

Contributions méthodologiques et expérimentales à la localisation de sources acoustiques

**Habilitation à diriger des recherches de l'Université
Paris-Saclay**

présentée et soutenue à Paris-Saclay, le 09/01/2025, par

Gilles Chardon

Composition du jury

Barbara Nicolas
Directrice de recherche CNRS, Créatis
Jérôme Antoni
Professeur, INSA Lyon, LVA
Jérôme Mars
Professeur, INP Grenoble, GIPSA-lab
Jean-Yves Tournet
Professeur, ENSEEIHT, IRIT
Jean-François Aujol
Professeur, Université de Bordeaux, IMB
Pascal Larzabal
Professeur, Université Paris-Saclay, SATIE

Présidente
Rapporteur & Examineur
Rapporteur & Examineur
Rapporteur & Examineur
Examineur
Examineur

Titre : Contributions méthodologiques et expérimentales à la localisation de sources acoustiques

Résumé : Ce document résume mes travaux de recherche des cinq dernières années passées.

Dans une première partie, mes contributions à la localisation de sources acoustiques sont présentées. Ces contributions prennent la forme d'analyses théoriques de méthodes populaires dans la communauté (formation de voies et DAMAS, vues respectivement comme du maximum de vraisemblance et un problème de moindres carrés non négatif), d'applications de l'algorithme *Sliding Frank Wolfe* pour la localisation de sources sans grille, et la conception de méthodes efficaces pour des problèmes moins classiques, comme un algorithme glouton pour la localisation de sources corrélées, et l'application du maximum de vraisemblance à l'utilisation de réseaux asynchrones. Toutes (ou presque) les méthodes proposées sont validées sur des données expérimentales.

La deuxième partie du document présente brièvement les résultats des quatre doctorants que j'ai co-encadrés pendant cette période. On y trouvera des sujets divers et variés tels que l'optimisation de séquences d'échantillonnage temporel pour des réseaux de capteurs commutés, une variante du gradient boosting proposant une explication de résultats de régression ou de classification, l'application du transport optimal à l'identification d'émetteurs RADAR, pour enfin retomber sur nos pieds avec les travaux en cours sur la séparation de sources de bruits de turbomachines à l'aide de réseaux de microphones.

Table des matières

1	Curriculum vitae	7
I	Contributions à la localisation de sources acoustiques	15
2	Introduction	17
2.1	Modélisation des sources acoustiques	18
2.2	Un exemple de données acoustiques	19
3	Beamforming et déconvolution	21
3.1	Une analyse de la formation de voie	21
3.2	Analyse théorique de l'algorithme DAMAS	26
3.3	Conclusion	28
4	Localisation de sources acoustiques sans grille	31
4.1	Algorithme	31
4.2	Modèle conditionnel	32
4.3	Modèle inconditionnel	34
4.4	Conclusion	36
5	Deux problèmes moins classiques	39
5.1	Localisation de sources corrélées	39
5.2	Utilisation de réseaux asynchrones	41
5.3	Conclusion	47
II	Encadrements de thèses	51
6	Introduction	53
7	Pierre Avital	55
7.1	Séquences d'échantillonnage pour réseaux commutés	55
7.2	Détection de passager par UWB	57

8	Manon Mottier	61
8.1	Une introduction rapide au transport optimal	61
8.2	Désentrelacement d'impulsions RADAR	62
8.3	Identification d'émetteurs RADAR	64
9	Emilien Boizard	67
9.1	<i>Gradient Boosting</i>	67
9.2	Le cas de la régression	71
9.3	Le cas de la classification	71
10	Sarah Roual	75
10.1	Décomposition de matrices de covariances	77
10.2	Perspectives de la thèse	78
III	Perspectives	81
11	Perspectives acoustiques	83
11.1	Sources directives	83
11.2	Sources corrélées	84
11.3	Sources étendues	84
11.4	Réseaux asynchrones	85
11.5	Diffusion des méthodes et jeux de données de référence	85
11.6	Application à des cas réels	85
11.7	Et l'apprentissage ?	85
12	Chaire Forvia	87
12.1	Fusion de données caméra-RADAR	87
12.2	Autocalibration de réseaux de caméras	88

Introduction

Ce document présente une partie importante de mon travail de recherche au L2S depuis mon recrutement en tant que maître de conférence à CentraleSupélec.

Dans une première partie, mes activités de recherche en localisation de sources acoustiques sont résumées. Ce domaine de recherche est le sillon que je creuse depuis ma thèse, avec la volonté toujours renouvelée de proposer des méthodes justifiées théoriquement, numériquement efficaces, et validées sur des données réelles. Les résultats de six articles dont je suis premier (ou seul) auteur sont présentés, dans un ordre plus logique que chronologique. Les sujets abordés sont des études théoriques de méthodes populaires en imagerie acoustique, les méthodes sans grilles pour la localisation de sources, et des problèmes moins classiques comme la localisation de sources corrélées ou l'utilisation de réseaux asynchrones.

Dans une deuxième partie, les travaux de thèses que j'ai co-encadrés, ou co-encadre encore, sont brièvement résumés. Ces travaux ont été l'occasion de sortir de ma zone de confort de l'acoustique, et d'aborder des méthodes et domaines auxquels je n'aurai pas été confronté sinon, comme l'intelligence électronique, le gradient boosting, le transport optimal, etc.

La présentation de ces travaux est bien entendu précédée par un CV et suivie par quelques perspectives.

J'ai fait le choix de ne pas parler de l'intégrité de mes travaux depuis la thèse, en particulier ceux dont je ne suis pas premier auteur, qui ne sont pas le résultat de l'encadrement d'un étudiant, et des "anciens" travaux sur la conception de réseaux de microphones, très corrélés à ma thèse.

Les articles dont les résultats sont discutés dans ce document sont disponibles sur ma [page web](#) ou en suivant les liens au début des sections.

Chapitre 1

Curriculum vitae

Expérience professionnelle

- Maître de conférence (contractuel CDI), Supélec puis CentraleSupélec, Gif-sur-Yvette, France, depuis 11/2014
- Postdoc, Acoustics Research Institute, Vienne, Autriche, 09/2012-10/2014
- Doctorant, Institut Langevin, Paris, France, 09/2009-08/2012
- Moniteur à l'UFR de mathématiques de l'Université Pierre et Marie Curie, 2009-2012

Diplômes

- Ingénieur de l'École Polytechnique, 2009
- Ingénieur Télécom Paris, 2009
- M2 ATIAM (Acoustique, traitement du signal et informatique appliqués à la musique), IRCAM et Université Pierre et Marie Curie, 2009
- Doctorat Université Pierre et Marie Curie, 2012

Responsabilités collectives locales

- Responsable de l'équipe Groupe Problèmes Inverses (2020-...) (11 permanents, 24 kE par an)
- Co-responsable du séminaire du pôle signal et statistique du L2S (2016-2019).
- Membre du conseil de laboratoire du L2S (2018-2019)
- Membre du copil Hub IA¹ CentraleSupélec (2021-...)

Responsabilités collectives extérieures

Reviewer pour (entre autres)

- IEEE Transactions on Audio Speech and Language Processing
- IEEE Transactions on Signal Processing
- Signal Processing
- Mechanical Systems and Signal Processing
- Journal of the Acoustical Society of America
- Journal of Sound and Vibration
- Applied Acoustics
- Forum of Mathematics, Sigma

Responsable et chairman de la session structurée "Compressive sensing and sparse signal reconstruction" à ICSV26 et ICSV27

Expertises ANR (2019, 2021) et ANRT (2022)

1. Le Hub IA, dirigé par Frédéric Pascal, a pour mission de coordonner les activités en intelligence artificielle de CentraleSupélec, pour l'enseignement tant que pour la recherche.

Enseignement

Charge de 192h eq. TD dans le cadre de mon poste à CentraleSupélec depuis 2015.

Traitement du signal audio Cet électif de deuxième année du cursus ingénieur consiste en une semaine (jouée deux fois dans l'année) durant laquelle les étudiants travaillent sur des sujets de traitement de signal audio (estimation de réponse impulsionnelle, séparation de sources, localisation de sources). Après des apports théoriques, les étudiants codent et testent les méthodes sur des données réelles qu'il produisent eux-mêmes, puis choisissent un sujet d'approfondissement sur lequel ils sont évalués.

J'ai monté et j'assure cet enseignement avec José Picheral, assistés cette année par Nathan Itare puis Sarah Roual. Nous utilisons pour ce cours le même matériel utilisé pour les résultats expérimentaux présentés dans ce document. Ce matériel est également sollicité lors de la présentation des activités de recherche de l'école à la rentrée des étudiants de première année.

Pôle projet data science Les pôles projets de CentraleSupélec coordonnent les projets étudiants de première et deuxième année, chacun dans une discipline, pour environ 80 étudiants. Je suis co-responsable avec Emmanuel Vazquez du pôle data science (statistiques, apprentissage, traitement du signal et des images, etc.), et encadre également quelques projets.

Compression et débruitage des signaux Cours électif de deuxième année que j'ai monté avec Emmanuel Vazquez. J'en suis le responsable et assure environ 75% des cours et TD/TP, sur 33h.

Traitement du signal Cours de première année en promotion complète (resp. Charles Soussen). Je suis responsable d'un groupe de cours magistral (10.5h), et deux groupes de TD ($2 \times 9h$). J'ai contribué à deux chapitres (sur huit) du polycopié (bases mathématiques et échantillonnage) et produit les notebooks python pour les TP. J'ai aussi produit des figures dynamiques que j'utilise en cours (https://gilleschardon.fr/signal/dsp_plots/index_fr.html)

Convergence, intégration, probabilité Cours d'analyse et probabilité de première année, en promotion complète (resp. Alexandre Richard). Un groupe de TD (15h) d'étudiants de filières (PT (comme moi), TSI, universitaires, etc.) moins intensives en mathématiques que la majorité des étudiants. Ces étudiants sont également accompagnés par des *teaching assistants* (des étudiants de deuxième année), que j'encadre.

