

Deep Learning and Reality Gap

RESPONSABLES: Michèle Sebag et Gaetan Marceau-Caron

LABORATOIRE: Laboratoire de Recherche en Informatique CNRS UMR 8623 & INRIA Saclay

ADRESSE: Université Paris-Sud, 91405 Orsay Cedex

MAIL: Michele.Sebag@lri.fr

URL: http://www.lri.fr/~sebag/Stages/DL_RG.pdf

RÉSUMÉ :

L'apprentissage par transfert a pour but de transférer les modèles appris dans un domaine source S , dans le contexte d'un domaine cible C . Par exemple, le modèle des préférences d'un utilisateur dans le domaine des films ($h : S \mapsto \mathbb{R}$) peut faciliter la modélisation de ses préférences dans le domaine de la musique. L'apprentissage par transfert sert à apprendre plus vite (on part d'un modèle assez bon) ou à apprendre tout court (lorsqu'on ne dispose pas d'exemples étiquetés du domaine cible) sous certaines conditions (la proximité des domaines source et cible, dans un sens bien formalisé).

L'adaptation de domaine, une des approches de l'apprentissage de transfert, consiste à définir deux plongements, respectivement des espaces source et cible, dans un même espace \mathbb{R}^d . Sous les hypothèses classiques de l'apprentissage de transfert, le modèle appris à partir des images des exemples source est alors directement applicable sur les images des exemples cible.

Objectif du stage

Nous nous attaquons ici au problème de la calibration des données et du modèle associé. Par exemple en robotique, un contrôleur qui est très performant en simulation (in-silico) donne souvent des résultats misérables lorsqu'on le transfère sur le robot (in-situ). Ce problème appelé *Reality Gap* pénalise fortement l'apprentissage par optimisation directe des contrôleurs : l'optimisation directe pose des problèmes de temps et de robustesse si elle est faite in-situ, mais elle pose des problèmes d'efficacité si elle est faite in silico. Le but du stage est de franchir le *Reality Gap*, en unifiant les deux distributions des données simulées (domaine source) et réelles (domaine cible).

Approche

Une approche possible est celle des réseaux neuronaux profonds (Deep Learning), en s'inspirant des travaux de Ganin et al, 2015. On disposera de deux jeux de données échantillonnant respectivement les domaines source et cible:

$$\mathcal{E}_S = \{(x_i, y_i), x_i \in S, y_i \in \mathbb{R}, i = 1 \dots n_S\}; \mathcal{E}_C = \{(x'_i, y'_i), x_i \in C, y_i \in \mathbb{R}, i = 1 \dots n_C\}$$

(eventuellement, les étiquettes y'_i sont inconnues dans la base \mathcal{E}_C). On cherche alors deux plongements f et g respectivement de S et C dans \mathbb{R}^d tels que:

- La base d'exemples $\{(f(x_i), 1), i = 1 \dots n_S\} \cup \{(g(x'_i), 0), i = 1 \dots n_C\}$ ne soit pas séparable (i.e. on n'arrive pas à discriminer les images des exemples source des images des exemples cibles);
- On peut apprendre à partir des exemples $(f(x_i), y_i)$, i.e. il existe $h : \mathbb{R}^d \mapsto \mathbb{R}$ tel que $hof(x_i) \approx y_i$.

Ce stage peut être traité sous l'angle théorique ou sous l'angle empirique. L'étude théorique demande de très bonnes capacités d'analyse. L'étude empirique demande d'excellentes capacités informatiques (programmation C++ ou Python, en partant de bibliothèques existantes ; portage sur GPU).

Références

Yaroslav Ganin, Victor S. Lempitsky: Unsupervised Domain Adaptation by Backpropagation. Int. Conf. on Machine Learning 2015: 1180-1189

Yaroslav Ganin, Evgeniya Ustinova, Hana Ajakan, Pascal Germain, Hugo Larochelle, François Laviolette, Mario Marchand, Victor S. Lempitsky: Domain-Adversarial Training of Neural Networks. JMLR, to appear.