



contact

114 Boulevard
Malesherbes, 75017,
Paris

ad@datakalab.com

kb@datakalab.com

lf@datakalab.com

Estimation d'incertitude de la prédiction des réseaux neuronaux profonds

Mots clés: Deep learning ; Uncertainty ; Out-of-domain generalization ; Dropout ; Ensembles ; Pruning

Environnement

Datakalab est une startup basée à Paris (17ème arrondissement) spécialisée dans des algorithmes d'apprentissage profond à faible consommation, efficaces en termes d'exécution, respectueux de la vie privée et fonctionnant entièrement en embarqué. Ses travaux de recherche ont donné lieu à des publications dans les meilleures conférences et journaux du domaine (T-PAMI, NeurIPS, ICCV, CVPR, AAAI)

Le stage sera encadré par Kévin Bailly directeur de la recherche de Datakalab et Maître de conférences, HDR, à l'ISIR et Arnaud Dapogny, chercheur en IA à Datakalab.

Contexte

Les réseaux de neurones profonds ont rendu possible des avancées considérables dans de nombreux domaines applicatifs de l'intelligence artificielle tels que la vision par ordinateur, la reconnaissance vocale ou le traitement naturel des langues. Toutefois, bien que ces réseaux fournissent des performances impressionnantes, on observe des différences importantes dans la généralisation de la précision pour des prédictions différant radicalement de la distribution d'apprentissage, quand bien même ces prédictions apparaîtraient très tranchées : autrement dit, la probabilité maximale (MCP [1]) n'est pas un bon indicateur du caractère certain d'une prédiction.

Étant partenaire du consortium confiance.ai¹, Datakalab souhaite mettre en place et étudier des techniques de modélisation d'incertitude des réseaux profonds : à défaut d'avoir une précision absolue dans un contexte donné, on souhaite savoir lorsque la prédiction est susceptible d'être rendue caduque par la présence de bruit dans les données (incertitude aléatoire) ou liée à une différence entre les domaines d'apprentissage et de test (incertitude épistémique).

Objectifs du stage

De nombreuses méthodes cherchent à fournir des indicateurs plus fiables de l'incertitude d'une prédiction: la méthode Monte-Carlo Dropout [2] consiste, par exemple, à utiliser une modélisation variationnelle pour obtenir, relativement à chaque prédiction, une variance locale. D'un point de vue ensembliste, cela consiste à utiliser plusieurs modèles très proches les uns des autres (donc à faible variabilité). Un autre extrême consiste à employer des ensembles de réseaux profonds [3] afin de décorréler davantage les différentes prédictions entre elles. Récemment, l'approche Masksembles [4] consiste à construire et apprendre un ensemble de plusieurs réseaux profonds contenus dans une même architecture par application de masques de dropout fixés à l'initialisation.

Dans le cadre du stage, on cherchera à étudier et étendre les méthodes d'auto-ensembles telles que Masksembles [4], en utilisant et combinant par exemple les approches telles que de profondeur stochastique [5], Bagging [6], ou encore MIMO [7]. En fonction de l'avancée des travaux, le stagiaire pourra investiguer des méthodes permettant d'apprendre conjointement les sous-réseaux de l'auto-ensemble : et cherchera alors à définir dans le réseau des sous-réseaux les plus indépendants possibles ayant une précision maximale. Il pourra par exemple s'inspirer d'approches pour l'élagage des réseaux neuronaux profonds [8].

Profil et compétences recherchées

Diplôme de Master ou Grande École. Compétences requises :

- Machine Learning / Deep Learning

¹<https://www.confiance.ai/>



- Programmation Python et librairie deep learning (tensorflow ou pytorch)
- Excellentes capacités relationnelles et rédactionnelles (français et anglais)

Modalités de candidature

Pour postuler à ce stage, le candidat est invité à communiquer par mail (cf. liste des contacts associés à cette fiche de stage) :

- Son CV
- Ses résultats académiques des deux dernières années universitaires
- (optionnel) Un lien vers un des ces projets en machine learning (lien GitHub / GitLab ou Colab)

Références

[1] Hendrycks, Dan and Gimpel, Kevin "A baseline for detecting misclassified and out-of-distribution examples in neural networks" ICLR 2017

[2] Gal, Yarin and Ghahramani, Zoubin "Dropout as a bayesian approximation: Representing model uncertainty in deep learning" ICML 2016

[3] Lakshminarayanan, Balaji and Pritzel, Alexander and Blundell, Charles "Simple and scalable predictive uncertainty estimation using deep ensembles" NeurIPS 2017

[4] Durasov, Nikita and Bagautdinov, Timur and Baque, Pierre and Fua, Pascal "Masksembles for Uncertainty Estimation" CVPR 2021

[5] Huang, Gao and Yu Sun, Zhuang Liu and Daniel Sedra and Kilian Q. Weinberger "Deep networks with stochastic depth" ECCV 2016

[6] Breiman, Leo "Bagging predictors" Machine learning, 1996

[7] Havasi, Marton and Rodolphe Jenatton and Stanislav Fort and Jeremiah Zhe Liu and Jasper Snoek and Balaji Lakshminarayanan and Andrew M. Dai and Dustin Tran. "Training independent subnetworks for robust prediction" ICLR 2021

[8] Yvinec, Edouard and Dapogny, Arnaud and Cord, Matthieu and Bailly, Kévin SInGE: Sparsity via Integrated Gradients Estimation of Neuron Relevance", NeurIPS 2022