J'ai également quelques interventions en dehors du cursus ingénieur :

Formation continue Dans une formation de traitement du signal (resp. Elisabeth Lahalle), j'interviens sur la transformée de Fourier (3h) et le filtrage de Kalman (1.5h), en moyenne deux fois par an.

Séminaire master 2 ATSI Intervention de 3 heures que je partage avec José Picheral sur nos thématiques de recherche pour les étudiants ATSI (Automatique et Traitement du Signal et des Images).

École d'été de Peyresq Cours de 2 heures pendant l'école d'été "Méthodes avancées pour les nouveaux défis en traitement d'antenne et radar", sur le thème "Méthodes parcimonieuses pour la localisation de sources complexes et/ou en environnement réverbérant".

Contrats

- CIFRE Valeo (Pierre Avital), avec José Picheral (50%), 2018-2021
- CIFRE Atos (Manon Mottier), avec Frédéric Pascal (50%), 2019-2022

- CIFRE Meilleursagents.com (Emilien Boizard), avec Frédéric Pascal (50%), 2020-2023
- CIFRE Safran (Sarah Roual), avec Charles Soussen (50%), 2023-2026
- Chaire Forvia, porteur de la chaire (3 thèses, 1 postdoc), 2023-2027

Encadrement

Thèse Pierre Avital

- Optimisation de la commutation d'antennes et détection de passagers par SVM, dans un contexte de contrôle d'accès pour véhicules
- Soutenance 30/06/2021
- Co-encadrement (50%), directeur de thèse : José Picheral
- poste actuel : ingénieur ZettaScale
- Contrat CIFRE Valéo
- 1 journal international (Signal Processing)

Thèse Manon Mottier

- Intelligence artificielle pour le RADAR passif
- Soutenance 28/06/2024
- Co-encadrement (50%), directeur de thèse : Frédéric Pascal
- poste actuel : ingénieur CS Group
- Contrat CIFRE Atos
- 1 journal international (IEEE Trans. AES), 2 conférences internationales (IEEE RADAR Conference 2021, Eusipco 2022), 1 conférence nationale (GRETSI 2022)

Thèse Émilien Boizard

- Méthodes d'estimations de prix immobiliers à partir de données manquantes et hétérogènes
- Depuis 1/4/2020
- Co-encadrement (50%), directeur de thèse : Frédéric Pascal
- poste actuel : ingénieur Meilleursagents.com (en parallèle de sa thèse)
- Contrat CIFRE Meilleursagents.com
- 1 conférence nationale acceptée (EUSIPCO 2024), 1 conférence nationale (GRETSI 2023)

Thèse Sarah Roual

- Séparation de sources informée pour le bruit large bande de turbomachines
- Depuis 1/3/2023
- Co-encadrement (50%), directeur de thèse : Charles Soussen
- Contrat CIFRE Safran
- 1 conférence internationale (Forum Acusticum 2023), 1 conférence nationale (GRETSI 2023)

Stage M2 Étienne Monier

- ENS Paris-Saclay - master SAR
- Bornes de Cramér-Rao pour la localisation de sources à rayonnement anisotropes
- avril à juillet 2016
- 1 conférence internationale (ICASSP 2017)

Stage M2 Sarah Roual

- Ecole Supérieure d'Ingénieurs Léonard de Vinci et CentraleSupélec
- Co-encadrement avec Claude Sensiau (Safran)
- Séparation de sources pour l'analyse du bruit des moteurs d'avion
- avril à octobre 2022

Stage L3 Aurélien Mante

- ENSTA
- Localisation de sources acoustiques corrélées
- juin-juillet 2021
- ce stage avait été l'occasion de se familiariser avec le matériel acoustique

Jurys et comités de suivi de thèse

Examineur dans les jurys de thèse de :

- Michal Ruzek (LVA, INSA Lyon), Identification expérimentale de l'équation du mouvement de milieux vibroacoustiques , décembre 2013
- François Deloche (Centre d'Analyse et de Mathématiques Sociales, EHESS), Short time-scale efficient coding of speech, novembre 2019
- Zijian Niu (LVA, INSA Lyon), A gridless method for three-dimensional acoustic imaging based on unconstrained sonars, janvier 2024

Membre des comités de suivi de thèse de :

- Mohammed Hafsati (Inria Rennes, b<>com), Higher Order Ambisonic sound scenes decomposition for six degrees of freedom navigation, 2017-2020
- Dora Novak (L2S), Optimisation de trajectoire de drone(s) pour des missions de cartographie, depuis novembre 2021
- Pierre Houdouin (L2S), Apprentissage par renforcement appliqué à la certification du bon fonctionnement d'un système dynamique, depuis septembre 2022

Collaborations

Hors L2S et industriels

- Wolfgang Kreuzer (ARI, Vienne, Autriche) et Markus Noisternig (IRCAM, Paris, France) pour la conception de réseaux de microphones (publication dans IEEE Journal of Selected Topics in Signal Processing, 2015)
- Shoichi Koyama (National Institute of Informatics, Tokyo, Japan), conception conjointe de réseaux de microphones et hauts-parleurs pour la synthèse de champ sonore (publication IEEE/ACM Transactions on Audio, Speech and Language Processing, 2020)
- Cyril Dahon (Geeps, Paris, France), parcimonie structurée pour l'imagerie RADAR, (publication dans Progress In Electromagnetics Research B, 2022)
- Peter Balasz (ARI, Vienne, Autriche), représentation d'opérateurs dans des *fusion frames* (publication dans Applied and Computational Harmonic Analysis, 2023)

Publications

- 21 articles de revues internationales
- 26 conférences internationales
- 14 conférences nationales

Les stagiaires et doctorants dont j'ai été ou suis (co-)encadrant sont soulignés.

Les étudiants de CentraleSupélec que j'ai encadrés en projet sont soulignés en tiretés.

Revues internationales à comité de lecture

1. M. Mottier, G. Chardon, F. Pascal, *Deinterleaving RADAR emitters with optimal transport distances*, IEEE Transactions on Aerospace and Electronic Systems, 2024, doi :10.1109/TAES.2024.3367287,
2. G. Chardon, *Gridless covariance matrix fitting methods for three dimensional acoustical source localization*, Journal of Sound and Vibration, 2023, doi :10.1016/j.jsv.2023.117608,

3. G. Chardon, *Maximum likelihood estimators and Cramér-Rao bounds for the localization of an acoustical source with asynchronous arrays*, Journal of Sound and Vibration, 2023, doi :10.1016/j.jsv.2023.117906,
4. P. Balazs, M. Shamsabadi, A. A. Arefijamaal, G. Chardon, *Representation of Operators using Fusion Frames*, Applied and Computational Harmonic Analysis, 2023, doi :10.1016/j.acha.2023.101596,
5. C. Dahon, A. Cano, M. Fall, G. Marrelec, G. Chardon, *Numerical Full Inversion of Two Dielectric Cylinders Upon a Metallic Plane : a First Step Toward Forest Parameters Retrieval from VHF to P-Band Radar Data*, Progress In Electromagnetics Research B, 2022, doi :10.2528/PIERB22020903,
6. G. Chardon, *Theoretical analysis of beamforming steering vector formulations for acoustic source localization*, Journal of Sound and Vibration, 2021
doi :10.1016/j.jsv.2021.116544
7. G. Chardon, U. Boureau, *Gridless three-dimensional compressive beamforming with the Sliding Frank-Wolfe algorithm*, Journal of the Acoustical Society of America, 2021
doi :10.1121/10.0006790
8. G. Chardon, J. Picheral, F. Ollivier, *Theoretical analysis of the DAMAS algorithm and efficient implementation of the Covariance Matrix Fitting method for large-scale problems*, Journal of Sound and Vibration, 2021
doi :10.1016/j.jsv.2021.116208
9. P. Avital, G. Chardon, J. Picheral, *Design of switching sequences for sine parameters estimation on switched antenna arrays*, Signal Processing, 2021
doi :10.1016/j.sigpro.2021.108244
10. S. Koyama, G. Chardon, L. Daudet, *Optimizing Source and Sensor Placement for Sound Field Control : An Overview*, IEEE Transactions on Audio, Speech and Language Processing, 2020
doi :10.1109/TASLP.2020.2964958
11. G. Chardon, F. Ollivier, J. Picheral, *Localization of sparse and coherent sources by Orthogonal Least Squares*, Journal of the Acoustical Society of America, 2019
doi :10.1121/1.5138931
12. A. Bouchain, J. Picheral, E. Lahalle, G. Chardon, A. Vercoutter, A. Talon, *Blade vibration study by spectral analysis of tip-timing signals with OMP algorithm*, Mechanical Systems and Signal Processing, 2019
doi :10.1016/j.ymsp.2019.04.063,
13. G. Chardon, W. Kreuzer, M. Noisternig, *Design of Spatial Microphone Arrays for Sound Field Interpolation*, IEEE Journal of Selected Topics in Signal Processing, 2015
doi :10.1109/JSTSP.2015.2412097
14. G. Chardon, Th. Nowakowski, J. de Rosny, L. Daudet, *A blind dereverberation method for narrow-band source localization*, IEEE Journal of Selected Topics in Signal Processing, 2015
doi :10.1109/JSTSP.2015.2422673
15. R. Mignot, G. Chardon, L. Daudet, *Low Frequency Interpolation of Room Impulse Responses using Compressed Sensing*, IEEE Transactions on Audio, Speech and Language Processing, 2014,
doi :10.1109/TASLP.2013.2286922
16. A. Leblanc, G. Chardon, *Acoustic eigenanalysis of 2D open cavity with Vekua approximations and the Method of Particular Solutions*, Engineering Analysis with Boundary Elements, 2014
doi :10.1016/j.enganabound.2014.03.006
17. G. Chardon, A. Cohen, L. Daudet, *Sampling and reconstruction of solutions to the Helmholtz equation*, Sampling Theory in Signal and Image Processing, 2014
18. A. Liutkus, D. Martina, S. Popoff, G. Chardon, O. Katz, G. Lerosey, S. Gigan, L. Daudet, I. Carron, *Imaging With Nature : Compressive Imaging Using a Multiply Scattering Medium*, Scientific Reports, 2014
doi :10.1038/srep05552,

