

## PROPOSITION DE STAGE EN COURS D'ETUDES

Référence : **DTIS -2018-28**

(à rappeler dans toute correspondance)

Lieu : Palaiseau

Département/Dir./Serv. : DTIS/M2CI

Tél. : 01.80.38.66.08  
01.80.38.66.88

Responsable(s) du stage : Mathieu Balesdent,  
Loïc Brevault

Email. : mathieu.balesdent@onera.fr,  
loic.brevault@onera.fr

### DESCRIPTION DU STAGE

Thématique(s) : Conception et optimisation des systèmes

Type de stage :  Fin d'études bac+5     Master 2     Bac+2 à bac+4

**Intitulé : Approches basées sur le machine learning pour la conception multidisciplinaire de véhicules aérospatiaux, application à la conception de lanceurs réutilisables**

Sujet : Le contexte de ce stage est l'élaboration de méthodologies de conception multidisciplinaires de véhicules aérospatiaux reposant sur des techniques de machine learning adaptées à la grande dimension.

L'optimisation multidisciplinaire (MDO pour Multidisciplinary Design Optimization [1]) est un ensemble de méthodes visant à améliorer l'efficacité des processus de conception. Ces méthodes, mettant en jeu plusieurs disciplines (aérodynamique, propulsion, structure, trajectoire, etc.), sont particulièrement utilisées lors des phases avant-projet afin de déterminer les futurs concepts à développer.

Les phases avant-projet de la conception requièrent très souvent d'explorer largement l'espace des solutions possibles afin de trouver le concept à développer. Ceci se fait en employant des modélisations "basse-fidélité" (modèle statistique, modélisations simplifiées des phénomènes physiques, etc.). Ce type de modélisations possède l'avantage de présenter des niveaux de détails (e.g. nombre de paramètres) et de complexité adaptés à la phase avant-projet ainsi qu'un coût de calculs limité. Cependant, pour l'étude de concepts de rupture (par exemple les lanceurs réutilisables), l'incertitude associée à ce niveau de fidélité est trop importante pour garantir une confiance suffisante dans les résultats obtenus. Ainsi, le recours à des modélisations dites "haute-fidélité" (modèles CFD, FEM) devient essentielle. Cependant, les coûts de calculs associés rendent impossible leur intégration directe dans un processus de MDO. Il est alors nécessaire de recourir à des modèles de substitution (e.g. processus gaussiens, réseaux de neurones, polynômes du chaos) afin de remplacer les modèles coûteux par des approximations mathématiques moins chères à évaluer.

L'exploitation de modèles de substitution dans les processus de conception multi-disciplinaires doit permettre d'accroître les connaissances en phase d'avant-projet (grâce à l'intégration de la "haute-fidélité") tout en maîtrisant les coûts de calculs. L'objectif du stage est de développer des méthodologies de conception à base de modèles de substitution en grande dimension pour la MDO. Pour cela, deux pistes de travail sont envisagées:

- un travail sur les modèles de substitution pour la prise en compte de la grande dimension. Le développement récent de nouvelles techniques de machine learning (e.g. Deep Learning) adaptées à la grande dimension permet d'envisager leur utilisation dans le cadre de la conception MDO. En effet, l'incorporation de techniques modernes d'algèbre (preconditionned conjugate gradients, MVM-based inference, stochastic variational deep learning, etc.) permet d'accélérer les phases d'entraînement des modèles de substitution mais également d'augmenter le nombre de points d'entraînement, essentiel dans des problèmes en grande dimension. Il s'agira dans un premier temps de prendre en main quelques bibliothèques existantes [3,4,5] apparaissant comme adaptées pour traiter ces problématiques sur des cas tests (analytiques et aérospatiaux) en grande dimension, de les adapter aux spécificités de la MDO, d'identifier les limites et de proposer des améliorations afin de pouvoir utiliser ces techniques pour la conception de véhicules aérospatiaux. On s'intéressera notamment au positionnement des données d'entrée pour les problèmes en grande dimension.

- un travail autour de la modélisation des noyaux pour les processus gaussiens (GP) avec deux applications: les problèmes mixtes continues / discrets et les problèmes non stationnaires.

