

Etude de la scabilité des méthodes d'optimisation d'architecture des réseaux de neurones. Application à l'estimation des redshifts photométriques

Nina Pelagie BEKONO

LIMOS, Université Blaise Pascal

09 Avril 2015

Plan

- 1 Première Partie: Memoire de C.Arouri
- 2 Deuxième Partie: Scalabilité

sommaire

- 1 Première Partie: Memoire de C.Arouri
- 2 Deuxième Partie: Scalabilité

Galaxie

Définition

Assemblage d'étoiles, de gaz, de poussières et de matière noire, contenant parfois un trou noir supermassif en son centre. **Exemple: La voie lactée.**

Différents Types: elliptique, Spirale, Irrégulière.



Figure : Capture de galaxies

Redshift Photométrie

Definition

Phénomène astronomique de décalage vers les grandes longueurs d'ondes (*rouge*) des raies spectrales et de l'ensemble du spectre d'une galaxie.

- **Cause:** la dilatation de l'espace provoquée par l'expansion de l'univers.

Redshift Photométrie

Definition

Phénomène astronomique de décalage vers les grandes longueurs d'ondes (*rouge*) des raies spectrales et de l'ensemble du spectre d'une galaxie.

- **Cause:** la dilatation de l'espace provoquée par l'expansion de l'univers.

Interêt

Evaluer la distance d'une galaxie par rapport à un observateur

- Redshift (z) \Rightarrow Vitesse d'éloignement ($v = cz$).
- $V = H_0 D$ (Relation d'Hubble).

Methodes Spectroscopiques

- 1 Observer les galaxies avec un élément disperseur pour séparer les différentes longueurs d'onde de la lumière.
- 2 Identifier des raies d'émission et d'absorption.
- 3 Déduire le décalage spectral.

Caractéristiques

- Efficaces.
- Précises.
- Coûteuses en temps.

Methodes Photométriques

Utilisation des filtres relativement grossiers.



- 1 Template Fitting ou ajustement des SED aux modèles.
- 2 Methodes empiriques: Utiliser le Redshift pour calibrer un algorithme d'apprentissage.

Plusieurs techniques:

- Les arbre de decision.
- Support Vector Machines.
- Forêts aléatoires.
- Réseaux de neurones.

Définition

Les reseaux de neurones artificiels



Neurone formel:

- Combinaison linéaire des entrées: $v = \sum_{i=1}^n w_i * x_i$ avec w_i les poids, x_i les entrées et n le nombre d'entrées.
- Sortie $y = f(v)$ avec f la fonction d'activation.

Problème

RNA: Approximateurs universels.

Trouver l'architecture adaptée

- 1 quel est le nombre de couches du reseau?
- 2 quel est le nombre de neurones par couche?
- 3 comment les connecter?
- 4 comment initialiser des poids de connexions?

Généralement le choix est fait par l'utilisateur.

Problème

RNA: Approximateurs universels.

Trouver l'architecture adaptée

- 1 quel est le nombre de couches du reseau?
- 2 quel est le nombre de neurones par couche?
- 3 comment les connecter?
- 4 comment initialiser des poids de connexions?

Généralement le choix est fait par l'utilisateur.

Deux approches d'optimisation dans la littérature:

- soit de manière dynamique: *MTLING*, *MTower*...
- soit de manière statique: *treillis de Galois*,...

Estimation de Redshifts photométriques => Problème de regression. Des travaux existants: *Collister et Lahav 2004, M.Brescia et al. 2012, F.Feroz et al. 2014 ...* mais pas d'optimisation d'architecture de réseaux de neurones.

Estimation de Redshifts photométriques \Rightarrow Problème de regression. Des travaux existants: *Collister et Lahav 2004, M.Brescia et al. 2012, F.Feroz et al. 2014 ...* mais pas d'optimisation d'architecture de réseaux de neurones.

Solution Proposée par C. Arouri

3 étapes:

- 1 Application d'un algorithme de clustering non paramétrique: *X-Means, DBSCAN, Meanshift.*
- 2 Construction d'un RNA à 3 couches avec la couche cachée ayant autant de neurones que de groupes retournés par l'étape précédente.
- 3 Apprentissage du réseau : *algorithme MLPQNA.*

Estimation de Redshifts photométriques \Rightarrow Problème de regression. Des travaux existants: *Collister et Lahav 2004, M.Brescia et al. 2012, F.Feroz et al. 2014 ...* mais pas d'optimisation d'architecture de réseaux de neurones.

