



Spectroscopie Raman comprimée pour la classification supervisée d'espèces : méthodologie pour la conception d'approches robustes

Timothée Justel, Frédéric Galland, Antoine Roueff

► To cite this version:

Timothée Justel, Frédéric Galland, Antoine Roueff. Spectroscopie Raman comprimée pour la classification supervisée d'espèces : méthodologie pour la conception d'approches robustes. 29^e Colloque GRETSI sur le traitement du signal et des images, GRETSI - Groupe de Recherche en Traitement du Signal et des Images, Aug 2023, Grenoble, France. pp.441-444. <hal-04285570>

HAL Id: hal-04285570

<https://hal.science/hal-04285570v1>

Submitted on 14 Nov 2023

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.



HAL Authorization

Spectroscopie Raman comprimée pour la classification supervisée d'espèces : méthodologie pour la conception d'approches robustes

Timothée JUSTEL¹ Frédéric GALLAND¹ Antoine ROUEFF²

¹Aix Marseille Univ, CNRS, Ecole Centrale Marseille, Institut Fresnel, Marseille, France.

²Université de Toulon, Aix Marseille Univ, CNRS, IM2NP, Toulon, France.

Résumé – La spectroscopie Raman est très utilisée pour l'analyse chimique, mais elle nécessite en général d'importants temps de pose. Pour pallier ce problème il est possible d'utiliser des techniques comprimées, qui consistent à ne mesurer qu'une partie du spectre après un filtrage en fréquence optimisé pour une tâche donnée grâce à un a priori sur l'échantillon analysé. En présence d'écarts de modèle, il est d'autant plus difficile de détecter et de caractériser ces écarts que le filtrage est spécialisé. Nous présentons une méthodologie basée sur les bornes de Bhattacharyya et de Cramér-Rao pour la conception d'un système Raman comprimé, permettant de classer les mesures parmi une liste d'espèces chimiques de spectres connus, de vérifier l'adéquation des mesures avec cet a priori, et de reconstruire les spectres rencontrés sans nécessiter de mesures supplémentaires.

Abstract – Raman spectroscopy is widely used for chemical analysis, but generally requires large exposure times. To mitigate this issue it is possible to use compressed acquisition techniques, which consist in measuring only some parts of the spectrum after a spectral filtering tailored for a given task using an a priori about the analyzed sample. In the presence of model shifts, the more specialized the filtering, the more difficult it is to detect and characterize these deviations. We present a methodology based on the Bhattacharyya and Cramér-Rao bounds for the design of a compressed Raman system, allowing to classify measurements among a list of reference species, to check the adequacy of these measurements with this a priori, and to reconstruct encountered spectra without requiring additional measurements.

1 Introduction

La spectroscopie Raman est un outil très utilisé pour déterminer la composition chimique d'un échantillon. Cependant, du fait de la faible intensité du rayonnement produit par la diffusion Raman spontanée et de l'utilisation de barrettes de détecteurs limitées par un bruit électronique, l'obtention de spectres exploitables nécessite généralement de longues acquisitions. Afin de répondre à ce problème, des approches Raman comprimées ont été proposées. Ces approches consistent à mesurer non plus le spectre entier mais uniquement certaines combinaisons de bandes spectrales pertinentes pour l'analyse, ce qui revient à filtrer le rayonnement en fréquence puis à intégrer le résultat de ce filtrage sur un petit nombre de détecteurs [1, 2, 13, 12, 8, 11]. Ce type d'approche est particulièrement intéressant dans le cas où les spectres des espèces en présence sont connus : il devient alors possible d'adapter les filtres à ces espèces ainsi qu'à la tâche à effectuer, par exemple pour l'estimation des concentrations d'un mélange [12, 8, 10] ou la discrimination d'espèces chimiques données [13, 7, 6], permettant ainsi de travailler à très faible nombre de photons.

