

Étude comparative de quatre méthodes statistiques pour l'estimation conjointe de l'émissivité et de la température par thermographie infrarouge multispectrale

Comparative study of four statistical methods for the simultaneous estimation of the emissivity and the temperature through multispectral infrared thermography

Thibaud TOULLIER¹, Jean DUMOULIN^{1*}, Laurent MEVEL¹

¹ Univ. Gustave Eiffel, Inria, COSYS-SII, I4S Team, F-44344 Bouguenais, France

*(auteur correspondant : jean.dumoulin@univ-eiffel.fr)

Résumé - Ces travaux portent sur l'estimation conjointe de la température de surface et de l'émissivité d'objets observés par thermographie infrarouge *in-situ*. La conversion du flux radiatif en température se heurte au manque de connaissance des propriétés radiatives de la scène réelle et en particulier de l'émissivité. L'éclairement reçu par la caméra depuis une cible virtuelle composée de quatre matériaux connus est simulé. Ensuite, une comparaison de quatre méthodes statistiques pour estimer simultanément l'émissivité et la température et ainsi évaluer leur sensibilité est proposée.

Mots-clés : Thermographie infrarouge ; Émissivité ; Bayesian estimation ; Kalman ; Krigage.

Abstract - This study addresses the simultaneous estimation of the surface temperature and emissivity of objects observed through *in-situ* infrared thermography. The conversion of the radiative flux to temperature is facing the lack of knowledge of the radiative properties of the scene and particularly the emissivity. The irradiance received at cameras' sensors from a virtual target made of four known materials is simulated. Then, four statistical methods that estimate simultaneously the emissivity and the temperature are compared and their sensitivity is evaluated.

Keywords: Infrared thermography; Emissivity; Bayesian estimation; Kalman; Kriging.

Nomenclature

Indices et exposants

\cdot_k quantité définie à l'instant k
 \cdot_p quantité définie pour une particule p
 \cdot° quantité liée au corps noir

Domaines
 \mathcal{S} domaine spatial de l'image
 \mathcal{T} domaine temporel

Grandeurs
 T température
 s variable d'espace (pixel)
 t temps
 λ_i longueur d'onde moyenne sur la bande spectrale i
 γ vecteur de mesure

L Luminance
 ϵ émissivité
 C_2 seconde constante de Planck ($= \frac{hc}{k_B}$)
 \mathbf{x} vecteur d'état
 \mathbf{y} vecteur d'observation
 \mathbf{A} évolution de l'état
 \mathbf{C} matrice d'observation
 v bruit de processus
 w bruit de mesure
 v_s composante statique
 v_d composante dynamique
 α logarithme de l'émissivité
 ξ vecteur de paramètres

1. Introduction

Les récentes avancées technologiques réalisées sur les détecteurs infrarouges non-refroidis offrent de nouvelles opportunités pour estimer la température par une mesure sans contact. En particulier, l'utilisation de caméras infrarouges multispectrales ouvre de nouvelles perspectives pour la surveillance thermique long terme des structures de génie civil en environnement naturel. Cependant, l'estimation de la température par thermographie infrarouge se heurte au manque de connaissance des propriétés radiatives des objets observés et en particulier l'émissivité. Ainsi, le système d'équations physiques mène à un système sous-déterminé. La résolution du problème de séparation d'émissivité et de température ne peut alors pas se faire sans l'ajout d'informations ou d'hypothèses simplificatrices *a priori* [1].

Cette étude s'intéresse à la comparaison de quatre méthodes statistiques pour l'estimation conjointe de l'émissivité et de la température : *Monte-Carlo Markov Chains* (MCMC), *Covariance Matrix Adaptation Evolution Strategy* (CMA-ES), *Interacting Particle Kalman Filter* (IPKF) et *Kriged Interacting Particle Kalman Filter* (KIPKF). Les deux premières s'adressent par construction à des mesures à un instant t , alors que les deux dernières tirent parti de l'évolution dynamique du signal pouvant être acquis sur des structures surveillées en environnement extérieur naturel. Pour tester ces méthodes, une cible constituée de matériaux dont les propriétés radiatives sont connues est simulée à l'aide d'un logiciel de simulation des radiosités [2].

