

Apprentissage et intelligence artificielle

Journées gymnasien·ne·s

François Fleuret

<http://fleuret.org>

21-22 novembre 2019



- Qu'est-ce que l'apprentissage statistique
- Pourquoi cela marche-t-il si bien depuis quelques années
- Quels problèmes fondamentaux cela peut-il résoudre
- Quelles sont les applications
- Que fait-on à l'Idiap/EPFL

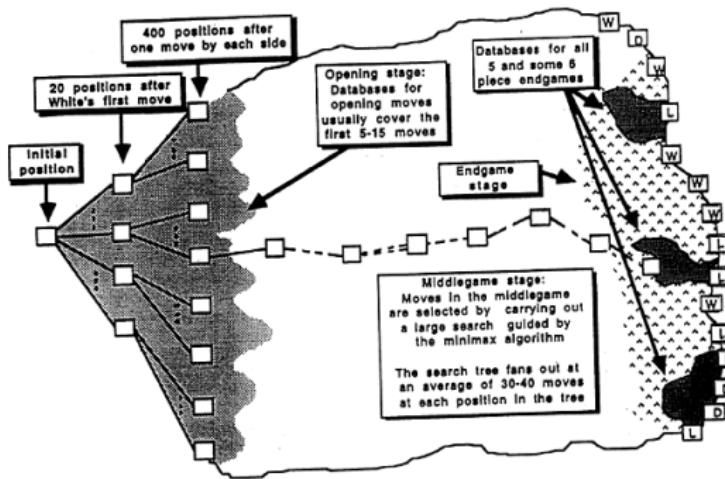
La manière traditionnelle de faire fonctionner un ordinateur consiste à lui dire exactement quoi faire à l'aide d'un programme

```
n = 15345

while n > 1:
    for k in range(2, n+1):
        if n%k == 0:
            print(k)
            n = n // k
            break
```

Historiquement, les premières méthodes d'Intelligence Artificielle reposaient sur le même principe pour des tâches de décisions médicales, de jeux de stratégie, ou de vision par ordinateur.

Chess game tree

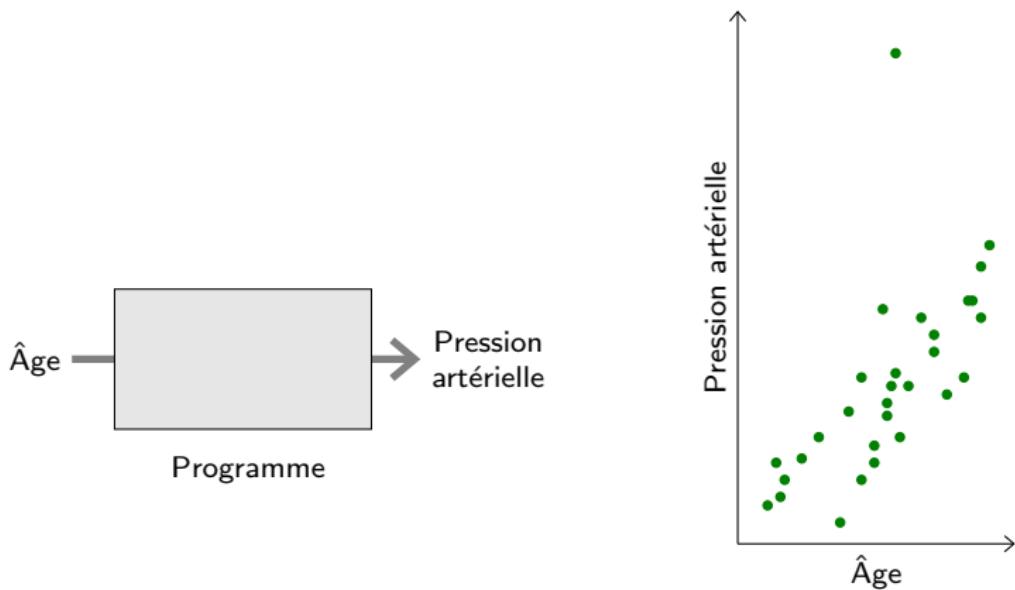


(Newborn, 1996)

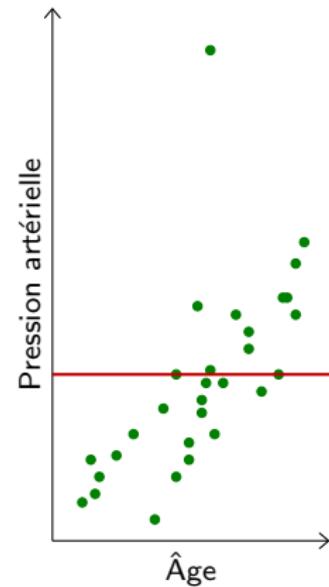
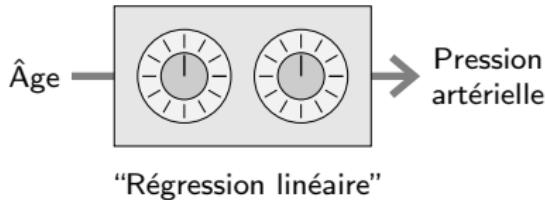
L'idée fondamentale de l'apprentissage automatique ("machine learning") est de régler les paramètres d'un programme pour le faire fonctionner sur des exemples.



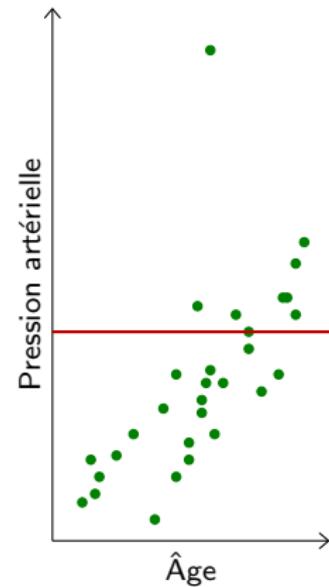
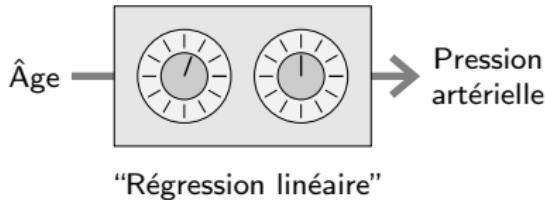
L'idée fondamentale de l'apprentissage automatique ("machine learning") est de régler les paramètres d'un programme pour le faire fonctionner sur des exemples.



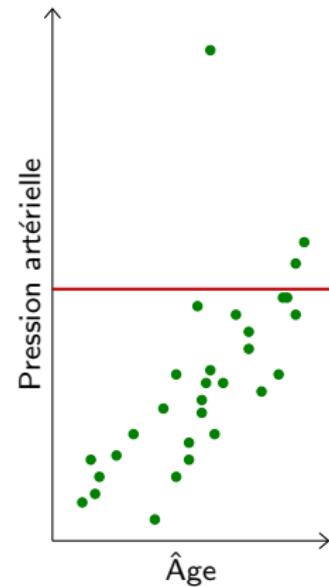
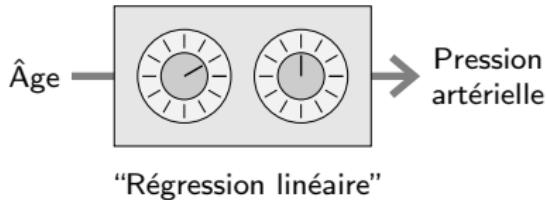
L'idée fondamentale de l'apprentissage automatique ("machine learning") est de régler les paramètres d'un programme pour le faire fonctionner sur des exemples.



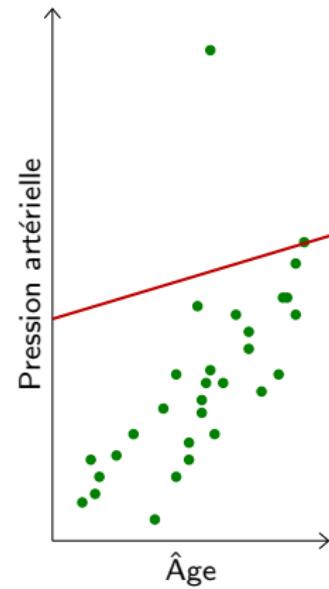
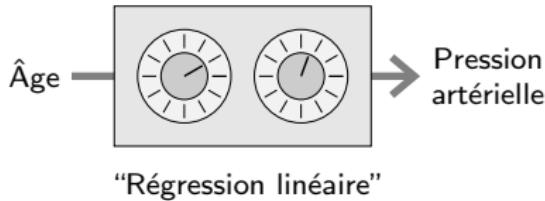
L'idée fondamentale de l'apprentissage automatique ("machine learning") est de régler les paramètres d'un programme pour le faire fonctionner sur des exemples.



