

Optimisation en haute dimension de l'aérodynamique interne et externe de véhicules

David Gaudrie

Encadrants de thèse : Victor Picheny (INRA - MIAT),
Rodolphe Le Riche (CNRS - EMSE), Benoit Enaux,
Vincent Herbert (Groupe PSA)

INRA MIAT - 28 Avril 2017

Plan

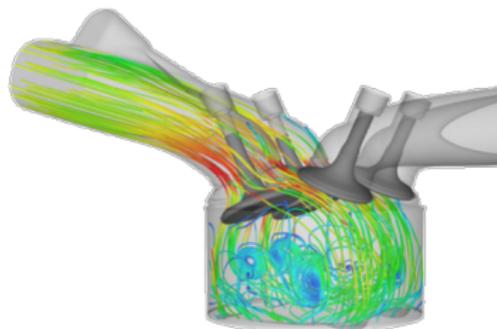
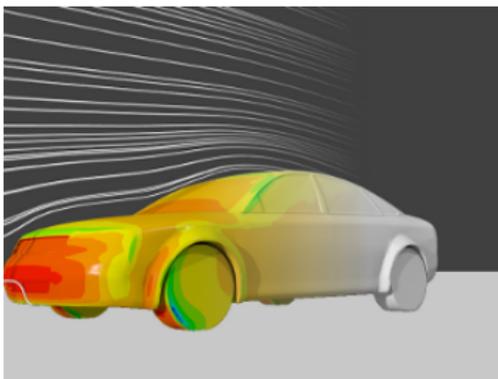
- 1 Introduction
 - Objectifs de la thèse
 - Problématiques spécifiques
- 2 Contexte Méthodologique
 - Méta-modèles et optimisation
- 3 Premiers travaux
 - Optimisation multi-objectif
 - Cas test étudié
 - Exemple d'optimisation multi-objectif
 - Expériences numériques
 - Quelques résultats
 - Pistes de recherche

Objectifs de la thèse

- Objectif de la thèse pour le Groupe PSA : se doter d'un optimiseur multicritère
 - Optimisations basées sur des simulations numériques utilisant des calculs CFD coûteux (\sim un jour par calcul)
→ nombre de simulations limité
 - Algorithmes d'optimisation déjà expérimentés par le passé → découverte de solutions non intuitives → intérêt du Groupe PSA pour effectuer de l'optimisation *efficacement*

Objectifs de la thèse

- Optimisations pour le Groupe PSA : Aérodynamique (optimisation de la forme de la voiture), Combustion (optimisation de la forme et des réglages du moteur)



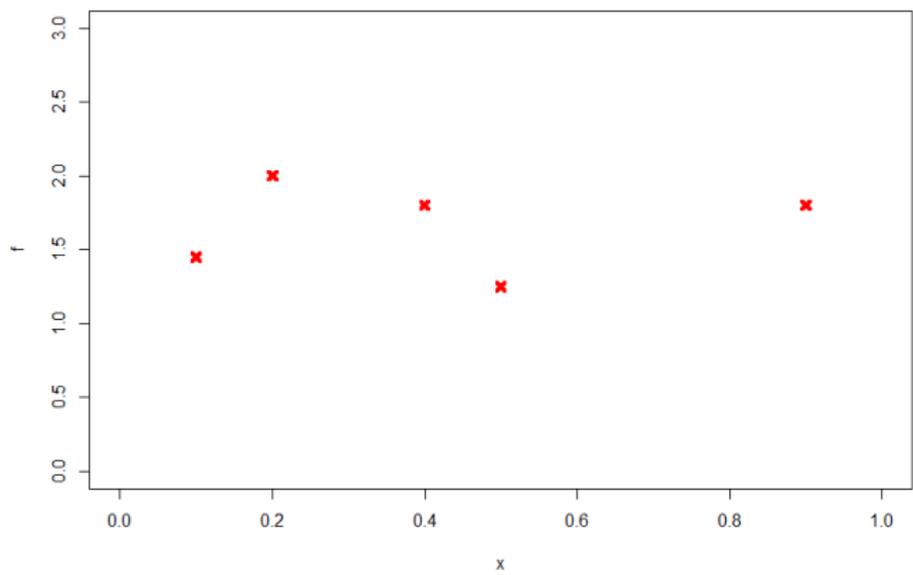
Problématiques spécifiques

- Temps de calcul d'une simulation : très long (plusieurs heures à une journée) → travail avec des ressources extrêmement restreintes
- Sorties connues de façon extrêmement parcimonieuse
- Grand nombre de paramètres (une quarantaine)
- Compromis entre de nombreux objectifs (jusqu'à 6)
- En plus : cas de crash de la simulation (CAO non conforme), exploiter la parallélisation des calculs

” Comment, en 200 simulations numériques coûteuses et complexes, et dépendant de nombreux paramètres, proposer 10 CAO de voiture optimales vis-à-vis de plusieurs objectifs antagonistes”