Dans un premier temps, le problème sous-déterminé de conversion du flux radiatif en température sera présenté. Dans un second temps, les méthodes statistiques et leurs équations seront introduites. Enfin, une comparaison de ces méthodes sur des données simulées sera réalisée. Finalement, une conclusion sur les résultats obtenus ainsi que des perspectives sur des données réelles seront proposées.

2. Conversion de la mesure du flux radiatif en température

Dans le cas d'une mesure en laboratoire ou lorsque l'ensemble des contributions peut être mesuré ou estimé, le système peut se simplifier à une unique observation capteur - objet, décrite par l'Equation 1 [1, 3, 4]. Soit $\mathcal{S} \subset \mathbb{R}^2$ le domaine spatial de l'image et $\mathcal{T} \subset \mathbb{R}^+$ l'espace temporel. En considérant des surfaces grises et diffuses dans les bandes spectrales sélectionnées, la quantité γ mesurée par thermographie infrarouge au niveau d'un pixel $\mathbf{s} \in \mathcal{S}$ donné, à un instant $t \in \mathcal{T}$ et pour une bande spectrale λ_i peut s'écrire :

$$\gamma(T, \mathbf{s}, t, \lambda_i) = \epsilon(\mathbf{s}, t, \lambda_i) L^\circ(T, \lambda_i) \quad (1)$$

Où $T = T(\mathbf{s}, t)$ dépend du pixel \mathbf{s} et de l'instant t . Pour N_b bandes spectrales, une telle mesure par thermographie infrarouge forme un système sous-déterminé de N_b équations à $N_b + 1$ inconnues (N_b valeurs d'émissivités et 1 valeur de température). Ainsi, l'estimation de la température par thermographie infrarouge multispectrale ne peut pas se faire sans l'ajout d'informations *a priori*. L'utilisation de méthodes statistiques permet d'inférer de l'information dans le système d'équations.

3. Estimation conjointe de l'émissivité et de la température

3.1. Monte-Carlo Markov Chains (MCMC)

Les méthodes MCMCs sont des métaheuristiques dont l'objectif est d'échantillonner une distribution de probabilité cible établie en amont. Cette méthode a notamment été utilisée dans la littérature pour l'estimation conjointe d'émissivité et de température. Elle a été implémentée dans le cadre de cette étude pour comparaison [5] et détaillée précédemment dans [4].

3.2. Covariance Matrix Adaptation Evolution Strategy (CMA-ES)

La résolution de l'Equation 1 peut aussi être abordée d'un point de vue optimisation spatiale en réalisant des approximations locales pour arriver à un système sur-déterminé localement. Ceci peut être réalisé en injectant l'hypothèse que l'émissivité et la température sont constantes sur une fenêtre locale de pixels en supposant ainsi que cet ensemble de pixels représentent le même matériau. Soit w_s une fenêtre de taille 3×3 pixels et centrée sur un pixel $s \in \mathcal{S} \setminus \partial\mathcal{S}$, on a l'hypothèse suivante :

$$\forall s' \in w_s, \begin{cases} \epsilon_{s'} &= \epsilon_s \\ T_{s'} &= T_s \end{cases} \quad (2)$$

Il est ainsi possible de formuler le problème d'optimisation suivant :

$$\forall s \in \mathcal{S} \setminus \partial\mathcal{S}, (\epsilon_s, T_s) = \arg \min_{(\epsilon, T)} \left(\sum_{s' \in w_s} \|\gamma(T, s', t, \lambda_i) - \epsilon L^\circ(T, \lambda_i)\| \right) \quad (3)$$

Ce problème d'optimisation est résolu ici par l'algorithme CMA-ES[6]. Cette méthode est une méthode d'optimisation globale, nécessaire ici où l'espace de recherche des solutions fait converger d'autres algorithmes vers des solutions locales (voir [7]). De plus, elle présente l'avantage de ne pas avoir de paramètres à régler et est un des algorithmes de référence en matière d'optimisation globale [8, 9].

