

# Rétropropagation

Introduction à l'apprentissage automatique  
Master Sciences Cognitives  
Aix Marseille Université

Alexis Nasr

# Motivations

- La phase d'apprentissage des réseaux de neurones nécessite généralement de calculer **le gradient de la fonction d'erreur**, sur les données d'apprentissage.
- La taille des réseaux peut être **importante**, ainsi que le nombre de données d'apprentissage.
- Il est donc nécessaire de trouver un moyen **rapide** pour calculer le gradient.
- C'est ce que permet de faire l'algorithme de **rétropropagation**.

# Objectifs

- Comprendre la notion de graphe de calcul d'une fonction
- Calcul de la valeur de la fonction en un point à partir du graphe
- Calcul du gradient à partir du graphe
- Calcul efficace du gradient à partir du graphe

# Plan

Graphe de calcul

Calcul de la valeur d'une fonction en un point

Calcul du gradient d'une fonction en un point

Un exemple plus réaliste

# Graphe de calcul


- Soit la fonction :  $f(a, b) = (a + b) \times (b + 1)$
- Elle comporte trois opérations : deux additions et une multiplication
- On introduit des **variables** pour représenter la valeur de la fonction (variable finale) et les résultats intermédiaires.
- On obtient trois équations, chacune composée d'une opération ou d'un appel de fonction :

$$c = a + b$$

$$d = b + 1$$


$$e = c \times d$$

# Graphe de calcul




- On peut représenter les équations sous la forme d'un graphe.
- Chaque sommet du graphe correspond à une variable ou une constante.
- On représente au niveau de chaque sommet la fonction où l'opération qui lui correspond.
- On peut se servir du graphe pour réaliser le calcul, en donnant des valeurs à  $a$  et à  $b$ .

# Graphe de calcul




# Calcul du gradient

- On peut aussi se servir du graphe de calcul correspondant à une fonction pour calculer le gradient de la fonction.
- On associe à tout arc  $x \rightarrow y$  la dérivée partielle  $\frac{\partial y}{\partial x}$



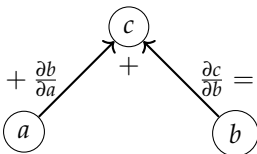



# Calcul du gradient



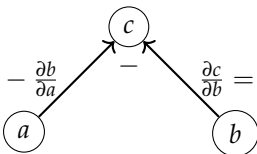
- On définit des règles spécifiques à chaque type de sommet
- qui dépendent de la fonction ou de l'opération associée au sommet.


# Addition

$$\frac{\partial c}{\partial a} = \frac{\partial}{\partial a}(a + b) = \frac{\partial a}{\partial a} + \frac{\partial b}{\partial a}$$

$$\frac{\partial c}{\partial b} = \frac{\partial}{\partial b}(a + b) = \frac{\partial a}{\partial b} + \frac{\partial b}{\partial b}$$

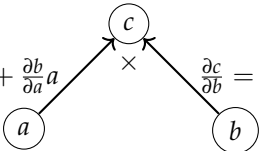


# Soustraction


$$\frac{\partial c}{\partial a} = \frac{\partial}{\partial a}(a - b) = \frac{\partial a}{\partial a} - \frac{\partial b}{\partial a}$$

$$\frac{\partial c}{\partial b} = \frac{\partial}{\partial b}(a - b) = \frac{\partial a}{\partial b} - \frac{\partial b}{\partial b}$$



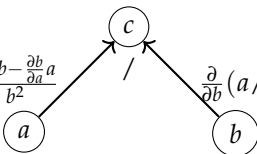
# Multiplication


$$\frac{\partial c}{\partial a} = \frac{\partial}{\partial a}(a \times b) = \frac{\partial a}{\partial a}b + \frac{\partial b}{\partial a}a$$


A diagram showing a multiplication operation. At the top is a circle containing the variable  $c$ . Below it is a multiplication symbol  $\times$ . Two arrows point upwards towards the  $\times$  symbol: one from a circle containing  $a$  on the left, and one from a circle containing  $b$  on the right.




# Division

$$\frac{\partial}{\partial a}(a/b) = \frac{\frac{\partial a}{\partial a}b - \frac{\partial b}{\partial a}a}{b^2}$$

$$\frac{\partial}{\partial b}(a/b) = \frac{\frac{\partial a}{\partial b}b - \frac{\partial b}{\partial b}a}{b^2}$$




# Exponentielle

- $y = b^x$




- $y = e^x$




# Logarithme

■  $y = \log_b(x)$




■  $y = \ln(x)$




# Opposée et inverse

■  $y = -x$



■  $y = \frac{1}{x}$



Pas nécessaire mais pratique.




# Composition

- $h(x) = f \circ g(x) = f(g(x))$
- introduction de variables intermédiaires

$$v = f(u)$$

$$u = g(x)$$

- Graphe correspondant




- Règle de dérivation des fonctions composées :

$$\frac{\partial v}{\partial x} = \frac{\partial v}{\partial u} \frac{\partial u}{\partial x}$$

- C'est le calcul qui est effectué si on multiplie les dérivées sur les arcs du graphe!

