

Réseaux de neurones profonds

Guillaume Bourmaud

PLAN

I. Réseaux de neurones profonds

II. Modèles de fondation

III. « Gradient checkpointing »

IV. Apprentissage multi-GPU

I) Réseaux de neurones profonds

Résumé des ingrédients du « Deep Learning »


1) Grande base de données étiquetées

2) « **Bonne** » architecture de réseau de neurones profond



- ▶ « Perceptron » multicouche, Réseau de neurones à convolution, Transformer
- ▶ Optimisation par descente de gradient stochastique (AdamW, etc.)

3) Grande capacité de calculs en parallèle (GPUs)



Limites du CNN « classique »



Limites du CNN « classique »



Limites du CNN « classique »




Ingrédient limitant les performances




Architecture du CNN

Ingrédient 1 : Couche de “Batch Normalization”




Ingrédient 1 : Couche de “Batch Normalization”




Fonctionnement de la couche BN **à l'entraînement**.

Ingrédient 1 : Couche de “Batch Normalization”




Fonctionnement de la couche BN à l'évaluation.

CNN + BN



CNN + BN




Remarque


$$\text{BN}(\text{conv}(\mathbf{x}) + b) = \gamma \frac{\text{conv}(\mathbf{x}) - \mu(\text{conv}(\mathbf{x}))}{\sigma(\text{conv}(\mathbf{x}))} + \beta$$

Le biais b de la couche de conv est « absorbé » (en mode « train») par la BN et ne sert à rien.

CNN + BN (suite)



CNN + BN (suite)




Rend le problème d'optimisation plus « lisse » :


→ Initialisation des paramètres moins critique

→ Possibilité d'utilisation d'un plus grand pas d'apprentissage → accélération de l'entraînement

Ingédient 2 : Connexion résiduelle




Ingédient 2 : Connexion résiduelle



Rend la fonction plus « linéaire » :

→ Réduit sa « capacité » → augmentation du nombre de couches pour un même résultat

Ingédient 2 : Connexion résiduelle




$$x^{(1)} = x^{(0)} + f(x^{(0)}; \theta)$$

$$\frac{\partial x^{(1)}}{\partial x^{(0)}} = I + \frac{\partial f(x^{(0)}; \theta)}{\partial x^{(0)}}$$

Rend la fonction plus « linéaire » :

→ Réduit sa « capacité » → augmentation du nombre de couches pour un même résultat

Ingédient 2 : Connexion résiduelle



$$x^{(1)} = x^{(0)} + f(x^{(0)}; \theta)$$


$$\frac{\partial x^{(1)}}{\partial x^{(0)}} = I + \frac{\partial f(x^{(0)}; \theta)}{\partial x^{(0)}}$$

Rend la fonction plus « linéaire » :

→ Réduit sa « capacité » → augmentation du nombre de couches pour un même résultat

Même si ce gradient « s'évanouit » (vaut presque zéro), il reste l'identité grâce à la connexion résiduelle

Ingédient 2 : Connexion résiduelle




$$x^{(1)} = x^{(0)} + f(x^{(0)}; \theta)$$

$$\frac{\partial x^{(1)}}{\partial x^{(0)}} = I + \frac{\partial f(x^{(0)}; \theta)}{\partial x^{(0)}}$$

Rend la fonction plus « linéaire » :

→ Réduit sa « capacité » → augmentation du nombre de couches pour un même résultat

→ Facilite la propagation du gradient → plus de couches conduit à de meilleurs résultats (en théorie)



ResBlock A


Transforme le tenseur d'entrée

- en préservant la résolution
- en préservant le nombre de canaux

ResBlock B

Transforme le tenseur d'entrée



- en divisant la résolution par 2
- en augmentant le nombre de canaux par 2






ResNet 18

$\arg \max(s) = 748 \doteq "raie"$




ResNet 18 < ResNet 34




I)


Différentes couches de normalisation







Différentes couches de normalisation




Différentes couches de normalisation




Différentes couches de normalisation




En 2024 : U-Net + ResBlock toujours là !



En 2024 : U-Net + ResBlock toujours là !



En 2024 : U-Net + ResBlock toujours là !