Méta-modèles et optimisation

- Optimisation par méta-modèle : exemple



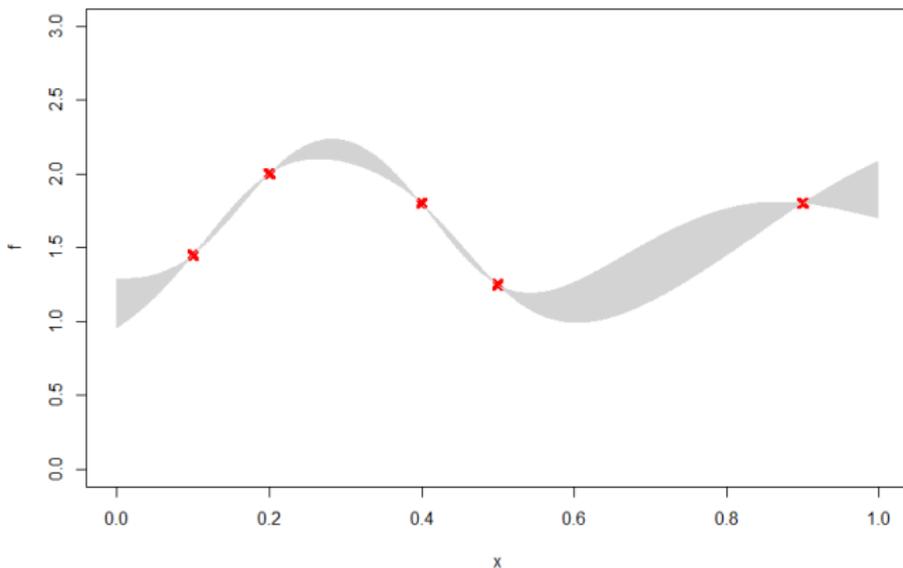
Méta-modèles et optimisation

Méta-modèle : Régression par Processus Gaussiens (Krigage)

- Données (x_i, y_i) , $\mathbb{X} := (x_1, \dots, x_n)^T$, $\mathbb{Y} := (y_1, \dots, y_n)^T$
- \mathbb{Y} réalisation d'un processus gaussien Y
- Modèle PG : $Y(x) = \beta + Z(x)$ avec β moyenne du processus, et $Z(x) \sim \mathcal{PG}(0, k(\cdot, \cdot))$
- $k(\cdot, \cdot)$ noyau de covariance, matrice de covariance $K_{ij} = k(x_i, x_j)$
- Prédicteur : $\hat{y}(x) = \hat{\beta} + k(x, \mathbb{X})^T K^{-1}(\mathbb{Y} - \mathbf{1}\hat{\beta})$
- Variance : $s^2(x) = \sigma^2(1 - k(x, \mathbb{X})^T K^{-1}k(\mathbb{X}, x))$