3.3. Interacting Particle Kalman Filter (IPKF)

Une autre approche, particulièrement adaptée aux mesures long-terme consiste à utiliser la caractéristique temporelle et multispectrale de la donnée [7]. Ainsi, un modèle dynamique de la température est ajouté à l'équation de mesure permettant d'obtenir la forme compagne discrétisée Equation 4 ; on ne parle plus de temps continu t mais d'échantillon noté \cdot_k . L'Equation 1 est modifiée en utilisant l'approximation de Wien et le logarithme afin de séparer en deux composantes la température et l'émissivité. De plus, la variation de l'émissivité en temps est supposée faible par rapport à la variation en température :

$$\begin{cases} x_k(\mathbf{s}) &= A_k x_{k-1}(\mathbf{s}) + v_k \\ \mathbf{y}_k &= \ln(\gamma_k(T_k, \mathbf{s}, \lambda_i)) = \ln(\epsilon(\mathbf{s}, \lambda_i)) - \frac{C_2}{\lambda_i} x_k(\mathbf{s}) + \mathbf{w}_k \end{cases} \quad (4)$$

Avec x_k le scalaire d'état à estimer, v_k et \mathbf{w}_k des bruits blancs ajoutés à l'équation dynamique et l'équation de mesure. Dans la suite, on suppose que les quantités impliquées suivent une loi normale. Cette hypothèse peut être discutée, notamment à cause du logarithme mis en jeu. Cependant, pour des applications de surveillance thermique long terme, les données sont sur-échantillonnées au vu des constantes de temps thermique des objets observés. Ainsi, ce sur-échantillonnage est mis à profit en moyennant les mesures sur un intervalle de temps donné pour s'approcher d'une loi normale (théorème central limite).

Le filtre de Kalman permet de réaliser une estimation du vecteur d'état grâce à un *a priori* sur le modèle dynamique sous-jacent du système. Lorsque le modèle n'est pas connu, le filtre IPKF proposé par [10] permet de réaliser une estimation des paramètres du modèle en même temps que le vecteur d'état. Pour cela, un ensemble de filtres de Kalman estime l'état du modèle linéaire défini par un modèle dynamique pour lequel les paramètres sont suivis par un filtre particulière. Une particule p est définie par son vecteur de paramètres ξ_k^p . A chaque pas de temps k , l'évolution des particules est définie par une perturbation aléatoire suivant une loi normale (\mathcal{N}) autour de sa position courante :

$$\xi_k^p = \xi_{k-1}^p + \mathcal{N}(\delta\xi_k; \sigma_k^\xi) \quad (5)$$

Ici, deux paramètres dans le modèle sont inconnus : l'émissivité et l'évolution dynamique (A_k) de la température [7]. On définit ainsi le vecteur de paramètres d'une particule par :

$$\xi_k^p(\mathbf{s}) = \left(a_k^p, \alpha_k^p(\mathbf{s})^T \right)^T \quad (6)$$

Où $a_k^p \in \mathbb{R}$ est un scalaire représentant l'évolution de la température au cours du temps et α_k^p l'émissivité telle que :

$$\alpha_k^p(\mathbf{s})^T = (\ln(\epsilon_k^p(\mathbf{s}, \lambda_i)))_{1 \leq i \leq N_b}^T \quad (7)$$

On a donc le système suivant pour une particule donnée :

$$\begin{cases} x_k^p(\mathbf{s}) &= a_k^p x_{k-1}^p(\mathbf{s}) + v_k^p \\ \mathbf{y}_k^p(\mathbf{s}) &= \alpha_k^p(\mathbf{s}) + \mathbf{C} x_k^p(\mathbf{s}) + \mathbf{w}_k^p \end{cases} \quad (8)$$

Les équations du filtre de Kalman peuvent ainsi être utilisées pour obtenir un estimé de l'état du système $\hat{x}_{k|k}^p$ à l'instant k et une prédiction $\hat{x}_{k|k-1}^p$ avant correction pour chaque particule. Cela permet de suivre l'évolution du vecteur d'état au cours du temps et d'obtenir de plus une estimation *a posteriori* de la covariance de l'erreur. Un critère de vraisemblance est alors défini pour la sélection des particules, comme pour [10] :

$$p(\mathbf{y}_k(\mathbf{s}) | \xi_k^p(\mathbf{s})) = \mathcal{N} \left(\alpha_k^p(\mathbf{s}) + \mathbf{C} \hat{x}_{k|k-1}^p(\mathbf{s}), \mathbf{S}_k^p(\mathbf{s}) \right) \quad (9)$$

où $\mathbf{S}_k^p(\mathbf{s})$ est la matrice de covariance de l'innovation du filtre de Kalman [7]. Un critère supplémentaire pour améliorer la convergence de l'algorithme est donné par :

$$\frac{\partial y(t, \lambda)}{\partial \lambda} = \frac{1}{\epsilon(\lambda)} \frac{d\epsilon(\lambda)}{d\lambda} \quad (10)$$