Puisque ces approches comprimées reposent sur la connaissance a priori des spectres des espèces présentes dans l'échantillon analysé, des problèmes peuvent apparaître lorsque les spectres constituant l'a priori diffèrent des spectres rencontrés. Pour éviter une mauvaise interprétation des données, il est donc nécessaire de pouvoir vérifier la cohérence des mesures avec cet a priori. Or, puisque le rayonnement est observé à travers un petit nombre de filtres, on ne dispose en général pas d'un accès direct au spectre observé, ce qui rend difficile la détection et la caractérisation des éventuelles anomalies.

Nous présentons dans cet article une méthodologie fon-

dée sur les principes présentés dans [8, 6, 4, 5], qui permet de concevoir des systèmes d'acquisition comprimée rendant possible de réaliser à la fois la classification supervisée des mesures avec des performances contrôlées, de tester l'adéquation de ces mesures avec les spectres de référence utilisés pour les classer et de diagnostiquer l'origine d'éventuels écarts au modèle, le tout sans mesure additionnelle.

2 Classification et reconstruction

Dans cette partie, nous décrivons le système d'acquisition Raman comprimé considéré ainsi que les contraintes à prendre en compte pour réaliser à la fois la classification supervisée de chaque mesure et la reconstruction des spectres rencontrés.

En chaque pixel le rayonnement Raman provenant de l'échantillon est filtré par un jeu de P filtres appliqués dans le domaine spectral, et les photons en sortie de chaque filtre sont ensuite intégrés sur un détecteur. Plus précisément, en notant $F_1^{(w)}, \dots, F_P^{(w)}$ le jeu de P filtres utilisé au pixel numéroté w , la valeur moyenne du nombre de photons $n_m^{(w)}$ reçu sur le détecteur en sortie du filtre $F_m^{(w)}$ est égale à [12, 8, 6]

$$\langle n_m^{(w)} \rangle = \tau^{(w)} \gamma^{(w)} \sum_{k=1}^K F_m^{(w)}(k) S_k \quad (1)$$

où l'on a supposé que le domaine fréquentiel était découpé en K intervalles $[\nu_k, \nu_k + \delta_\nu]$ disjoints, avec $\mathbf{S} = (S_1, \dots, S_K)^T$ le spectre Raman normalisé observé (i.e. $\sum_{k=1}^K S_k = 1$), et $\mathbf{F}_m^{(w)} = (F_m^{(w)}(1), \dots, F_m^{(w)}(K))^T$ le $m^{\text{ème}}$ filtre utilisé en w . Dans cette équation, le coefficient $\gamma^{(w)}$ correspond à l'intensité

du rayonnement au pixel w et $\tau^{(w)}$ au temps d'acquisition.

Lorsque l'objectif est de classer les mesures en chaque pixel parmi M espèces chimiques de spectres connus, il est suffisant d'utiliser $P = 2$ filtres par pixel, et ce même lorsque M est strictement supérieur à 2 [6]. Dans la suite, nous considérons donc que $P = 2$. Nous imposons également que ces 2 filtres soient binaires, orthogonaux et complémentaires, c'est à dire que $F_m^{(w)}(k) \in \{0, 1\}$ et $F_1^{(w)}(k) + F_2^{(w)}(k) = 1 \forall k, w$. L'orthogonalité de ces filtres permet de les employer en parallèle et ainsi de limiter le temps d'acquisition [9, 8]. De plus, lorsque les mesures sont effectuées en parallèle il est possible d'arrêter l'acquisition non pas après un temps donné mais lorsqu'un nombre fixé de photons N a été détecté, i.e. lorsque $n_1^{(w)} + n_2^{(w)} = N$. Si l'on note D_m le capteur placé en sortie du filtre $F_m^{(w)}$, le nombre de photons $n_m^{(w)}$ reçu sur D_m en w est alors distribué selon une loi binomiale de paramètres N et $p_m^{(w)} = \langle n_m^{(w)} \rangle / (\langle n_1^{(w)} \rangle + \langle n_2^{(w)} \rangle) = \sum_{k=1}^K F_m^{(w)}(k) S_k$. Fixer le nombre total de photons détectés plutôt que le temps d'acquisition implique notamment que les distributions des nombres de photons détectés par filtre et donc les performances de classification soient indépendantes de l'intensité inconnue du rayonnement Raman $\gamma^{(w)}$ [6].