Solution Proposée par C. Arouri

3 étapes:

- 1 Application d'un algorithme de clustering non paramétrique: *X-Means, DBSCAN, Meanshift.*
- 2 Construction d'un RNA à 3 couches avec la couche cachée ayant autant de neurones que de groupes retournés par l'étape précédente.
- 3 Apprentissage du réseau : *algorithme MLPQNA.*

Solution appliquée à des données de tailles raisonnables.
Qu'en est-il des grandes masses données?

sommaire

- 1 Première Partie: Memoire de C.Arouri
- 2 Deuxième Partie: Scalabilité

Nous sommes à l'ère du "Big Data"

Big Data: Définition

Quatre dimensions(4 V):

- 1 **Volume:** Grandes quantités de données (ordre du zettaoctet: 10^{21} O).
- 2 **Variété:** Différents types de données provenant de différentes sources.
- 3 **Vélocité:** Frequence à laquelle les données sont générées, capturées et partagées.
- 4 **Véracité:** Plausibilité des informations générées.

Nous sommes à l'ère du "Big Data"

Big Data: Définition

Quatre dimensions(4 V):

- 1 **Volume:** Grandes quantités de données (ordre du zettaoctet: 10^{21} O).
- 2 **Variété:** Différents types de données provenant de différentes sources.
- 3 **Vélocité:** Frequence à laquelle les données sont générées, capturées et partagées.
- 4 **Véracité:** Plausibilité des informations générées.


Exemple: nombre de galaxies

- 100 milliards: galaxies observables dans l'univers visible.
- Dizaines de millions déjà photographiées.

Projet PetaSky

Gestion et exploration des grandes masses de données scientifiques issues d'observations astronomiques grand champ.

- 1 **LSST** : 3,2 pixels de données par nuit pendant 10 ans
=> 140 Po d'images en fin de programme.



- 2 **Euclid**: mesurera les distances de 50 millions de galaxies par un spectographe infrarouge (7 ans).

Etapas

Trois grandes étapes:

- 1 Etudier l'état de l'art sur les methodes de classification non supervisé et le passage à l'échelle, notamment à travers les plateformes comme *SPARK ou Hadoop /MapReduce*.

Etapas

Trois grandes étapes:

- 1 Etudier l'état de l'art sur les methodes de classification non supervisé et le passage à l'échelle, notamment à travers les plateformes comme *SPARK ou Hadoop /MapReduce*.
- 2 Etudier l'etat sur le deepLearning et notamment les problèmes d'optimisation d'architecture.

Etapes

Trois grandes étapes:

- 1 Etudier l'état de l'art sur les méthodes de classification non supervisé et le passage à l'échelle, notamment à travers les plateformes comme *SPARK* ou *Hadoop/MapReduce*.
- 2 Etudier l'état sur le deepLearning et notamment les problèmes d'optimisation d'architecture.
- 3 Proposer une approche d'optimisation d'architecture neuronale.

Ce qui a déjà été fait

① Etape préliminaire:

- Comprendre le travail précédemment fait (*Mémoire de l'étudiante C. Arouri.*)
- Reproduire les expérimentations (*Weka, ANN_Z,...*)

Ce qui a déjà été fait

① Etape préliminaire:

- Comprendre le travail précédemment fait (*Mémoire de l'étudiante C. Arouri.*)
- Reproduire les expérimentations (*Weka, ANN_Z,...*)

② Etude des algorithmes proposés pour le clustering des Big Data

- *A survey of clustering Algorithms for Big Data: Taxonomy and Empirical Analysis, Fahad et al.*
- *Big Data Clustering: A review, A. Seyed et al.*
- *Scalable K-Means ++, Bahman Bahmani.*

Ce qui a déjà été fait

① Etape préliminaire:

- Comprendre le travail précédemment fait (*Mémoire de l'étudiante C. Arouri.*)
- Reproduire les expérimentations (*Weka, ANN_Z,...*)

② Etude des algorithmes proposés pour le clustering des Big Data

- *A survey of clustering Algorithms for Big Data: Taxonomy and Empirical Analysis, Fahad et al.*
- *Big Data Clustering: A review, A. Seyed et al.*
- *Scalable K-Means ++, Bahman Bahmani.*

③ Survey sur les plateformes de manipulation des Big Data

- *Hadoop MapReduce => Mahout, Oryx*
- *Apache Spark => MLlib*
- *Sparkling water = Spark + H2O*

Ce qu'il reste à faire

- Etudier l'impact de la selection d'une partie de l'ensemble des données sur l'optimisation de l'architecture.

Ce qu'il reste à faire

- Etudier l'impact de la selection d'une partie de l'ensemble des données sur l'optimisation de l'architecture.
- DeepLearning: définition, fonctionnement,...

Ce qu'il reste à faire

- Etudier l'impact de la selection d'une partie de l'ensemble des données sur l'optimisation de l'architecture.
- DeepLearning: définition, fonctionnement,...
- Proposer et tester une approche d'optimisation d'architecture neuronale.

