



Estimation statistique de la dispersion de la signature infrarouge d'un aéronef

Sidonie Lefebvre, Antoine Roblin, Suzanne Varet, Gérard Durand

► To cite this version:

Sidonie Lefebvre, Antoine Roblin, Suzanne Varet, Gérard Durand. Estimation statistique de la dispersion de la signature infrarouge d'un aéronef. 41èmes Journées de Statistique, SFdS, Bordeaux, 2009, Bordeaux, France, France. inria-00386623

HAL Id: inria-00386623

<https://inria.hal.science/inria-00386623>

Submitted on 22 May 2009

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

ESTIMATION STATISTIQUE DE LA DISPERSION DE LA SIGNATURE INFRAROUGE D'UN AÉRONEF

Sidonie Lefebvre & Antoine Roblin & Suzanne Varet & Gérard Durand

ONERA DOTA, Chemin de la Hunière, 91761 Palaiseau Cedex France (sidonie.lefebvre@onera.fr)

Résumé — Les simulations numériques de calcul de la signature infrarouge (SIR) d'un aéronef ne prennent pas en compte la dispersion induite par les incertitudes sur les données d'entrée telles que les angles de présentation de l'avion et les conditions météorologiques. Elles ne permettent donc pas d'estimer les performances de détection des systèmes optroniques. En effet, dans ce contexte, un scénario regroupe un grand nombre de situations différentes, qui doivent être prises en compte, mais ne peuvent pas être simulées une par une. Nous proposons ici une méthodologie en trois étapes de prédiction de la dispersion de la SIR d'un aéronef connu seulement partiellement, dans un environnement décrit de façon statistique. La première étape consiste en une analyse de sensibilité, afin d'identifier les variables d'influence négligeable sur la SIR, qui peuvent être fixées à une valeur constante. La seconde étape est une estimation de la dispersion de la sortie du code par la méthode de Quasi-Monte Carlo. Enfin, dans la dernière étape, un métamodèle du code de calcul de la SIR est construit. Cette méthodologie est illustrée pour un scénario typique d'attaque frontale air-sol par un avion de combat générique et permet d'obtenir une estimation satisfaisante de la dispersion de la SIR.

Abstract — Existing computer simulations of aircraft infrared signature (IRS) do not account for the dispersion induced by uncertainty on input data such as aircraft aspect angles and meteorological conditions. As a result, they are of little use to estimate the detection performance of optronic systems: in that case, the scenario encompasses a lot of possible situations that must indeed be addressed, but can not be singly simulated. In this paper, a three-step methodological approach for predicting simulated IRS dispersion of poorly known aircraft is proposed. The first step is a sensitivity analysis, which identifies inputs that have negligible influence on the IRS and can be set at a constant value. The second step consists in a Quasi-Monte Carlo survey of the code output dispersion. In the last step, a metamodel of the IRS simulation code is constructed. This method is illustrated in a typical scenario, namely an air-to-ground full-frontal attack by a generic combat aircraft, and gives a satisfactory estimation of the infrared signature dispersion.

Mots-clés — Ingénierie-industrie, Plans d'expérience, Apprentissage, Quasi-Monte Carlo

1. Introduction

Les codes qui permettent de prédire la signature infrarouge (SIR) d'un aéronef sont des outils complexes, mis au point et utilisés dans le contexte d'un problème direct : calculer la SIR d'un aéronef à partir d'un modèle précis de son comportement. Ils sont très utiles, car il est souvent impossible de réaliser des mesures expérimentales de la SIR, soit pour des raisons de sécurité, soit pour des raisons pratiques : trop d'expériences à mener, avions indisponibles... Ils sont cependant limités, car ils ne permettent pas de tenir compte d'une connaissance partielle des caractéristiques de l'aéronef, et de l'état de l'environnement. Or, dans le cas du dimensionnement d'un capteur futur, l'environnement dans lequel sera utilisé le capteur ne peut être connu que de manière statistique. De même, les propriétés de l'aéronef sont plus ou moins bien connues. Il apparaît alors nécessaire, non pas de prédire une valeur précise représentative d'une seule condition bien maîtrisée, mais une enveloppe de valeurs de signature, caractéristique de notre méconnaissance partielle de certains paramètres d'entrée du code. Si on se restreint à une SIR scalaire, l'éclairement

différentiel en entrée de capteur de l'avion par rapport au fond intégré sur la bande spectrale 3-5 μm , le critère de performance d'un capteur est très simple, il s'agit de la probabilité que l'éclairement du capteur produit par l'aéronef soit au dessous d'un seuil de détection donné.