19. G. Chardon, L. Daudet, *Low-complexity computation of plate eigenmodes with Vekua approximations and the Method of Particular Solutions*, Computational Mechanics, 2013
doi :10.1007/s00466-013-0859-2
20. G. Chardon, L. Daudet, A. Peillot, F. Ollivier, N. Bertin, R. Gribonval, *Near-field acoustic holography using sparse regularization and compressive sampling principles*, J. Acoust. Soc. Am., 2012
doi :10.1121/1.4740476
21. G. Chardon, A. Leblanc, L. Daudet, *Plate impulse response spatial interpolation with sub-Nyquist sampling*, Journal of Sound and Vibration, 2011
doi :10.1016/j.jsv.2011.07.003

Communications dans des congrès internationaux

1. E. Boizard, G. Chardon, F. Pascal, *Enhancing the Explainability of Gradient Boosting Classification through Comparable Samples Selection*, EUSIPCO 2024
2. S. Roual, C. Sensiau, G. Chardon, *Informed Source Separation for Turbofan Broadband Noise Using Non-Negative Matrix Factorization*, Forum Acusticum 2023
3. M. Mottier, G. Chardon, F. Pascal, *RADAR Emitter Classification with Optimal Transport Distances*, EUSIPCO 2022
4. G. Chardon, J. Picheral, F. Ollivier, *Some results on the convergence of the DAMAS algorithm and application to large scale problems*, ICSV27, 2021
5. G. Chardon, *Gridfree source localization using the Sliding Frank-Wolfe algorithm*, ICSV27, 2021
6. M. Mottier, G. Chardon, F. Pascal, *Deinterleaving and Clustering Unknown Radar Pulses*, RadarConf 2021
7. G. Chardon, S. Koyama, L. Daudet, *Numerical evaluation of source and sensor placement methods for sound field control*, Forum Acusticum 2020
8. G. Chardon, J. Picheral, F. Ollivier, *Correlated source localization with Orthogonal Least Squares*, Forum Acusticum 2020
9. W. Xiong, G. Chardon, J. Picheral, S. Marcos, F. Ollivier, *Correlated sources localization with sparse and low-rank regularization*, ICSV26, Montréal
10. S. Koyama, G. Chardon, L. Daudet, *Joint source and sensor placement for sound field control based on empirical interpolation method*, International Conference on Acoustics, Speech and Signal Processing (ICASSP) 2018, Calgary, Canada, 2018,
11. E. Monier, G. Chardon, *Cramér-Rao bounds for the localization of anisotropic sources*, ICASSP 2017, New Orleans, USA, 2017, doi :10.1109/ICASSP.2017.7952763,
12. G. Chardon, *Design of variable densities for least-squares approximations*, SampTA, Tallinn, Estonia, 2017, doi :10.1109/SAMPSTA.2017.8024445,
13. W. Xiong, J. Picheral, G. Chardon, S. Marcos, *Sparsity-based localization of spatially coherent distributed sources*, International Conference on Acoustics, Speech and Signal Processing (ICASSP) 2016, Shanghai, China, 2016,
14. B. Elie, G. Chardon, *Robust tonal and noise separation in presence of colored noise, and application to voiced fricatives*, International Congress on Acoustics ICA 2016, Buenos Aires, Argentina, 2016,
15. G. Chardon, T. Necciari, P. Balazs, *Perceptual Matching Pursuit with Gabor dictionaries and time-frequency masking*, International Conference on Acoustics, Speech and Signal Processing (ICASSP) 2014, Florence, Italy, 2014, doi :10.1109/ICASSP.2014.6854171,
16. G. Chardon, W. Kreuzer, M. Noisternig, *Design of a robust open spherical microphone array*, International Conference on Acoustics, Speech and Signal Processing (ICASSP) 2014, Florence, Italy, 2014, doi :10.1109/ICASSP.2014.6854919 ,

17. G. Chardon, *A block-sparse MUSIC algorithm for the localization and the identification of directive sources*, International Conference on Acoustics, Speech and Signal Processing (ICASSP) 2014, Florence, Italy, 2014, doi :10.1109/ICASSP.2014.6854343,
18. S. Gigan, S. Popoff, A. Liutkus, D. Martina, O. Katz, G. Chardon, R. Carminati, G. Lerosey, M. Fink, C. Boccara, I. Carron, L. Daudet, *Image transmission through a scattering medium : Inverse problem and sparsity-based imaging*, 13th Workshop on Information Optics, WIO 2014, Lausanne, Switzerland, 2014, doi :10.1109/WIO.2014.6933276,
19. G. Chardon, A. Cohen, L. Daudet, *Reconstruction of solutions to the Helmholtz equation from punctual measurements*, SampTA, Bremen, Germany, 2013,
20. R. Gribonval, G. Chardon, L. Daudet, *Blind calibration for compressed sensing by convex optimization*, International Conference on Acoustics, Speech and Signal Processing (ICASSP) 2012, Kyoto, Japan, 2012, doi :10.1109/ICASSP.2012.6288477,
21. G. Chardon, L. Daudet, *Narrowband source localization in an unknown reverberant environment using wavefield sparse decomposition*, International Conference on Acoustics, Speech and Signal Processing (ICASSP) 2012, Kyoto, Japan, 2012, doi :10.1109/ICASSP.2012.6287804,
22. A. Peillot, F. Ollivier, G. Chardon, L. Daudet, *Acoustic sources joint localization and characterization using compressive sampling*, Acoustics 2012, Nantes, France, 2012,
23. G. Chardon, L. Daudet, *Source localisation in an unknown reverberant environment using compressive sampling in the frequency domain*, Acoustics 2012, Nantes, France, 2012,
24. A. Peillot, F. Ollivier, G. Chardon, L. Daudet, *Localization and identification of sound sources using "compressive sampling" techniques*, 18th International Congress on Sound and Vibration, Rio de Janeiro, Brasil, 2011,
25. G. Chardon, L. Daudet, *Computation of plate eigenmodes with the plane wave decomposition method*, WAVES 2011, Vancouver, Canada, 2011,
26. R. Mignot, G. Chardon, L. Daudet, *Compressively sampling the plenacoustic function*, SPIE Conference Wavelets and Sparsity XIV, San Diego, USA, 2011, doi :10.1117/12.892761,
27. G. Chardon, L. Daudet, *Optimal subsampling of multichannel damped sinusoids*, Sensor Array and Multichannel Signal Processing Workshop (SAM), 2010 IEEE, Jerusalem, Israel, 2010, doi :10.1109/SAM.2010.5606750,

Communications dans des congrès nationaux

1. S. Roual, G. Chardon, C. Sensiau, Application de la factorisation en matrices non-négatives à la séparation de sources acoustiques dans le bruit de turbomachines, GRETSI 2023
2. E. Boizard, G. Chardon, F. Pascal, Une méthode de Gradient Boosting d'Arbre de Décision explicative basée sur l'algorithme de Frank-Wolfe, GRETSI 2023
3. N. Itare, G. Chardon, J. Picheral, Méthode sans grille pour la localisation de sources à partir de mesures asynchrones, GRETSI 2023
4. M. Mottier, G. Chardon, F. Pascal, Désentrelacement et classification de signaux RADAR basés sur des distances de transport optimal, GRETSI 2022
5. G. Chardon, F. Ollivier, J. Picheral, S. Marcos, Approches parcimonieuses pour l'estimation de la matrice de covariance spatiale et la localisation de sources acoustiques, GRETSI 2019
6. G. Chardon, M. Delattre, J. Manderscheid, M. Narozny, Autocalibration bayésienne de phase pour le suivi de cible, GRETSI 2019
7. G. Chardon et B. Elie, Séparation périodique/apériodique robuste de signaux de parole. Congrès Français d'Acoustique 2018
8. G. Chardon, Localisation et identification de sources complexes, Congrès Français d'Acoustique 2016

9. G. Chardon, W. Kreuzer et M. Noisternig, Optimisation de réseaux de microphones pour la capture de champs acoustiques, Congrès Français d'Acoustique 2016
10. J. Picheral, G. Chardon, W. Xiong et S. Marcos, Méthode parcimonieuse faible rang pour l'imagerie aéro-acoustique, Congrès Français d'Acoustique 2016
11. T. Nowakowski, L. Daudet, J. de Rosny, G. Chardon, Localisation de sources en milieu réverbérant par décomposition parcimonieuse du champ acoustique sur un modèle hybride pression-vitesse, GRETSI 2013
12. G. Chardon, N. Bertin, L. Daudet, Multiplexage spatial aléatoire pour l'échantillonnage compressif - application à l'holographie acoustique, GRETSI 2011
13. A. Peillot, G. Chardon, F. Ollivier, L. Daudet, Le 'Compressed sensing' pour l'holographie acoustique de champ proche - II : Mise en oeuvre expérimentale, Congrès Français d'Acoustique, 2010
14. G. Chardon, A. Peillot, L. Daudet, F. Ollivier, Le 'Compressed sensing' pour l'holographie acoustique de champ proche - I : Aspects algorithmiques et simulations, Congrès Français d'Acoustique, 2010

Première partie

**Contributions à la localisation de
sources acoustiques**

Chapitre 2

Introduction

La localisation de sources, qu'elles soient acoustiques, vibratoires, électromagnétiques, etc., a de nombreuses applications. Elle fait aussi lieu d'un état de l'art conséquent, tant sur les aspects théoriques qu'applicatifs [1, 2].

Mes contributions dans ce domaine se situent dans un contexte de localisation de sources acoustiques [3]. Par rapport à d'autres modalités physiques, l'acoustique présente la particularité que le champ de pression est scalaire, et ne nécessite donc pas de prise en compte de la polarisation, comme en électromagnétisme ou en vibration. D'autre part, il est fréquent que les sources à localiser soient en champ proche, ou que le réseau de capteurs entoure les sources. Ceci empêche l'utilisation d'approximation des sources comme des fronts d'ondes plans, et nécessite parfois de prendre en compte le rayonnement anisotrope des sources.

