

- (1) Ajouter un **flou gaussien** à l'image à chaque itération
- (2) **Forcer à 0** les pixels ayant une petite valeur



62



63

Et la recherche continue!

La visualisation de réseaux de neurones est un sujet de recherche actif!

 Neuron $\text{layer}_n[x, y, z]$	 Channel $\text{layer}_n[:, :, z]$	 Layer/DeepDream $\text{layer}_n[:, :, :]^2$	 Class Logits $\text{pre\_softmax}[k]$	 Class Probability $\text{softmax}[k]$
---	--	--	--	--

<https://distill.pub/2017/feature-visualization/>

64

Et la recherche continue!

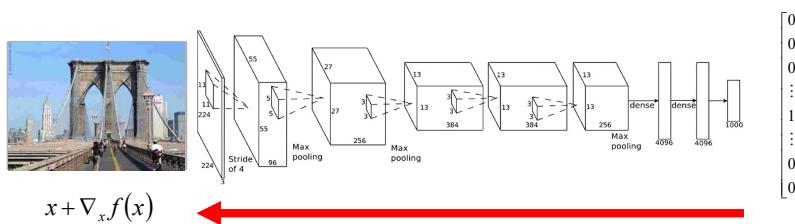
La visualisation de réseaux de neurones est un sujet de recherche actif!