# Composition


- $y = h(f(x), g(x))$



- $\frac{\partial y}{\partial x} = \frac{\partial y}{\partial u} \frac{\partial u}{\partial x} + \frac{\partial y}{\partial v} \frac{\partial v}{\partial x}$


- On fait la somme des poids des chemins !

# Calcul du gradient




- 1 On attribue une valeur aux variables libres.
- 2 On calcule la valeur des différentes variables du graphe en partant des variables libres.
- 3 On calcule les dérivées partielles.
- 4 Pour chaque variable libre, on calcule le poids de tous les chemins menant au dernier sommet

Exemple :  $a = 3$  et  $b = 5$



- 1 On attribue une valeur aux variables libres.
- 2 On calcule la valeur des différentes variables du graphe en partant des variables libres.
- 3 On calcule les dérivées partielles.
- 4 Pour chaque variable libre, on calcule le poids de tous les chemins menant au dernier sommet
  - $\frac{\partial e}{\partial a} = 6 \times 1$
  - $\frac{\partial e}{\partial b} = 6 \times 1 + 8 \times 1$
  - $\nabla f(3,5) = [6, 14]^T$


# Problème d'efficacité



$$\frac{\partial f}{\partial a} = \frac{\partial c}{\partial a} \times \frac{\partial d}{\partial c} \times \frac{\partial e}{\partial d} \times \frac{\partial f}{\partial e}$$
$$\frac{\partial f}{\partial b} = \frac{\partial c}{\partial b} \times \frac{\partial d}{\partial c} \times \frac{\partial e}{\partial d} \times \frac{\partial f}{\partial e}$$

Le produit  $\frac{\partial d}{\partial c} \times \frac{\partial e}{\partial d} \times \frac{\partial f}{\partial e}$  est répété deux fois


# Problème d'efficacité



$$\begin{aligned}\frac{\partial f}{\partial e} &= \frac{\partial f}{\partial e} \times \frac{\partial f}{\partial f} & \frac{\partial f}{\partial d} &= \frac{\partial e}{\partial d} \times \frac{\partial f}{\partial e} \\ \frac{\partial f}{\partial c} &= \frac{\partial d}{\partial c} \times \frac{\partial f}{\partial d} & \frac{\partial f}{\partial a} &= \frac{\partial c}{\partial a} \times \frac{\partial f}{\partial c} \\ \frac{\partial f}{\partial b} &= \frac{\partial c}{\partial b} \times \frac{\partial f}{\partial c}\end{aligned}$$


Chaque produit n'est fait qu'une fois et stocké dans un sommet du graphe.

# Calcul efficace du gradient



- 1 On attribue une valeur aux variables libres.
- 2 On calcule la valeur des différentes variables du graphe en partant des variables libres.
- 3 On calcule les dérivées partielles.
- 4 On calcule la dérivée partielle de la variable finale par rapport à chaque variable du graphe.


# Calcul efficace du gradient



- 1 On attribue une valeur aux variables libres.
- 2 On calcule la valeur des différentes variables du graphe en partant des variables libres.
- 3 On calcule les dérivées partielles.
- 4 On calcule la dérivée partielle de la variable finale par rapport à chaque variable du graphe.



## Un exemple plus réaliste




$$h_1 = \text{ReLU}(w_1 x_1 + w'_2 x_2 + b_1)$$

$$h_2 = \text{ReLU}(w'_1 x_1 + w_2 x_2 + b_2)$$

$$\hat{y}_1 = w_3 \times h_1 + w_4 \times h_2 + b_3$$

$$\hat{y}_2 = w'_3 \times h_1 + w'_4 \times h_2 + b_4$$


# Grphe de calcul - première couche



$$h_1 = \text{ReLU}(w_1 x_1 + w'_2 x_2 + b_1)$$

$$h_2 = \text{ReLU}(w'_1 x_1 + w_2 x_2 + b_2)$$


# Graphe de calcul - deuxième couche



$$\hat{y}_1 = w_3 \times h_1 + w_4 \times h_2 + b_3$$

$$\hat{y}_2 = w'_3 \times h_1 + w'_4 \times h_2 + b_4$$


# Graphe de calcul - Softmax



$$e_1 = \frac{e^{\hat{y}_1}}{e^{\hat{y}_1} + e^{\hat{y}_2}}$$


$$e_2 = \frac{e^{\hat{y}_2}}{e^{\hat{y}_1} + e^{\hat{y}_2}}$$

# Graphe de calcul - entropie croisée




$$E = y_1 \times -\log_2(e_1) + y_2 \times -\log_2(e_2)$$


# Calcul de la valeur de l'erreur



# Calcul de la valeur de l'erreur




# Calcul des dérivées partielles





# Calcul du gradient



# Sources

- Ian Goodfellow, Yoshua Bengio, Aaron Courville, *Deep Learning*, MIT Press, 2016.
- Le blog de Christopher Colah <http://colah.github.io>