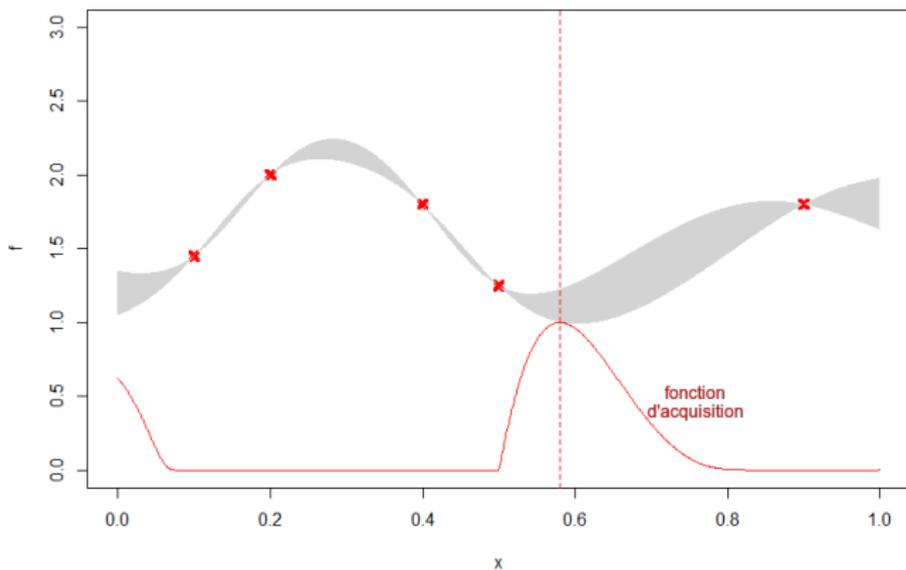
Méta-modèles et optimisation

- Optimisation par méta-modèle : exemple



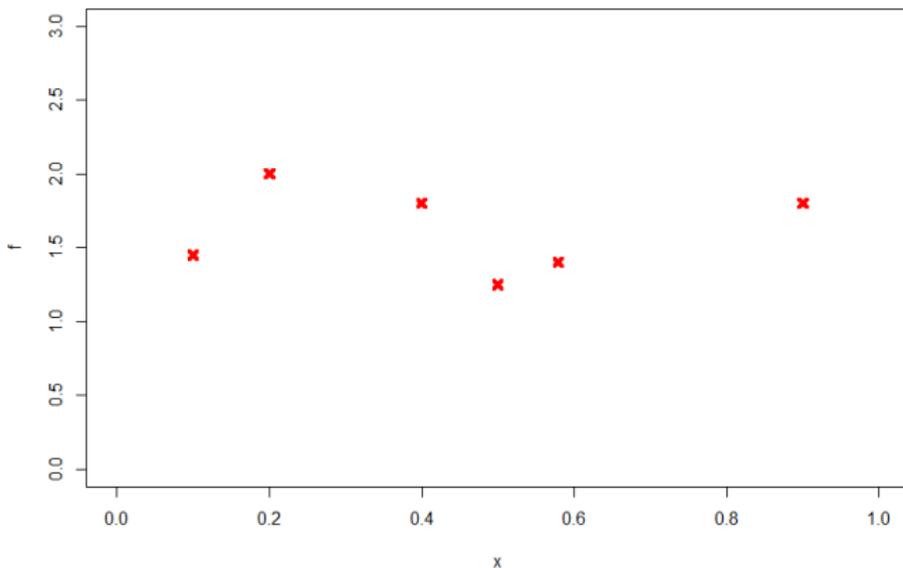
Méta-modèles et optimisation

- Optimisation par méta-modèle : exemple



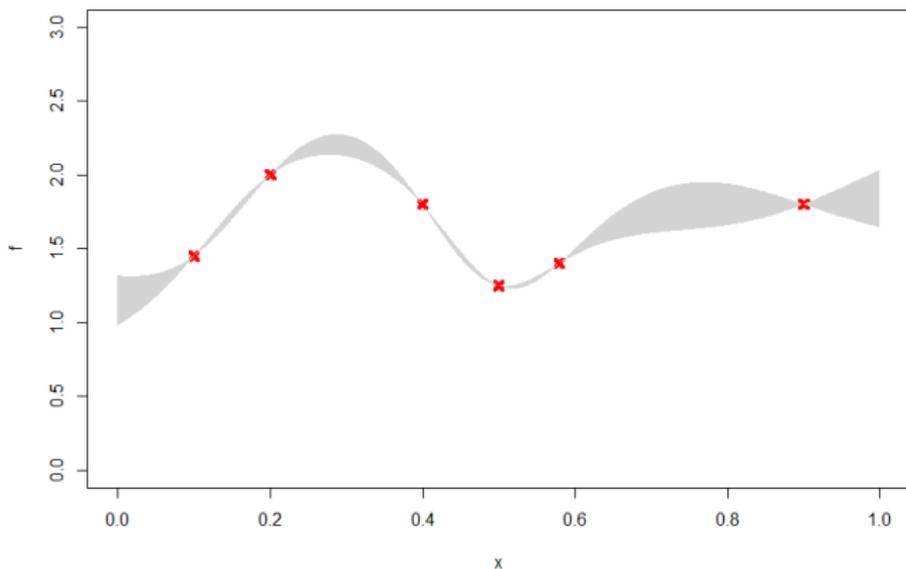
Méta-modèles et optimisation

- Optimisation par méta-modèle : exemple



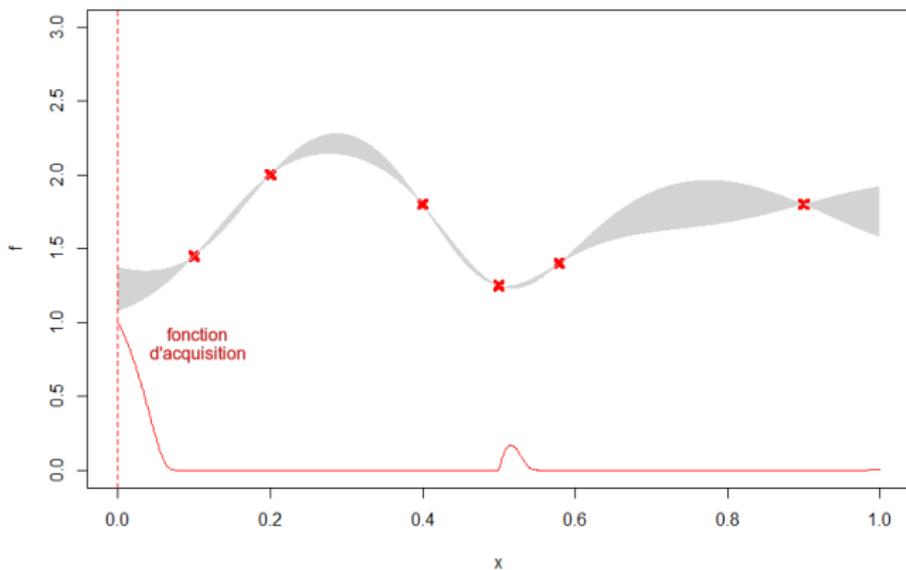
Méta-modèles et optimisation

- Optimisation par méta-modèle : exemple



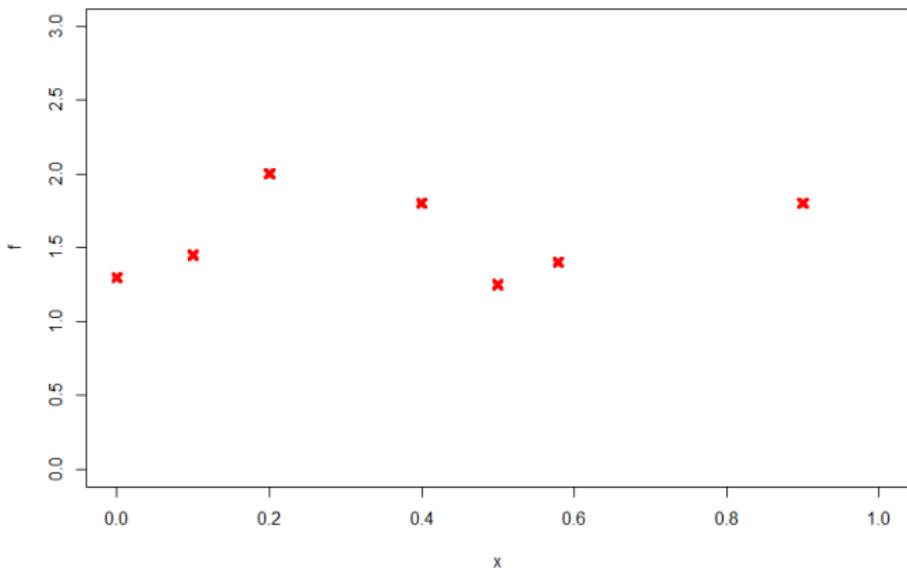
Méta-modèles et optimisation

- Optimisation par méta-modèle : exemple



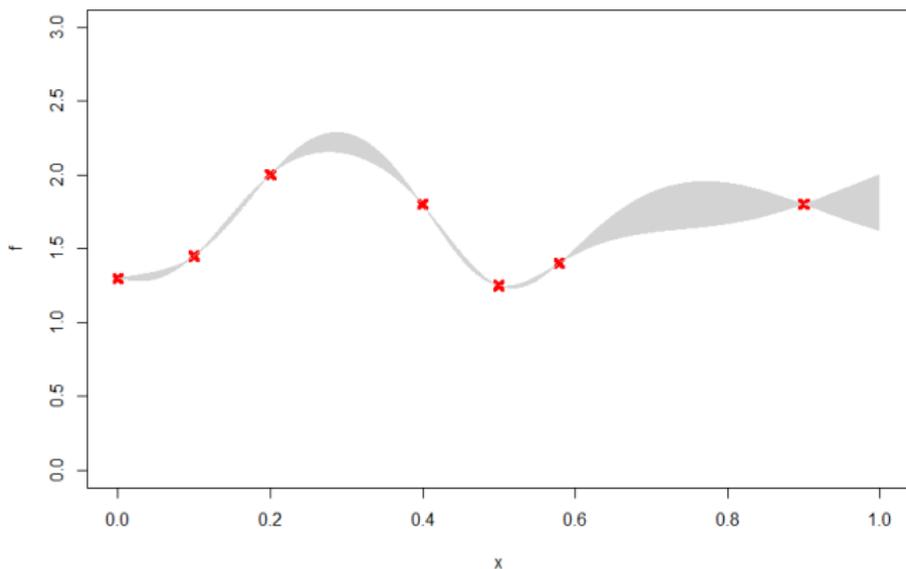
Méta-modèles et optimisation

- Optimisation par méta-modèle : exemple



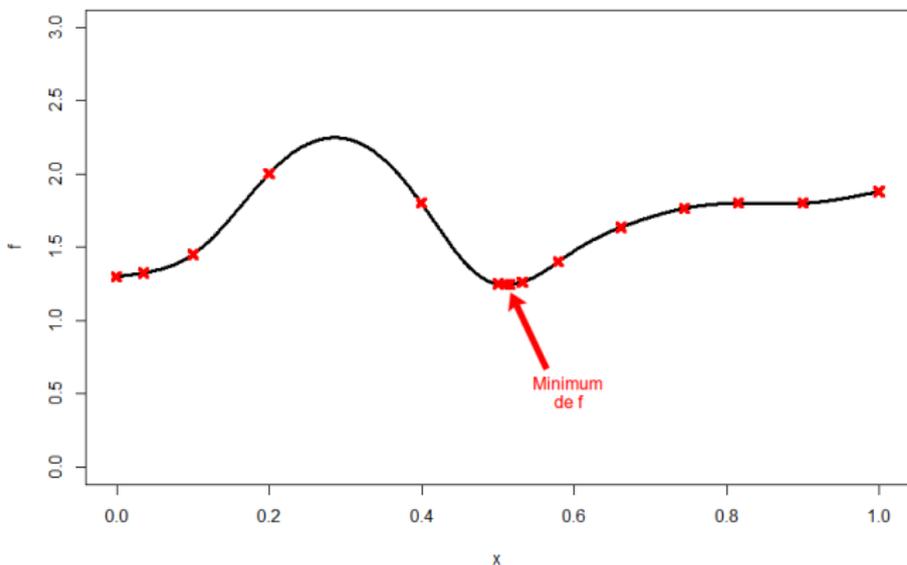
Méta-modèles et optimisation

- Optimisation par méta-modèle : exemple