II) Modèles de fondation

Résumé des ingrédients du « Deep Learning »

1) **Grande** base de données étiquetées

2) « Bonne » architecture de réseau de neurones profond

- ▶ « Perceptron » multicouche, Réseau de neurones à convolution, Transformer
- ▶ Optimisation par descente de gradient stochastique (AdamW, etc.)

3) Grande capacité de calculs en parallèle (GPUs)

Comment faire avec une petite base de données étiquetées ?

Exemple : détection du frelon asiatique



Présence (1042 images)



Absence (1844 images)

Ingrédient limitant les performances



Taille de la base de données étiquetées

Comment faire avec une petite base de données étiquetées ?

Exemple : détection du frelon asiatique



Présence (1042 images)



Absence (1844 images)

Ingrédient limitant les performances



Taille de la base de données étiquetées

Solution

1) Récupérer un modèle de fondation

2) Spécialiser ce modèle de fondation sur sa petite base de données étiquetées

Modèle de fondation « historique »

Historiquement (~ à partir de 2012), un modèle de fondation (le terme « foundation model » n'est introduit qu'en 2021) est :

Modèle de fondation « historique »

Historiquement (~ à partir de 2012), un modèle de fondation (le terme « foundation model » n'est introduit qu'en 2021) est :

- un CNN (e.g ResNet)

Modèle de fondation « historique »


Historiquement (~ à partir de 2012), un modèle de fondation (le terme « foundation model » n'est introduit qu'en 2021) est :

- un CNN (e.g ResNet)
- qui est **pré-entraîné** = entraîné sur ImageNet1k


Rappel : ImageNet1k = 1.2M d'images étiquetées sur 1000 classes qui représentent une grande diversité d'images **issues de notre monde**




II) Exemple de spécialisation (« fine-tuning ») d'un ResNet 18 pré-entraîné sur ImageNet1k




II) Exemple de spécialisation (« fine-tuning ») d'un ResNet 18 pré-entraîné sur ImageNet1k



II) Exemple de spécialisation (« fine-tuning ») d'un ResNet 18 pré-entraîné sur ImageNet1k



II) Exemple de spécialisation (« fine-tuning ») d'un ResNet 18 pré-entraîné sur ImageNet1k



Paramètres du ResNet18 pré-entraîné sur ImageNet

Initialisation classique (aléatoire)

II) Exemple de spécialisation (« fine-tuning ») d'un ResNet 18 pré-entraîné sur ImageNet1k

Lors du pré-entraînement sur ImageNet1k :

- Les images sont normalisées (comme on l'a fait en TP sur MNIST)

$$x_{\text{norm}} = \frac{x - \mu_{\text{ImageNet1k}}}{\sigma_{\text{ImageNet1k}}}$$

II) Exemple de spécialisation (« fine-tuning ») d'un ResNet 18 pré-entraîné sur ImageNet1k

Lors du pré-entraînement sur ImageNet1k :


- Les images sont normalisées (comme on l'a fait en TP sur MNIST)

$$x_{\text{norm}} = \frac{x - \mu_{\text{ImageNet1k}}}{\sigma_{\text{ImageNet1k}}}$$


- Pour utiliser le réseau, il faut appliquer cette **même** normalisation à nos images !

II) Exemple de spécialisation (« fine-tuning ») d'un ResNet 18 pré-entraîné sur ImageNet1k

Image « normalisée »



$\arg \max(s) = 2 \doteq \text{"Présence"}$



Modèles de fondation « modernes »

Pré-entraînement sur une **très** grande base de données.

Exemple : ~2012 ImageNet 1k = 1.2×10^6 images étiquetées
~2022 LAION-5B = 5×10^9 images étiquetées

Modèles de fondation « modernes »

Pré-entraînement sur une **très** grande base de données.

Exemple : ~2012 ImageNet 1k = 1.2×10^6 images étiquetées
~2022 LAION-5B = 5×10^9 images étiquetées

Rendu possible grâce à :

- l'augmentation continue de la puissance des cartes graphiques
- l'apparition des couches d'attention (« Transformer »)

Modèles de fondation « modernes »

Pré-entraînement sur une **très** grande base de données.

Exemple : ~2012 ImageNet 1k = 1.2×10^6 images étiquetées
~2022 LAION-5B = 5×10^9 images étiquetées

Rendu possible grâce à :

- l'augmentation continue de la puissance des cartes graphiques
- l'apparition des couches d'attention (« Transformer »)

Apparition de modèles de fondation dans un grand nombre de domaines :

- Reconstruction 3D, Segmentation d'image, Imagerie médicale etc.