L'ONERA développe depuis trente ans un code de calcul de la SIR d'un aéronef militaire, CRIRA, initié par Gauffre (1981). Notre but est de mettre au point une méthodologie qui permette, à partir de CRIRA, d'estimer la dispersion de la signature infrarouge et la probabilité de non-détection pour un seuil fixé, afin d'aider au dimensionnement des capteurs optroniques futurs. Nous considérons le code comme une boîte noire $f : Y=f(X_1,...,X_n)$ avec Y la sortie du code et n facteurs d'entrée incertains X_i . La probabilité de non détection P_α pour un seuil α s'écrit :

$$P\left(f(X_1,...,X_n) < \alpha\right) = \int_{[0,1]^n} \chi_{|f(X_1,...,X_n)| < \alpha}(\vec{t}) p_{X_1,...,X_n}(\vec{t}) d\vec{t},$$

avec χ la fonction indicatrice et $p_{X_1,...,X_n}$ la densité de probabilité conjointe des X_i . La méthode de Monte Carlo semble bien indiquée pour évaluer cette probabilité, mais sa vitesse de convergence est lente. Comme l'erreur initiale est souvent grande, il n'est pas rare d'avoir besoin de faire plus d'un million de calculs pour garantir une précision acceptable, de l'ordre de 1 %, sur l'estimation d'une intégrale. Des variantes ont été proposées afin d'accélérer la convergence, parmi lesquelles nous avons choisi la méthode de Quasi-Monte Carlo. La convergence dépend alors de la dimension n , et il est donc important de se concentrer uniquement sur les variables d'entrée du code qui ont une influence sur la SIR. La méthodologie que nous proposons se décompose en trois étapes :

- utilisation de plans d'expériences pour identifier les variables d'entrée d'influence négligeable sur la SIR, qui sont ensuite fixées à une valeur constante,
- estimation de la dispersion de la SIR par la méthode Quasi-Monte Carlo,
- conception d'un métamodèle à base de réseaux de neurones, afin d'évaluer rapidement la SIR.

Elle est illustrée pour un scénario typique d'attaque frontale air-sol, de jour, par un avion de combat générique, volant à basse altitude. La section 2 détaille la sélection des variables, la section 3 l'estimation de la dispersion de la SIR, la section 4 la construction du métamodèle, et la section 5 les conclusions et perspectives de cette étude.

2. Sélection de variables par plans d'expérience

Notre code CRIRA a un grand nombre de variables d'entrée incertaines, entre 20 et 60. Pour le scénario choisi, 28 variables sont mal connues :

- 9 concernent les propriétés optiques du revêtement de l'avion dans l'IR, elles sont notées E_...
- 7 concernent les conditions de vol de l'aéronef : altitude (H2) de l'avion par rapport au capteur, Mach, Régime moteur, et les angles de présentation : Cap, Assiette, Gîte, Gisement,
- 12 concernent l'environnement : visibilité (Vis), modèle d'atmosphère (Model), température de l'air (Ta), humidité relative de l'atmosphère (Rh), présence de nuages (Nuages), hauteur de base et épaisseur de la couche nuageuse (Hbase - Epaisseur), type d'aérosol (Ihaze), albédo du sol (Salb), heure, numéro du jour (Iday), et déviation de la température du sol par rapport à la température moyenne de la saison (Deltat).

La plupart sont quantitatifs, mais trois sont qualitatifs : Nuages, Ihaze et Model. Les seuls facteurs potentiellement corrélés, pour ce scénario particulier, sont les six premiers facteurs décrivant l'environnement. Le temps de calcul de la SIR est raisonnable, de l'ordre de six minutes, et nous nous autorisons au plus 4000 calculs pour cette étape de sélection des variables influentes.

Il existe plusieurs méthodes pour réaliser une analyse de sensibilité d'un code de calcul, les deux principales étant le calcul des indices de Sobol, décrit dans l'ouvrage de Saltelli et al. (2000) et l'utilisation de plans d'expérience, dont l'ouvrage édité par Droesbke et al. (1997) fait une revue détaillée. Nous savons que les effets d'interaction entre deux ou trois facteurs peuvent être très importants dans notre cas, et nous voulons évaluer ceux impliquant deux variables. Le calcul des indices de Sobol et des indices totaux pour chaque variable étant trop coûteux, nous nous sommes

donc orientés vers l'utilisation de plans d'expérience, factoriels fractionnaires plutôt que de criblage, du fait de l'importance des interactions.