Méta-modèles et optimisation

- Optimisation par méta-modèle : exemple



Optimisation multi-objectif

- Le problème d'optimisation multi-objectif

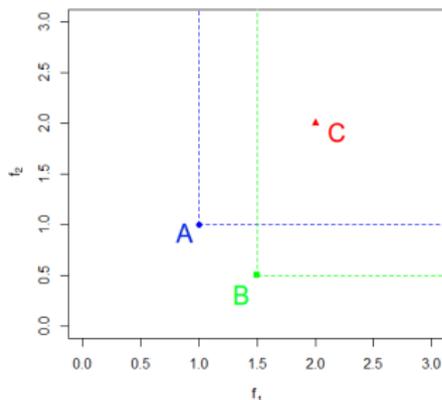
$$\min_{\mathbf{x} \in X \subset \mathbb{R}^d} (f_1(\mathbf{x}), \dots, f_m(\mathbf{x}))$$

où $f_i(\cdot)$ sont les m fonctions à optimiser simultanément

- Antagonisme entre objectifs $\rightarrow \nexists$ de solution minimisant les m fonctions simultanément

Optimisation multi-objectif

- Dominance : $\mathbf{x} \preceq \mathbf{x}' \Leftrightarrow f_i(\mathbf{x}) \leq f_i(\mathbf{x}') \forall i = 1, \dots, m$

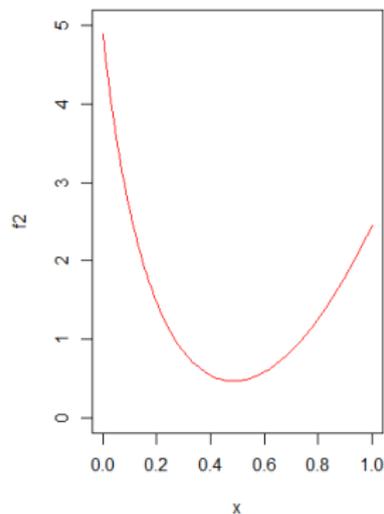
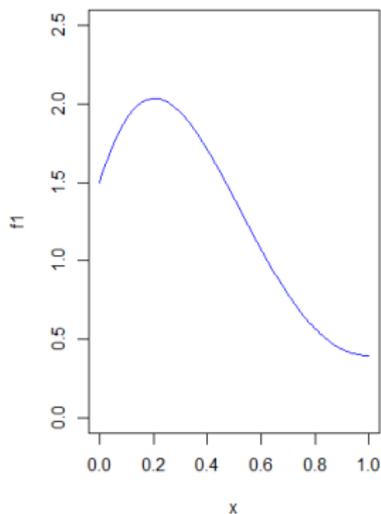


- Objectif d'un algorithme d'optimisation multi-objectif : trouver un *ensemble* \mathbb{X}^* de solutions non-dominées