Mes travaux ont été guidés par deux objectifs :

- le développement et l'utilisation de méthodes basées sur des analyses théoriques. Ceci peut passer par l'analyse théorique de méthodes déjà existantes, l'utilisation d'algorithmes dont le comportement est garanti, ou le développement de méthodes originales.
- la rapidité d'exécution, les problèmes acoustiques pouvant rapidement atteindre des tailles conséquentes (nombre de microphones, discrétisation de l'espace 3D, traitement sur un grand nombre de fréquences, estimation de covariances, etc.), alors que les problèmes ne présentent pas toujours de structure exploitable pour l'accélération des calculs (en général, l'imagerie acoustique n'est pas de la déconvolution).

Le chapitre 3 présente des contributions théoriques sur la formation de voies (*beamforming*) et l'algorithme DAMAS (Deconvolution Approach for the Mapping of Acoustical Source), des méthodes populaires dans la communauté acousticienne. Certains des aspects de ces analyses paraîtront évidents, voire triviaux aux collègues aguerris au traitement statistique du signal et à l'optimisation, mais elles ont permis de répondre à des questions d'implémentation de ces méthodes qui n'avaient pas encore été élucidées par la communauté.

La localisation de sources sans grilles, basée sur l'algorithme de Sliding Frank-Wolfe, est traitée dans le chapitre 4, dans le cas de sources déterministes et aléatoires. Ces méthodes permettent de localiser des sources sans besoin de définir une grille de sources possibles, comme pour DAMAS ou LASSO, qui limite la précision de localisation. Les méthodes obtenues après quelques adaptations de l'algorithme sont testées sur des données réelles.

Enfin, deux problèmes de localisation de sources dans des conditions moins classiques sont discutés dans le chapitre 5. Un algorithme pour la localisation de sources corrélées est proposé, qui a la particularité d'être efficace en temps de calcul, sa complexité étant linéaire par rapport à la taille de la discrétisation de l'espace. L'utilisation de mesures asynchrones est également étudiée. Ce type de mesures consiste à répéter l'expérience en déplaçant le réseau de microphones, avec l'espoir de s'approcher des performances d'un grand réseau. Une analyse du cas simple d'une source unique permet ici de donner des préconisations sur l'exploitation de telles mesures.

Pour rendre ces travaux plus convaincants, mes collègues et moi avons tenu à les valider expérimentalement. Je remercie ici vivement François Ollivier (et son laboratoire, l'Institut Jean le Rond d'Alembert) avec qui nous avons effectué les mesures acoustiques exploitées dans plusieurs articles.

Le code permettant de reproduire les résultats de ces articles est disponible sur ma [page github](#).

2.1 Modélisation des sources acoustiques

Avant d'exposer ces contributions, il est nécessaire de faire quelques rappels sur la modélisation des sources acoustiques. Nous supposons que le modèle de propagation des ondes entre la source et le réseau de microphones (i.e., la fonction de Green) est connu, et que nous sommes en régime harmonique. Ce modèle est représenté par un vecteur $\mathbf{g}(\mathbf{x})$, où \mathbf{x} est la position de la source, et dont les coefficients sont les amplitudes complexes du champ mesuré par chaque microphone pour une source d'amplitude 1. Dans le cas idéal d'une source monopolaire en champ libre (ou dans une chambre anéchoïque), les coefficients de $\mathbf{g}(\mathbf{x})$ sont

$$g_i(\mathbf{x}) = \frac{e^{-ik\|\mathbf{x}-\mathbf{z}_i\|_2}}{\|\mathbf{x}-\mathbf{z}_i\|_2}, \quad (2.1)$$

où \mathbf{z}_i est la position du i -ième microphone. Cependant, les méthodes présentées ici ne nécessitent pas d'hypothèses sur la forme précise de \mathbf{g} .

Les mesures collectées par le réseau de microphones peuvent être modélisées de deux manières [4], rappelées ci-dessous.

Modèle conditionnel Dans ce modèle, l'amplitude et la phase de la source sont des paramètres déterministes. La source est paramétrée par cette amplitude A et cette phase ϕ , et sa position \mathbf{x} . En supposant les mesures affectées d'un bruit blanc gaussien, une mesure \mathbf{m} se modélise par

$$\mathbf{m} \sim \mathcal{CN}(Ae^{i\phi}\mathbf{g}(\mathbf{x}), \sigma^2\mathbf{I}). \quad (2.2)$$

où \mathcal{CN} désigne la distribution normale complexe circulaire [5], σ^2 est la puissance du bruit, et \mathbf{I} la matrice identité.

Dans le cas où J mesures \mathbf{m}_j sont obtenues à des temps différents, on pourra les considérer indépendantes, et on paramétrisera la source par les amplitudes A_1, \dots, A_J , les phases ϕ_1, \dots, ϕ_J , et sa position \mathbf{x} supposée invariante.

Dans ce modèle, les données utilisées pour l'estimation sont directement les amplitudes complexes des signaux reçus par les microphones après analyse de Fourier.

Ce modèle est plutôt agréable à utiliser, la présence de bruit blanc additif gaussien se traduisant, dans des problèmes de maximum de vraisemblance ou de maximum a posteriori, par une norme ℓ_2 , lisse et strictement convexe. Cependant, quand le nombre de mesures augmente, le nombre de paramètres à estimer augmente d'autant, avec les problèmes de complexité computationnelle et de performances asymptotiques associés [4].

Modèle inconditionnel Dans le cas où plusieurs mesures sont disponibles, une modélisation alternative consiste à supposer que les amplitudes complexes $A_j e^{i\phi_j}$ sont des variables aléatoires indépendantes gaussiennes complexes centrées de variance p , la puissance de la source. Dans ce cas, une mesure est modélisée par

$$\mathbf{m} \sim \mathcal{CN}(0, p\mathbf{g}(\mathbf{x})\mathbf{g}(\mathbf{x})^H + \sigma^2\mathbf{I}). \quad (2.3)$$

Ce dernier modèle à l'avantage que quand S augmente, le nombre de paramètres reste fixe, ce qui aboutit à de meilleurs propriétés (par ex., l'efficacité asymptotique du maximum de vraisemblance [6]).

De plus, dans ce modèle, la matrice de covariance estimée des mesures, à partir de plusieurs échantillons temporels des amplitudes complexes des signaux

$$\hat{\Sigma} = \frac{1}{J} \sum_{j=1}^J \mathbf{m}_j \mathbf{m}_j^H \quad (2.4)$$

est une statistique exhaustive pour l'estimation des paramètres des sources [7].

En pratique, ce résultat signifie que toute l'information disponible dans les données est résumée dans cette matrice de covariance empirique. Cette propriété est particulièrement intéressante, puisque la prolongation de la mesure pour atteindre le régime asymptotique du grand nombre d'échantillons ne fait pas exploser la taille des données à traiter.




Figure 2.1 – Géométrie du réseau de microphone. Certains résultats n'utiliseront que les microphones indiqués par les points foncés.

2.2 Un exemple de données acoustiques

Il est bien entendu très intéressant d'analyser la convergence d'algorithmes, de dériver des estimateurs par maximum de vraisemblance, de calculer des bornes de Cramér-Rao, etc., mais la validation finale des méthodes ne peut se faire qu'expérimentalement. Toutes les méthodes présentées dans les chapitres suivants (sauf la formation de voie qui est tout de même bien connue) sont validées sur des données réelles. Ces données, pour la plupart, sont le fruit d'une manipulation que j'ai effectuée avec François Ollivier, avec le matériel de son laboratoire, l'Institut Jean le Rond d'Alembert (Sorbonne Université).

Ces données avaient été produites pour valider la méthode de localisation de sources corrélées présentée dans le chapitre 5. Nous avons utilisé quatre sources émettant un bruit blanc, avec divers scénarios, tels que sources indépendantes, actives une à une, corrélées par paires, etc. Nous avons également utilisé une table pour servir de réflecteur et créer des sources images.

Le réseau de microphones est constitué de 128 éléments, dont la géométrie est donnée figure 2.1. La figure 2.2 présente la géométrie générale du dispositif de mesure, et une photographie des sources est donnée figure 2.3.




Figure 2.2 – Dispositif expérimental de localisation de sources. Le réflecteur n'est utilisé que pour le cas des sources image du chapitre 5.




Figure 2.3 – Photographie des quatres sources dans la chambre anéchoïque de Sorbonne Université.

Chapitre 3

Beamforming et déconvolution

Ce chapitre traite de deux méthodes de localisation de sources très populaires en acoustique. La formation de voie tout d'abord, est d'utilisation élémentaire, puisqu'elle ne nécessite pas le réglage de paramètres, et est de complexité algorithmique réduite. Cependant, des détails d'implémentation liés au fait qu'en acoustique, les sources soient souvent à une distance du réseau de microphones du même ordre de grandeur que l'ouverture du réseau, n'avaient jusqu'à récemment pas été élucidés. Une interprétation de la formation de voie comme le maximum de vraisemblance [6] pour la localisation d'une source m'a permis de donner une formulation des vecteurs directeurs permettant d'obtenir des estimations des paramètres des sources asymptotiquement non biaisées et efficaces, dans le régime asymptotique du grand nombre d'échantillons pour le modèle inconditionnel [6], et du fort SNR pour le modèle conditionnel [8].

Les limites de la formation de voie sont connues : en présence de plusieurs sources proches, les lobes principaux correspondant aux sources fusionnent, et il est impossible de les résoudre. La présence de lobes secondaires aura également tendance à cacher des sources peu puissantes. Ces limitations peuvent être levées par une approche de "déconvolution" de la carte obtenue par formation de voie. L'algorithme DAMAS [9], très populaire dans la communauté, consiste à déconvoluer sous hypothèse de positivité (la carte recherchée est une répartition des puissances des sources), dans un sens qui n'avait pas été précisé. En collaboration avec José Picheral et François Ollivier, nous avons analysé l'algorithme DAMAS, et montré qu'il estime la distribution de sources par la résolution d'un problème de moindres carrés non négatif sur la matrice de covariance des mesures [10]. De plus, nous avons proposé un algorithme de résolution de ce problème d'optimisation combinant l'algorithme de Lawson-Hanson et une factorisation de la matrice du problème permettant une accélération du calcul de plusieurs ordres de grandeurs.