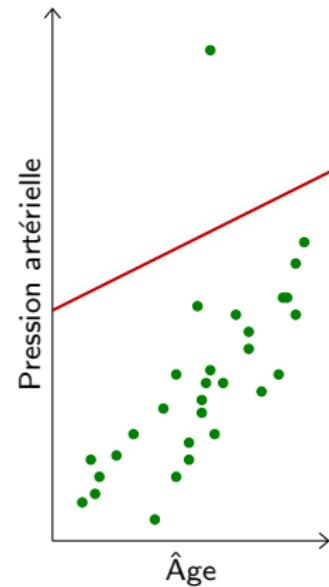
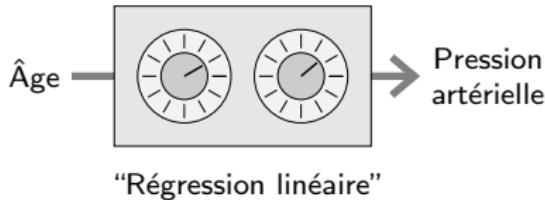
L'idée fondamentale de l'apprentissage automatique ("machine learning") est de régler les paramètres d'un programme pour le faire fonctionner sur des exemples.



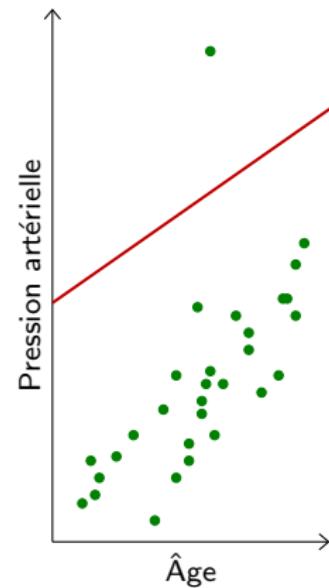
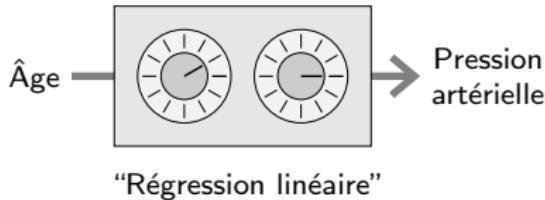
L'idée fondamentale de l'apprentissage automatique ("machine learning") est de régler les paramètres d'un programme pour le faire fonctionner sur des exemples.



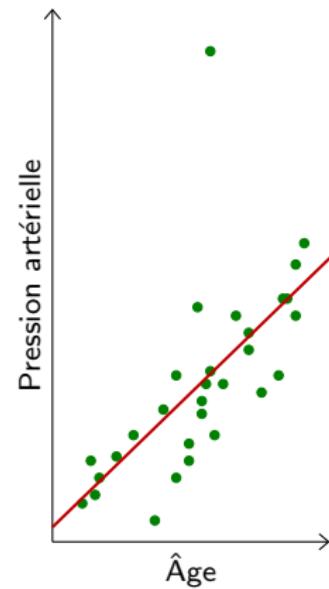
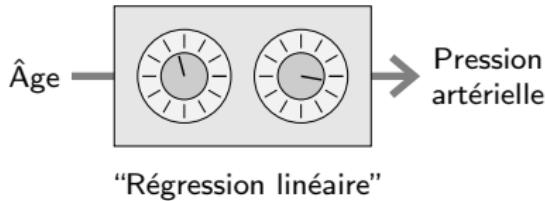
L'idée fondamentale de l'apprentissage automatique ("machine learning") est de régler les paramètres d'un programme pour le faire fonctionner sur des exemples.



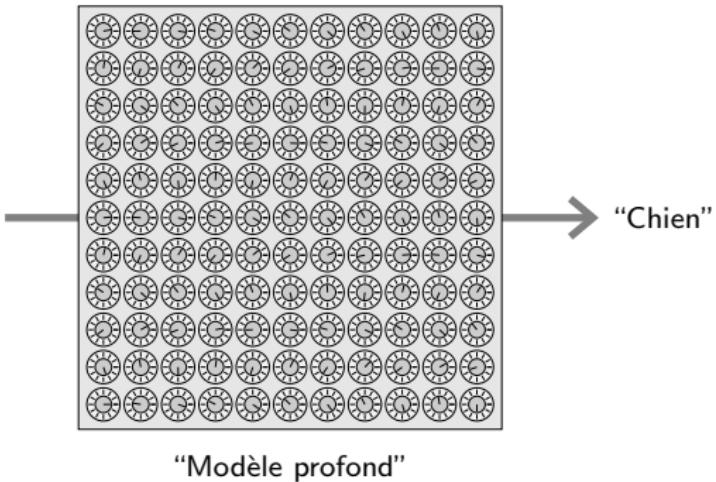
L'idée fondamentale de l'apprentissage automatique ("machine learning") est de régler les paramètres d'un programme pour le faire fonctionner sur des exemples.



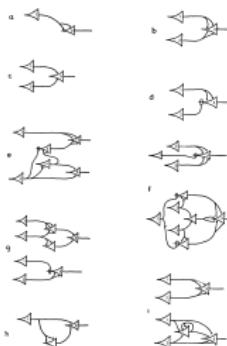
L'idée fondamentale de l'apprentissage automatique ("machine learning") est de régler les paramètres d'un programme pour le faire fonctionner sur des exemples.



La même idée se généralise à des problèmes de prédiction complexes.

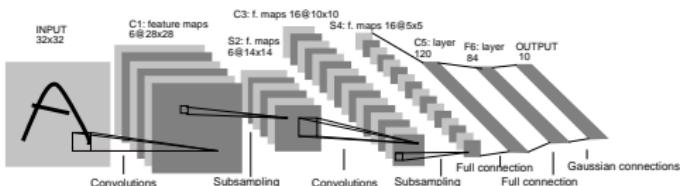


Les modèles les plus performants, dit “profonds”, sont très proches des réseaux de neurones artificiels “traditionnels.”



- 1943 – McCulloch et Pitts modèlent un réseau de neurones.
- 1949 – Hebb propose une règle d'apprentissage.
- 1951 – Minsky crée le premier réseau de neurones artificiel.
- 1958 – Rosenblatt crée un neurone qui classe des images.
- 1959 – Hubel et Wiesel analysent le cortex visuel du chat.
- 1982 – Werbos propose la rétro-propagation de l'erreur.

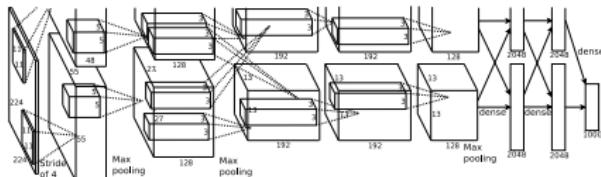
LeNet-5



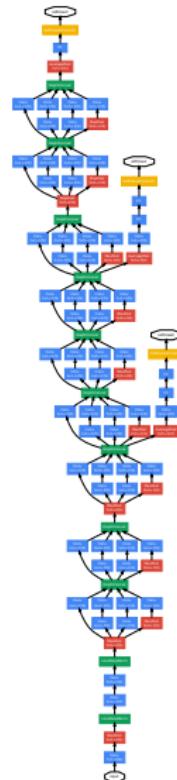
(LeCun et al., 1998)

... 1990–2010 “éclipse des réseaux de neurones” ...

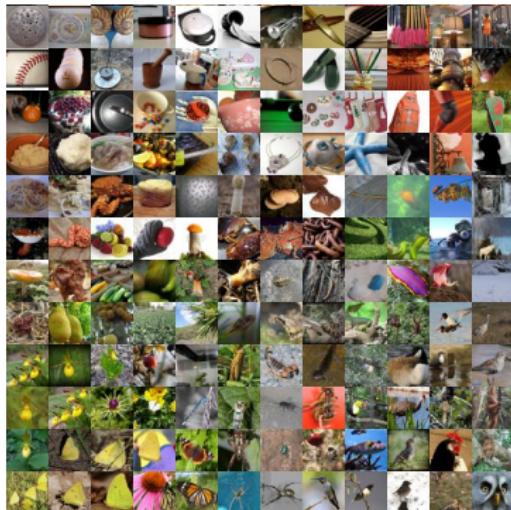
AlexNet



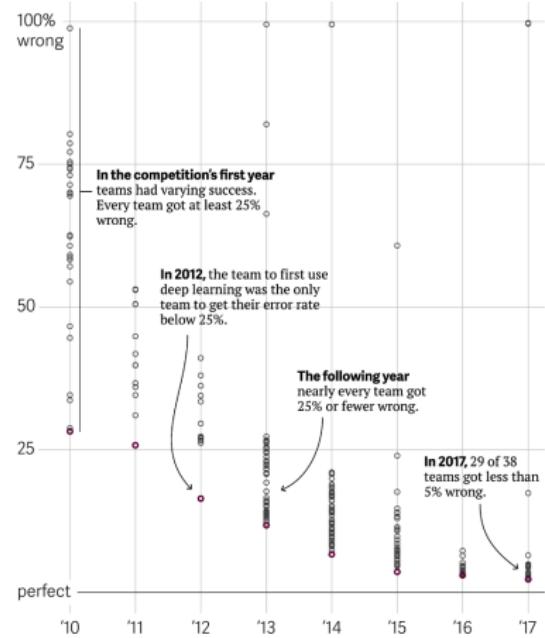
(Krizhevsky et al., 2012)



