

---

## Master's Thesis : Differentiable Surrogate Models to Solve Nonlinear Inverse Problems

**Auteur** : Vandegar, Maxime

**Promoteur(s)** : Louppe, Gilles

**Faculté** : Faculté des Sciences appliquées

**Diplôme** : Master en ingénieur civil en informatique, à finalité spécialisée en "intelligent systems"

**Année académique** : 2019-2020

**URI/URL** : <http://hdl.handle.net/2268.2/9064>

---

### *Avertissement à l'attention des usagers :*

*Tous les documents placés en accès ouvert sur le site le site MatheO sont protégés par le droit d'auteur. Conformément aux principes énoncés par la "Budapest Open Access Initiative"(BOAI, 2002), l'utilisateur du site peut lire, télécharger, copier, transmettre, imprimer, chercher ou faire un lien vers le texte intégral de ces documents, les disséquer pour les indexer, s'en servir de données pour un logiciel, ou s'en servir à toute autre fin légale (ou prévue par la réglementation relative au droit d'auteur). Toute utilisation du document à des fins commerciales est strictement interdite.*

*Par ailleurs, l'utilisateur s'engage à respecter les droits moraux de l'auteur, principalement le droit à l'intégrité de l'oeuvre et le droit de paternité et ce dans toute utilisation que l'utilisateur entreprend. Ainsi, à titre d'exemple, lorsqu'il reproduira un document par extrait ou dans son intégralité, l'utilisateur citera de manière complète les sources telles que mentionnées ci-dessus. Toute utilisation non explicitement autorisée ci-avant (telle que par exemple, la modification du document ou son résumé) nécessite l'autorisation préalable et expresse des auteurs ou de leurs ayants droit.*

---

# Differentiable Surrogate Models to Solve Nonlinear Inverse Problems

Maxime Vandegar, Gilles Louppe

*University of Liège - Faculty of Applied Sciences  
Department of Electrical Engineering and Computer Science  
Academic year 2019-2020*

---

## **Abstract**

Doing inference on a model defining an implicit likelihood that is not known in closed form is called likelihood-free inference. This occurs frequently in engineering and science domains where a simulator is used as a generative model of data, but the likelihood of the generated data is not known and is intractable. Given observed data, we combine the idea of hierarchical Bayesian modeling, empirical Bayes, and neural density estimation with normalizing flow to first learn a surrogate approximation of the model likelihood and then, to learn a prior distribution over the model parameters. The learned prior and the surrogate likelihood further allow to learn a posterior distribution for each observation. This is a general approach to likelihood-free inference, and is especially useful in settings where the simulator is too costly to run at inference time. We show the applicability of our methods on a real physical problem from high energy physics (HEP).

*Keywords:* HEP, Amortized inference, Generative modeling

---