Considérons d'abord la classification des mesures parmi les M espèces connues que l'on suppose composer l'échantillon et dont les spectres normalisés sont notés $S^{(1)}, \dots, S^{(M)}$. Lorsque ces classes sont équiprobables le classifieur optimal (au sens de la probabilité d'erreur de classification) des mesures $n_1^{(w)}$ et $n_2^{(w)}$ réalisées au pixel w est

$$\hat{u}_{\text{opt}}^{(w)} = \underset{u \in \{1, \dots, M\}}{\operatorname{argmax}} \left(n_1^{(w)} \log p_1^{(w,u)} + n_2^{(w)} \log p_2^{(w,u)} \right) \quad (2)$$

où $p_m^{(w,u)}$ est la probabilité $p_m^{(w)}$ correspondant au spectre $S^{(u)}$. Les performances de ce discriminateur, et en particulier sa probabilité d'erreur de classification $\mathcal{P}_e^{(w)}$, dépendent des spectres $S^{(u)}$ mais aussi du choix des filtres. Il est possible de montrer [6] que cette probabilité d'erreur est majorée par une borne de Bhattacharyya généralisée $\mathcal{B}^{(w)}$, c'est à dire

$$\mathcal{P}_e^{(w)} \leq \mathcal{B}^{(w)} = \frac{1}{M} \sum_u \sum_{v > u} \left(\sum_{m=1}^2 \sqrt{p_m^{(w,u)} p_m^{(w,v)}} \right)^N, \quad (3)$$

et on peut donc optimiser les filtres en minimisant cette borne.

Comme évoqué précédemment il peut également être utile de pouvoir vérifier que les spectres observés correspondent bien aux spectres de référence. Si l'on souhaite conserver un système Raman comprimé où seules 2 mesures sont effectuées à chaque pixel, il n'est pas possible de reconstruire un spectre entiers à partir des mesures effectuées sur un pixel unique. Une solution [4, 5] est de modifier les filtres entre chaque pixel de façon à ce que l'on puisse reconstruire un spectre à partir des mesures effectuées sur W pixels. Les performances de reconstruction peuvent être caractérisées à l'aide des bornes de Cramér-Rao associées à l'estimation des coefficients du spectre observé S dans les différentes bandes spectrales. En effet, la variance σ_k^2 d'un estimateur non biaisé de $S(k)$ est minorée par la borne de Cramér-Rao $\text{CRB}_k = [\mathbf{I}_F^{-1}]_{k,k}$ où \mathbf{I}_F est la matrice d'information de Fisher. Cette matrice s'écrit ici [4]

$$[\mathbf{I}_F]_{k,l} = N \sum_{w=1}^W \sum_{m=1}^2 \frac{\delta F_m^{(w)}(k) \delta F_m^{(w)}(l)}{\sum_{k'=1}^K F_m^{(w)}(k') S(k')} \quad (4)$$

où $\delta F_m^{(w)}(k) = F_m^{(w)}(k) - F_m^{(w)}(K)$ et $k, l \in \llbracket 1, K-1 \rrbracket$. Ainsi, si l'on souhaite reconstruire un spectre en combinant les mesures sur W pixels, il peut être pertinent d'optimiser les filtres employés en chacun de ces pixels de façon à minimiser la quantité $\overline{\text{CRB}} = \sum_{k=1}^{K-1} \text{CRB}_k$. Comme l'optimisation des filtres est réalisé avant de faire les mesures et que l'on souhaite pouvoir reconstruire un spectre inconnu, $\overline{\text{CRB}}$ est alors calculée pour un spectre uniforme, i.e. $S(k) = 1/K \forall k$.

