

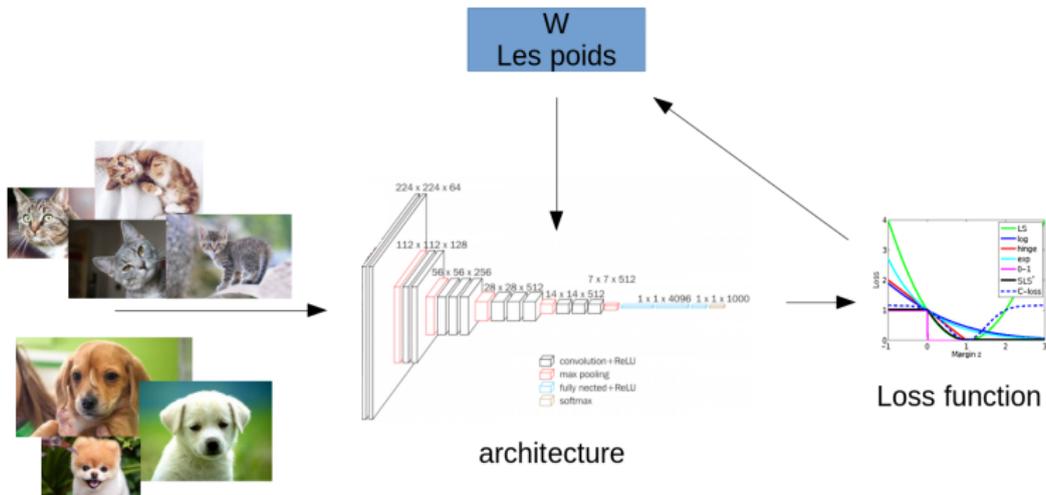
Deep learning

mots clés : deep learning, convolution, pooling, pytorch, segmentation,
exemples adversaires

Adrien CHAN-HON-TONG
ONERA

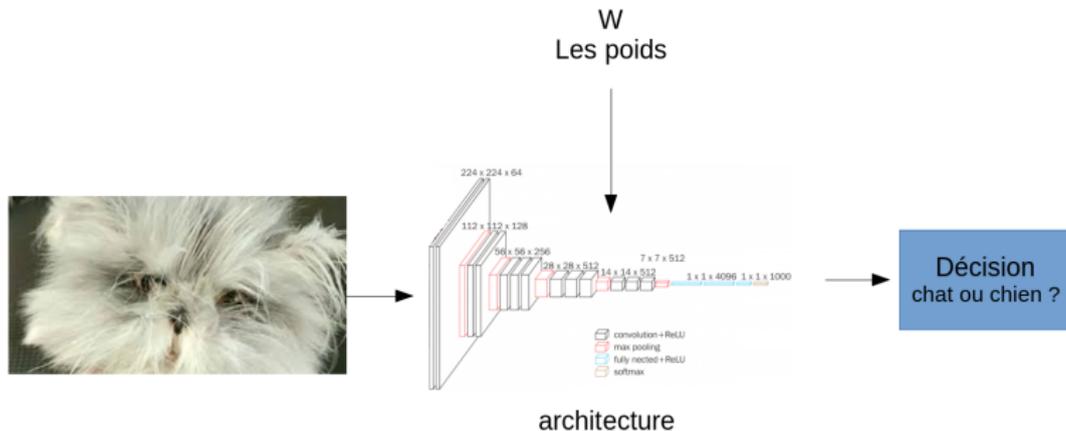
Rappel : apprentissage vs test

Apprentissage



Rappel : apprentissage vs test

Test et/ou production et/ou inférence



Rappel

SVM vs DL

Dans le cas du SVM, on a $f(x, w) = w^T x + w_{\text{biais}}$ qui donne un signe

$$f(x, w) > 0 \text{ ou } f(x, w) < 0$$

pour dire de quel coté on est.

Dans un réseau de neurone c'est PAREIL sauf que

$$f(x, w) = w_Q \times \text{relu}(w_{Q-1} \times \text{relu}(\dots(\text{relu}(w_1 \times x))))$$

Rappel

L'apprentissage en pratique

L'apprentissage consiste à appliquer la méthode de la descente de gradient stochastique (optimiseur à choisir) à une fonction de perte (à choisir) qui approxime l'erreur d'apprentissage

Par exemple

$$partial_loss(w) = \sum_{n \in Batch} relu(1 - y_n f(x_n, w))$$

$$w = w - \lambda_{iter} \nabla_w partial_loss$$

Plan

- ▶ Rappel
- ▶ Pytorch
- ▶ CNN
- ▶ Segmentation
- ▶ Exemples adversaires
- ▶ Perspective

Forward - Backward

```
for t
  for i
    for j
      A[t][i] += relu(A[t-1][j])*w[t-1][i][j]
DA[z][1] = partial_loss
for t from z to 1
  for j
    for i
      DA[t][j] += DA[t+1][i]*w[t][i][j]*relu'(A[t][j])
```

Pytorch

Forward backward

```
for t
  for i
    for j
       $A[t][i] += \text{relu}(A[t-1][j]) * w[t-1][i][j]$ 
DA[z][1] = partial_loss
for t from z to 1
  for j
    for i
       $DA[t][j] += DA[t+1][i] * w[t][i][j] * \text{relu}'(A[t][j])$ 
```