3.1 Une analyse de la formation de voie

G. Chardon, Theoretical analysis of beamforming steering vector formulations for acoustic source localization, *Journal of Sound and Vibration*, 2022

Dans sa version la plus simple (pour des sources en champ lointain), la formation de voie consiste à appliquer des déphasages aux mesures pour focaliser dans une direction donnée. C'est, en quelque sorte, une version numérique de l'utilisation d'une parabole pour focaliser un front d'onde sur un point. Le champ émis par une source venant de l'angle α est

$$p(\mathbf{x}) = Ae^{i\phi}e^{i\mathbf{k}(\alpha)\cdot\mathbf{x}} \quad (3.1)$$

où A est l'amplitude de la source, ϕ sa phase, et $\mathbf{k}(\alpha)$ le vecteur d'onde pointant depuis la direction α .

Les mesures obtenues sur un réseau de microphones de positions \mathbf{z}_n sont modélisées par la variété d'antenne $\mathbf{a}(\alpha)$ de coefficients

$$a_n(\alpha) = e^{i\mathbf{k}(\alpha)\cdot\mathbf{z}_n}. \quad (3.2)$$

Dans le modèle conditionnel, le critère de la formation de voie est obtenu en calculant le produit scalaire entre les mesures \mathbf{m} et le vecteur directeur $\mathbf{h}(\alpha) = \mathbf{a}(\alpha)/N$:

$$B_C(\alpha) = |\langle \mathbf{m}, \mathbf{h}(\alpha) \rangle|^2. \quad (3.3)$$

Dans le cas inconditionnel, le critère de la formation de voie est le suivant, avec $\hat{\Sigma}$ la matrice de covariance estimée des mesures :

$$B_U(\alpha) = \mathbf{h}(\alpha)^H \hat{\Sigma} \mathbf{h}(\alpha). \quad (3.4)$$

Dans les deux cas, en l'absence de bruit, le critère de la formation de voie est maximal à l'angle d'arrivée de la source, et sa valeur permet de retrouver l'amplitude ou la puissance de la source.

Les choses se compliquent quand la source n'est pas en champ lointain, par exemple avec le modèle de champ libre (2.1). En effet, dans ce cas, pour une position donnée, les coefficients $g_i(\mathbf{x})$ n'ont pas la même valeur absolue, et la norme $\|\mathbf{g}(\mathbf{x})\|_2$ varie en fonction de la position \mathbf{x} .

Ce modèle un peu plus compliqué a donné lieu à plusieurs définitions du vecteur directeur \mathbf{h} . Commençons par utiliser une version légèrement différente du modèle de source,

$$a_n(\mathbf{x}) = \frac{r_0}{r_n} e^{-ik(r_n - r_0)} \quad (3.5)$$

où r_n est la distance entre la source et le microphone n , et r_0 la distance entre la source et un point de référence \mathbf{x}_0 . L'amplitude ou la puissance sont ici celles du signal reçu au point de référence \mathbf{x}_0 généralement choisi au centre du réseau de microphones.

Les quatres formulations des vecteurs directeurs recensées par Sarradj [11] sont les suivantes.

Formulation I La seule prise en compte des phases des coefficients de \mathbf{a} aboutit au vecteur directeur

$$h_n^I(\mathbf{x}) = \frac{1}{N} \frac{a_n(\mathbf{x})}{|a_n(\mathbf{x})|}. \quad (3.6)$$

Ce vecteur directeur est semblable à celui du champ lointain, prenant en compte la courbure du front d'onde.

Formulation II Ici, les différences d'amplitudes sont compensées :

$$h_n^{II}(\mathbf{x}) = \frac{1}{N} \frac{a_n(\mathbf{x})}{|a_n(\mathbf{x})|^2}. \quad (3.7)$$

Formulation III Dans cette formulation, le vecteur directeur est obtenu par une normalisation par la norme carrée de la variété d'antenne.

$$\mathbf{h}^{III}(\mathbf{x}) = \frac{\mathbf{a}(\mathbf{x})}{\|\mathbf{a}(\mathbf{x})\|_2^2}. \quad (3.8)$$

Formulation IV Finalement, la formulation IV normalise par la norme :

$$\mathbf{h}^{IV}(\mathbf{x}) = \frac{1}{\sqrt{N}} \frac{\mathbf{a}(\mathbf{x})}{\|\mathbf{a}(\mathbf{x})\|_2}. \quad (3.9)$$

Ces quatre formulations se rencontrent effectivement dans la bibliographie, dont un échantillon est donné dans le tableau 3.1. Aucune préconisation claire n'était disponible dans la littérature concernant le choix de ces formulations, et ceci pour deux raisons. Il était toujours fait l'hypothèse que la même formulation devait servir à l'estimation de la position et l'amplitude (presque toujours, cf. [12] qui combine formulations I et II), et la variance des estimations en présence de bruit n'était pas prise en compte.

L'estimation de la position et l'amplitude de la source par maximum de vraisemblance permet de donner des réponses précises et finales à ce problème. On rappelle brièvement que l'estimation par maximum de vraisemblance consiste à estimer un ou plusieurs paramètres θ à partir de données \mathbf{m} suivant une loi de probabilité de densité f_θ en cherchant le paramètre $\hat{\theta}$ maximisant $f_\theta(\mathbf{m})$.

I	[13] [14] [15] [12]
II	[9] [13] [16] [17] [12]
III	[18] [19] [20] [21] [22] [23]
IV	[24] [25] [26] [27]

Table 3.1 – Un échantillonnage de la littérature de formation de voie en acoustique, classé suivant la formulation utilisée.

	$\langle \mathbf{a}(\mathbf{x}_s), \mathbf{h}(\mathbf{x}_s) \rangle$	$\ \mathbf{h}(\mathbf{x}_s)\ _2^2$
I	$\frac{1}{N} \sum_{n=1}^N \frac{r_0}{r_n}$	$\frac{1}{N}$
II	1	$\frac{1}{N^2} \sum_{n=1}^N \frac{r_n^2}{r_0^2}$
III	1	$\frac{1}{\sum_{n=1}^N r_0^2 / r_n^2}$
IV	$\sqrt{\frac{1}{N} \sum_{n=1}^N \frac{r_0^2}{r_n^2}}$	$\frac{1}{N}$

Table 3.2 – Valeurs de $\langle \mathbf{a}(\mathbf{x}_s), \mathbf{h}(\mathbf{x}_s) \rangle$ et $\|\mathbf{h}(\mathbf{x}_s)\|_2^2$ pour les quatre formulations.

3.1.1 Estimation de l'amplitude

L'étude des performances de l'estimation de l'amplitude à position connue \mathbf{x}_s est élémentaire. Pour le modèle conditionnel, l'estimateur de l'amplitude $\hat{A} = \langle \mathbf{m}, \mathbf{h} \rangle$ suit la loi

$$\hat{A} \sim \mathcal{CN} \left(A \langle \mathbf{a}(\mathbf{x}_s), \mathbf{h}(\mathbf{x}_s) \rangle, \sigma^2 \|\mathbf{h}(\mathbf{x}_s)\|_2^2 \right). \quad (3.10)$$

La lecture du tableau 3.2 montre que les formulations II et III sont non biaisées pour l'estimation de l'amplitude. Une application de l'inégalité de Cauchy-Schwartz permet de montrer que la variance de la formulation III est plus petite que pour la formulation II.

Dans le cas du modèle inconditionnel, l'espérance et la variance de l'estimation de la puissance \hat{p} sont données par

$$E(\hat{p}) = |\langle \mathbf{a}(\mathbf{x}_s), \mathbf{h}(\mathbf{x}_s) \rangle|^2 p \quad (3.11)$$

$$\text{Var}(\hat{p}) = \frac{1}{S} \left(|\langle \mathbf{a}(\mathbf{x}_s), \mathbf{h}(\mathbf{x}_s) \rangle|^2 p + \|\mathbf{h}(\mathbf{x}_s)\|_2^2 \sigma^2 \right)^2 \quad (3.12)$$

avec des conclusions similaires au cas conditionnel.

3.1.2 Estimation de la position

L'estimation de la position pour des mesures non bruitées est donnée pour la configuration de microphones et de sources de la figure 3.1, avec un réseau carré uniforme de 81 microphones. Le critère de la formation de voies est tracé sur la figure 3.2 dans la zone rectangulaire grisée, pour deux choix de point de référence \mathbf{x}_0 .

Les formulations I et IV apparaissent non biaisées, tandis que les formulations II et III sont biaisées. De plus, ce biais dépend du choix du point de référence \mathbf{x}_0 , phénomène qui n'avait pas été observé dans la littérature. Une étude plus poussée confirme ces observations, la formulation IV correspondant à l'estimateur du maximum de vraisemblance, la formulation I à un problème de maximum de vraisemblance pour un modèle mal spécifié [28], mais dont on peut montrer qu'il est non biaisé.

3.1.3 Estimation conjointe de la position et l'amplitude

Le calcul du maximum de vraisemblance pour les modèles conditionnel et inconditionnel aboutit dans les deux cas à la combinaison de la formulation IV pour l'estimation de la position, suivie de la formulation III pour estimer l'amplitude ou la puissance de la source. Toute autre combinaison de formulations est soit biaisée, soit non efficace.




Figure 3.1 – Géométrie du problème numérique. Le rectangle gris indique la région d'intérêt de la figure 3.2.




Figure 3.2 – Valeurs du critère de formation de voies pour les quatre formulations dans un plan. Pour les formulations II et III, ces valeurs sont données pour les points de référence x_0 (II et III) et x'_0 (II' et III'). La position de la source est indiquée par un cercle, la valeur maximale du critère par un point.