La Figure 1 présente les résultats obtenus avec cette approche. Le profil d'émissivité sur un seul pixel est retrouvé avec une estimation de la température suivant l'évolution temporelle de référence. Cependant, il est à noter que ce type de calcul intensif est couteux en temps de calcul. Bien que l'algorithme soit parallélisable, le nombre de particules requis pour une image haute résolution devient trop important. De plus, l'algorithme convient à des données hyperspectrales à cause de la condition sur la dérivée première en longueur d'onde.

Pour pallier ces difficultés et adapter l'algorithme à des données multispectrales, une étape de krigeage a été intégrée à la méthode IPKF pour prendre en compte la donnée spatiale et s'affranchir du caractère multispectral des données.




Figure 1 : Estimation de la température et de l'émissivité avec 8000 particules par IPKF.

3.4. Kriged Interacting Particle Kalman Filter (KIPKF)

Le krigeage est une méthode d'interpolation spatiale basée sur l'ajustement d'un modèle de covariance spatiale sur les données [11, 12, 13]. Ce modèle de covariance spatiale peut notamment être ajusté à partir de données réelles. Ajouter cette étape de krigeage à la précédente méthode IPKF permet d'exécuter le filtre sur un sous-ensemble de pixels de l'image et d'utiliser les données interpolées pour affiner la sélection des particules.

Supposons que le champ spatial à interpoler (ϵ) soit la somme d'une tendance $\mu : \mathcal{S} \rightarrow \mathbb{R}$ et d'un processus aléatoire centré de carré intégrable Z de covariance connue (estimée depuis les données réelles [14]) :

$$\epsilon(\mathbf{s}) = \mu(\mathbf{s}) + Z(\mathbf{s}) \quad (11)$$

Les équations de krigeage non présentées ici permettent alors d'estimer à la volée la fonction de tendance $\mu(\mathbf{s})$ et d'interpoler sur \mathcal{S} un ensemble de N_m mesures $\mathbf{S} = (\mathbf{s}_i)_{1 \leq i \leq N_m} \in \mathcal{S}$ en garantissant le minimum de variance [15].

Dans cette approche, l'Equation 4 de mesure est formulée en espace à la place d'être formulée en fréquence. De plus, deux composantes se distinguent, l'une dynamique $\mathbf{v}_{d,k}$ (la température) et l'autre stationnaire $\mathbf{v}_{s,k}$ (l'émissivité) :

$$\tilde{\mathbf{y}}_k(\lambda_i) = \mathbf{v}_{s,k}(\lambda_i) + C(\lambda_i)\mathbf{v}_{d,k} + \boldsymbol{\nu}_k \quad (12)$$

Avec $\boldsymbol{\nu}_k \sim \mathcal{N}(0, \Sigma_{\boldsymbol{\nu},k})$ le bruit de processus et $C(\lambda_i) = \frac{C_2}{\lambda_i T_{\text{ref}}}$ où T_{ref} est une constante de normalisation pour des questions numériques [1], $\mathbf{v}_{s,k}(\lambda_i) = \ln(\epsilon_k(\mathbf{s}_k, \lambda_i))_{1 \leq k \leq N_m}$, $\mathbf{v}_{d,k} = (\frac{T_{\text{ref}}}{T_k(\mathbf{s}_k)})_{1 \leq k \leq N_m}$ et $\tilde{\mathbf{y}}_k(\lambda_i) = (\ln(\gamma_k(\mathbf{s}_k, \lambda_i)))_{1 \leq k \leq N_m}$.