Forward backward en pytorch

```
z = net(x)
loss = l(z,y)
loss.backward()
```

Qu'est ce que c'est

- ▶ C'est un moteur de réseau de neurones : ça permet de programmer à l'aide de fonction haut niveau (`loss.backward()`), le reste est pris en charge par le moteur
- ▶ Cette abstraction est réalisé grâce à des objets *variable* qui stocke leur dépendance : $c = a + b$, la variable c stocke qu'elle dépend de a et b
- ▶ En plus, la plupart des objets classiques sont précodés (couches de neurones, stratégie d'optimisation, loss function, activation)
- ▶ En particulier pour l'image, torchvision propose des fonctions de très haut niveau (ex télécharge et charge en mémoire le jeu de données MNIST)

moindre carré

minimisons $f(x) = (Ax - b) \cdot (Ax - b)$

À la main

pour t de 1 à T :

$$\nabla_x f = 2A^T(Ax_t - b)$$

$$x_{t+1} = x_t - \rho \nabla_x f$$

Pytorch

`optimizer = optim.SGD([x], lr= ∇)`

pour t de 1 à T :

$$f = (Ax - b) \cdot (Ax - b)$$

`optimizer.zero_grad()`

`f.backward()`

`optimizer.step()`

Pytorch et MLP

```
import torch
class Net(torch.nn.Module):
    def __init__(self):
        super(Net, self).__init__()
        self.fc1 = torch.nn.Linear(2, 64, bias=True)
        self.fc2 = torch.nn.Linear(64, 64, bias=True)
        self.fc3 = torch.nn.Linear(64, 2, bias=True)

    def forward(self, x):
        x = torch.nn.functional.relu(self.fc1(x))
        x = torch.nn.functional.relu(self.fc2(x))
        x = self.fc3(x)
        return x

net = Net()
net(torch.rand((16, 2)))
net = net.cuda()
net(torch.rand((16, 2)).cuda())
```

Pytorch et test

```
def compute_accuracy(batchprovider, net):
    with torch.no_grad():
        net.eval()
        nb, nbOK = 0, 0
        for x, y in batchprovider:
            x, y = x.cuda(), y.cuda()
            z = net(x)

            _, z = z.max(1)
            good = (y==z).float()
            nb+=good.shape[0]
            nbOK+=good.sum().cpu().numpy()
    return nbOK, nb
```

Pytorch et train

```
def simple_training(batchprovider, net, lr, nbepoch):
    net.train()
    criterion = torch.nn.CrossEntropyLoss()
    optimizer = torch.optim.Adam(net.parameters(), lr=lr)
    meanloss = collections.deque(maxlen=200)
    for epoch in range(nbepoch):
        print(epoch, "/", nbepoch)
        nb, nbOK, l = 0, 0, []
        for x, y in batchprovider:
            x, y = x.cuda(), y.cuda()
            z = net(x)

            loss = criterion(z, y)
            l.append(loss.cpu().data.numpy())

            optimizer.zero_grad()
            loss.backward()
            torch.nn.utils.clip_grad_norm_(net.parameters(), 1)
            optimizer.step()

        _, z = z.max(1)
        good = (y==z).float()
        nb+=good.shape[0]
        nbOK+=good.sum().cpu().numpy()

        if len(l)==50:
            print("average loss=", sum(l) / 50)
            l=[]
    print("average train accuracy", nbOK/nb)
```

Plan

- ▶ Rappel
- ▶ Pytorch
- ▶ CNN
- ▶ Segmentation
- ▶ Exemples adversaires
- ▶ Perspective

Données structurées

Avant le deep learning

Données annotées et structurées
en dimension 100000000



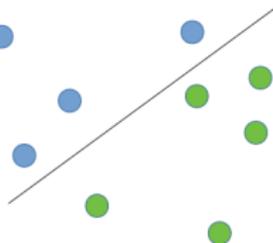
Descriptions des données (features)
faites à la main
(hand crafted)



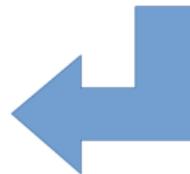
Nuage de points (D=10000)