Lors de la sélection des filtres, il convient donc de choisir des filtres permettant à la fois d'avoir une faible borne de Cramér-Rao $\overline{\text{CRB}}$ sur un ensemble de W pixels, et une faible borne de Bhattacharyya $\mathcal{B}^{(w)}$ en chacun de ces pixels [4, 5], ou de manière équivalente une faible borne de Bhattacharyya moyenne $\bar{\mathcal{B}} = \frac{1}{W} \sum_{w=1}^W \mathcal{B}^{(w)}$ sur ces W pixels. Dans la mesure où l'objectif principal reste la classification, une possibilité consiste à sélectionner parmi un large ensemble de jeux de 2 filtres ayant une faible borne de Bhattacharyya la combinaison de W jeux de filtres permettant d'avoir la plus faible valeur de $\overline{\text{CRB}}$ [4]. Cela signifie en particulier qu'il faut sélectionner au moins $K-1$ jeux de filtres différents (et donc $W \geq K-1$) pour que la matrice d'information de Fisher soit inversible et que l'on puisse reconstruire un spectre sans avoir à introduire d'hypothèse supplémentaire.

3 Tests d'adéquation

Dans cette section, nous allons voir comment la configuration proposée permet à la fois de réaliser une classification pixel à pixel avec de bonnes performances et d'analyser la validité des hypothèses utilisées.

Afin d'illustrer nos propos, nous avons généré une image de patchwork (Fig. 1.a) où chaque pixel est censé appartenir à l'une des 3 classes dont les spectres sont affichés sur la Fig. 1.b, mais où nous avons également rajouté une classe supplémentaire dont le spectre est inconnu. Les spectres de ces espèces comportent $K = 128$ fréquences et les $W = 144$ jeux de 2 filtres employés ont été optimisés selon la procédure présentée précédemment [4], en ne prenant en compte que les 3 spectres de référence de la Fig. 1.b. Nous justifierons plus loin le choix de ce nombre W de jeux de filtres. Le nombre de photons à acquérir par pixel avant d'arrêter l'acquisition est fixé à $N = 250$, permettant après optimisation des filtres d'obtenir $\bar{\mathcal{B}} = 7.5 \times 10^{-4}$ et $\overline{\text{CRB}} = 3.3 \times 10^{-2}$. Pour simuler ces données à partir des filtres et des spectres associés à chacune des 4 classes, nous avons généré aléatoirement les nombres de photons $n_1^{(w)}$ et $n_2^{(w)}$ (avec $n_1^{(w)} + n_2^{(w)} = N$) mesurés en chaque pixel de l'image sur les capteurs D_1 et D_2 en sortie des filtres $F_1^{(w)}$ et $F_2^{(w)}$.

Nous présentons en Fig. 1.c la classification obtenue en appliquant en chaque pixel le classifieur optimal adapté aux 3 espèces de référence (cf. Éq. 2). Sur les pixels appartenant effectivement aux classes 1 à 3 la fréquence d'erreur de classification est égale à 1.8×10^{-4} , et reste comme prévu inférieure à la borne de Bhattacharyya $\bar{\mathcal{B}} = 7.5 \times 10^{-4}$. Les pixels appartenant à la classe 4 sont évidemment assignés aux classes 1 à 3. De plus, la texture observée dans les régions correspondant à la classe 4 est directement liée au fait d'avoir changé de filtres à chaque pixel, permettant éventuellement de révéler un problème à l'utilisateur. A titre de comparaison, nous avons affiché en Fig. 1.d la classification obtenue lorsque les mesures




FIGURE 1 : (a) Vérité de terrain. Les spectres des classes 1 à 3 ont été appris. La classe 4 correspond à une espèce non prévue. Taille de l'image : 1000×1000 pixels. (b) Spectres des classes 1 à 3 ($K = 128$ fréquences). (c, d) Résultats de la classification (Éq. 2) des mesures effectuées en sortie de filtres $F_1^{(w)}$ et $F_2^{(w)}$ adaptés aux spectres de référence : (c) lorsque l'on a utilisé $W = 144$ paires de filtres différents [4], (d) lorsque l'on a utilisé en chaque pixel le même jeu de filtres optimisé pour la classification [6]. Nombre de photons détectés par pixel : $N = 250$.

sont effectuée en utilisant en chaque pixel le même jeu de filtre optimisé uniquement pour la classification [6].