Optimisation multi-objectif

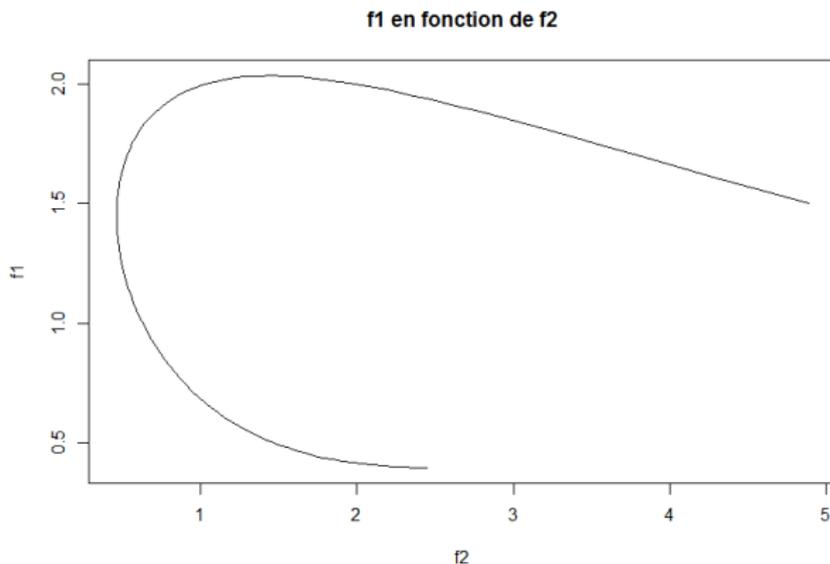
- Minimiser deux fonctions simultanément → recherche de *toutes* les solutions de compromis

Deux fonctions à minimiser simultanément



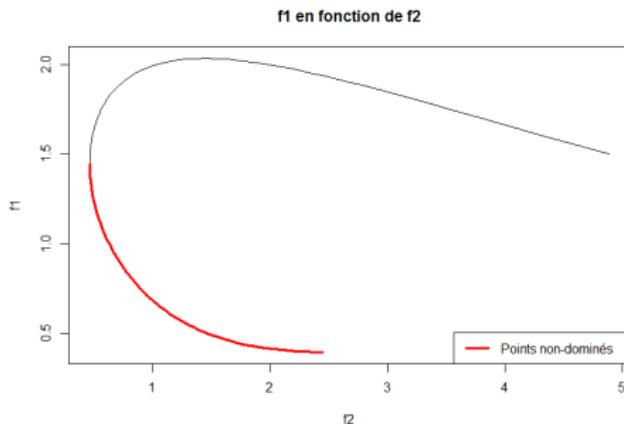
Optimisation multi-objectif

- Minimiser deux fonctions simultanément → recherche de *toutes* les solutions de compromis



Optimisation multi-objectif

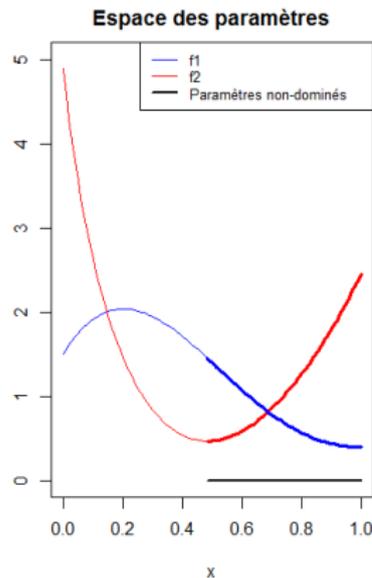
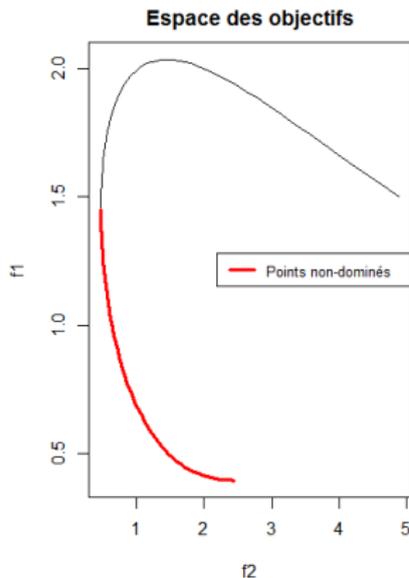
- Minimiser deux fonctions simultanément → recherche de *toutes* les solutions de compromis



- Non-dominance : impossible d'améliorer f_1 sans dégrader f_2 (et inversement)
- Ensemble des points non dominés : *Front de Pareto*

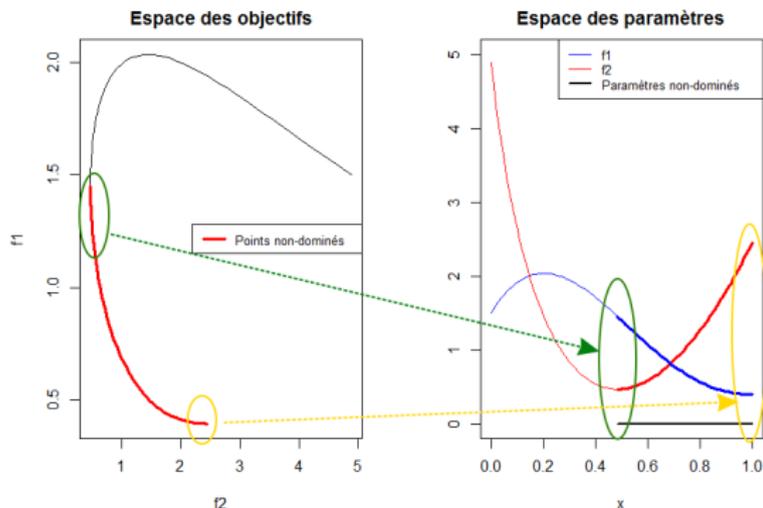
Optimisation multi-objectif

- Minimiser deux fonctions simultanément → recherche de *toutes* les solutions de compromis