chat/chien



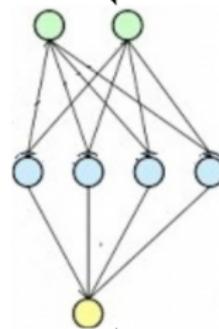
Classification de points



Données structurées

Après

Données annotées et structurées
en dimension 100000000

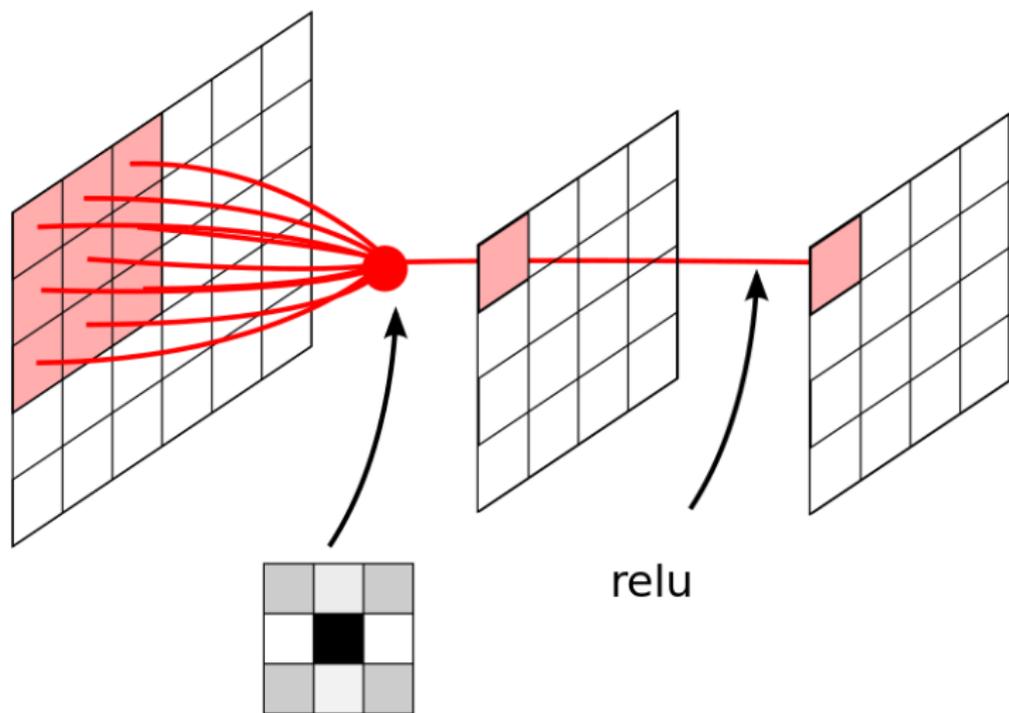


Le réseau de neurones fait TOUT

chat/chien

Données structurées

Le neurone convolutif



Données structurées

Le neurone convolutif

Si l'entrée est $I \in \mathbb{R}^{C \times H \times L}$: C canaux (3 pour Rouge Vert Bleu) H la hauteur et L la largeur. On peut considérer la convolution de I avec un noyau $K \in \mathbb{R}^{C \times (2\delta_H+1) \times (2\delta_L+1)}$ noté $I \star K \in \mathbb{R}^{H \times L}$ et défini par :

$$(I \star K)_{h,l} = \sum_{c=0}^C \sum_{\alpha=0}^{2\delta_H+1} \sum_{\beta=0}^{2\delta_L+1} I_{c,h-\delta_H+\alpha,l-\delta_L+\beta} \times K_{c,\alpha,\beta}$$

Comme pour les neurones, on pourra considérer un groupe de \mathcal{C} neurones convolutifs $K_1, \dots, K_{\mathcal{C}}$ dont on regroupe les sorties en une nouvelle image dans $\mathbb{R}^{C \times H \times L}$.

Le neurone convolutif

Si on considère 1 valeur de $I \star K$ typiquement

$$(I \star K)_{h,l} = \sum_{c=0}^C \sum_{\alpha=0}^{2\delta_H+1} \sum_{\beta=0}^{2\delta_L+1} I_{c,h-\delta_H+\alpha,l-\delta_L+\beta} \times K_{c,\alpha,\beta}$$

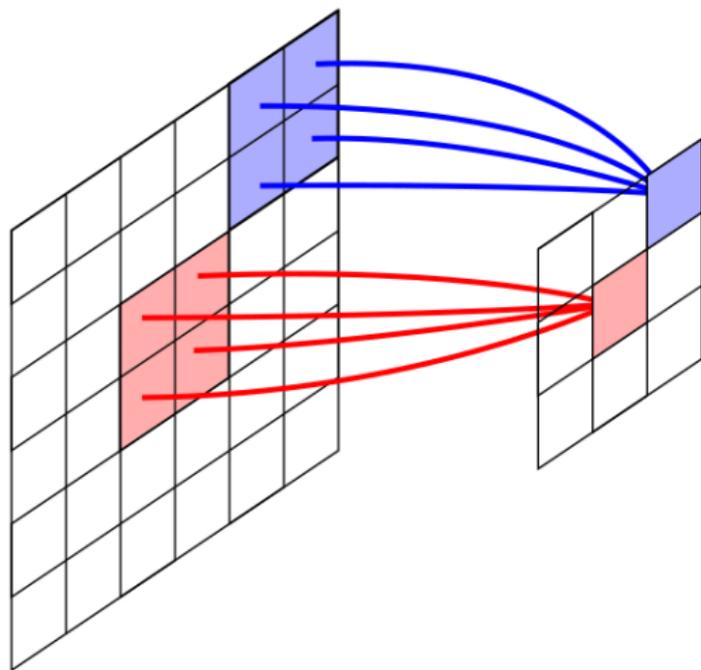
On voit que cette valeur peut tout à fait se coder avec un neurone classique $I \cdot \mathcal{K}$ avec

$$\mathcal{K}_{i,j} = \begin{cases} K_{i-h+\delta_H,j-l+\delta_L} & \text{si } \begin{matrix} h - \delta_H \leq i \leq h + \delta_H \\ l - \delta_L \leq j \leq l + \delta_L \end{matrix} \\ 0 & \text{sinon} \end{cases}$$

SAUF que la convolution n'a que $O(\delta_H \times \delta_L)$ paramètres pour générer $I \star K$ contre $O(H^2 \times L^2)$ avec une couche classique : 9 contre 4294967296 pour une image 256x256 et un noyau 3x3 ...