(Szegedy et al., 2015)



ImageNet

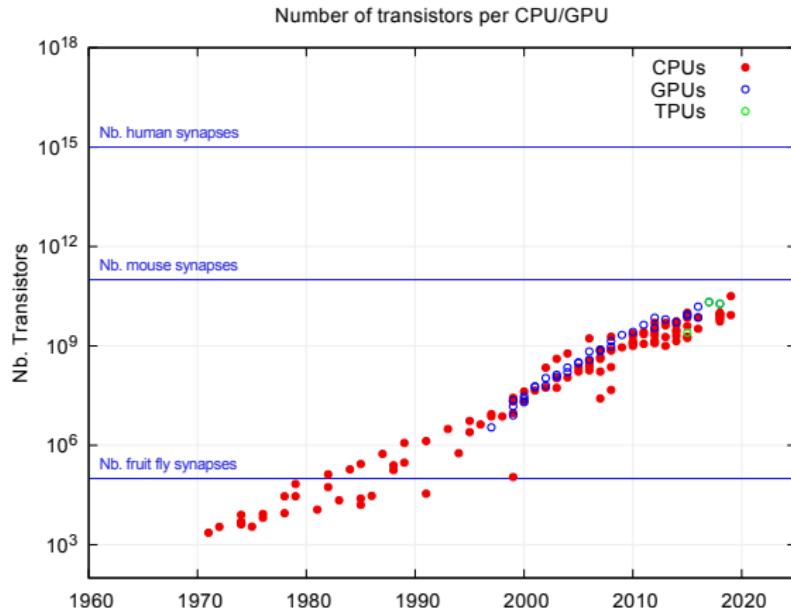


(Gershgorin, 2017)

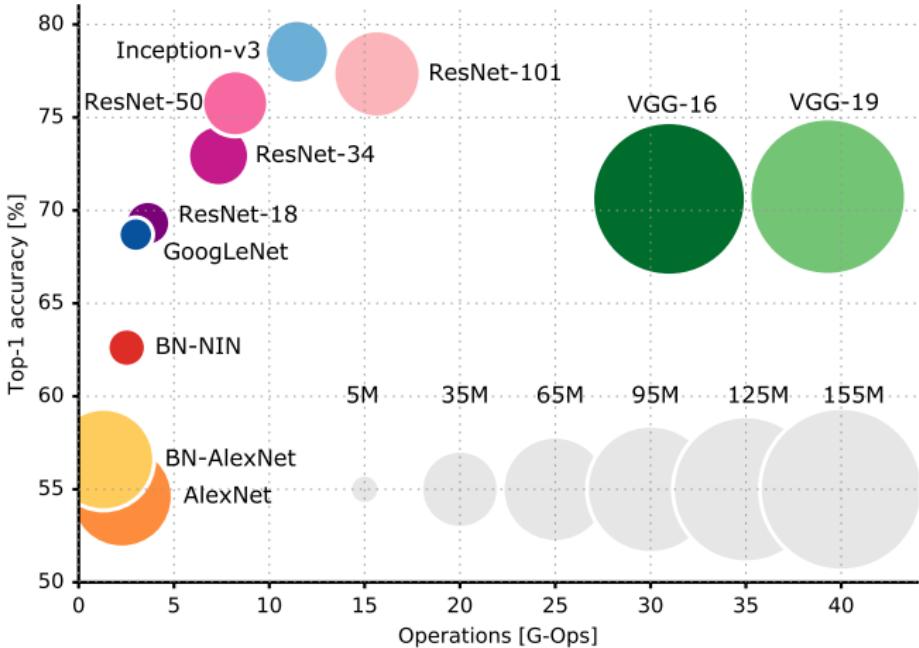
Les raisons des progrès récents et spectaculaires de l'IA sont multiples:

- Cinq décennies de recherche en intelligence artificielle,
- des ordinateurs développés pour d'autres raisons,
- d'énormes quantités de données grâce à "internet",
- une culture de développement collaboratif de logiciels libres,
- des ressources et des efforts de grands groupes industriels.

En particulier la puissance de calcul et les capacités de stockage des ordinateurs n'ont cessé de croître exponentiellement depuis près de 50 ans.

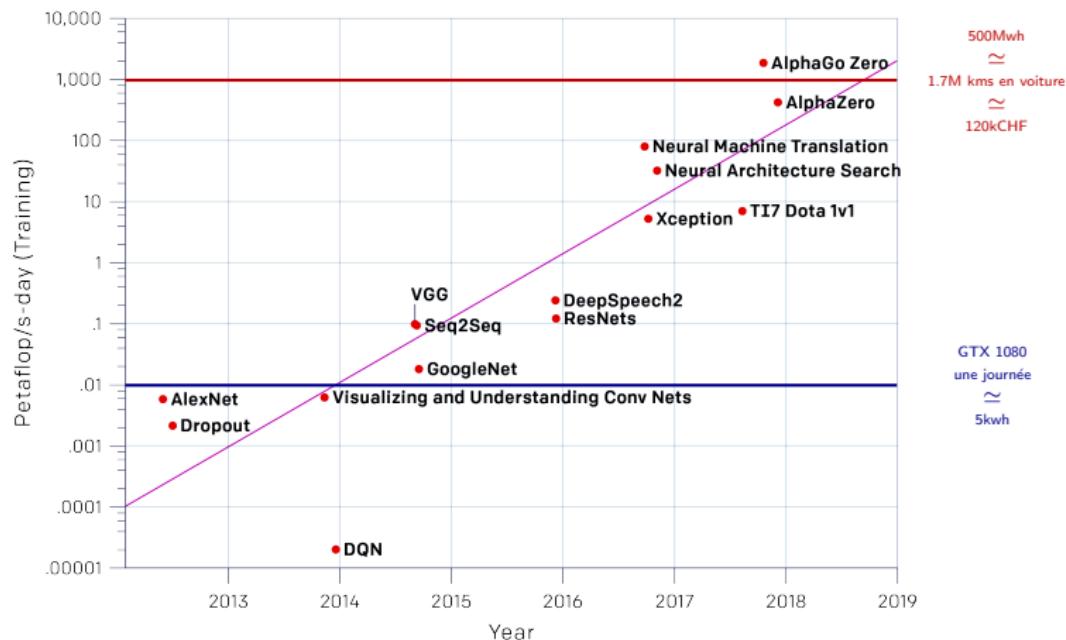


Un PC standard peut effectuer 10'000 milliards d'opérations scalaires par seconde, et stocker 4'000 milliards de caractères.



(Canziani et al., 2016)

AlexNet to AlphaGo Zero: A 300,000x Increase in Compute



1 petaflop/s-day \simeq 100 GPUs pendant un jour, \simeq 100CHF d'électricité

Utilisation et applications

Le domaine demande une bonne connaissance dans des domaines très variés:

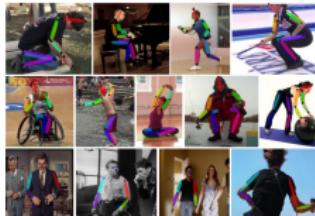
- Mathématiques
 - Algèbre linéaire
 - Probabilités
 - Traitement du signal
 - Calcul différentiel
 - Optimisation
- Informatique
 - Algorithmique
 - Parallélisme
 - Programmation haut niveau (Python)
 - Programmation bas niveau (assembleur / cuda)

Néanmoins, les librairies de “Deep Learning” tells que PyTorch ou TensorFlow simplifient énormément l’utilisation de ces techniques.

Les applications vont du traitement d'images à celui de la langue.