Modèles de fondation « modernes »

Pré-entraînement sur une **très** grande base de données.

Exemple : ~2012 ImageNet 1k = 1.2×10^6 images étiquetées
~2022 LAION-5B = 5×10^9 images étiquetées

Rendu possible grâce à :

- l'augmentation continue de la puissance des cartes graphiques
- l'apparition des couches d'attention (« Transformer »)

Apparition de modèles de fondation dans un grand nombre de domaines :

- Reconstruction 3D, Segmentation d'image, Imagerie médicale etc.
- Et bien-sûr les LLM (« Large Language Model ») avec GPT !

II) Exemple de modèle de fondation pour la segmentation d'images

« Segment Anything »




Entraînement sur « SA-1B » : une base de 11×10^6 images avec 1.1×10^9 masques de segmentation


III) « Gradient checkpointing »

Rétropropagation « classique »


Rétropropagation (“Backward”)




Rétropropagation « classique »




Rétropropagation « classique »




Rétropropagation « classique »




Rétropropagation « classique »




Rétropropagation « classique »




Rétropropagation « classique »




Rétropropagation « classique »




Rétropropagation « classique »



Rétropropagation « classique »




Rétropropagation « classique »




Toutes les activations sont conservées en mémoire pour effectuer la rétropropagation. 66

Rétropropagation « classique »




Toutes les activations sont conservées en mémoire pour effectuer la rétropropagation.
 « Gradient checkpointing » = conserver uniquement quelques activations en mémoire


Exemple de « checkpointing » des couches 2 et 4




Exemple de « checkpointing » des couches 2 et 4




Exemple de « checkpointing » des couches 2 et 4




Exemple de « checkpointing » des couches 2 et 4




Exemple de « checkpointing » des couches 2 et 4




Exemple de « checkpointing » des couches 2 et 4




Exemple de « checkpointing » des couches 2 et 4




Exemple de « checkpointing » des couches 2 et 4



Exemple de « checkpointing » des couches 2 et 4



Exemple de « checkpointing » des couches 2 et 4



Résumé « checkpointing »

Réduit l'empreinte mémoire de la rétropropagation
→ permet d'entraîner de plus gros réseau ou d'augmenter la taille du minibatch

Nécessite de recalculer des activations
→ Accroît le temps de rétropropagation et donc le temps d'entraînement

IV) Apprentissage multi-GPU

Résumé des ingrédients du « Deep Learning »

1) Grande base de données étiquetées

2) « Bonne » architecture de réseau de neurones profond

- ▶ « Perceptron » multicouche, Réseau de neurones à convolution, Transformer
- ▶ Optimisation par descente de gradient stochastique (AdamW, etc.)

3) Grande capacité de calculs en parallèle (GPUs)


Grande capacité de calculs en parallèle

Hypothèse : On dispose de plusieurs GPUs sur lesquels rentrent de « petits » minibatchs

$$\{\mathbf{x}_i, \mathbf{y}_i\}_{i \in \mathcal{B} = \mathcal{B}_1 \cup \mathcal{B}_2 \cup \dots \cup \mathcal{B}_N}$$


Grande capacité de calculs en parallèle

Hypothèse : On dispose de plusieurs GPUs sur lesquels rentrent de « petits » minibatchs




Grande capacité de calculs en parallèle

Hypothèse : On dispose de plusieurs GPUs sur lesquels rentrent de « petits » minibatchs




Grande capacité de calculs en parallèle

Hypothèse : On dispose de plusieurs GPUs sur lesquels rentrent de « petits » minibatchs



Grande capacité de calculs en parallèle

Hypothèse : On dispose de plusieurs GPUs sur lesquels rentrent de « petits » minibatchs



Grande capacité de calculs en parallèle

Hypothèse : On dispose de plusieurs GPUs sur lesquels rentrent de « petits » minibatchs



On a la capacité d'apprendre sur de grands minibatchs

Grande capacité de calculs en parallèle

Hypothèse : On dispose de plusieurs GPUs sur lesquels rentrent de « petits » minibatchs



On a la capacité d'apprendre sur de grands minibatchs



Peut-on exploiter cette capacité pour réduire le temps d'entraînement ?