Il est également possible de faire un test en chaque pixel afin de vérifier si les mesures effectuées sont bien en adéquation avec les spectres des 3 classes connues. En chaque pixel w où la classification est correcte, le nombre de photons $n_m^{(w)}$ sur le capteur D_m est distribué selon une loi binomiale de paramètres $(N, p_m^{(w, \hat{u})})$, où \hat{u} est la classe estimée. Afin de vérifier si les mesures effectuées sont bien en adéquation avec les spectres des 3 classes connues, il est alors possible de mettre en place un test du rapport de vraisemblances où l'on compare la vraisemblance calculée en supposant que les mesures $n_m^{(w)}$ sont bien distribuées selon ces lois binomiales (hypothèse H_0) et celle calculée lorsque l'on estime les paramètres $p_m^{(w)}$ au sens du maximum de vraisemblance, c'est à dire en supposant que les mesures $n_m^{(w)}$ sont distribuées selon des loi binomiales de paramètres $(N, n_m^{(w)}/N)$ (hypothèse H_1). Ce test s'écrit alors

$$n_1^{(w)} \log \frac{N p_1^{(w, \hat{u})}}{n_1^{(w)}} + n_2^{(w)} \log \frac{N p_2^{(w, \hat{u})}}{n_2^{(w)}} \underset{H_1}{\overset{H_0}{\gtrless}} T. \quad (5)$$

Sous H_0 et pour N suffisamment grand, ce test est distribué selon une loi du χ^2 à 1 degré de liberté. Le seuil T du test peut donc être calculé afin d'obtenir une certaine probabilité de fausse alarme (pfa). Dans la suite nous fixerons une pfa de 10^{-2} , ce qui correspond à $T = 6.635$.

Si l'on effectue ce test d'adéquation sur l'exemple de la Fig. 1.c, on obtient la carte de détection d'inadéquation affi-

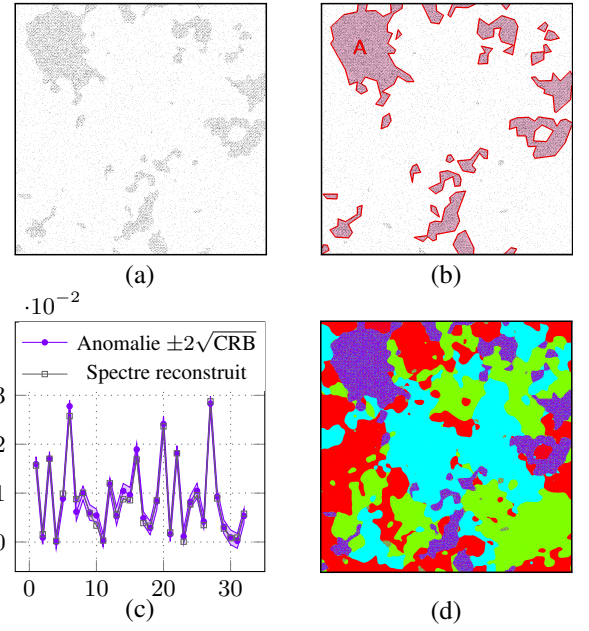


FIGURE 2 : (a) Détection des pixels où les mesures ne sont pas en adéquation avec les 3 spectres de la Fig 1.b (pfa = 10^{-2}), dans le cas où l'on utilise $W = 144$ paires de filtres différentes. Les pixels détectés sont affichés en noir. (b) Résultat de la segmentation en zone homogènes de la carte de détection (a), en fonction de la proportion de points détectés. Les zones où cette proportion est notablement supérieure à la pfa (ici 2 fois la pfa) ont été colorées en rouge pâle. (c) Reconstruction par pseudo-inverse du spectre correspondant à la région notée A sur la Fig. 2.b, et comparaison avec le véritable spectre de la classe 4. (d) Amélioration de la classification de la Fig. 1.c en effectuant une nouvelle classification dans les zones détectées en inadéquation sur la Fig. 2.b, mais en utilisant maintenant le spectre reconstruit en plus des 3 spectres de référence. Cette nouvelle classification n'a pas nécessité de mesures additionnelles.