Chacun des 28 facteurs est alors décrit par deux niveaux, un niveau haut et un niveau bas, symbolisés par 1 et -1 dans la matrice d'expériences, qui sont déterminés à l'aide de connaissances d'experts, et de façon à pouvoir décorrélérer les facteurs. Un plan factoriel fractionnaire ne contient pas l'ensemble des 2^{28} combinaisons possibles des niveaux, et ne permet donc pas d'estimer toutes les interactions entre les facteurs. Seuls des groupes d'interactions peuvent être évalués. La nature des interactions comprises dans le même groupe, ou aliase, dépend d'une propriété du plan appelée résolution. Dans notre cas, nous estimons que les interactions entre deux et trois facteurs peuvent être importantes, et que les interactions entre quatre facteurs et plus sont négligeables. Nous voulons estimer correctement les effets principaux des facteurs et les effets d'interaction entre deux facteurs. Nous utilisons donc un plan de résolution VI, car dans ce cas les effets qui nous intéressent sont aliésés avec des interactions entre au moins quatre facteurs, négligeables.

Pour 28 facteurs, un plan factoriel fractionnaire de résolution VI comprend 2048 expériences. Les sorties du code de SIR associées sont analysées à l'aide d'un modèle polynomial du type :

$$Y = c_0 + \sum_i c_i \cdot X_i + \sum_{i < j} c_{ij} \cdot X_i \cdot X_j + \varepsilon_r$$

avec Y le vecteur des 2048 sorties, X_i le vecteur des 2048 valeurs du $i^{\text{ème}}$ facteur, c_0 la moyenne des réponses, c_i l'effet principal du $i^{\text{ème}}$ facteur, c_{ij} l'effet d'interaction entre les $i^{\text{ème}}$ et $j^{\text{ème}}$ facteurs et ε_r le vecteur des résidus. Les facteurs sont supposés indépendants et le vecteur des résidus gaussien. La dispersion des résultats est très grande, de quatre ordres de grandeur, aussi réalisons-nous l'analyse de variance sur le logarithme népérien de la SIR. Les coefficients du modèle sont ensuite estimés par moindres carrés, et un test de Student permet d'évaluer si ils sont négligeables. Le diagramme de Pareto de la figure 1, tracé avec la librairie *qcc* de R, présente les valeurs en

pourcentage des 28 $\frac{|c_i|}{\sum_{i=1}^{28} |c_i|}$ par ordre décroissant de gauche à droite. La courbe pointillée représente la part cumulée de variance de la SIR expliquée par les i facteurs les plus influents.




Figure 1. Diagramme de Pareto des effets principaux des 28 facteurs

On peut constater que, pour ce scénario, 80 % de la variabilité de la SIR est expliquée par cinq facteurs principaux, trois liés à l'environnement : Vis, Ihaze et Rh, et deux aux conditions d'attaque : H2 et Mach. Nous avons décidé de conserver les treize facteurs les plus influents, qui expliquent plus de 95 % de la variabilité de la SIR, pour l'étape suivante et de fixer les autres à une valeur constante. Nous retenons donc trois facteurs liés à l'environnement supplémentaires : Model, Nuages et Heure, quatre liés aux conditions d'attaque : Assiette, Gîte, Cap et Régime, et un lié aux caractéristiques de l'avion : E_e_ai. De plus, nous avons vérifié que toutes les variables impliquées dans des interactions influentes entre deux facteurs étaient conservées. Un seul facteur décrivant l'avion ressort dans cette analyse de sensibilité du fait du choix du scénario, pour lequel la plupart des caractéristiques de l'avion, comme sa géométrie, sont supposées parfaitement connues. Les deux hypothèses d'indépendance des facteurs et de normalité des résidus ne sont pas parfaitement vérifiées dans notre cas. Nous avons donc mis au point dans Varet et al. (2009) un calcul simplifié des indices de Sobol, à partir des sorties associées à un plan d'expérience factoriel fractionnaire, qui permet d'estimer la part de variance expliquée par les effets principaux et les effets d'interaction entre deux facteurs en supposant uniquement les facteurs de base du plan indépendants. Pour le scénario choisi, les résultats ainsi obtenus sont identiques à ceux présentés ici.