CNN

Le pooling



Le pooling

Si l'entrée est $I \in \mathbb{R}^{C \times H \times L}$, alors $\text{pool}(I) \in \mathbb{R}^{C \times \frac{H}{2} \times \frac{L}{2}}$

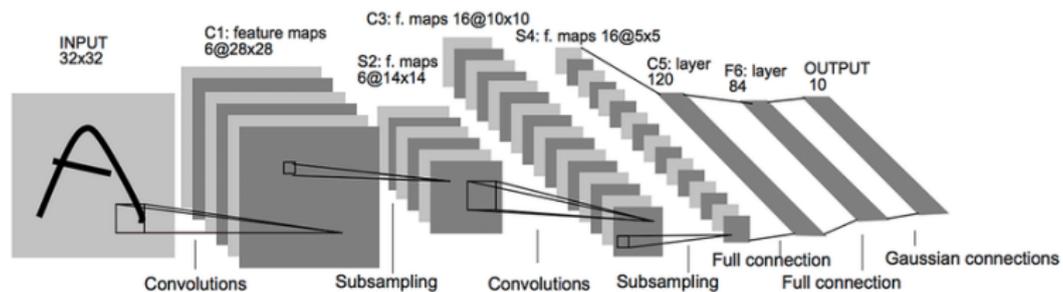
$$\text{pool}(I)_{c,h,l} = \max_{\alpha \in \{2h, 2h+1\}, \beta \in \{2l, 2l+1\}} I_{c,\alpha,\beta}$$

Il s'agit plus d'une activation car il n'y a pas de poids.

Notez que le max peut se coder avec un relu (comme vu en TD : $\max(a, b) = \text{relu}(b - a) + a$) donc en théorie les réseaux relu peuvent déjà encodé le pooling. Mais en pratique cela force une certaine invariance...