chée sur la Fig. 2.a. On peut observer qu'il existe des zones de l'image où le nombre de pixels détectés est clairement supérieur à cette pfa, en l'occurrence celles où la classe inconnue apparaît. Bien sûr, puisque l'on travaille sur des données fortement bruitées et que l'on ne mesure pas la totalité du spectre du rayonnement, ce test ne détectera pas nécessairement toutes les inadéquations. En revanche, dans la mesure où l'on modifie les filtres entre chaque pixel, la probabilité pour qu'une même inadéquation ne soit détectée sur aucun de ces pixels est moins importante que si l'on avait toujours utilisé le même jeu de filtre. A partir de cette carte de détection, on peut alors identifier les zones où l'on est en bonne adéquation avec le modèle utilisé pour la classification, i.e. les zones où la proportion de pixels déclenchant le test est de l'ordre de la pfa.

Afin de déterminer la proportion de pixels détectés comme étant en inadéquation nous avons utilisé un algorithme de segmentation en zones homogènes de la carte de détection [3]. Pour ce faire, on associe à chaque pixel une valeur binaire valant 1 si le test est déclenché et 0 sinon, et cette valeur est modélisée comme la réalisation d'une loi de Bernoulli dont le paramètre est la proportion de pixels en inadéquation dans la zone considérée. La segmentation obtenue est affichée sur la Fig. 2.b. La plupart des régions ont une proportion de pixels détectés de l'ordre de la probabilité de fausse alarme, et

peuvent donc être considérées comme étant en adéquation avec le modèle. Cela signifie en particulier que l'on peut garantir dans ces zones que la probabilité d'erreur de classification est inférieure à $\bar{B} = 7.5 \times 10^{-4}$. En revanche on peut considérer que les résultats de classification sur les zones où la proportion de pixels détectés est nettement supérieure à la pfa ne peuvent pas être exploités.

Lorsque des anomalies sont détectées, il peut être nécessaire d'en connaître l'origine. Puisque les filtres ont été optimisés de sorte à ce que l'on puisse reconstruire un spectre dès lors que l'on combine les mesures effectuées sur au moins $W = 144$ pixels sur lesquels ont été employés des jeux de filtres différents, il a été choisi de répartir ces $144 = 12 \times 12$ filtres selon un motif carré de 12 pixels de côté, et de paver l'image à acquérir avec ce motif. Cela garantit de pouvoir reconstruire un spectre sur n'importe quelle zone de l'image contenant au moins un carré de cette taille. A titre d'exemple, nous avons reconstruit sur la Fig. 2.c le spectre correspondant à la région notée A en haut à gauche de la Fig. 2.b.

Reconstruire le spectre de l'anomalie permet de déterminer sa nature. Pour aller plus loin, il est par exemple possible de refaire la classification dans les zones qui posaient problème à partir des mesures déjà effectuées, en prenant en compte le spectre reconstruit en plus des 3 spectres de référence. Les résultats de cette nouvelle classification sont affichés en 2.d. Ces résultats sont en meilleur accord avec la réalité que ceux de la Fig. 1.d, bien qu'ils aient été obtenus sans réaliser de mesure supplémentaire.

4 Conclusion

Dans cet article, nous avons présenté une méthodologie permettant la conception d'un système d'acquisition Raman comprimé donnant à la fois la possibilité de classer les mesures réalisées en chaque pixel parmi une liste d'espèces de référence, de vérifier la validité des hypothèses a priori utilisées pour la classification et de reconstruire les spectres rencontrés, le tout sans nécessiter de mesure supplémentaire, ce qui serait rédhibitoire pour un grand nombre d'applications. Il en résulte une technique de classification supervisée quantitative, i.e. telle que l'on puisse distinguer les zones en adéquation avec les spectres des espèces de référence, sur lesquelles la probabilité d'erreur de classification est bornée, des zones sur lesquelles les résultats de classification ne peuvent être exploités, et permettre une analyse plus poussée de ces zones.