Supposons maintenant que le champ spatial stationnaire $\mathbf{v}_{s,k}$ suive un processus aléatoire avec $\boldsymbol{\mu}_\epsilon$ son espérance et Σ_ϵ sa matrice de covariance spatiale pour une longueur d'onde donnée. Dans un premier temps, $\mathbf{v}_{s,k}$ est considéré comme un bruit dans l'équation de mesure [12] :

$$\tilde{\mathbf{y}}_k(\lambda_i) - \boldsymbol{\mu}_\epsilon(\lambda_i) = C(\lambda_i)\mathbf{v}_{d,k} + (\mathbf{v}_{s,k}(\lambda_i) - \boldsymbol{\mu}_\epsilon(\lambda_i)) + \boldsymbol{\nu}_k \quad (13)$$

On obtient alors l'équation de mesure suivante :

$$\hat{\mathbf{y}}_k(\lambda_i) = C(\lambda_i)\mathbf{v}_{d,k} + \mathbf{e}_{s,k}(\lambda_i) \quad \text{avec} \quad \begin{cases} \hat{\mathbf{y}}_k(\lambda_i) &= \tilde{\mathbf{y}}_k(\lambda_i) - \boldsymbol{\mu}_\epsilon(\lambda_i) \\ \mathbf{e}_{s,k}(\lambda_i) &= (\mathbf{v}_{s,k}(\lambda_i) - \boldsymbol{\mu}_\epsilon(\lambda_i)) + \boldsymbol{\nu}_k \\ \Sigma_e &= \Sigma_\epsilon(\lambda_i) + \Sigma_{\boldsymbol{\nu},k} \end{cases} \quad (14)$$

Comme précédemment, avec $\boldsymbol{\eta}_k \sim \mathcal{N}(0, \Sigma_\eta)$ le modèle d'état devient :

$$\begin{cases} \mathbf{v}_{d,k} &= \mathbf{A}_k \mathbf{v}_{d,k} + \boldsymbol{\eta}_k \\ \hat{\mathbf{y}}_k(\lambda_i) &= C(\lambda_i)\mathbf{v}_{d,k} + \mathbf{e}_{s,k}(\lambda_i) \end{cases} \quad \text{avec} \quad \mathbf{A}_k = a_k \mathbf{I}, a_k \in \mathbb{R} \quad (15)$$

Dans, cette méthode, la température est suivie en temps grâce à un filtre de Kalman. Les paramètres μ_ϵ et a_k sont estimés par un filtre particulaire comme pour le filtre IPKF. Enfin, les particules sont sélectionnées à l'aide du krigeage. Pour des détails sur l'algorithme, cf [7, 16].

4. Comparaison des méthodes

4.1. Cas test numérique

Afin de comparer les méthodes, un cas test numérique a été réalisé avec un logiciel de simulation des radiosités [2]. Une cible composée de quatre matériaux distincts dont les propriétés radiatives sont connues a été modélisée (voir Figure 2). Le cadre de la cible (peinture noire) est maintenu à température constante et les 4 autres matériaux (béton, aluminium, or et bois) ont une température variable au sein des quatre petits carrés. Les profils d'émissivité sont pris à partir de mesures réelles et l'évolution de la température à partir de mesures thermocouples au sol à l'extérieur en janvier 2017. Quatre bandes spectrales ont été utilisées pour la simulation : $[1.5; 3]\mu\text{m}$, $[3; 5]\mu\text{m}$, $[8; 10]\mu\text{m}$ and $[10; 12]\mu\text{m}$.




Figure 2 : De gauche à droite : Émissivité spectrale des matériaux de la cible. Rendu dans le visible de la scène. Résultat de simulation pour un cadre à 293.15 K et des matériaux à 278.35 K

4.2. Résultats

MCMC L'estimation conjointe a été faite en un instant donné pour un seul pixel. L'algorithme s'arrête au bout de 10k iterations soit environ 20 min de calculs. En première approche, la loi pour l'émissivité est prise comme $\mathcal{N}(0.5, 0.5)$ et pour la température $\mathcal{N}(273.15, 5)$. La Figure 3 montre les estimations d'émissivité et de température obtenues pour le béton. La méthode MCMC permet ainsi de retrouver les profils d'origines de l'émissivité (dans l'hypothèse de corps gris) ainsi qu'une convergence vers la température originale. Il est à noter que cette méthode est également coûteuse en temps de calcul. De plus, cette méthode est sensible au nombre d'itérations nécessaires qui doit être fixé en amont.