CNN

Lenet

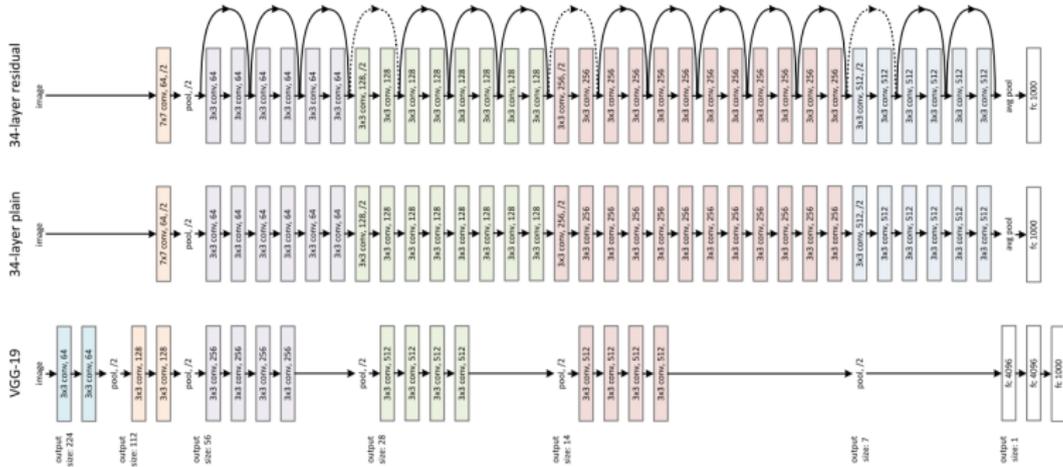


CNN

Lenet, Alexnet, VGG



VGG, Resnet



Pytorch et CNN

```
import torch
class Net(torch.nn.Module):
    def __init__(self):
        super(Net, self).__init__()
        self.fc1 = torch.nn.Conv2d(3, 64, bias=True)
        self.fc2 = torch.nn.Conv2d(64, 64, bias=True)
        self.fc3 = torch.nn.Linear(64, 2, bias=True)

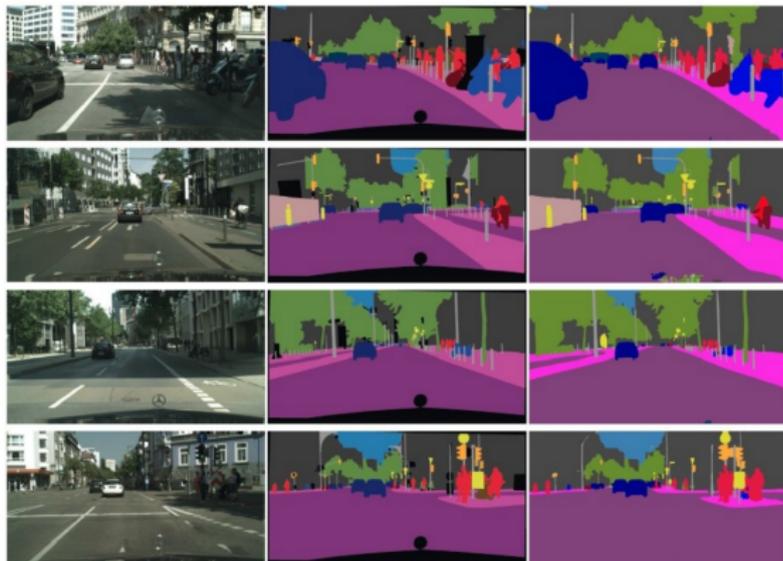
    def forward(self, x):
        x = torch.nn.functional.relu(self.fc1(x))
        x = torch.nn.functional.max_pool2d(x, kernel_size=2, stride=2)
        x = torch.nn.functional.relu(self.fc2(x))

        resize = torch.nn.AdaptiveAvgPool2d((1,1))
        x = resize(x)
        x = x.view(x.shape[0], 64)

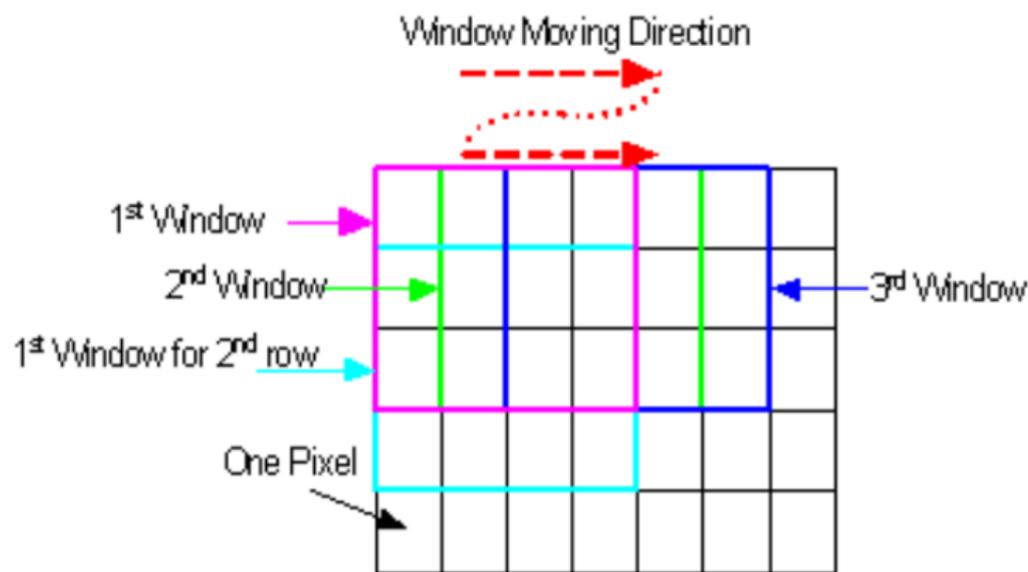
        x = self.fc3(x)
        return x

net = Net()
net = net.cuda()
net(torch.rand((16, 3, 32, 32)).cuda())
```