Optimisation multi-objectif

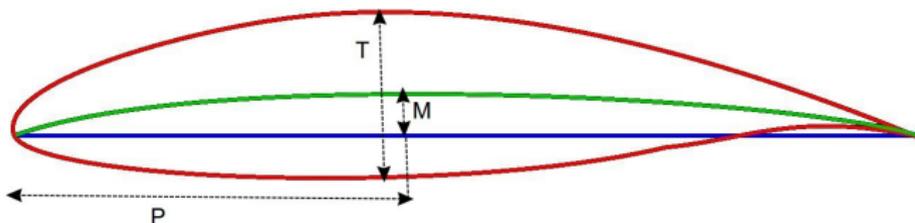
- Minimiser deux fonctions simultanément → recherche de *toutes* les solutions de compromis



- But d'un algorithme d'optimisation multi-objectif :
s'approcher du Front de Pareto, et proposer un *ensemble* de solutions de *compromis*

Cas test étudié

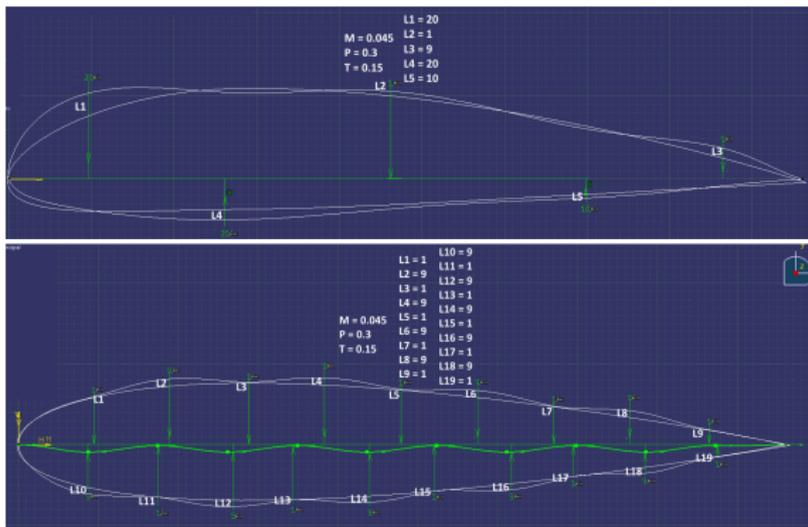
- Cas test simplifié : simulation aérodynamique (*boîte noire*) de l'écoulement autour d'un profil d'aile d'avion NACA
- 3 paramètres à optimiser
 - M : Cambrure maximale
 - P : Position du maximum de cambrure
 - T : Épaisseur maximale du profil



- 2 objectifs à minimiser : Traînée et -Portance

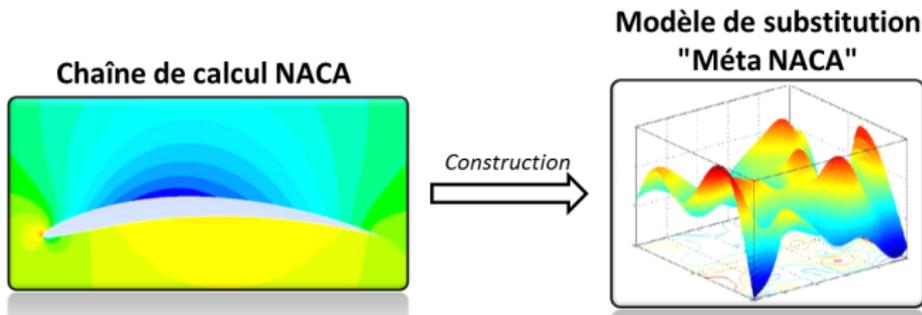
Cas test étudié

- Extension du cas test à des dimensions supérieures : 8 et 22 paramètres
- Paramètres supplémentaires : "bosses" le long du profil



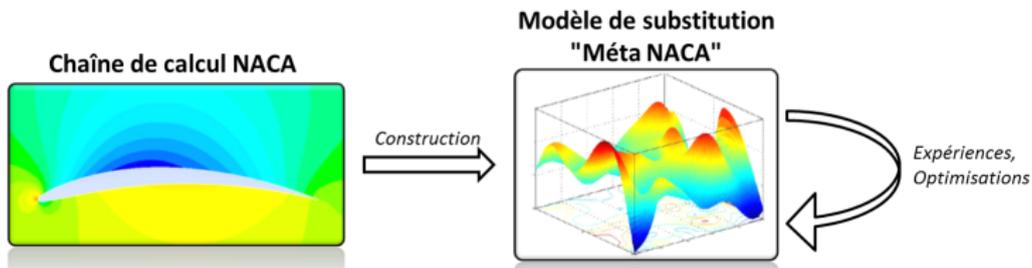
Banc d'essai pour optimisations

- Pour chacun des trois cas tests, création d'un modèle de substitution ("Méta NACA") de la chaîne de calcul sur la connaissance de
 - 1000 points (plan factoriel complet) en 3D
 - 1200 points (plan LHS optimisé par maximin, et raffiné dans les zones de compromis) en 8 et 22D



Banc d'essai pour optimisations

- Intérêts du modèle de substitution
 - Temps d'évaluation négligeable
 - Utilisation facilitée pour simuler des optimisations
 - Possibilité de connaître les vraies solutions optimales
- Dans la suite : expériences d'optimisation faisant appel au ~~code de calcul~~ Méta NACA pour évaluer le comportement des algorithmes