La principale perspective de ces travaux est l'implémentation de cette approche sur un système Raman comprimé réel. Il serait également intéressant d'analyser comment la technique proposée peut être adaptée aux cas où on ne mesure plus une espèce pure, mais un mélange d'espèces.

5 Remerciements

Les auteurs remercient Philippe Réfrégier pour son aide et ses conseils.

Références

- [1] D. CEBECI, B. R. MANKANI et D. BEN-AMOTZ : Recent trends in compressive raman spectroscopy using dmd-based binary detection. *Journal of Imaging*, 5(1):1, 2019.
- [2] B. M. DAVIS, A. J. HEMPHILL, D. CEBECI MALTAŞ, M. A. ZIPPER, P. WANG et D. BEN-AMOTZ : Multivariate hyperspectral raman imaging using compressive detection. *Analytical chemistry*, 83(13):5086–5092, 2011.
- [3] F. GALLAND, N. BERTAUX et P. RÉFRÉRIER : Multicomponent image segmentation in homogeneous regions by stochastic complexity minimization. *Patt. Rec.*, 38(11):1926–1936, 2005.
- [4] T. JUSTEL, F. GALLAND et A. ROUEFF : Compressed raman method combining classification and estimation of spectra with optimized binary filters. *Optics Letters*, 47(5):1101–1104, 2022.
- [5] T. JUSTEL, F. GALLAND et A. ROUEFF : Optimal trade-off filters for compressed raman classification and spectrum reconstruction. *JOSA A*, 40(6):1058–1065, 2023.
- [6] P. RÉFRÉRIER, E. CHEVALLIER et F. GALLAND : Compressed Raman classification method with upper-bounded error probability. *Optics Letters*, 44(23):5836, 2019.
- [7] P. RÉFRÉRIER et F. GALLAND : Bhattacharyya bound for raman spectrum classification with a couple of binary filters. *Opt. Lett.*, 44(9):2228–2231, May 2019.
- [8] P. RÉFRÉRIER, C. SCOTTÉ, H. B. de AGUIAR, H. RIGNEAULT et F. GALLAND : Precision of proportion estimation with binary compressed raman spectrum. *J. Opt. Soc. Am. A*, 35(1):125–134, Jan 2018.
- [9] O. G. REHRAUER, V. C. DINH, B. MANKANI, B. BUZZARD, B. LUCIER et D. BEN-AMOTZ : Binary complementary filters for compressive raman spectroscopy. *Applied Spectroscopy*, 72:69 – 78, 2018.
- [10] C. SCOTTÉ, H. B. de AGUIAR, D. MARGUET, E. M. GREEN, P. BOUZY, S. VERGNOLE, C. P. WINLOVE, N. STONE et H. RIGNEAULT : Assessment of compressive raman versus hyperspectral raman for microcalcification chemical imaging. *Analytical chemistry*, 90(12):7197–7203, 2018.
- [11] F. SOLDEVILA, J. DONG, E. TAJAHUERCE, S. GIGAN et H. B. de AGUIAR : Fast compressive raman bio-imaging via matrix completion. *Optica*, 6(3):341–346, 2019.
- [12] D. WILCOX, G. BUZZARD, B. LUCIER, Owen REHRAUER, P. WANG et D. BEN-AMOTZ : Digital compressive chemical quantitation and hyperspectral imaging. *The Analyst*, 138, 07 2013.
- [13] D. WILCOX, G. BUZZARD, B. LUCIER, P. WANG et D. BEN-AMOTZ : Photon level chemical classification using digital compressive detection. *Analytica chimica acta*, 755:17–27, 11 2012.