Problèmes structurés

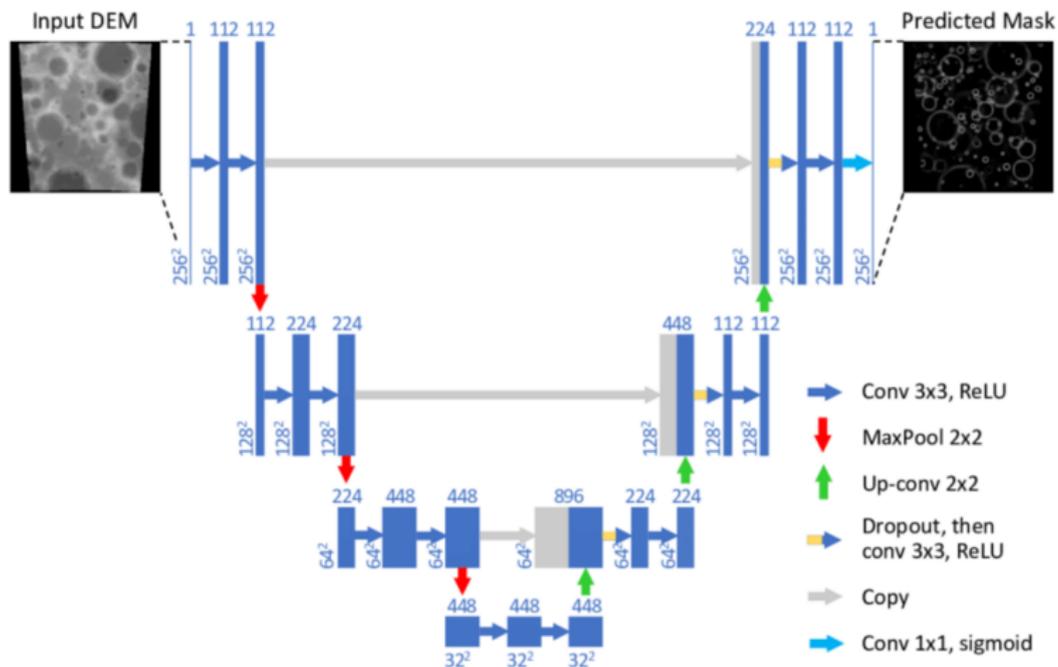


segmentation sémantique



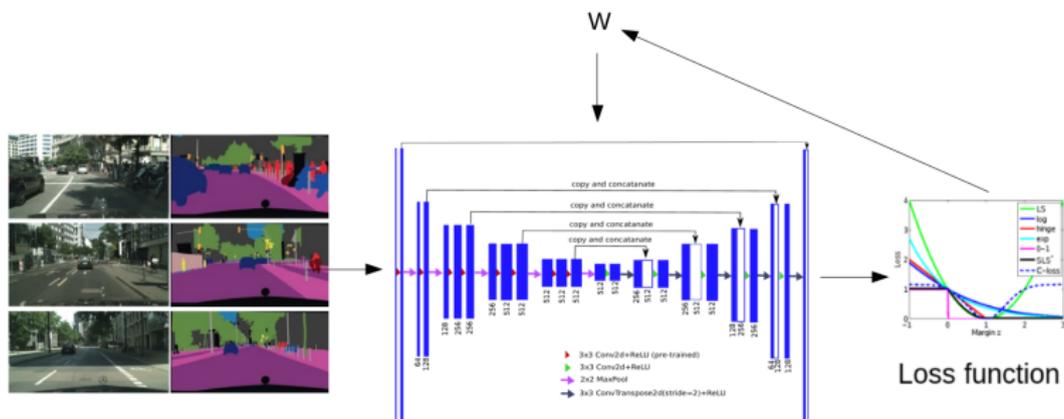
raisonner par fenêtre est une mauvaise idée : il faut raisonner par couche !

segmentation sémantique



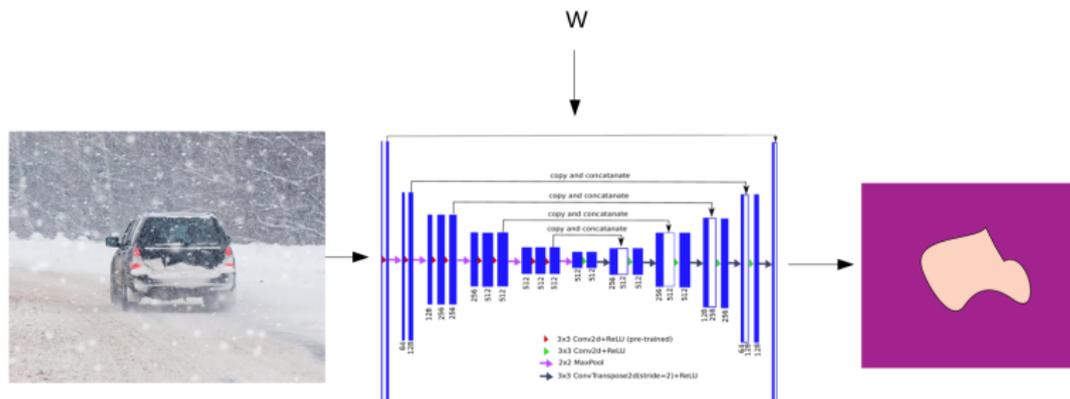
segmentation sémantique : 2 phases aussi

Apprentissage



segmentation sémantique : 2 phases aussi

Test



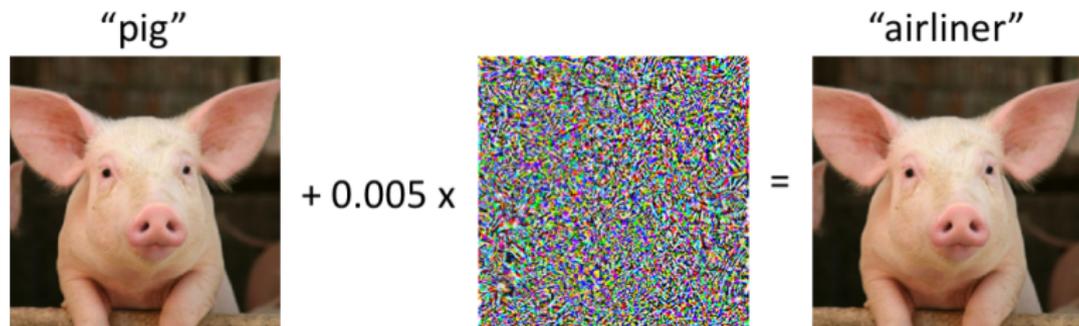
Le deep learning est incontestablement l'état de l'art sur les
données/problèmes structurées
(son, image, vidéo, texte, détection, segmentation, génération...)