Détection d'objets



Estimation de poses



Planification de l'action



Stratégie



Description d'images

- I: Jane went to the hallway.
- I: Mary walked to the bathroom.
- I: Sandra went to the garden.
- I: Daniel went back to the garden.
- I: Sandra took the milk there.
- Q: Where is the milk?
- A: garden

Compréhension de textes

MNIST

1 1 8 3 6 1 0 3 1 0 0 1 1 2 7 3 0 4 6 5
2 6 4 7 1 8 9 9 3 0 7 1 0 2 0 3 5 4 6 5
8 6 3 7 5 8 0 9 1 0 3 1 2 2 3 3 6 4 7 5
0 6 2 7 9 8 5 9 2 1 1 4 4 5 6 4 1 2 5 3
9 3 9 0 5 9 6 5 7 4 1 3 4 0 4 8 0 4 3 6
8 7 6 0 9 7 5 7 2 1 1 6 8 9 4 1 5 2 2 9
0 3 9 6 7 2 0 3 5 4 3 6 5 8 9 5 4 7 4 2
1 3 4 8 9 1 9 2 8 7 9 1 8 7 4 1 3 1 1 0
2 3 9 4 9 2 1 6 8 4 1 7 4 4 9 2 8 7 2 4
4 2 1 9 7 2 8 7 6 9 2 8 3 8 1 6 5 1 1 0
4 0 9 1 1 2 4 3 2 7 3 8 6 9 0 5 6 0 7 6
2 6 4 5 8 3 1 5 1 9 2 7 4 4 8 1 5 8 9
5 6 7 9 9 3 7 0 9 0 6 6 2 3 9 0 7 5 4 8
0 9 4 1 2 8 7 1 2 6 1 0 3 0 1 1 8 2 0 3
9 4 0 5 0 6 1 7 7 8 1 9 2 0 5 1 2 2 7 3
5 4 4 7 1 8 3 9 6 0 3 1 1 2 6 3 5 7 6 8
2 9 5 8 5 7 4 1 1 3 1 7 5 5 5 2 5 8 7 0
9 7 7 5 0 9 0 0 8 9 2 4 8 1 6 1 6 5 1 8
3 4 0 5 5 8 3 6 2 3 9 2 1 1 5 2 1 3 2 8
7 3 7 2 4 6 9 7 2 4 2 8 1 1 3 8 4 0 6 5

(LeCun et al., 1998)

```

model = nn.Sequential(
    nn.Conv2d(1, 32, 5),
    nn.ReLU(),
    nn.MaxPool2d(3),
    nn.Conv2d(32, 64, 5),
    nn.ReLU(),
    nn.MaxPool2d(2),
    Shape1D(),
    nn.Linear(256, 256),
    nn.ReLU(),
    nn.Linear(256, 10)
)

criterion = nn.CrossEntropyLoss()

optimizer = torch.optim.SGD(model.parameters(), lr = 1e-2)

for e in range(nb_epochs):
    for input, target in data_loader_iterator(train_loader):
        output = model(input)
        loss = criterion(output, target)
        optimizer.zero_grad()
        loss.backward()
        optimizer.step()

```

Temps d'apprentissage <10s, erreur \simeq 1%

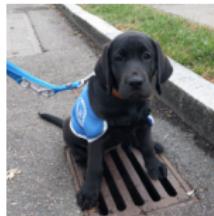


```
import PIL, torch, torchvision

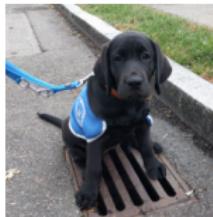
img = torchvision.transforms.ToTensor()(PIL.Image.open('blacklab.jpg'))
img = img.view(1, img.size(0), img.size(1), img.size(2))
img = 0.5 + 0.5 * (img - img.mean()) / img.std()

alexnet = torchvision.models.alexnet(pretrained = True)
alexnet.eval()
output = alexnet(Variable(img))
scores, indexes = output.data.view(-1).sort(descending = True)

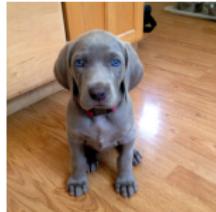
class_names = eval(open('imagenet1000_clsid_to_human.txt', 'r').read())
for k in range(15):
    print('#{:d} {:.02f} {}'.format(k, scores[k], class_names[indexes[k]]))
```



- #1 (12.26) Weimaraner
- #2 (10.95) Chesapeake Bay retriever
- #3 (10.87) Labrador retriever
- #4 (10.10) Staffordshire bullterrier, Staffordshire bull terrier
- #5 (9.55) flat-coated retriever
- #6 (9.40) Italian greyhound
- #7 (9.31) American Staffordshire terrier, Staffordshire terrier
- #8 (9.12) Great Dane
- #9 (8.94) German short-haired pointer
- #10 (8.53) Doberman, Doberman pinscher
- #11 (8.35) Rottweiler
- #12 (8.25) kelpie



- #1 (12.26) Weimaraner
- #2 (10.95) Chesapeake Bay retriever
- #3 (10.87) Labrador retriever
- #4 (10.10) Staffordshire bullterrier, Staffordshire bull terrier
- #5 (9.55) flat-coated retriever
- #6 (9.40) Italian greyhound
- #7 (9.31) American Staffordshire terrier, Staffordshire terrier
- #8 (9.12) Great Dane
- #9 (8.94) German short-haired pointer
- #10 (8.53) Doberman, Doberman pinscher
- #11 (8.35) Rottweiler
- #12 (8.25) kelpie

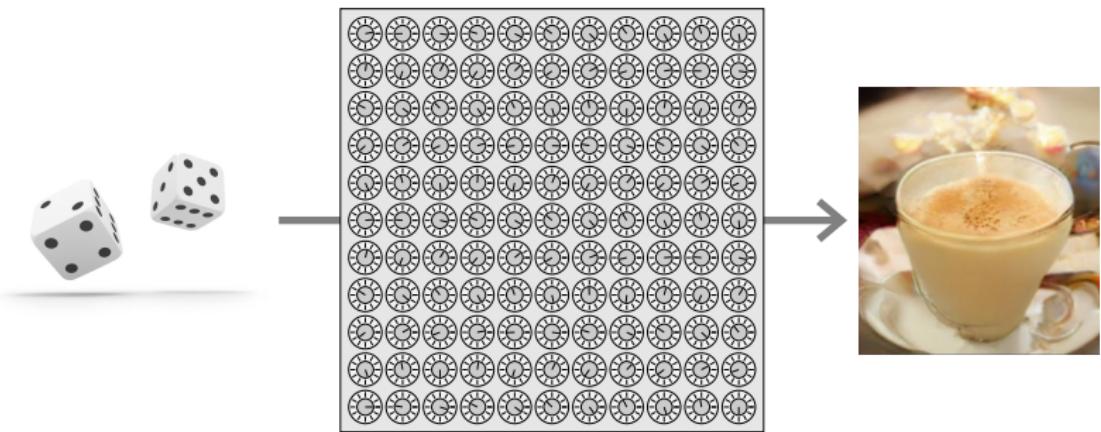


Weimaraner



Chesapeake Bay retriever

Les mêmes méthodes peuvent être adaptées pour générer des images ou du son.



```
from torch import from_numpy, no_grad
from pytorch_pretrained_biggan import BigGAN, one_hot_from_names, \
    truncated_noise_sample, save_as_images

objects = [ 'coffee', 'mushroom', 'military uniform', 'garter snake' ]
cv = from_numpy(one_hot_from_names(objects, batch_size=len(objects)))
nv = from_numpy(truncated_noise_sample(truncation=0.4, batch_size=len(objects)))
model = BigGAN.from_pretrained('biggan-deep-512')
with no_grad(): save_as_images(model(nv, cv, 0.4))
```



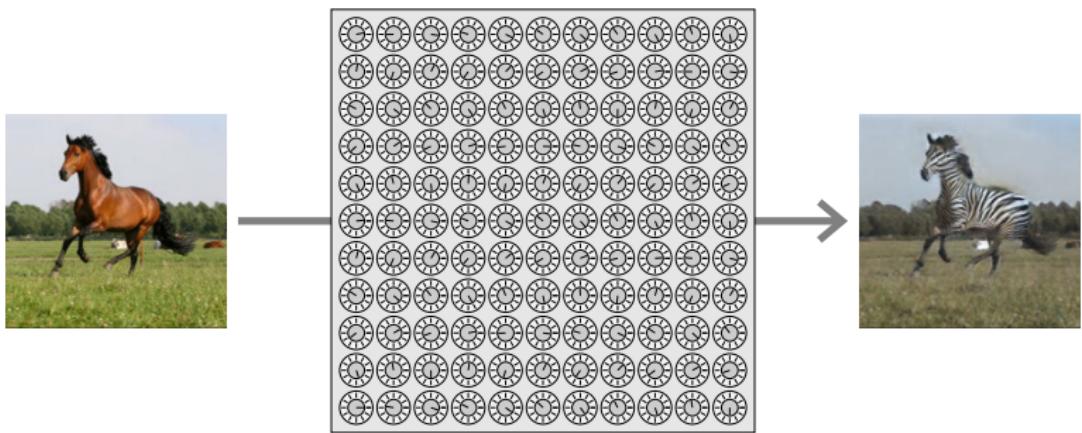


(Brock et al., 2018)



(Karras et al., 2018)

Elles peuvent aussi le faire, étant donné un signal de référence (Mirza and Osindero, 2014; Zhu et al., 2017).





