



## Réseaux de neurones bayésiens pour la quantification de l'incertitude

### Encadrements et contacts :

Noura Dridi, [noura.dridi@ens2m.fr](mailto:noura.dridi@ens2m.fr)

Zeina Al Masry, [zeina.almasry@femto-st.fr](mailto:zeina.almasry@femto-st.fr)

### Lieu du stage

Établissement : SUPMICROTECH-ENSMM, 26 Rue de l'Épitaphe, 25000 Besançon.

Laboratoire : Institut FEMTO-ST.

Période de stage : Avril-septembre 2024. Dates flexibles.

Compétences souhaitées : mathématiques-appliquées, apprentissage profond, programmation Python.

Mots-clés : quantification de l'incertitude, réseaux de neurones, apprentissage profond, approche bayésienne.

Profil recherché : étudiant.e de Master 2 ou en dernière année d'école d'ingénieur.

### Contexte et résumé

Les réseaux de neurones (RN) sont largement utilisés dans plusieurs domaines. Toutefois, les résultats fournis par un algorithme basé sur les RN intègrent des incertitudes liées aux données et au modèle. Il est important de quantifier ces incertitudes, pour fournir une information supplémentaire afin d'assister la décision finale. Par exemple, en industrie J. Fernández (2022) lorsqu'une anomalie est détectée avec un faible niveau de confiance, une vérification supplémentaire à l'aide d'une autre source d'information est ajoutée (image, intervention humaine...) avant de planifier des actions de réparation. Un autre exemple en médical, la mesure de l'incertitude permet aux praticiens de prendre des décisions adaptées pour la prise en charge des patientes comme par exemple explorer d'autres tests Orucevic et al. (2019). Plus généralement, une quantification fiable de l'incertitude de la prédiction permet de faire confiance ou non aux prévisions pour des entrées interpolant/extrapolant les situations vues dans l'ensemble d'entraînement. Plusieurs approches sont proposées pour la quantification d'incertitude Angelopoulos and Bates (2022), certaines sont dédiées aux RN Gal and Ghahramani (2016), B Lakshminarayanan (2017), Murat et al. (2018)...

Les réseaux de neurones bayésiens (RNB) fournissent un outil mathématique pour mesurer l'incertitude du modèle, Graves (2011) . L'idée est de remplacer les valeurs déterministes des paramètres du RN (poids et biais) par des distributions de probabilité avec un a priori gaussien, pour ensuite apprendre les paramètres de ces distributions.

Une fois entraîné, les sorties du RN peuvent être évaluées plusieurs fois pour obtenir une distribution empirique des prédictions. Plusieurs méthodes ont été proposées pour les RNB basées, par exemple, sur l'approximation de Laplace MacKay (1992) ou des méthodes de Monte Carlo Hamiltonien Neal (1995). Dans le cadre de ce projet, l'objectif est de développer une méthode de quantification basée sur les RNB. La méthode sera appliquée pour un problème de classification et régression sur des données synthétiques.

**Objectifs du stage :**

- Etat de l'art sur les RNB.
- Développer un algorithme basé sur les RNB.
- Optimisation de l'architecture du réseau ainsi que les différents hyperparamètres.
- Appliquer l'algorithme pour la quantification l'incertitude pour la régression et la classification et évaluation les performances.
- Comparer l'approche proposée avec d'autres techniques de la littérature dropout Gal and Ghahramani (2016), ensemble learning B Lakshminarayanan (2017).

## Références

Anastasios N. Angelopoulos and Stephen Bates. A gentle introduction to conformal prediction and distribution-free uncertainty quantification. 2022.

C Blundell B Lakshminarayanan, A Pritzel. Simple and scalable predictive uncertainty estimation using deep ensembles. *Advances in neural information processing systems.proceedings.neurips*, 2017.

Yarin Gal and Zoubin Ghahramani. Dropout as a bayesian approximation : Representing model uncertainty in deep learning. 2016.

Alex Graves. Practical variational inference for neural networks. *Advances in Neural Information Processing Systems 24 (NIPS)*, 24, 2011.

J. Chiachío R. Muñoz F. Herrera J. Fernández, M. Chiachío. Uncertainty quantification in neural networks by approximate bayesian computation : Application to fatigue in composite materials. *Engineering Applications of Artificial Intelligence*, 107, 2022.

D J C. MacKay. A practical bayesian framework for back-propagation networks.neural computation. *Neural computation*, 4(3), 1992.

S. Murat, L. Kaplan, and M. Kandemir. Evidential deep learning to quantify classification uncertainty. volume 31, 2018.

Radford M. Neal. Bayesian learning for neural networks. 1995.

Amila Orucevic, John L Bell, Megan King, Alison P McNabb, and Robert E Heidel. Nomogram update based on tailorx clinical trial results-oncotype dx breast cancer recurrence score can be predicted using clinicopathologic data. *The Breast*, 46 :116–125, 2019.