Plan

- ▶ Rappel
- ▶ Pytorch
- ▶ CNN
- ▶ Segmentation
- ▶ Exemples adversaires
- ▶ Perspective

Grande dimension et instabilité

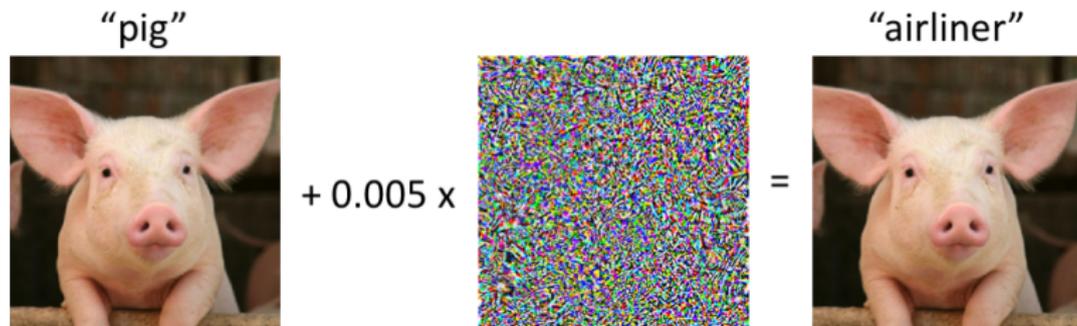
Exemple adversaire



Les réseaux de neurones sont sensibles à des perturbations invisibles à l'oeil !

Grande dimension et instabilité

Exemple adversaire



Les réseaux de neurones sont sensibles à des perturbations invisibles à l'oeil !

En réalité, c'est pas clair que ce soit grave car ces perturbations ne pas forcément réalisable physiquement

Grande dimension et instabilité

Pourquoi ?

L'apprentissage consiste à calculer

$$\nabla_w \text{loss}(y_n, f(x_n, w))$$

et à **actualiser** w de sorte que

$$\text{loss}(y_n, f(x_n, w)) \approx 0$$

Grande dimension et instabilité

Pourquoi ?

Mais avec le même outils, on peut calculer

$$\nabla_x \text{loss}(y_n, f(x_n, w))$$

et **actualiser** x_n de sorte que

$$\text{loss}(y_n, f(x_n, w)) \gg 0$$

Grande dimension et instabilité

Pourquoi ?

Mais avec le même outils, on peut calculer

$$\nabla_x \text{loss}(y_n, f(x_n, w))$$

et **actualiser** x_n de sorte que

$$\text{loss}(y_n, f(x_n, w)) \gg 0$$

⇒ ce qui permet de construire une image x_n spécifiquement perturbée pour échapper au réseau : *adversarial exemple*.

Grande dimension et instabilité

Rendre les réseaux robustes

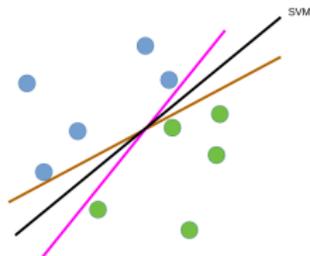
- ▶ f un réseau binaire
- ▶ Ce qu'on ne veut pas c'est $f(x) > 0$ et $f(x + \textit{delta}) < 0$ (ou l'inverse) sur le testing set
- ▶ on veut donc apprendre au réseau à considérer que x est bien classé
 - ▶ non pas si $f(x) > 0$
 - ▶ mais si $f(x + \delta) > 0$ (avec $\|\delta\| < \epsilon$)

Grande dimension et instabilité

Rendre les réseaux robustes

- ▶ f un réseau binaire
- ▶ Ce qu'on ne veut pas c'est $f(x) > 0$ et $f(x + \delta) < 0$ (ou l'inverse) sur le testing set
- ▶ on veut donc apprendre au réseau à considérer que x est bien classé
 - ▶ non pas si $f(x) > 0$
 - ▶ mais si $f(x + \delta) > 0$ (avec $\|\delta\| < \epsilon$)

⇒ comme ferait le SVM



Grande dimension et instabilité

Rendre les réseaux robustes

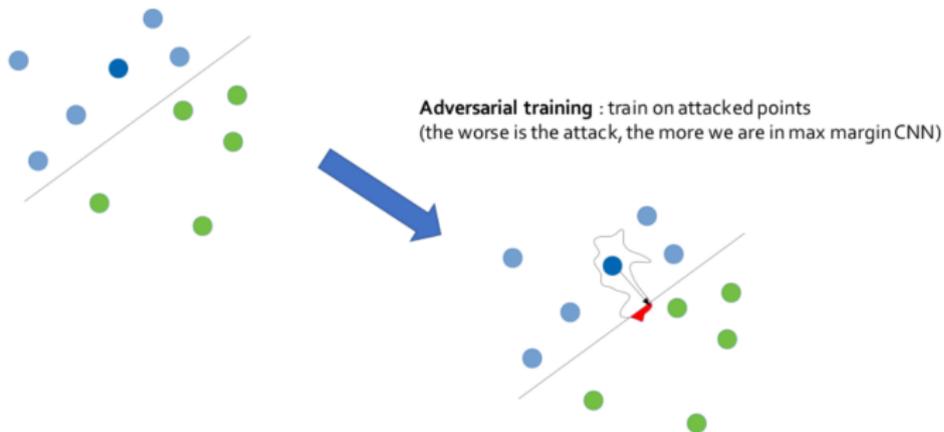
Sauf que calculer la marge c'est NP complet pour des réseaux relus !