Grande capacité de calculs en parallèle

Hypothèse : On dispose de plusieurs GPUs sur lesquels rentrent de « petits » minibatchs



On a la capacité d'apprendre sur de grands minibatchs



Peut-on exploiter cette capacité pour réduire le temps d'entraînement ?



Oui ! Il suffit d'augmenter le pas d'apprentissage (« learning rate ») et de modifier l'évolution du pas d'apprentissage (« scheduling ») !

Augmentation du pas d'apprentissage

« **Linear Scaling Rule** » : Quand la taille du minibatch est multipliée par s , multiplier le pas d'apprentissage par s .

Augmentation du pas d'apprentissage

« **Linear Scaling Rule** » : Quand la taille du minibatch est multipliée par s , multiplier le pas d'apprentissage par s .

s itérations avec un minibatch de taille n

$$\boldsymbol{\theta}_{k+s} = \boldsymbol{\theta}_k - \alpha \frac{1}{n} \sum_{j=0}^{s-1} \sum_{i \in \mathcal{B}_j} \frac{\partial l(Y_{\text{train},i}, f(X_{\text{train},i}; \boldsymbol{\theta}))}{\partial \boldsymbol{\theta}} \Big|_{\boldsymbol{\theta}=\boldsymbol{\theta}_{k+j}}$$

1 itération avec un minibatch de taille sn

$$\hat{\boldsymbol{\theta}}_{k+1} = \boldsymbol{\theta}_k - \hat{\alpha} \frac{1}{sn} \sum_{j=0}^{s-1} \sum_{i \in \mathcal{B}_j} \frac{\partial l(Y_{\text{train},i}, f(X_{\text{train},i}; \boldsymbol{\theta}))}{\partial \boldsymbol{\theta}} \Big|_{\boldsymbol{\theta}=\boldsymbol{\theta}_k}$$

Augmentation du pas d'apprentissage

« **Linear Scaling Rule** » : Quand la taille du minibatch est multipliée par s , multiplier le pas d'apprentissage par s .

s itérations avec un minibatch de taille n


$$\boldsymbol{\theta}_{k+s} = \boldsymbol{\theta}_k - \alpha \frac{1}{n} \sum_{j=0}^{s-1} \sum_{i \in \mathcal{B}_j} \frac{\partial l(Y_{\text{train},i}, f(X_{\text{train},i}; \boldsymbol{\theta}))}{\partial \boldsymbol{\theta}} \Big|_{\boldsymbol{\theta}=\boldsymbol{\theta}_{k+j}}$$

1 itération avec un minibatch de taille sn

$$\hat{\boldsymbol{\theta}}_{k+1} = \boldsymbol{\theta}_k - \hat{\alpha} \frac{1}{sn} \sum_{j=0}^{s-1} \sum_{i \in \mathcal{B}_j} \frac{\partial l(Y_{\text{train},i}, f(X_{\text{train},i}; \boldsymbol{\theta}))}{\partial \boldsymbol{\theta}} \Big|_{\boldsymbol{\theta}=\boldsymbol{\theta}_k}$$

Si $\frac{\partial l(Y_{\text{train},i}, f(X_{\text{train},i}; \boldsymbol{\theta}))}{\partial \boldsymbol{\theta}} \Big|_{\boldsymbol{\theta}=\boldsymbol{\theta}_{k+j}} \approx \frac{\partial l(Y_{\text{train},i}, f(X_{\text{train},i}; \boldsymbol{\theta}))}{\partial \boldsymbol{\theta}} \Big|_{\boldsymbol{\theta}=\boldsymbol{\theta}_k}$ et $\hat{\alpha} = s\alpha$ alors $\boldsymbol{\theta}_{k+s} \approx \hat{\boldsymbol{\theta}}_{k+1}$


Évolution du pas d'apprentissage



« Linear warmup » : augmentation progressive et **rapide** du pas d'apprentissage

Permet de se placer dans une « bonne » région de l'espace des paramètres


Évolution du pas d'apprentissage



« Linear warmup » : augmentation progressive et **rapide** du pas d'apprentissage
« Decay » : décroissance progressive et **lente** du pas d'apprentissage

Décroissance « classique » du pas d'apprentissage


Évolution du pas d'apprentissage



Valeur du pic définie par la « linear scaling rule ».