<https://talktotransformer.com/>

The meeting about deep fakes is an important event since it will give consumers and journalists the facts before these companies rush to exploit them. With the meeting, we hope that we will reach a good balance between protecting the legitimate business and being fair to companies that do not follow traditional guidelines. This is a very important issue and is now going to be discussed at many more international conferences. And I can only hope that the government will take the initiative to address it urgently so that consumers get a right to know the true nature of their product."

Performances surhumaines:

- Reconnaissance d'images.
- Lecture de panneaux de signalisation.
- Reconnaissance de visages.
- Go et échecs ("from first principles"), poker.
- Jeux vidéos des années 80.

Performances au niveau des humains:

- Détection de cancers de la peau.
- Compréhension de la parole.

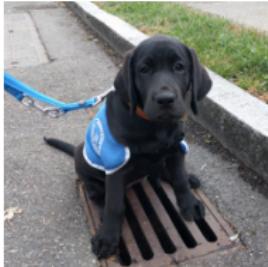
Il est extrêmement difficile de comprendre les modèles actuels, et de prévoir les développements et les progrès possibles de l'IA à 10-20 ans.

Compréhension des modèles

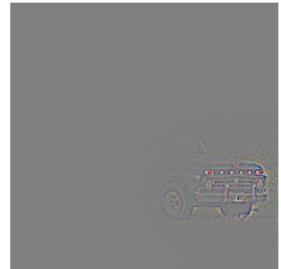
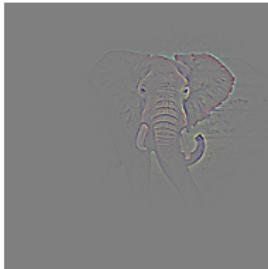
Les classes de fonctions considérées ont des propriétés d'approximateurs universels, et sont en pratiquement extrêmement complexes. Le "fonctionnement" du *f* appris n'est que partiellement compris.

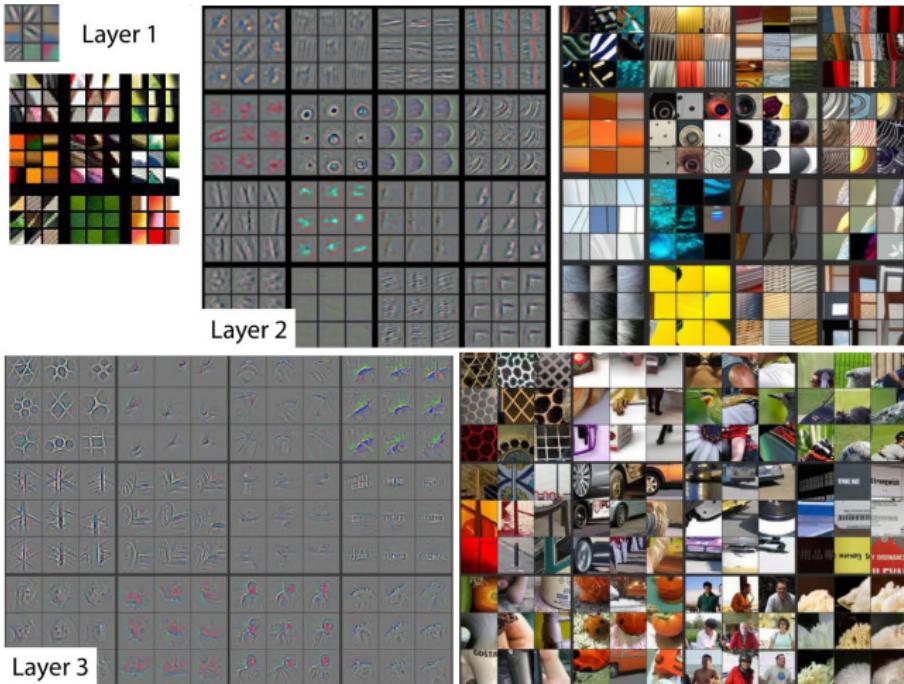
Nombres de techniques ont été développées pour analyser les grandeurs intermédiaires qui sont calculées dans un modèle.

Images originales

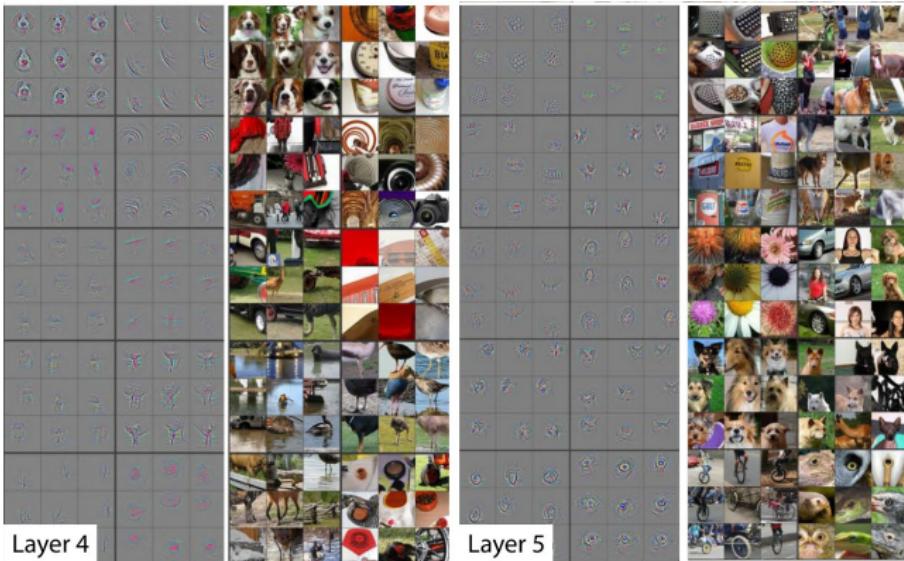


VGG16, rétro-propagation guidée



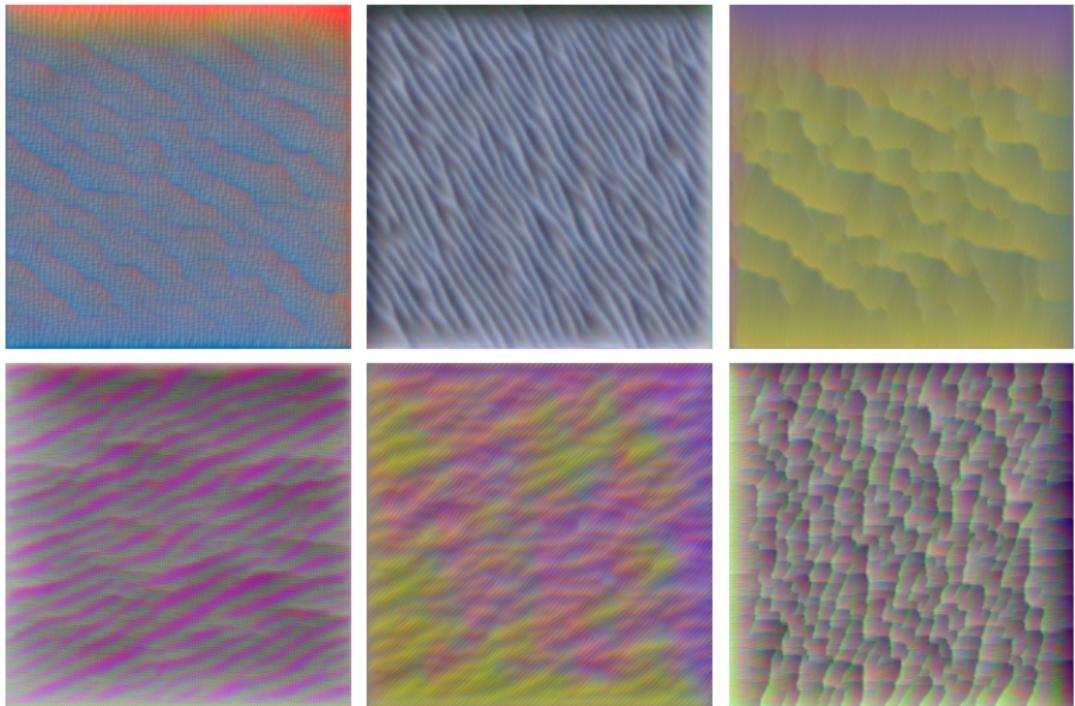


(Zeiler and Fergus, 2014)