Grande dimension et instabilité

Rendre les réseaux robustes

2 options

- ▶ adversarial training (sous estimé le déplacement maximal)
- ▶ construction d'une enveloppe convexe (sur estimation du déplacement maximal)



Grande dimension et instabilité

Rendre les réseaux robustes

2 options

- ▶ adversarial training (sous estimé le déplacement maximal)
- ▶ construction d'une enveloppe convexe (sur estimation du déplacement maximal)

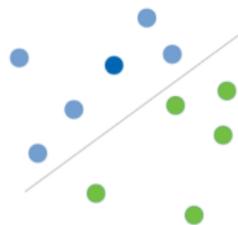


provable defenses against adversarial examples via the convex outer adversarial polytope

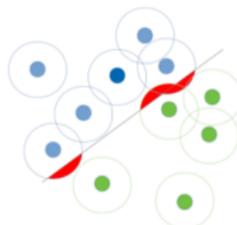
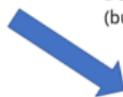
Grande dimension et instabilité

Rendre les réseaux robustes

Ou tenter des réseaux Lipschitz



Lipschitz training :
a simple ball can be used to bound the accessible space!
(but requires specific architecture e.g. no relu)



Sorting Out Lipschitz Function Approximation

Grande dimension et instabilité

MinMax

$$\text{relu} \begin{pmatrix} a \\ b \\ c \\ d \end{pmatrix} = \begin{pmatrix} \max(0, a) \\ \max(0, b) \\ \max(0, c) \\ \max(0, d) \end{pmatrix}$$

(les valeurs n'augmentent pas mais elles peuvent diminuer)

$$\text{MinMax} \begin{pmatrix} a \\ b \\ c \\ d \end{pmatrix} = \begin{pmatrix} \max(a, b) \\ \max(c, d) \\ \min(a, b) \\ \min(c, d) \end{pmatrix}$$

(les valeurs ne changent pas, seul les places changent !)

Grande dimension et instabilité

MinMax

$$\text{MinMax} \begin{pmatrix} a \\ 0 \\ b \\ 0 \end{pmatrix} = \begin{pmatrix} \max(0, a) \\ \max(0, b) \\ \min(0, a) \\ \min(0, b) \end{pmatrix} = \begin{pmatrix} \text{relu} \begin{pmatrix} a \\ b \end{pmatrix} \\ -\text{relu} \begin{pmatrix} -a \\ -b \end{pmatrix} \end{pmatrix}$$

MinMax est aussi expressif que Relu en théorie

Mais l'activation est repoussée dans la partie linéaire pour permettre un meilleur contrôle du réseau !

Les axes de recherche aujourd'hui

- ▶ frugal learning : apprendre avec peu de données
- ▶ incremental learning : Apprentissage de classes à la volé
- ▶ fairness, privacy preserving : Apprentissage éthique
- ▶ robustness : on en a parlé (tempête dans un verre d'eau)
- ▶ explainability : Apprentissage et langage
- ▶ physically informed neural network : Apprentissage hybride
- ▶ self supervised learning, representation learning : Apprentissage de représentation
- ▶ transfert learning : Adaptation de domaine

Les axes de recherche aujourd'hui

- ▶ frugal learning : apprendre avec peu de données
- ▶ incremental learning : Apprentissage de classes à la volé
- ▶ fairness, privacy preserving : Apprentissage éthique
- ▶ robustness : on en a parlé (tempête dans un verre d'eau)
- ▶ explainability : Apprentissage et langage
- ▶ physically informed neural network : Apprentissage hybride
- ▶ self supervised learning, representation learning : Apprentissage de représentation
- ▶ transfert learning : Adaptation de domaine

Mais le problème de la généralisation n'est PAS réglé !

Conclusion

La généralisation

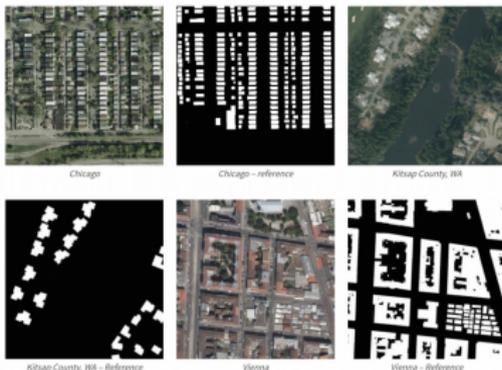
- c'est un problème d'apprentissage mais aussi d'industrialisation de la collecte de données



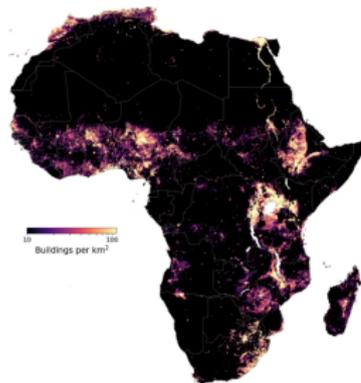
Conclusion

La généralisation

- c'est un problème d'apprentissage mais aussi d'industrialisation de la collecte de données



Inria Aerial Dataset : 6 villes



Open building dataset : l'Afrique en entier

Questions ?