Grande capacité de calculs en parallèle


Il suffit d'augmenter le pas d'apprentissage (« learning rate ») et de modifier l'évolution du pas d'apprentissage (« scheduling ») !




Annexes

Augmentation de données

- Mirroir
- Transformation affine
- Perturbation couleur
- Effacement
- Bruit
- ...



“Adversarial examples”



“panda”

57.7% confidence

“gibbon”

99.3% confidence

“Adversarial patches”



Sources : “ADVHAT: Real-world adversarial attack on ArcFace face ID system” (<https://arxiv.org/pdf/1908.08705.pdf>)
“Robust Physical-World Attacks on Deep Learning Visual Classification” (<https://arxiv.org/pdf/1707.08945.pdf>)

Annexe : Application à la détection d'objets dans une image

Détection d'objets

Classification




**Classification
+ Localization**




CAT

Object Detection



CAT, DOG, DUCK

Exemple de détection d'objets




Formulation du problème

- Objectif
 - Prédire une boîte englobante autour de chaque objet,
 - Prédire la classe de l'objet,
 - En utilisant un réseau de neurones en apprentissage supervisé.
- Questions
 - Quelles données annotées disponibles ?
 - Quelle architecture ?
 - Quelle fonction de coût ?

Quelles données annotées disponibles ?

Microsoft COCO dataset (80 classes)

1: 'person',
2: 'bicycle',
3: 'car',
4: 'motorcycle',
5: 'airplane',
6: 'bs',
7: 'train',
8: 'trck',
9: 'boat',
10: 'traffic light',
11: 'fire hydrant',
12: 'stop sign',
13: 'parking meter',
14: 'bench',
15: 'bird',
16: 'cat',
17: 'dog',
18: 'horse',
19: 'sheep',
20: 'cow',
21: 'elephant',
22: 'bear',
23: 'zebra',
24: 'giraffe',
25: 'backpack',
26: 'mbrella',
27: 'handbag',
28: 'tie',
29: 'sitcase',
30: 'frisbee',
31: 'skis',
32: 'snowboard',
33: 'sports ball',
34: 'kite',
35: 'baseball bat',
36: 'baseball glove',
37: 'skateboard',
38: 'srfboard',
39: 'tennis racket',
40: 'bottle',
41: 'wine glass',
42: 'cp',
43: 'fork',
44: 'knife',
45: 'spoon',
46: 'bowl',
47: 'banana',
48: 'apple',
49: 'sandwich',
50: 'orange',
51: 'broccoli',
52: 'carrot',
53: 'hot dog',
54: 'pizza',
55: 'don',
56: 'cake',
57: 'chair',
58: 'coch',
59: 'potted plant',
60: 'bed',
61: 'dining table',
62: 'toilet',
63: 'tv',
64: 'laptop',
65: 'mose',
66: 'remote',
67: 'keyboard',
68: 'cell phone',
69: 'microwave',
70: 'oven',
71: 'toaster',
72: 'sink',
73: 'refrigerator',
74: 'book',
75: 'clock',
76: 'vase',
77: 'scissors',
78: 'teddy bear',
79: 'hair drier',
80: 'toothbrsh'



Pascal VOC dataset (20 classes)

Person:
1: person

Animal:
2: bird
3: cat
4: cow
5: dog
6: horse
7: sheep

Vehicle:
8: aeroplane
9: bicycle
10: boat
11: bus
12: car
13: motorbike
14: train

Indoor:
15: bottle
16: chair
17: dining table
18: potted plant
19: sofa
20: tv/monitor

Comment prédire le nombre d'objets et pour chaque objet sa boîte et sa classe ?

Exemple de solution : CenterNet (Zhou et. al, Objects as points, 2019)



keypoint heatmap [C]






local offset [2]



object size [2]

CenterNet




C scores (un pour chaque classe)

Décalage x et y
du centre de la boîte

Largeur et hauteur
de la boîte₁₀₉

CenterNet (suite)



Fonction de coût = somme de trois fonctions de coût

- Pour les scores : « pixelwise logistic regression » (i.e. sur chaque case grise)
- Pour le décalage : régression L1 (sur les cases oranges s'il y a une boîte sinon rien)
- Pour la largeur et la hauteur : régression L1 (sur les cases vertes s'il y a une boîte sinon rien)

CenterNet (suite)