- Pour la première application, des approches récentes [6,7] ont été développées pour prendre en compte dans les stratégies de machine learning à base de GP la présence de variables continues (e.g. diamètre, masse d'ergols), discrètes (e.g. nombre d'étages de lanceurs) et catégorielles (e.g. type de propulsion, solide ou liquide). Ces approches impliquent une re-définition des noyaux modélisant la corrélation entre les données d'apprentissage. On s'intéressera plus particulièrement aux Group Kernels [6] et on comparera cette approche avec des expériences déjà menées à l'ONERA [7].

- Concernant la seconde application, des noyaux dédiés à des problèmes non-stationnaires [8,9] (régularité de modèle différent selon la région d'entrée d'intérêt à cause de comportements physiques différents) ont été développés afin d'adapter les GP pour de tels problèmes. Des développements sur cette thématique autour des Deep Gaussian Process (DGP, plusieurs couches de GPs) sont en cours à l'ONERA [2], il s'agira de comparer les techniques GP à une couche mais avec noyaux non-stationnaires aux approches par DGP.

Ce stage s'inscrit dans la dynamique de recherche autour de la conception de lanceurs réutilisables et l'optimisation multidisciplinaire au sein de l'Onera. Dans la suite des travaux précédemment menés à l'Onera, il s'agira d'identifier dans la littérature les techniques basées sur les Processus Gaussiens les plus pertinentes vis-à-vis des approches MDO, de les adapter en fonction des spécificités des problèmes de conception de véhicules aérospatiaux et de les mettre en pratique sur un processus MDO de lanceur réutilisable.

#### Références :

[1] S. Defoort, M. Balesdent, P. Klotz et al. (2012) Multidisciplinary Aerospace System Design: Principles, Issues and Onera Experience, Aerospace Lab, Vol.4

[2] A. Hebbal, L. Brevault, M. Balesdent, E.G. Tabli, N. Melab, Efficient Global Optimization using Deep Gaussian Processes, WCCI conference, Brazil, July 2018

[3] J. Gardner, G. Pleiss, R. Wu, K. Weinberger, A. Wilson, Product Kernel Interpolation for Scalable Gaussian Processes, AISTATS, 2018, (<https://github.com/cornellius-gp/gpytorch>)

[4] A. Matthews G. de G. Matthews, M. van der Wild, T. Nickson, K. Fujii, A. Boukouvalas, P. Leon-Villagra, Z. Ghahramani, J. Hensman, GPflow: A Gaussian process library using TensorFlow, Journal of Machine Learning Research, 2017, (<https://github.com/GPflow/GPflow>)

[5] GPy: A Gaussian process framework in Python, (<https://github.com/SheffieldML/GPy>)

[6] O. Roustant et al. (2018) Group kernels for Gaussian process metamodels with categorical inputs, arXiv : 1802.02368

[7] J. Pelamatti, L. Brevault, M. Balesdent, E.G. Talbi (2018) Efficient global optimization of constrained mixed variable problems, arXiv:1806.03975

[8] C. Paciorek, M. Schervish (2004) Nonstationary Covariance Functions for Gaussian Process Regression, NIPS 2004

[9] V. Volodina, D. Williamson (2018) Nonstationary Gaussian Process Emulators with Kernel Mixtures <https://arxiv.org/pdf/1803.04906.pdf>

Est-il possible d'envisager un travail en binôme ? **Non**

#### Méthodes à mettre en oeuvre :

Recherche théorique

Travail de synthèse

Recherche appliquée

Travail de documentation

Recherche expérimentale

Participation à une réalisation

Possibilité de prolongation en thèse : **Oui**

**Durée du stage :** Minimum : 4 mois

Maximum : 6 mois

Période souhaitée : Février - Août

### PROFIL DU STAGIAIRE

Connaissances et niveau requis :

Mathématiques appliquées, modèle de substitution, optimisation

Des connaissances dans la conception de véhicules aérospatiaux et en Python seraient un plus.

Ecoles ou établissements souhaités :

3ème année Ecole d'Ingénieur généraliste ou option aéronautique/spatial, ou M2R