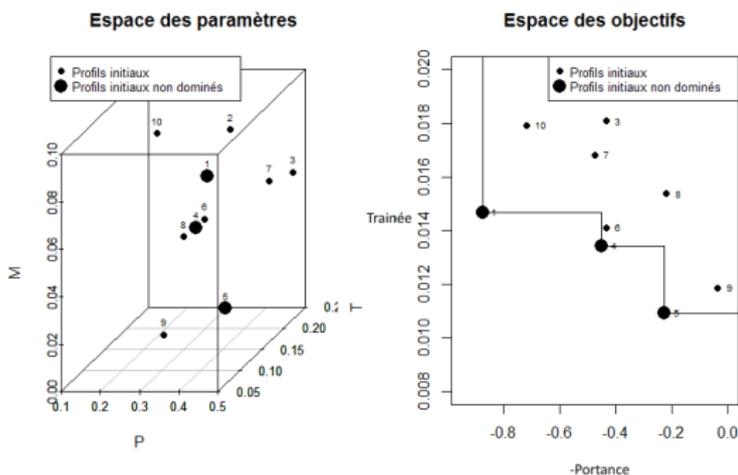


Banc d'essai pour optimisations

- But des "expériences d'optimisation"
 - Compréhension du fonctionnement des algorithmes
 - Étude des régions favorisées
 - Différences entre stratégies (fonction d'acquisition, répartition du budget de calcul)
 - Évaluation des solutions obtenues en grande parcimonie
 - → Trouver la *meilleure* stratégie pour approcher le Front de Pareto au cours de l'optimisation
- Optimisations dans le cadre des problématiques de la thèse
 - Grand nombre de paramètres
 - Beaucoup d'objectifs antagonistes
 - Budget d'extrême parcimonie

Exemple d'une optimisation multi-objectif (NACA 3D)

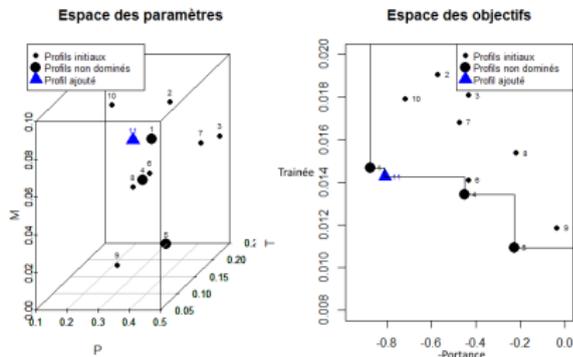
- Initialisation de l'algorithme : 10 points évalués



- Construction d'un méta-modèle (pour chacun des objectifs)

Exemple d'une optimisation multi-objectif (NACA 3D)

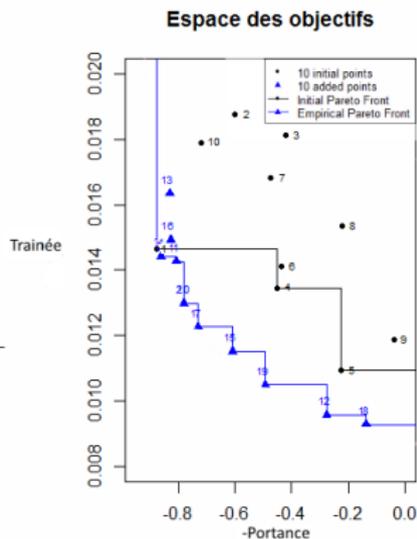
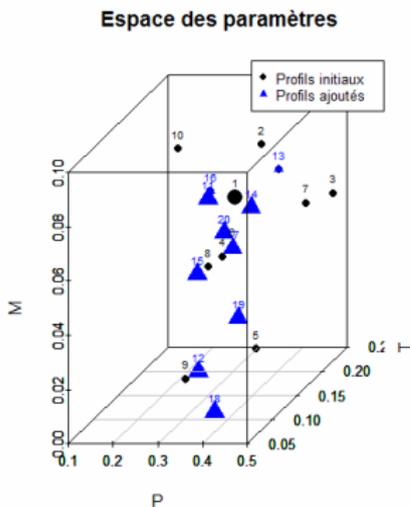
- Méta-modèles + fonction d'acquisition → détermination d'un premier point à évaluer
 - Amélioration des solutions non-dominées (exploitation)
 - Réduction de l'incertitude (exploration)
- Calcul de la Traînée et de la Portance de nouveau point



- Mise à jour des méta-modèles

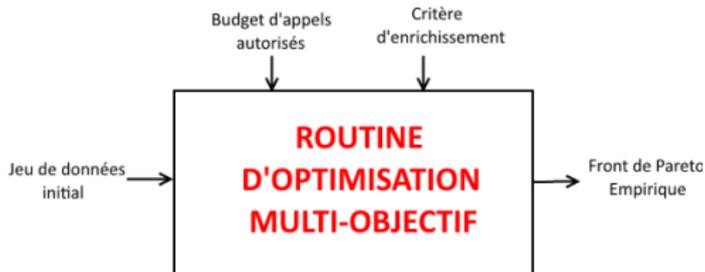
Fonctionnement d'une optimisation multi-objectif (NACA 3D)

- Résultats de l'optimisation (après 10 itérations)



Étude des paramètres de l'algorithme d'optimisation

- Paramétrisation de l'algorithme d'optimisation

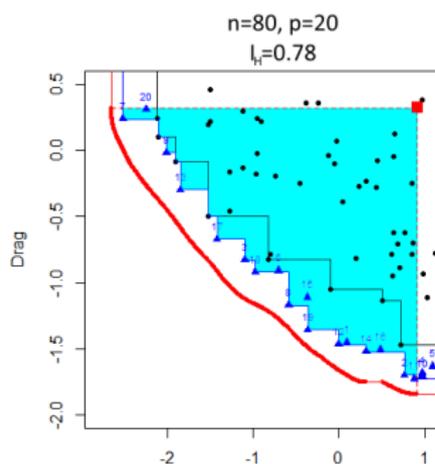
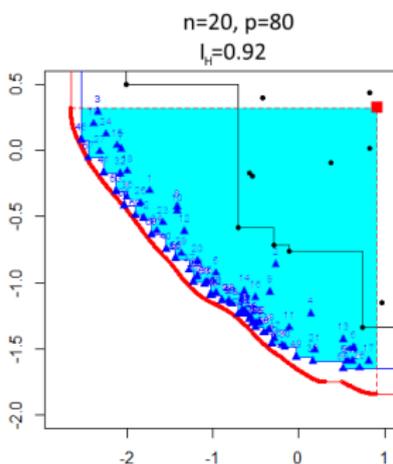