3. Méthode de Quasi-Monte Carlo et étude de la dispersion de la SIR

La méthode de Quasi-Monte Carlo suit le même principe que celle de Monte Carlo, mais avec un échantillonnage différent : les nombres pseudo-aléatoires sont remplacés par des suites déterministes régulièrement réparties dans l'espace, les suites à discrétion faible, la discrétion D_N^* étant une mesure de l'uniformité de la dispersion des points. Une suite à discrétion faible est

caractérisée par une discrétion D_N^* en $O\left(\frac{\log(N)^n}{N}\right)$, avec n la dimension. Pour une description

très complète sur ce sujet, se reporter à la thèse de Tuffin (1997). Le théorème de Koksma-Hlawka donne une borne maximale pour la vitesse de convergence, malheureusement peu utilisable en pratique, mais de nombreuses utilisations des suites à discrétion faible font état d'un gain en vitesse de convergence par rapport à Monte Carlo pour n raisonnablement grand, de l'ordre de dix environ. Si on note N le nombre de simulations, on génère N jeux de données d'entrée $(x_{1i}, x_{2i}, \dots, x_{Ni})$ pour chacun des treize facteurs influents X_i dans l'intervalle $[0,1]$ puis on les transforme suivant la loi jointe des X_i . Les sorties du code $(y_1, y_2, \dots, y_N)$ associées permettent d'estimer la distribution de Y et d'évaluer la probabilité de non-détection P_α par :

$$P_{\alpha N} = \frac{1}{N} \sum_{i=1}^N \mathcal{X}_{(|f(x_{i1}, \dots, x_{i13})| < \alpha)}.$$

Le mode de construction des suites à discrétion faible entraîne des corrélations entre les coordonnées des points, et donc une mauvaise répartition des projections sur des sous-espaces. Ce phénomène concerne essentiellement les dimensions consécutives, et est amplifié pour les grandes dimensions. Les projections forment des bandes, et certains couples de valeurs ne sont pas représentés, ce qui est gênant si l'interaction entre les deux variables associées est influente. Pour remédier à ce problème, des techniques dites de « randomisation » ont été proposées, pour « mélanger » les points et éviter ainsi les corrélations. Elles ajoutent un caractère aléatoire aux ensembles de points générés, ce qui est utile pour estimer des intervalles de confiance pour les probabilités de non-détection, et permettent de préserver la propriété de faible discrétion. Nous utilisons ici une suite de Faure à laquelle a été appliquée le « scrambling » de Faure et Tezuka (2003).

Au vu du temps nécessaire pour mener à bien un calcul avec CRIRA, nous avons choisi de nous limiter à 10240 calculs pour cette étape. Parmi les 13 facteurs identifiés comme influents sur la SIR au cours de la deuxième étape de la méthodologie, seuls cinq (Vis-Ihaze-Rh-Model-Nuages) n'ont

pas une loi uniforme. Ce sont des facteurs liés à l'environnement, pour lesquels nous n'avons d'information que par le biais d'une base de données météorologiques, qui n'est pas assez conséquente pour nous permettre d'estimer une loi jointe. Nous avons donc choisi de traiter ces facteurs par bootstrap dans la base de données et non par Quasi-Monte Carlo. L'échantillonnage des huit autres facteurs influents, qui sont indépendants, est raffiné à l'aide de suites de Faure avec "scrambling". Les variables jugées non influentes sont fixées à une valeur constante.

La figure 2 présente la fonction de répartition empirique de la SIR pour les 10240 calculs. Pour des raisons de confidentialité, les valeurs de SIR ont été multipliées par une constante arbitraire. Pour un seuil d'éclairement réaliste, de 1 Wm^{-2} après transformation, nous obtenons une probabilité de non-détection de 17 %, ce qui est tout à fait vraisemblable. Nous avons également vérifié, en effectuant 50 tirages avec remise de deux tiers des 10240 valeurs de SIR, que l'écart sur les fonctions de répartition ainsi obtenues restait très faible, de l'ordre du pourcent.

4. Apprentissage d'un métamodèle

Lorsqu'on veut vérifier qu'un capteur optronique satisfait à des spécifications données, seules les SIR proches du seuil de détection du capteur doivent être calculées précisément. En effet, les SIR très faibles ne sont jamais détectées, alors que les SIR élevées le sont systématiquement. Il est donc particulièrement intéressant de disposer d'un métamodèle du code de calcul de SIR pour un scénario donné : celui-ci permet de donner une première évaluation de la SIR, et de n'utiliser le code, bien plus coûteux en temps de calcul, que si la SIR estimée par le métamodèle est proche du seuil de détection. Notre code de calcul de SIR est complexe, et les modèles de régression linéaire ne permettent pas de prédire de façon pertinente les SIR. Nous nous sommes donc orientés vers une modélisation non linéaire, à base de réseaux de neurones. Une description très complète des réseaux de neurones est donnée dans l'ouvrage de Dreyfus et al. (2004).