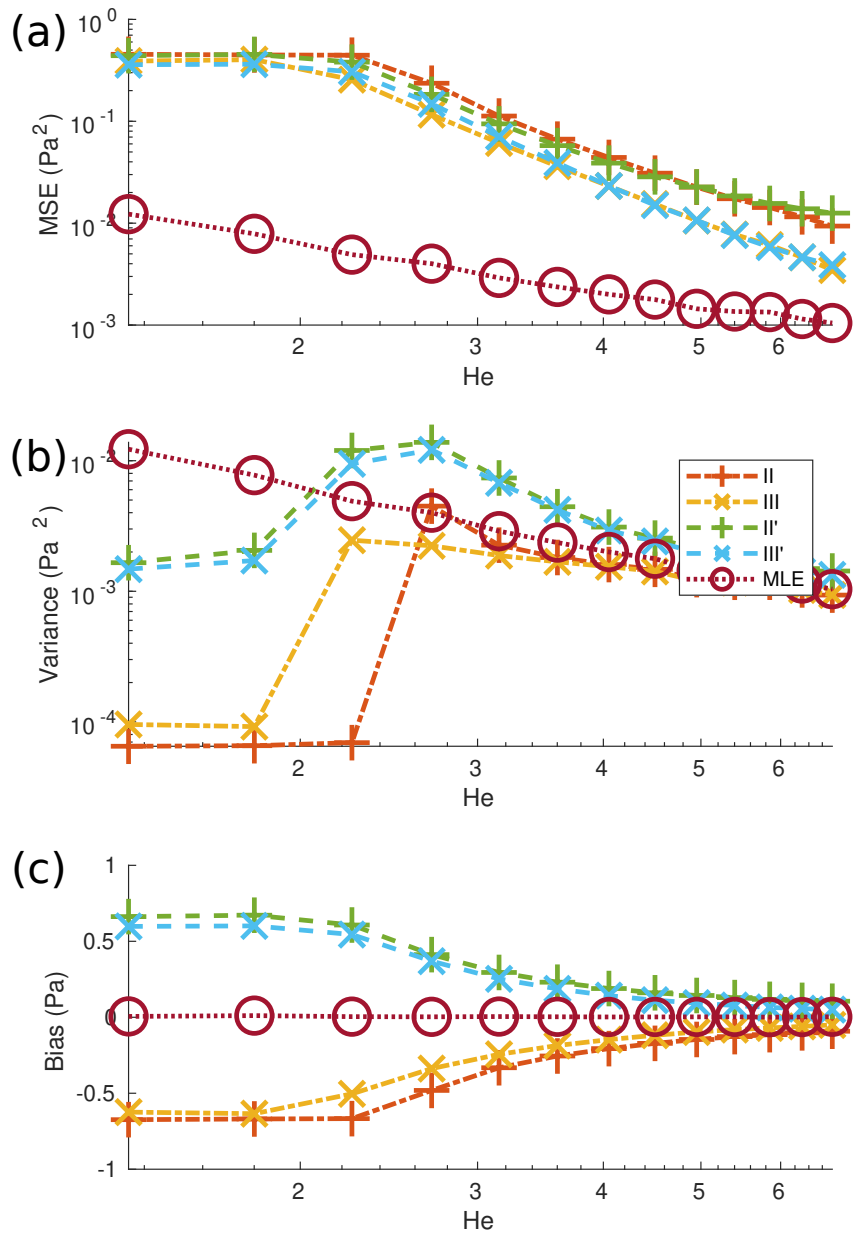


Figure 3.3 – (a) EQM, (b) variance et (c) norme carrée du biais pour l'estimation de l'amplitude à un mètre de la source.

Ce résultat théorique est confirmé par des simulations. On ne montrera ici que les résultats sur l'estimation de l'amplitude reçue à une distance fixe de la source, qui ne dépend pas d'un point de référence, et est donc relative à la source uniquement. Sur la figure 3.3, l'erreur quadratique moyenne (EQM, MSE), le biais et la variance de l'estimation de cette amplitude sont tracées en fonction de la fréquence, pour les formulations II et III, avec deux choix de point de référence, et le maximum de vraisemblance. L'axe des abscisses est formulé en nombre d'Helmholtz

$$H_e = \frac{fd}{c} \quad (3.13)$$

avec f la fréquence, d l'ouverture du réseau et c la vitesse du son. Les performances pour les formulations I et IV ne sont pas tracées, ces formulations étant de toute façon biaisées pour l'amplitude de la source même à position connue.

L'estimateur du maximum de vraisemblance, comme attendu, présente les meilleures performances. Le biais des formulations I et II dépend du choix du point de référence. En effet, le biais en position entraîne un biais en amplitude, une source étant estimée plus près du réseau sera évidemment considérée comme moins puissante, et inversement si elle est estimée plus loin.

En conclusion, ces résultats donnent donc une réponse finale à la question de l'utilisation des différentes formulations des vecteurs directeurs. La combinaison IV-III est la seule asymptotiquement non biaisée et efficace, et permet l'estimation de l'amplitude ou de la puissance de la source indépendamment du choix d'un point de référence.

3.2 Analyse théorique de l'algorithme DAMAS

G. Chardon, J. Picheral, F. Ollivier, *Theoretical analysis of the DAMAS algorithm and efficient implementation of the Covariance Matrix Fitting method for large-scale problems*, *Journal of Sound and Vibration*, 2021

Pour le cas d'une source unique, et à condition d'utiliser les bonnes formulations des vecteurs directeurs, la formation de voie est donc aisée à utiliser, et possède de bonnes propriétés statistiques. Cependant, son utilisation pour la localisation de plusieurs sources se heurte à sa résolution limitée. En effet, des sources trop proches seront confondues. De nombreuses méthodes ont été développées à des fins de super-résolution (MUSIC [29], ESPRIT [30], etc.). Les acousticiens se sont principalement intéressés à des méthodes dites de déconvolution (nomenclature légèrement abusive, l'opérateur à inverser étant linéaire mais pas invariant par translation), c'est à dire l'estimation d'une distribution de sources à partir de la carte de beamforming.

Dans ces méthodes, le critère de la formation de voie \mathbf{b} est calculé sur une grille discrète de N points. En supposant que les sources à estimer soient placées sur cette même grille, avec des puissances \mathbf{p} , on peut écrire, en négligeant le bruit et en supposant la matrice de covariance des mesures connue exactement,

$$\mathbf{b} = \mathbf{A}\mathbf{p} \quad (3.14)$$

où \mathbf{A} est une matrice carrée de taille $N \times N$, de coefficients

$$A_{ij} = |\mathbf{g}_i^H \mathbf{g}_j|^2, \quad (3.15)$$

les vecteurs \mathbf{g}_i étant les valeurs de $\mathbf{g}(\mathbf{x})$ aux points de la grille. Cette matrice est généralement non-inversible, le système linéaire (3.14) n'a donc pas de solution unique. Cependant, il est évident que les éléments de \mathbf{p} , étant des puissances, doivent être positifs. L'algorithme DAMAS [9] consiste à résoudre ce système sous contrainte de positivité, dans un certain sens laissé vague. Une itération de l'algorithme DAMAS consiste en une itération de Gauss-Seidel pour la résolution du système (3.14), suivie par l'annulation des coefficients négatifs. Bien que les points fixes de l'algorithme n'ait jamais été précisés (et encore moins la convergence vers un de ces potentiels points fixes), et en dépit de sa lourdeur calculatoire, cette méthode a bénéficié d'une certaine popularité.

Plus formellement, les itérées \mathbf{p}^k de l'algorithme sont obtenues en choisissant un indice i_k , et en fixant $p_j^k = p_j^{k-1}$ pour $j \neq i_k$, et

$$p_{i_k}^k = \max \left(0, \frac{1}{A_{i_k i_k}} \left(b_{i_k} - \sum_{l=0}^{i_k-1} A_{i_k l} p_l^{k-1} - \sum_{l=i_k+1}^N A_{i_k l} p_l^{k-1} \right) \right). \quad (3.16)$$

Cette formulation, légèrement différente de celle rencontrée dans la littérature, permet de définir deux algorithmes DAMAS :

- L'algorithme a été introduit avec un choix cyclique des coefficients mis à jour (c'est à dire, $i_k = k \bmod N$). Cette version sera appelée *DAMAS cyclique* dans la suite.
- L'algorithme *DAMAS aléatoire*, où les indices sont choisis aléatoirement, est utile pour obtenir des résultats théoriques de convergence.

L'algorithme est généralement initialisé à $p_i^0 = 0$ pour tout i , et arrêté quand les itérées successives sont suffisamment proches, généralement après un temps de calcul de l'ordre de l'heure, ou du jour [13].

Nous avons montré que l'algorithme DAMAS aléatoire n'est rien d'autre que l'algorithme *Uniform Coordinate Descent for Composite Functions algorithm* de [31] appliqué au problème

$$\operatorname{argmin}_{\mathbf{P} \in \mathcal{D}_+^N} \|\mathbf{G}\mathbf{P}\mathbf{G}^H - \mathbf{C}\|_F^2 \quad (3.17)$$

où \mathbf{G} est la matrice dont les colonnes sont les \mathbf{g}_j , et \mathcal{D}_+^N l'ensemble des matrices diagonales positives, proposé par Yardibi et al. sous le nom de Covariance Matrix Fitting (CMF) [10]. Une équivalence similaire avait déjà été montrée pour un problème idéal, sans prise en compte des incertitudes sur les mesures [32].

Si la solution est unique, alors l'algorithme DAMAS converge vers la solution du problème :

Theorem 1 Soient \mathbf{p}^k les itérées de l'algorithme DAMAS aléatoire. Alors pour $\varepsilon > 0$ et $0 < \rho < 1$, et

$$k \geq \frac{C_1}{\varepsilon} (1 - \log \rho) + C_2 \quad (3.18)$$

où C_1 et C_2 sont constants par rapport à k , ε et ρ , la probabilité d'avoir $J(\mathbf{p}^k) - J(\mathbf{p}^*) \leq \varepsilon$ est plus grande que $1 - \rho$.