- Front de Pareto Empirique dépendant de
 - n : Points dans le design initial
 - p : Nombre de points ajoutés
 - $crit$: Fonction d'acquisition
- Expériences en faisant varier ces facteurs ($b := n + p$ budget total de calcul)
- Comparaison des solutions obtenues (fronts de Pareto empiriques) via l'utilisation d'indicateurs

Quelques résultats

Indicateur d'hypervolume dominé

- Budget total fixé $b = 100$ calculs

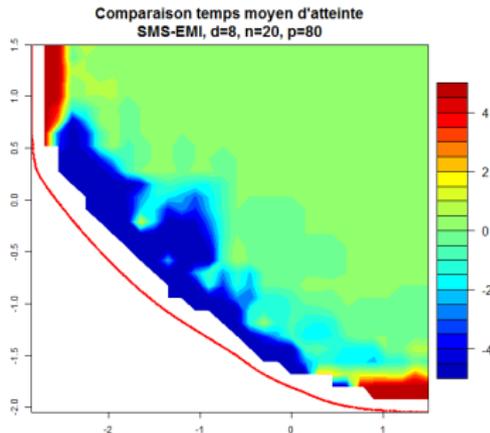


- À budget fixé, favoriser les calculs ajoutés via la fonction d'acquisition (p) par rapport aux points donnés à l'initialisation (n)

Quelques résultats

Temps moyen d'atteinte

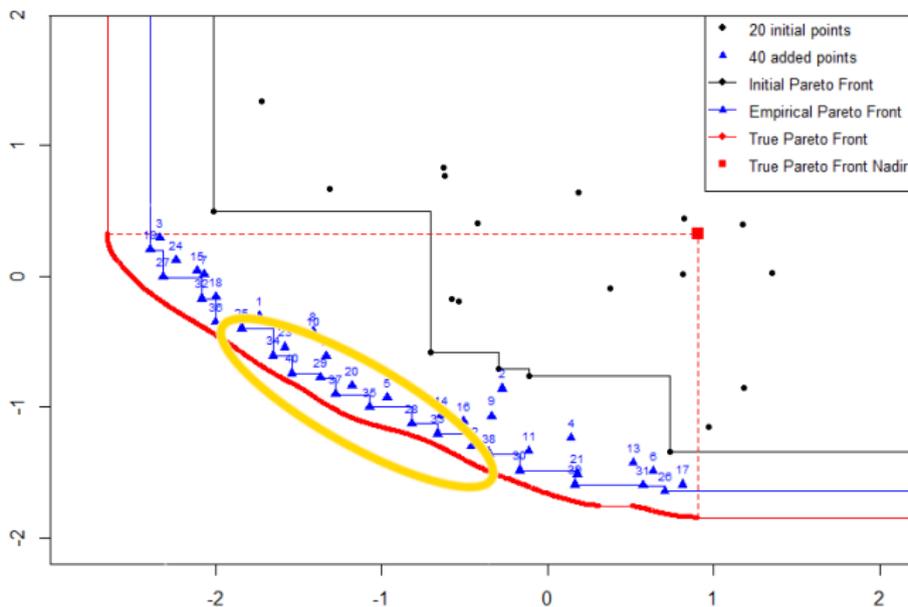
- Comparaison entre deux fonctions d'acquisition (SMS-EMI) via le temps moyen d'atteinte



- SMS semble atteindre plus rapidement le centre du Front de Pareto, et EMI plus rapidement les bords

Prochaines pistes de recherche

- PSA généralement plutôt intéressé par les zones "centrales" du Front de Pareto → cibler directement les zones qui nous intéressent



Prochaines pistes de recherche

- Quelques pistes : Choix du point de référence de l'hypervolume, fonction d'acquisition favorisant certaines zones du Front de Pareto ou un point particulier dans l'espace des objectifs, étudier la dynamique du Front de Pareto...
- ... dans le but de
 - Approcher certaines zones d'optimalité en effectuant encore moins de calculs !
 - Faire ressortir de l'algorithme uniquement des solutions qui nous intéressent vraiment
 - Pouvoir continuer à trouver des solutions acceptables avec un grand nombre d'objectifs (≥ 4)

Merci pour votre attention...
... avez-vous des questions ?

Références

- [1] Michael TM Emmerich, Kyriakos C Giannakoglou, and Boris Naujoks. Single-and multiobjective evolutionary optimization assisted by gaussian random field metamodels. IEEE Transactions on Evolutionary Computation, 10(4):421–439, 2006.
- [2] Donald R Jones, Matthias Schonlau, and William J Welch. Efficient global optimization of expensive black-box functions. Journal of Global optimization, 13(4):455–492, 1998.
- [3] Victor Picheny. Multiobjective optimization using gaussian process emulators via stepwise uncertainty reduction. Statistics and Computing, 25(6):1265–1280, 2015.
- [4] Wolfgang Ponweiser, Tobias Wagner, Dirk Biermann, and Markus Vincze. Multiobjective optimization on a limited budget of evaluations using model-assisted s-metric selection. In International Conference on Parallel Problem Solving from Nature, pages 784–794. Springer, 2008.
- [5] Joshua D Svenson. Computer experiments: Multiobjective optimization and sensitivity analysis. PhD thesis, The Ohio State University, 2011.