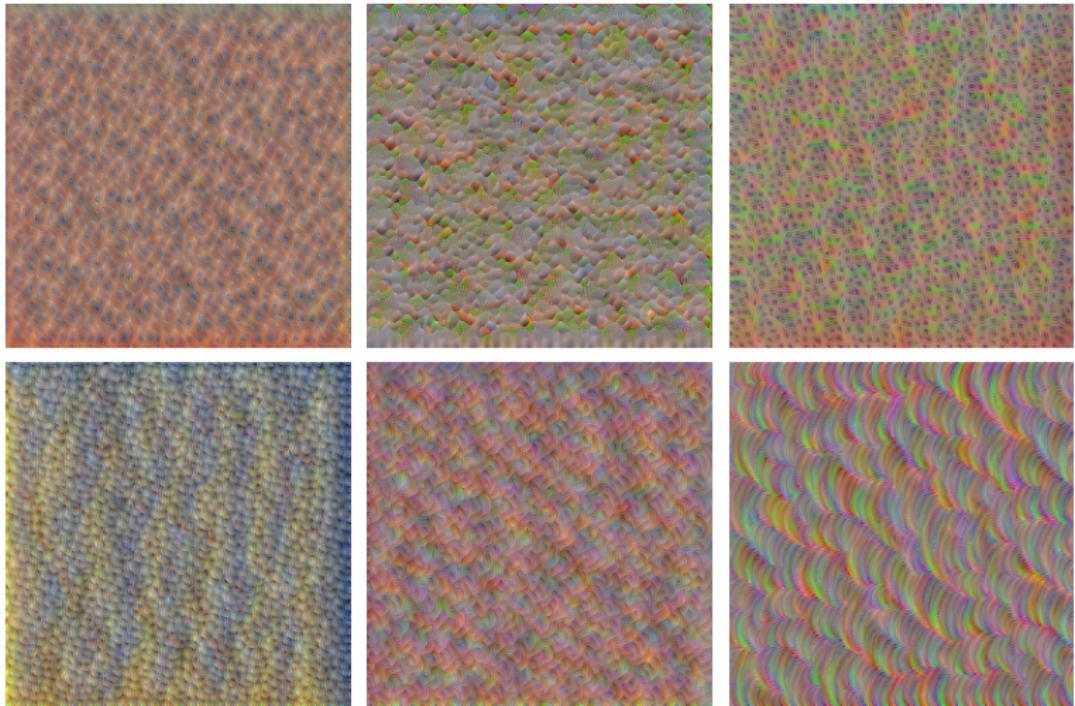


(Zeiler and Fergus, 2014)

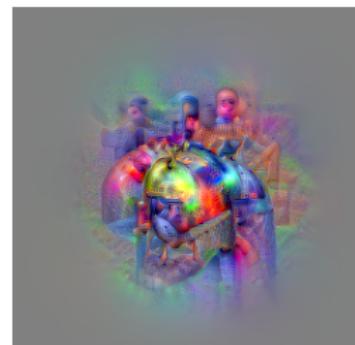
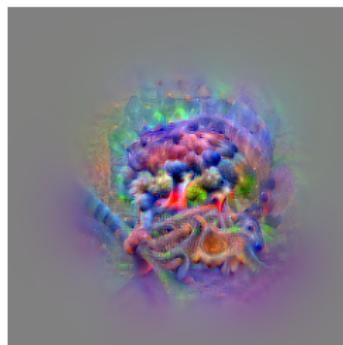
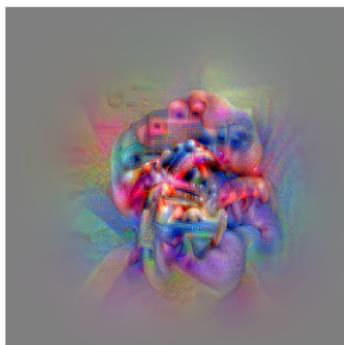
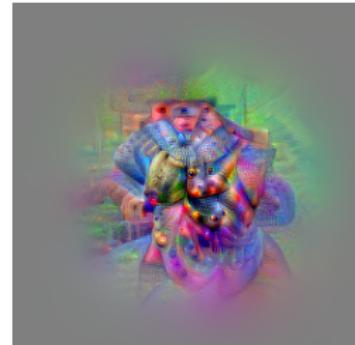
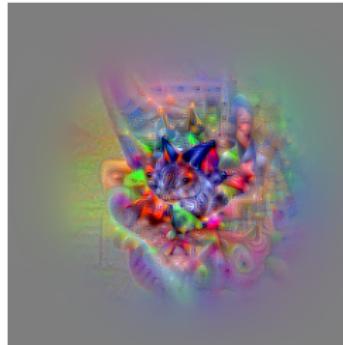
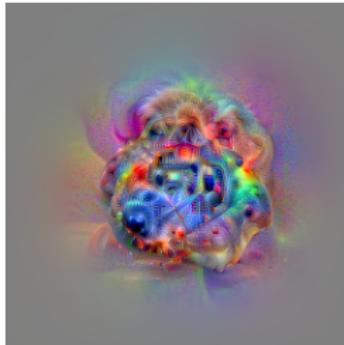
VGG16, maximisation d'un canal de la 4ème couche convolutionnelle



VGG16, maximisation d'un canal de la 7ème couche convolutionnelle



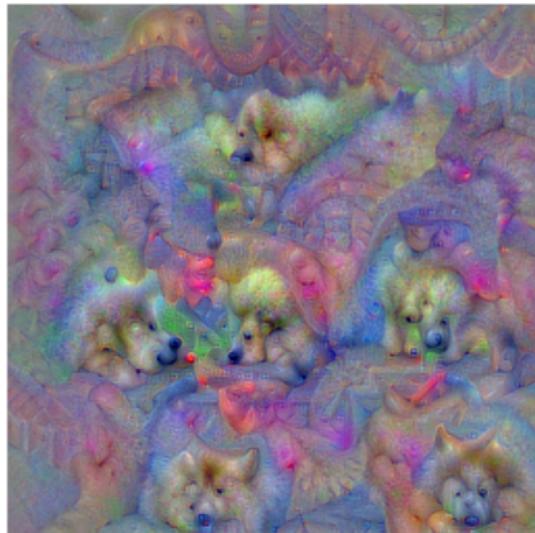
VGG16, maximisation d'une unité de la 13ème couche



VGG16, maximisation d'une unité de la couche de sortie

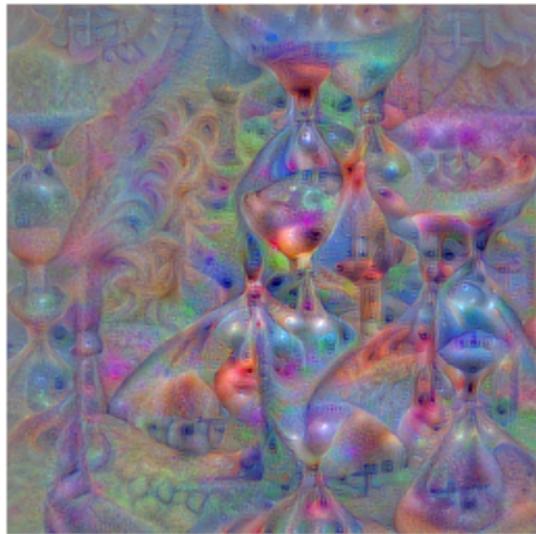


“King crab”

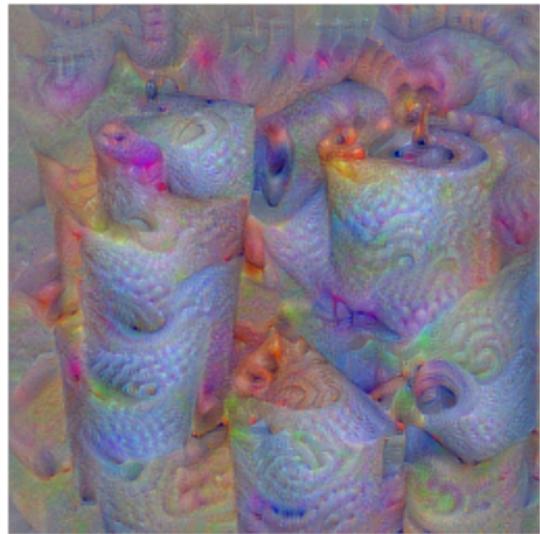


“Samoyed”

VGG16, maximisation d'une unité de la couche de sortie

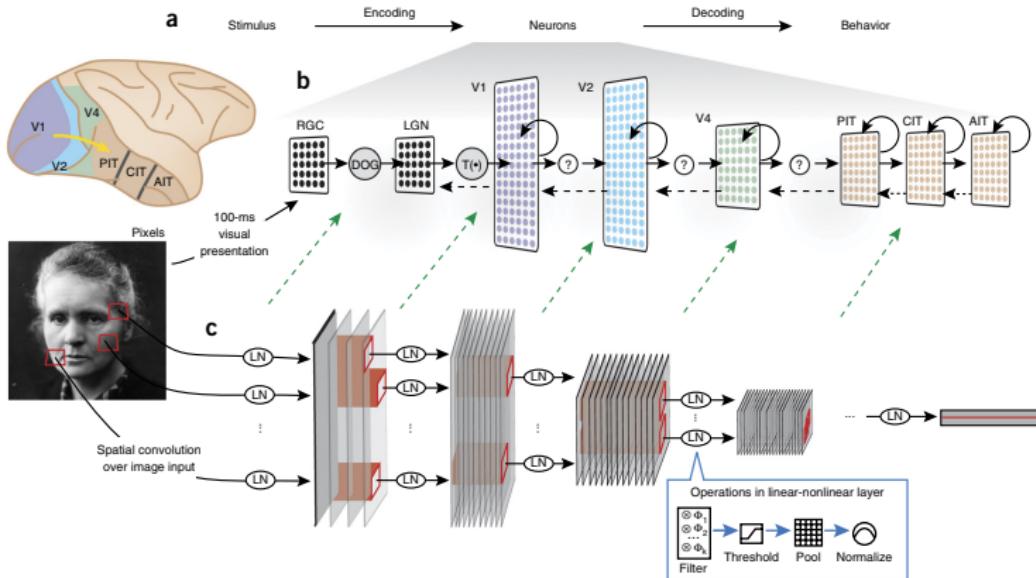


“Hourglass”



“Paper towel”

Relation avec la neurobiologie.