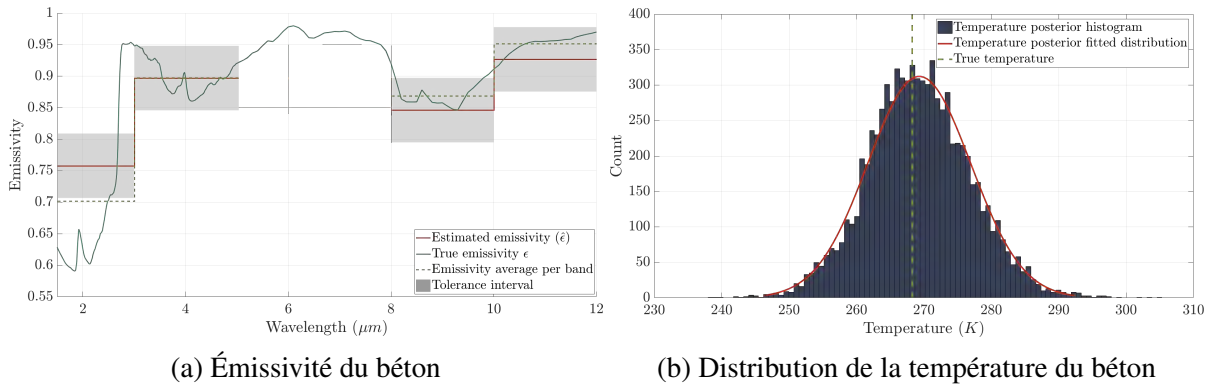


Figure 3 : Résultat de l'estimation conjointe d'émissivité et de température avec la méthode MCMC pour un pixel à un instant donné. (a) estimation de l'émissivité, (b) estimation de la température. Le profil d'origine (en pointillés) est comparé à l'estimé (en continu).

CMA-ES L'approche par optimisation avec l'algorithme CMA-ES a ensuite été testée sur les données numériques. Des bornes sur les valeurs d'émissivité ($0 < \epsilon < 1$) et de température ($260.15K < T < 300.15K$) ont par ailleurs été ajoutées. Une émissivité constante de 0.8 est choisie comme point initial. Un filtre médian 2D est appliqué sur l'image obtenue afin de lisser le résultat montré dans la Figure 4. Les différents matériaux deviennent identifiables grâce à la carte d'émissivité. On observe cependant qu'une petite erreur sur des émissivités faibles implique une erreur relativement importante sur l'estimation en température. Bien que ces résultats semblent prometteurs, l'utilisation d'une telle méthode sur des données long-terme reste relativement lourde (≈ 0.08 s pour un pixel à un instant donné).