Un réseau de neurones est un graphe orienté constitué d'un ensemble de neurones, qui sont des fonctions non linéaires paramétrées, structurés en couches successives. Les neurones d'une même couche fonctionnent en parallèle. Un des réseaux de neurones les plus utilisés est le réseau perceptron multi couches (MLP), pour lequel les paramètres w_i sont attachés aux entrées des neurones. Les théorèmes de Hornik (1989) et de Barron (1993) montrent qu'un MLP avec une couche de neurones cachés en nombre fini, possédant tous la même fonction d'activation non linéaire, du type tangente hyperbolique, et un neurone de sortie linéaire, est un approximateur universel parcimonieux. Les poids sont estimés par apprentissage supervisé non adaptatif à partir de N_0 valeurs de SIR choisies au hasard parmi les 10240 valeurs de notre base de points ayant servi à estimer la dispersion de la SIR. Le reste des points sert de base de test.

Nous avons construit plusieurs réseaux, avec 2000, 4000 ou 6000 points de base d'apprentissage et 5, 7 ou 10 neurones cachés. Les variables d'entrée sont les 13 variables les plus influentes identifiées par les plans d'expérience, centrées et réduites. La variable de sortie considérée est $\ln|SIR|$. Le réseau qui donne les meilleures prédictions sur la base de test est celui comprenant 7 neurones cachés, et construit à partir de 4000 points. Le coefficient de détermination R^2 estimé sur les 6240 points de test est alors de 0.85. La figure 2 présente une comparaison des fonctions de répartition empiriques de la SIR, obtenues directement à l'aide du code de calcul ou bien avec le réseau de neurones. Le réseau de neurones fournit une très bonne approximation de notre code de calcul, et les erreurs commises en remplaçant le code par son métamodèle pour l'estimation des probabilités de non-détection sont au plus de 1 %.

5. Conclusion

Nous avons mis au point une méthodologie en trois étapes, qui permet d'estimer la dispersion de la signature infrarouge d'un avion militaire mal connu dans un environnement défini de façon statistique. Pour le scénario type choisi, la dispersion de la signature infrarouge est estimée de façon

satisfaisante avec moins de dix mille calculs. De plus, le métamodèle construit permet d'obtenir de très bonnes approximations des probabilités de non-détection. Il faut noter cependant que nous nous sommes restreints au cas d'une signature scalaire : l'adaptation de la démarche au cas d'un avion faiblement résolu, en une dizaine de pixels environ, est en cours.




Figure 2. Comparaison des fonctions de répartition de la SIR

Bibliographie

- [1] Gauffre, G. (1981) Aircraft infrared radiation modeling. *Recherche Aérospatiale*, 4, 245–265.
- [2] Saltelli, A., Chan, K. et Scott M. (Eds.) (2000) *Sensitivity Analysis*. Wiley Series in Probability and Statistics. New York: John Wiley and Sons.
- [3] Driesbeke, J.J., Fine, J. Et Saporta, G. Éditeurs (1997) *Plans d'expériences : applications à l'entreprise*, Editions Technip, Paris.
- [4] Varet, S., Lefebvre, S., Durand, G., Roblin, A. et Cohen, S. (2009) Effective Dimension and Discrepancy. soumis aux proceedings de MCQMC2008.
- [5] Tuffin, B. (1997) *Simulation accélérée par les méthodes de Monte Carlo et Quasi-Monte Carlo : théorie et applications*. Thèse de l'Université Rennes 1.
- [6] Tezuka, S. et Faure, H. (2003) I-binomial scrambling of digital nets and sequences. *J. of Complexity*, 19, 744–757.
- [7] Dreyfus, G., Martinez J.M., Samuelides et al. (2004) *Réseaux de neurones : méthodologie et applications*, Editions Eyrolles.
- [8] Hornik, K., Stinchcombe, M. et White, H. (1989) Multilayer feedforward networks are universal approximators. *Neural Networks*, 2, 359–366.
- [9] Barron, A. (1993) Universal approximation bounds for superposition of a sigmoidal function. *IEEE Trans. on Information Theory*, 39, 930–945.