(Yamins and DiCarlo, 2016)



Machine Learning group

François Fleuret



- Créé en 1991, "Institut Dalle Molle d'Intelligence Artificielle Perceptive".



UNIVERSITÉ
DE GENÈVE



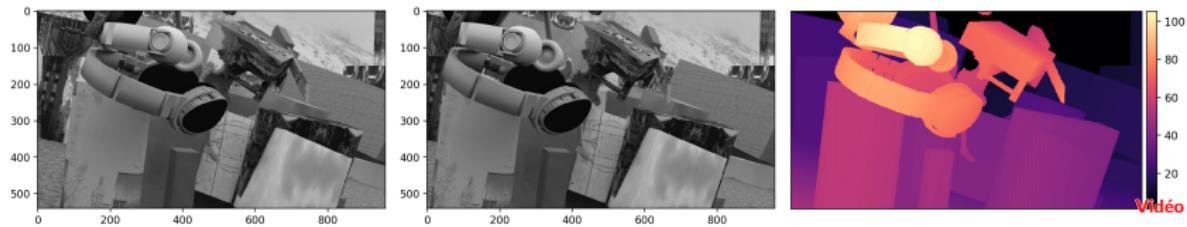
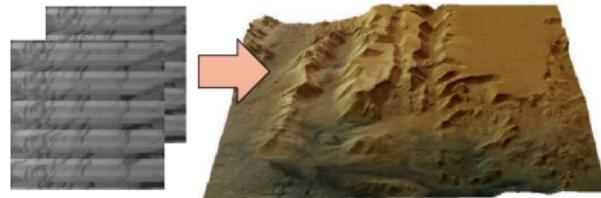
- Situé à Martigny, VS.
- \approx 120 employés.
- 14 groupes de recherche, \approx 40 doctorants, 16 développeurs.



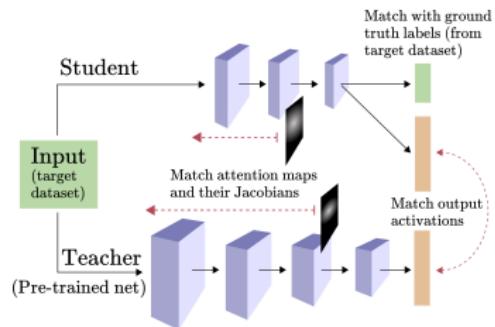
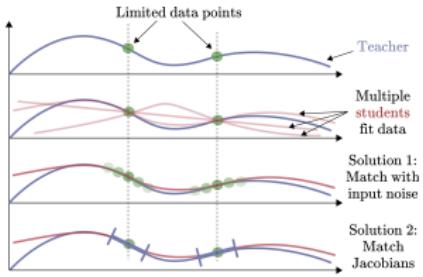
Groupe de recherche en apprentissage automatique.

- Apprentissage statistique et réseaux de neurones.
- Comment contrôler le coût computationnel.
- Réduire l'occupation mémoire.
- Entraîner des modèles à partir d'un petits nombre d'exemples.

Reconstruction stéréo



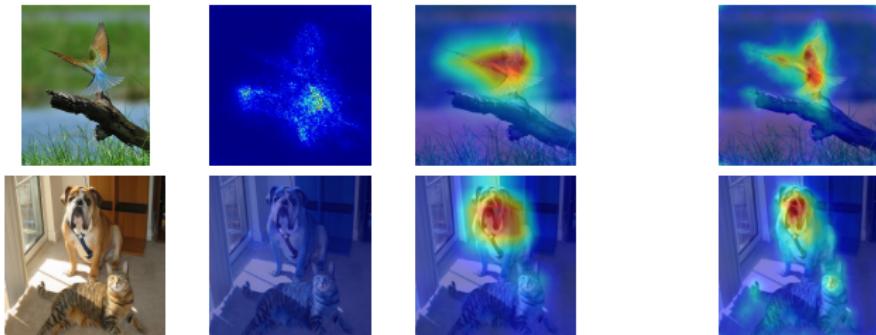
Transfert d'apprentissage et régularisation intelligente



Optimisation pour des méthodes adversariales



Interprétabilité des modèles

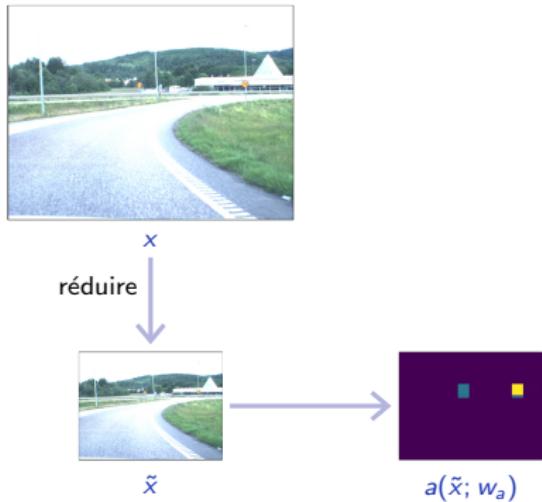


Échantillonnage attentionnel

Pour traiter une image de très grande taille, nous avons développé une méthode qui déterminer quelles parties regarder attentivement.