De plus, si la solution \mathbf{p}^* est unique, alors avec même probabilité,

$$\|\mathbf{p}^k - \mathbf{p}^*\|_2 \leq C_3 \varepsilon + C_4 \sqrt{\varepsilon} \quad (3.19)$$

avec C_3 et C_4 constantes par rapport à k , ε et ρ .

Ce résultat a plusieurs implications importantes. D'une part, il justifie, a posteriori, l'utilisation de DAMAS pour la localisation de sources acoustiques. C'est en effet un algorithme très lent pour résoudre le problème CMF. D'autre part, il suggère de ne plus utiliser l'algorithme DAMAS. En effet, le problème CMF peut être résolu de façon efficace par l'algorithme de Lawson-Hanson [33], après réécriture comme un problème de moindres carrés non négatif usuel (on notera cette méthode CMF-NNLS). Ce problème de moindres carrés non négatif est connu pour avoir des propriétés similaires au problème LASSO pour l'estimation de vecteurs parcimonieux [34].

Enfin, des astuces de réécriture des produits matriciels intervenant dans l'algorithme permettent d'accélérer les calculs. En particulier, le produit par \mathbf{A} peut être accéléré en remarquant que

$$\mathbf{A} = (\mathbf{G}^H \mathbf{G}) \odot \overline{(\mathbf{G}^H \mathbf{G})} \quad (3.20)$$

où \odot est le produit terme à terme. Une accélération supplémentaire peut être obtenue en effectuant ces calculs en parallèle sur GPU. On obtient alors des accélérations significatives par rapport à l'algorithme DAMAS, ce qui justifie de ne plus l'utiliser.




Figure 3.4 – Décroissance de $\delta_k = J(\mathbf{p}^k) - J(\mathbf{p}^*)$ en fonction de temps de calcul, avec indication du nombre d'itérations.

3.2.1 Résultats expérimentaux

La méthode est testée sur les mesures présentées dans la section 2.2. La décroissance du critère en fonction du temps de calcul est donnée sur la figure 3.4. L'accélération obtenue par l'utilisation de l'algorithme de Lawson Hanson est particulièrement visible (lsqnonneg). De plus, les optimisations liées au problème particulier considéré ici permettent encore une accélération d'un ordre de grandeur (Lawson-Hanson (optimized)).

L'application à un cas de localisation en deux dimensions est donnée sur la figure 3.5. La comparaison avec la formation de voie confirme les capacités de haute résolution de la méthode. De plus, en comparaison avec l'algorithme DAMAS, la méthode proposée converge plus rapidement vers des solutions parcimonieuses.

Les performances de l'algorithme permettent de s'attaquer à des problèmes en grandes dimensions, en particulier pour la localisation des sources dans un espace tridimensionnel. Le résultat de l'algorithme est donné figure 3.6, l'espace étant discrétisé sur 3.75×10^5 points. Le temps de calcul est de 7 minutes. On remarquera quand dans ce cas, la matrice \mathbf{A} utilisée par l'algorithme DAMAS nécessiterait de l'ordre d'un téraoctet de mémoire.

3.3 Conclusion

Ces deux travaux montrent que des études théoriques, même simples, peuvent apporter des contributions importantes à des problèmes pratiques. Dans le cas de la formation de voie, la question de la formulation des vecteurs directeurs est résolue définitivement. Dans le cas de l'algorithme DAMAS, on montre à la fois que cet algorithme est basé sur une estimation par problème de moindres carrés non négatif, et qu'il ne faut plus l'utiliser, pouvant être remplacé par un algorithme beaucoup plus rapide.

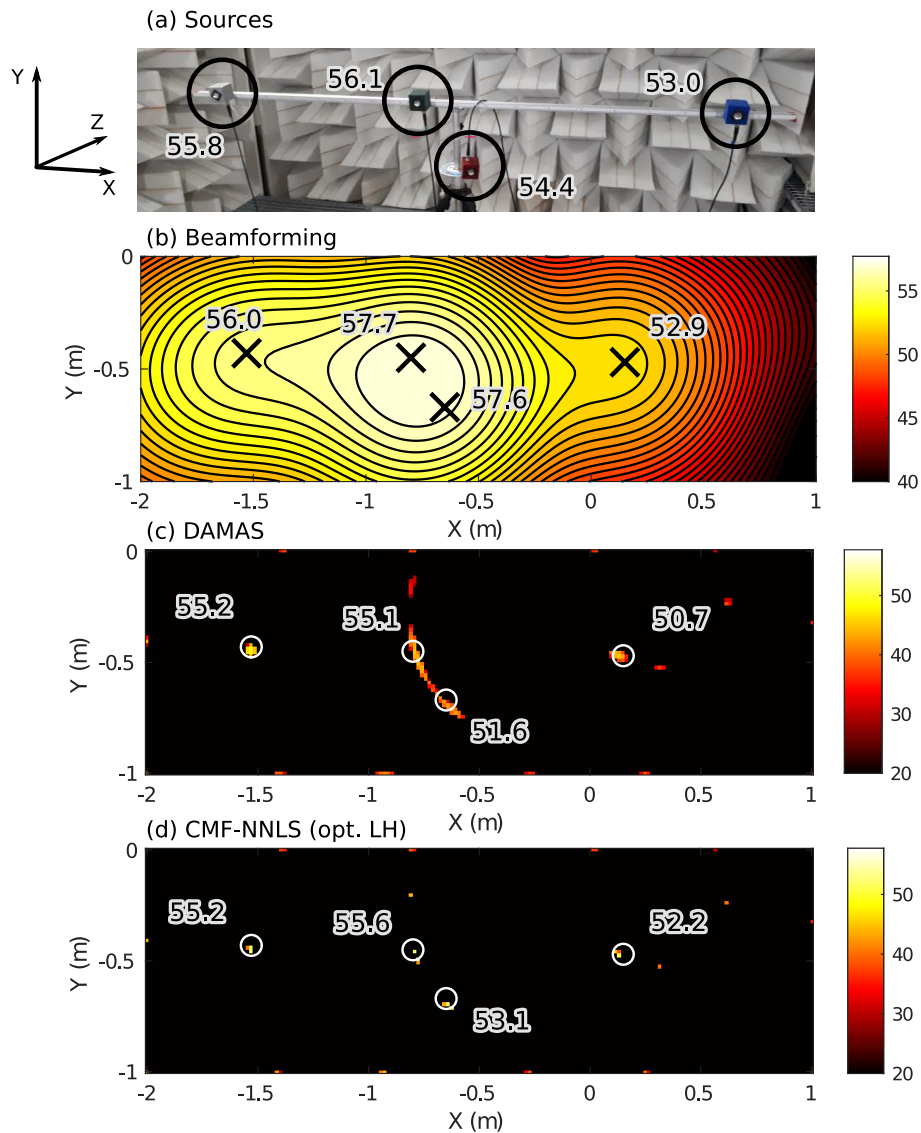


Figure 3.5 – Cas à deux dimensions, $F = 1806$ Hz. Comparaison de (a) puissance des sources, (b) formations de voies, (c) DAMAS, (d) CMF-NNLS. Puissances en dB. Les positions des sources sont indiquées par des croix ou des cercles. Les puissances estimées sont indiquées à proximité des sources.

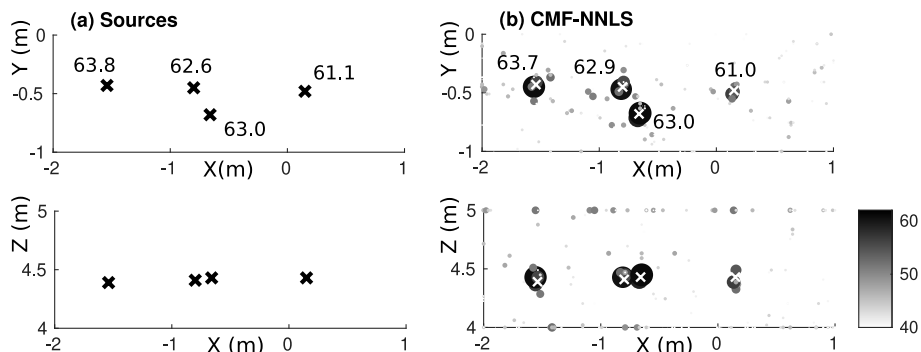


Figure 3.6 – Cas tridimensionnel, $F = 4858$ Hz. Vue de face (haute) et dessus (bas). (a) Positions et puissances des sources. (b) Méthode proposée. Les positions et puissances estimées sont indiquées par des disques de rayons proportionnels à la puissance, les positions réelles par des croix.

Chapitre 4

Localisation de sources acoustiques sans grille

Les méthodes d'estimation telles que CMF, ou LASSO, etc., sont basées sur l'utilisation d'une grille sur laquelle on espère que les sources recherchées soient situées. C'est évidemment rarement le cas, mais cela permet de formuler des problèmes d'optimisation en dimension finie. Il est tentant de raffiner la grille pour améliorer les performances, mais les travaux de Duval et Peyré [35] ont montré que cela ne permet pas de contrôler le support de la solution de manière satisfaisante. En effet, dans le cas où la position des sources est décrite par un paramètre (par exemple, un angle d'arrivée), chaque source est représentée par deux coefficients non nuls, même à niveaux de bruit faibles et quand la source est située sur un point de la grille.

De nombreuses méthodes (en général ou en acoustique en particulier) ont déjà été proposées pour se passer d'une grille de discrétisation. Dans des cas d'analyse spectrale, où de déconvolution, des méthodes basées sur des problèmes SDP (programmation semi-définie positive) ont été proposées [36]. Ils sont cependant limités et ne permettent pas de traiter des modèles plus généraux. CBP (Continuous Basis Pursuit), basé sur un développement de Taylor autour des points de la grille [37, 38], est affecté, dans certains régimes, des mêmes limites que LASSO [39], et augmente la dimension des problèmes à résoudre. NOMP (Newtonized OMP), une variante d'OMP [40, 41], avec des itérations de Newton pour raffiner position et amplitudes des sources, a également été proposée. Quelques méthodes basées sur de l'apprentissage profond ont été proposées en acoustique, sans résultats convaincants.