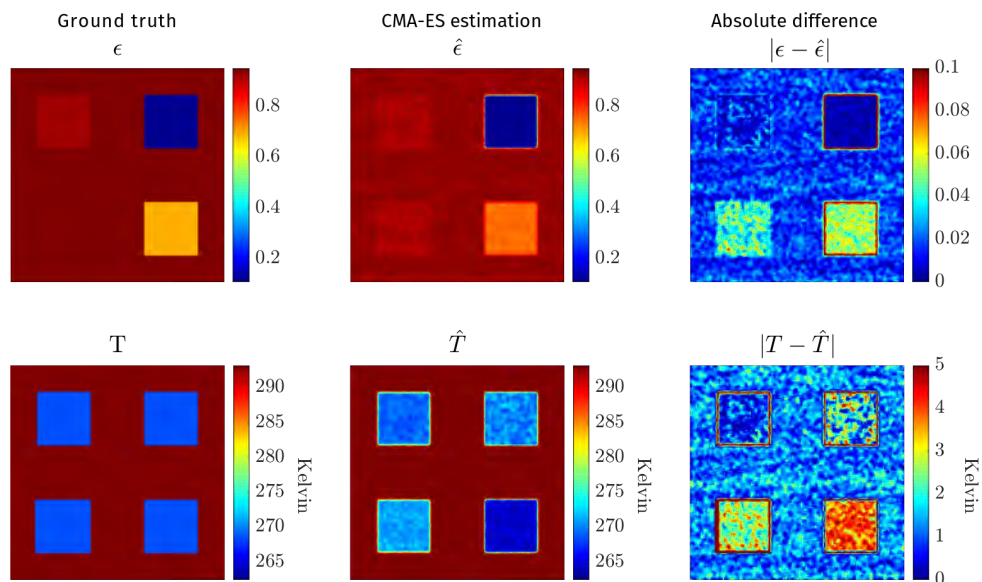
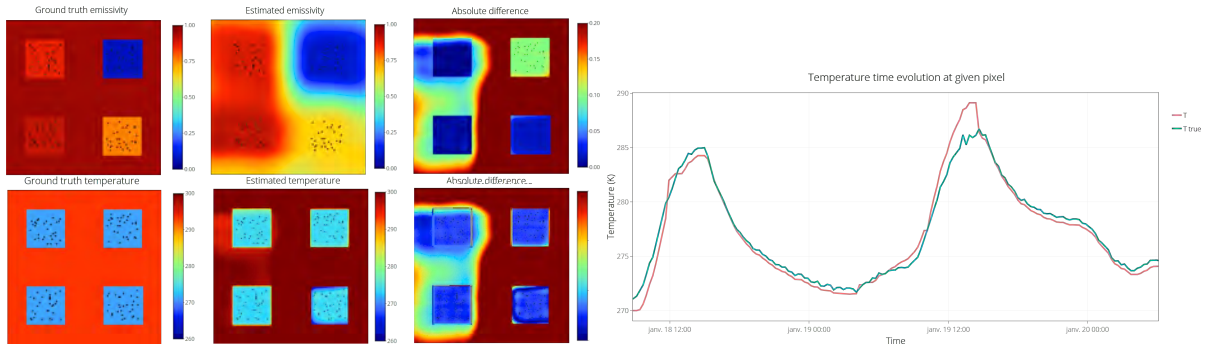


Figure 4 : Résultat de l'estimation conjointe d'émissivité et de température avec la méthode CMA-ES pour une image à un instant donné. De gauche à droite : valeur originale, estimée et différence absolue. De haut en bas : émissivité, température

KIPKF Afin de pouvoir réaliser une comparaison avec les autres méthodes, une adaptation a été faite sur la méthode KIPKF. En effet, les données simulées considèrent une cible avec un cadre à température constante et des matériaux à température variable. Cependant, la méthode KIPKF repose sur la dynamique du signal, ainsi aucun point de référence pour le krigeage n'a été pris dans le cadre. La Figure 5 (à gauche) montre finalement l'estimé sur la totalité de la période où les valeurs originales sont comparées aux valeurs estimées. Enfin, la Figure 5 (à droite) montre l'estimation en température au cours du temps.



(a) Résultat de l'estimation conjointe pour une image à un instant donné. (b) Résultat pour l'évolution temporelle de la température.

Figure 5 : Résultats obtenus avec la méthode KIPKF.

Contrairement aux précédentes méthodes, le filtre est capable de suivre en temps l'évolution des paramètres du modèle et de la température. Cette caractéristique est particulièrement intéressante. En perspectives, si au bout d'un certain temps la prédiction du krigeage est compromise, il serait alors possible d'ajouter un terme de réinitialisation permettant d'observer les changements d'émissivité dans la scène. Le krigeage autorise le suivi d'un sous-ensemble de pixels et permet de réduire le temps de calcul, ici à environ 0.06 ms par pixel à un instant donné t .

5. Conclusions et perspectives

Quatre méthodes statistiques pour l'estimation conjointe de l'émissivité et de la température par thermographie infrarouge multispectrale ont été présentées et comparées. Ces méthodes permettent d'exploiter l'information *a priori* dans le système d'équations. De plus, ces méthodes offrent un moyen de mesurer l'incertitude induite par l'estimation. Si les méthodes MCMC et CMA-ES proposent des résultats intéressants, le temps et l'énergie requis pour de tels calculs sont un frein à leur application sur des données long-terme. La méthode IPKF est quant à elle plus adaptée à des mesures hyperspectrales. Finalement, la méthode KIPKF est prometteuse pour des données multispectrales et long-terme. En effet, l'ajout d'une étape de krigeage dans la méthode IPKF a permis d'inférer un modèle de covariance spatiale pour l'émissivité et permis de réduire les temps de calculs. Ces résultats préliminaires sont encourageants sur des données simulées, mais nécessitent encore des travaux pour être mis en œuvre sur un système de thermographie infrarouge multispectral long-terme. La carte d'émissivité permet notamment d'identifier les matériaux même si des différences existent avec les valeurs originales. Des travaux sont engagés pour améliorer l'algorithme afin de le rendre plus robuste, particulièrement pour ajuster ses paramètres de fonctionnement. Enfin, des essais en laboratoires seront développés afin de valider la méthode sur des données réelles.