<https://distill.pub/2017/feature-visualization/>

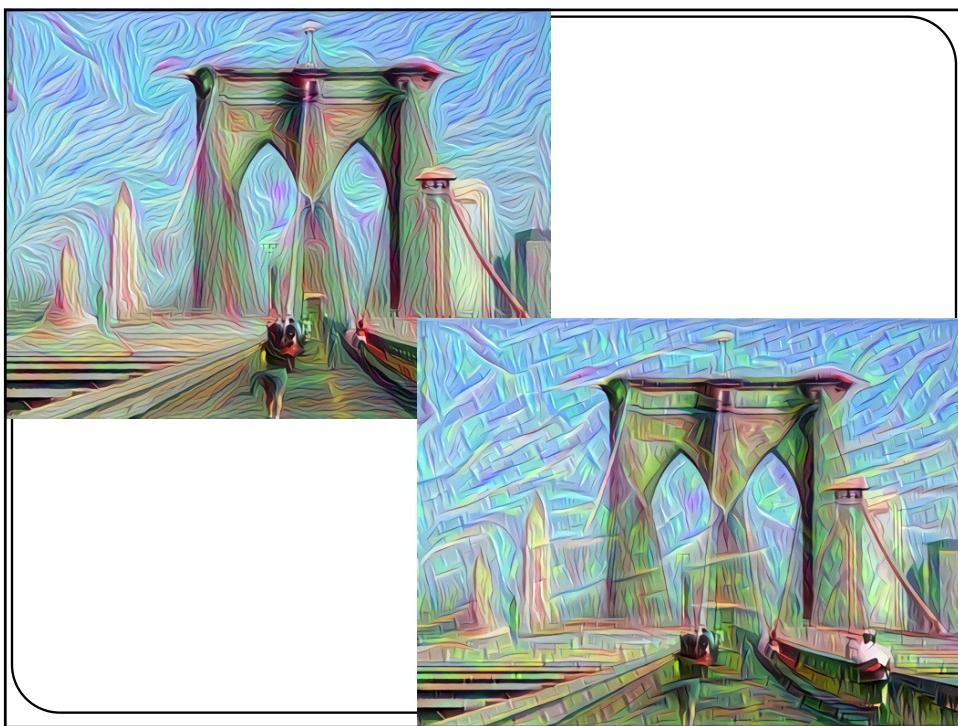
65

*Deep dream* : même opération mais partant d'une image réelle

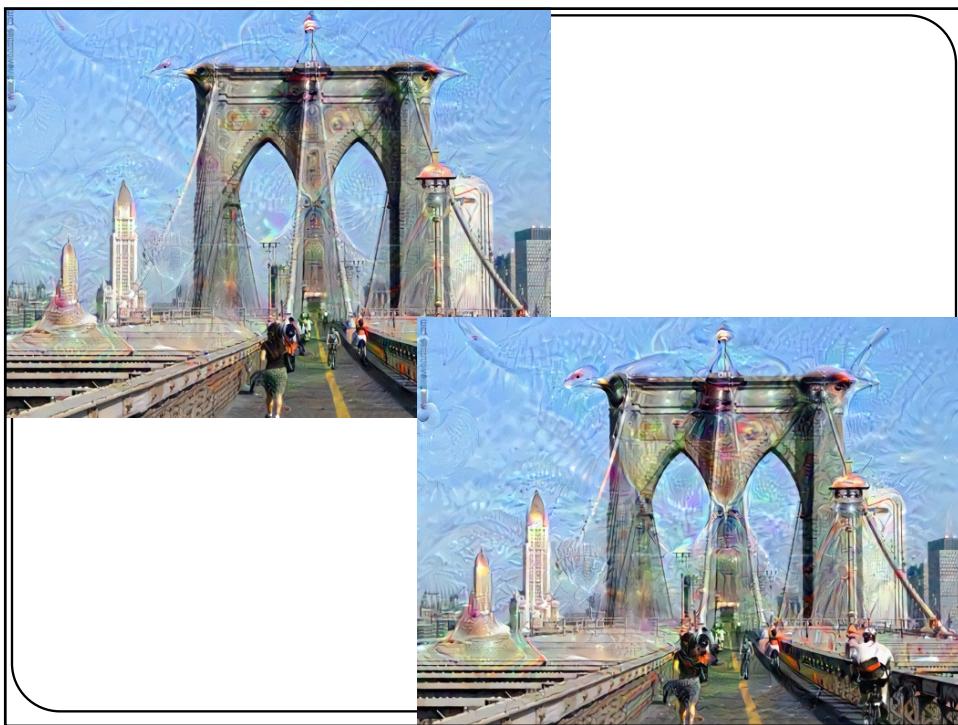


**NOTE IMPORTANTE:** pour cette opération, les poids du réseau sont gelés seule l'image d'entrée est modifiée

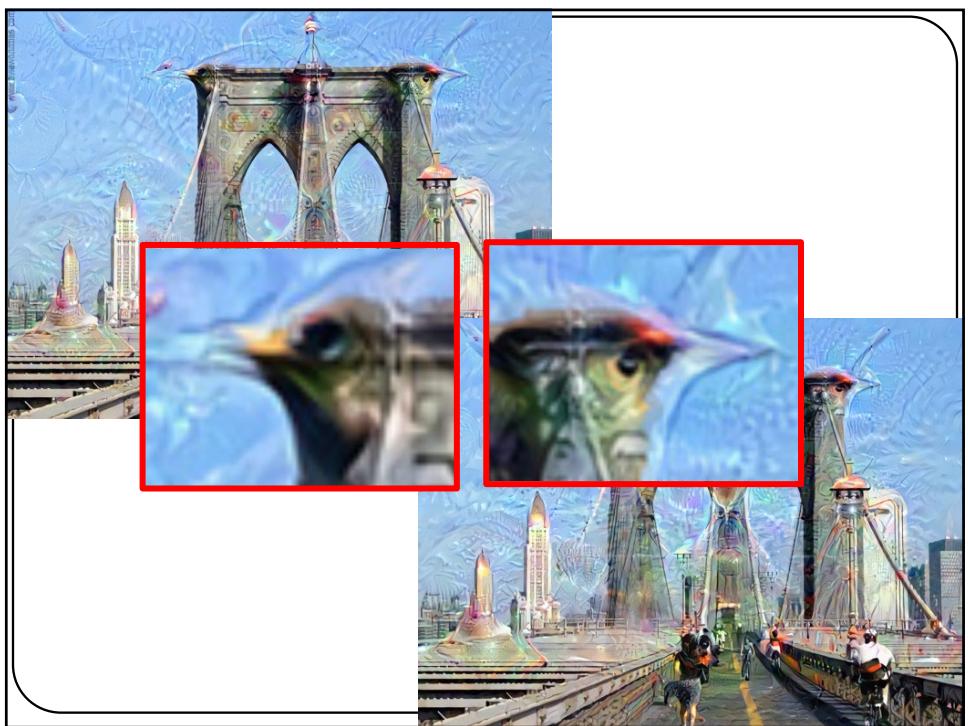
66



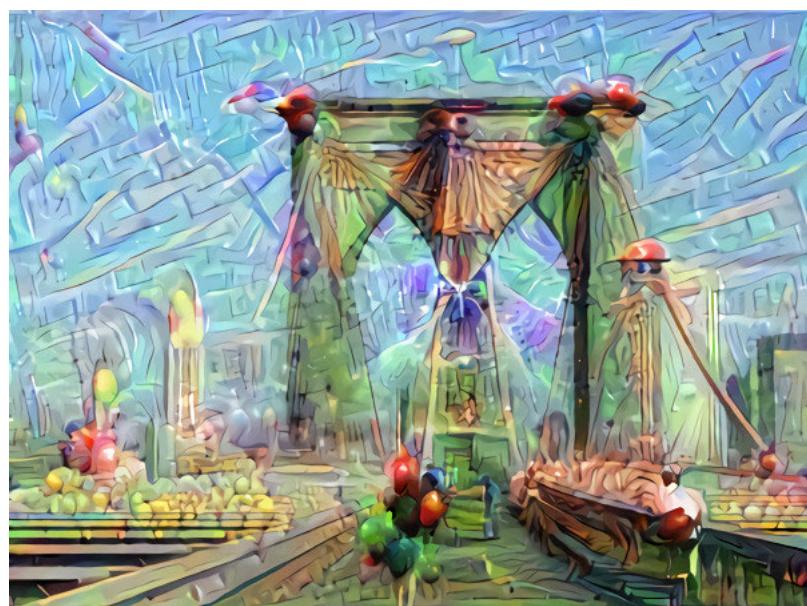
67



68



69



70



[deeprdreamgenerator.com/](http://deeprdreamgenerator.com/)



[deepscopeapp.com/](http://deepscopeapp.com/)