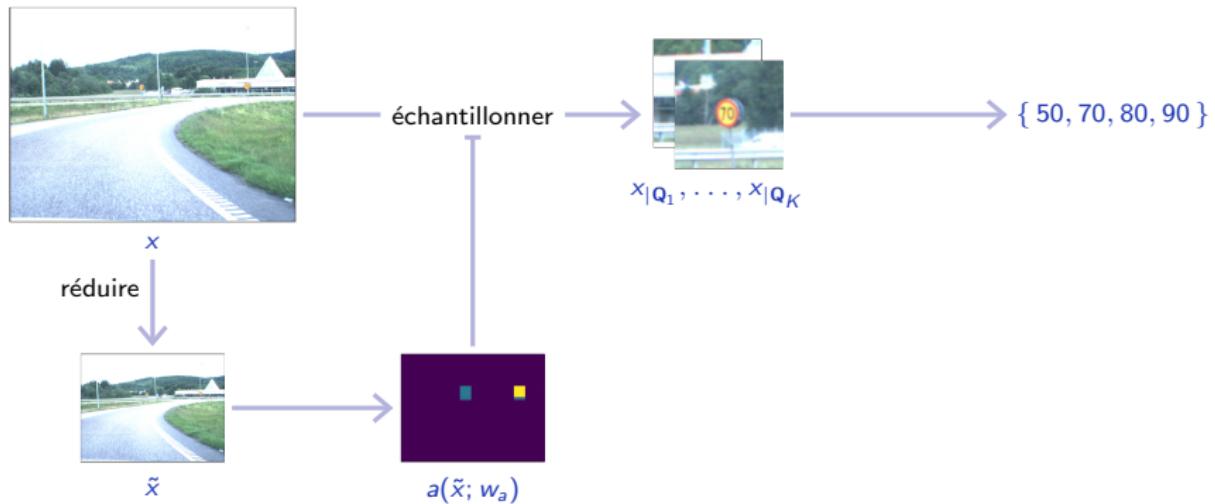
Échantillonnage attentionnel

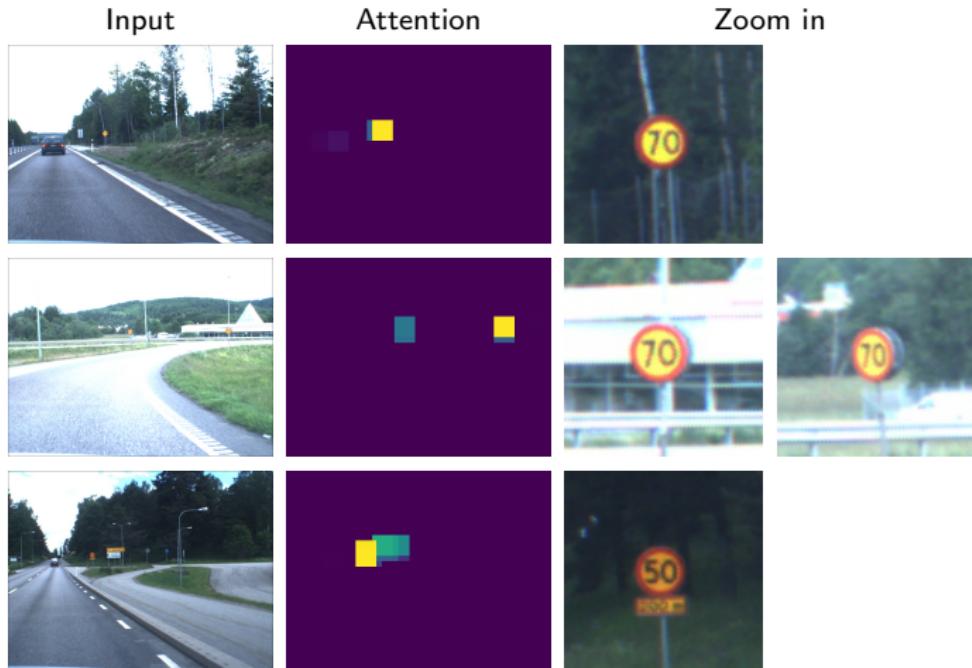
Pour traiter une image de très grande taille, nous avons développé une méthode qui déterminer quelles parties regarder attentivement.



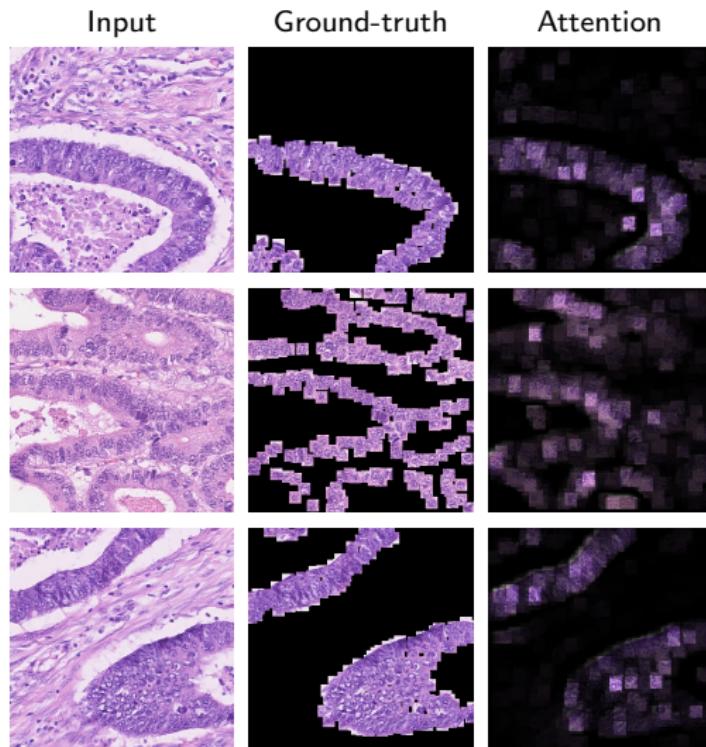
Échantillonnage attentionnel

Pour traiter une image de très grande taille, nous avons développé une méthode qui déterminer quelles parties regarder attentivement.





(Katharopoulos and Fleuret, 2019)



(Katharopoulos and Fleuret, 2019)

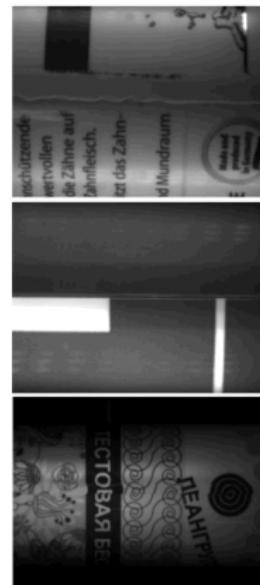
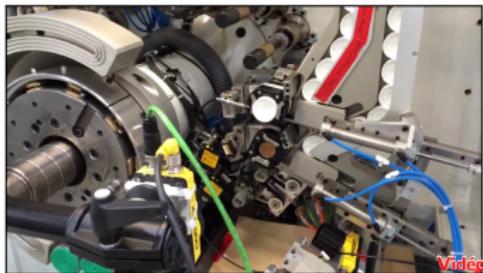
Application: Détection de visages temps réel embarquée



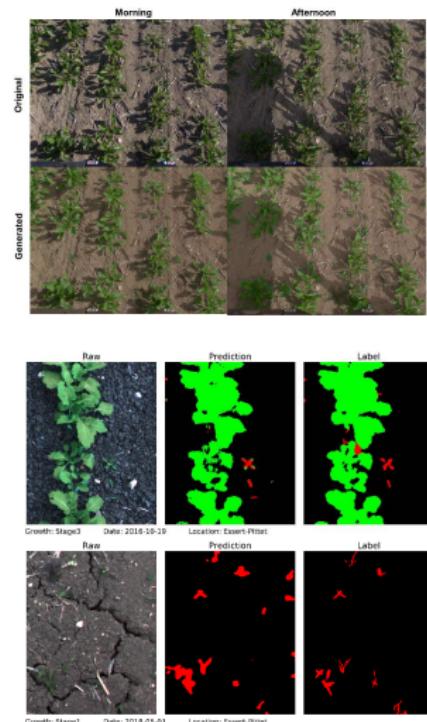
Application: Production de pièces en plastique

Détection de défauts esthétiques

Alignment



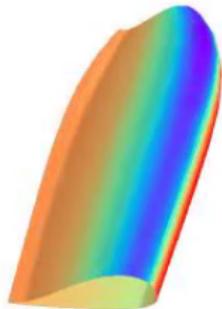
Application: Détection de mauvaises herbes



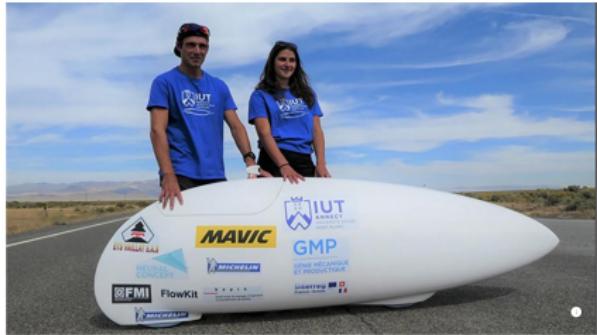
Application: Design industriel automatique



Bike designed with artificial intelligence breaks world speed records



[Vidéo](#)



The end

References

- A. Brock, J. Donahue, and K. Simonyan. Large scale GAN training for high fidelity natural image synthesis. [CoRR](#), abs/1809.11096, 2018.
- A. Canziani, A. Paszke, and E. Culurciello. An analysis of deep neural network models for practical applications. [CoRR](#), abs/1605.07678, 2016.
- D. Gershgorn. The data that transformed ai research—and possibly the world, July 2017.
- T. Karras, S. Laine, and T. Aila. A style-based generator architecture for generative adversarial networks. [CoRR](#), abs/1812.04948, 2018.
- A. Katharopoulos and F. Fleuret. Processing megapixel images with deep attention-sampling models. In [Proceedings of the International Conference on Machine Learning \(ICML\)](#), pages 3282–3291, 2019.
- A. Krizhevsky, I. Sutskever, and G. Hinton. Imagenet classification with deep convolutional neural networks. In [Neural Information Processing Systems \(NIPS\)](#), 2012.
- Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner. Gradient-based learning applied to document recognition. [Proceedings of the IEEE](#), 86(11):2278–2324, 1998.
- M. Mirza and S. Osindero. Conditional generative adversarial nets. [CoRR](#), abs/1411.1784, 2014.
- M. Newborn. [Kasparov versus Deep Blue: Computer Chess Comes of Age](#). Springer, 1996.
- C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich. Going deeper with convolutions. In [Conference on Computer Vision and Pattern Recognition \(CVPR\)](#), 2015.

- D. L. K. Yamins and J. J. DiCarlo. Using goal-driven deep learning models to understand sensory cortex. Nature neuroscience, 19:356–65, Feb 2016.
- M. D. Zeiler and R. Fergus. Visualizing and understanding convolutional networks. In European Conference on Computer Vision (ECCV), 2014.
- J. Zhu, T. Park, P. Isola, and A. Efros. Unpaired image-to-image translation using cycle-consistent adversarial networks. CoRR, abs/1703.10593, 2017.