Références

- [1] Jean-Claude Krapez. Radiative Measurements of Temperature. In *Thermal Measurements and Inverse Techniques*, Heat Transfer. CRC Press, Boca Raton, FL, 2011. OCLC : ocn587104377.
- [2] Thibaud Toullier, Jean Dumoulin, and Laurent Mevel. Étude et développement d'un simulateur d'échanges radiatifs dans des scènes 3D statiques et dynamiques surveillées par thermographie infrarouge. In *SFT 2019 - 27eme congrès français de thermique*, Nantes, France, June 2019.
- [3] G. Gaussorgues and S. Chomet. *Infrared Thermography*. Springer Science & Business Media, December 1993.
- [4] Thibaud Toullier, Jean Dumoulin, and Laurent Mevel. Etude de sensibilité de différentes méthodes de séparation pour l'évaluation simultanée de l'émissivité et de la température par thermographie infrarouge multispectrale. In *SFT 2018 - 26eme congrès français de thermique*, June 2018.
- [5] Joshua N. Ash and Joseph Meola. Temperature-emissivity separation for LWIR sensing using MCMC. In *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imager XXII*, volume 9840, page 98401O. International Society for Optics and Photonics, May 2016.
- [6] Nikolaus Hansen. *The CMA Evolution Strategy : A Comparing Review*, volume 192, pages 75–102. 06 2007.
- [7] Thibaud Toullier. *Simultaneous Characterization of Objects Temperature and Radiative Properties through Multispectral Infrared Thermography*. PhD thesis, Université de Rennes 1, IFSTTAR - Nantes, 2019.
- [8] Salvador García, Daniel Molina, Manuel Lozano, and Francisco Herrera. A study on the use of non-parametric tests for analyzing the evolutionary algorithms' behaviour : A case study on the CEC'2005 Special Session on Real Parameter Optimization. 15(6) :617–644.
- [9] Nikolaus Hansen, Anne Auger, Raymond Ros, Steffen Finck, and Petr Pošík. Comparing results of 31 algorithms from the black-box optimization benchmarking BBOB-2009. In *Proceedings of the 12th Annual Conference Comp on Genetic and Evolutionary Computation - GECCO '10*, page 1689. ACM Press.
- [10] Meriem Zghal, Laurent Mevel, and Pierre Del Moral. Modal parameter estimation using interacting Kalman filter. *Mechanical Systems and Signal Processing*, 47(1-2) :139–150, August 2014.
- [11] Olivier Roustant and Yves Deville. (Re)Dice Packages for Computer Experiments. In *Troisièmes rencontres R*, Montpellier, France, June 2014.
- [12] Venkat Roy, Andrea Simonetto, and Geert Leus. Spatio-Temporal Field Estimation Using Krige Kalman Filter (KKF) with Sparsity-Enforcing Sensor Placement. *Sensors*, 18(6) :1778, June 2018.
- [13] Kanti V. Mardia, Colin Goodall, Edwin J. Redfern, and F Alonso. The Krige Kalman Filter. *TEST : An Official Journal of the Spanish Society of Statistics and Operations Research*, 7 :217–282, February 1998.
- [14] Olivier Roustant, David Ginsbourger, and Yves Deville. , : Two Packages for the Analysis of Computer Experiments by Kriging-Based Metamodeling and Optimization. *Journal of Statistical Software*, 51, 2012.
- [15] Georges Matheron, Fernand Blondel, and Bureau de recherches géologiques et minières (France). *Traité de géostatistique appliquée. Tome I Tome I*. Technip, Paris, 1962. OCLC : 491866302.
- [16] Thibaud Toullier, Jean Dumoulin, and Laurent Mevel. A kriging-based interacting particle kalman filter for the simultaneous estimation of temperature and emissivity in infra-red imaging. In *International Federation of Automatic Control (IFAC)*, 2020.