L'algorithme Sliding Frank-Wolfe (SFW) de Denoyelle et al. [42] paraît être une bonne alternative à ces méthodes. Je l'ai appliqué dans un premier temps au modèle conditionnel. Le modèle de source est semblable à celui utilisé par Denoyelle, une petite adaptation a cependant été nécessaire pour gérer le cas de plusieurs mesures. L'application au modèle inconditionnel est plus intéressante, avec l'utilisation de critères COMET [43, 44] donnant une approximation convexe de l'antilog-vraisemblance. Ces critères sont l'occasion d'appliquer l'algorithme SFW à des problèmes autres que le BLASSO. Dans les deux cas, les méthodes sont plus performantes que l'état de l'art, et sont validées sur des données réelles.

4.1 Algorithme

Dans le modèle conditionnel à plusieurs sources, les mesures s'écrivent

$$\mathbf{m} = \sum_{s=1}^S a_s \mathbf{g}(\mathbf{x}_s) + \mathbf{n} \quad (4.1)$$

où a_s et \mathbf{x}_s sont respectivement les amplitudes et positions des S sources, et \mathbf{n} un bruit de mesure, supposé blanc gaussien. Les sources sont supposées être dans un volume Ω connu. En modélisant la distribution de sources par une mesure discrète complexe $\mu = \sum_{s=1}^S a_s \delta_{\mathbf{x}_s}$, l'équation (4.1) peut se reformuler

$$\mathbf{m} = \int_{\Omega} \mathbf{g} d\mu + \mathbf{n}. \quad (4.2)$$

L'algorithme Sliding Frank-Wolfe, tel qu'introduit par Denoyelle et al., consiste à estimer la distribution

de sources μ en résolvant un problème de la forme

$$\mu^* = \operatorname{argmin}_{\mu \in \mathcal{M}} \frac{1}{2} \left\| \int_{\Omega} \mathbf{g} d\mu - \mathbf{m} \right\|_2^2 + \lambda |\mu|(\Omega) \quad (4.3)$$

où $|\mu|$ est la norme de variation totale, définie par

$$|\mu|(\Omega) = \max_{f \in C_1} \int_{\Omega} f d\mu. \quad (4.4)$$

C_1 est ici l'ensemble des fonctions continues sur Ω de valeur absolue bornée par 1. Cette norme peut être vue comme analogue à la norme ℓ_1 des vecteurs en dimension finie. En effet, pour une mesure discrète $\mu = \sum a_i \delta_{x_i}$, où les x_i sont distincts deux à deux, $|\mu| = \sum |a_i|$. De plus, il est connu que les solutions de (4.3) sont des mesures discrètes [45]. On peut donc voir ce problème BLASSO comme une version en dimension infinie du problème LASSO.

Le fonctionnement de l'algorithme de Sliding Frank-Wolfe est donné dans l'algorithme 1. Les trois problèmes d'optimisation à résoudre sont respectivement un problème non convexe en petite dimension, LASSO, et un problème non convexe mais pour lequel un minimum local est suffisant. Bien que l'algorithme résolve un problème d'optimisation sans grille, une discrétisation est toutefois nécessaire pour résoudre le problème non-convexe en petite dimension, par exemple en initialisant plusieurs méthodes de Newton en partant de points d'une grille grossière.

Sous certaines conditions, entre autre si la solution est unique, l'algorithme converge en un nombre fini d'itérations. Passons sur les détails, et remarquons que SFW ressemble fortement aux algorithmes de type Matching Pursuit, où à chaque étape, un coefficient non nul est ajouté dans l'estimation du signal à reconstruire.

Algorithm 1 Algorithme Sliding Frank-Wolfe

À partir de données, d'un modèle de source, et d'un paramètre de régularisation

- identifier une nouvelle source candidate en maximisant un critère, et l'ajouter à l'ensemble des sources
 - optimiser les amplitudes des sources (LASSO)
 - optimiser conjointement les positions et amplitudes des sources
 - itérer jusqu'à convergence
-

4.2 Modèle conditionnel

G. Chardon, U. Boureau, *Gridless three-dimensional compressive beamforming with the Sliding Frank-Wolfe algorithm*, *The Journal of the Acoustical Society of America*, 2021

L'application au modèle conditionnel est évidente, puisque (4.3) est exactement le problème BLASSO pour ce modèle. Il est toutefois nécessaire d'étendre l'algorithme aux cas de plusieurs mesures, pour lesquelles les positions des sources sont conservées, mais avec des amplitudes pouvant varier. Cette adaptation ne pose pas de problème particulier. Ulysse Boureau, étudiant à CentraleSupélec, m'avait aidé pour la comparaison avec l'état de l'art.

4.2.1 Résultats de simulation

La méthode proposée est comparée à l'état de l'art, en particulier NOMP, les autres méthodes étant incapables de prendre en compte le modèle de champ proche utilisé ici, ou trop demandeur en temps de calcul pour estimer des performances. Les simulations reprennent la configuration des mesures présentées dans la section 2.2. L'algorithme est ici utilisé avec $\lambda = 0$, et un nombre d'itérations égal au nombre de sources.

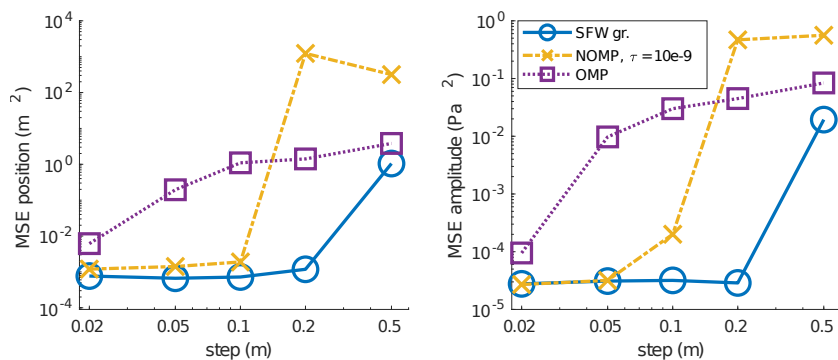


Figure 4.1 – Erreurs d’estimation des positions et amplitudes des sources en fonction du pas de la grille, pour SFW, OMP et NOMP.

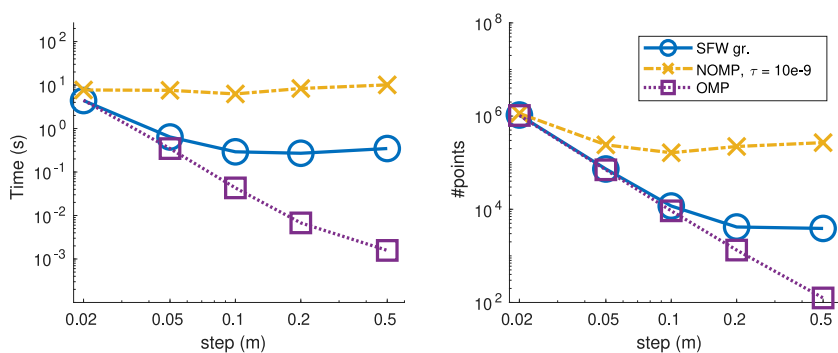


Figure 4.2 – Temps de calcul et nombre de positions visitées en fonction du pas de la grille, pour SFW, OMP et NOMP.

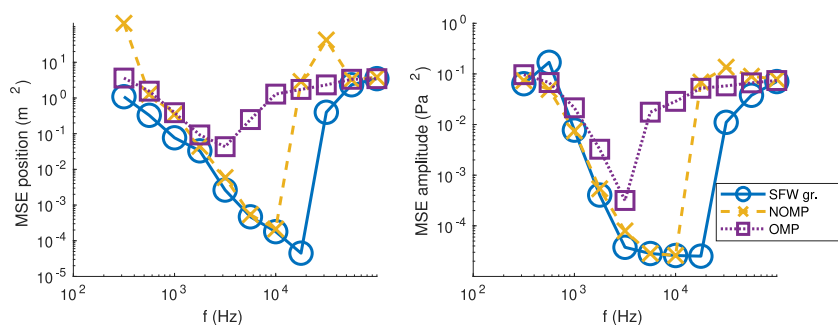


Figure 4.3 – Erreurs d’estimation des positions et amplitudes des sources en fonction de la fréquence, pour SFW, OMP et NOMP.




Figure 4.4 – Localisation des quatre sources, sur données réelles, pour SFW, OMP et NOMP.

La figure 4.1 montre les erreurs d'estimation des positions et amplitudes des sources en fonction du pas de la grille (définissant le dictionnaire pour OMP, initialisant la position des sources pour NOMP et SFW) et la fréquence. Ces résultats montrent que SFW ne nécessite pas une discrétisation fine de la grille d'initialisation pour donner de bons résultats. Cependant, avec une discrétisation trop grossière, le problème non convexe d'identification d'une nouvelle source ne trouve pas le minimum global, et l'algorithme ne parvient pas à bien localiser les sources.

Le temps de calcul, ainsi que le nombre de positions visitées par les algorithmes, sont donnés sur la figure 4.2, également en fonction du pas de la grille. En plus des meilleures performances, SFW est plus rapide que NOMP. Cet avantage peut être expliqué par le fait que NOMP traite la position et l'amplitude des sources indépendamment, alors que la distance entre le réseau et la source, et son amplitude, sont corrélées, ralentissant la convergence de NOMP.

Le tracé des performances en fonction de la fréquence, figure 4.3 montre la supériorité de SFW en comparaison à OMP et NOMP. À hautes fréquences, la discrétisation de la grille n'est plus assez fine, expliquant la perte de performances.

4.2.2 Résultats expérimentaux

Les résultats de localisation pour les différentes méthodes testées sur les données réelles sont visibles figure 4.4, qui montre les capacités de super résolution de ces méthodes par rapport à la formation de voies.

Les conséquences du choix du paramètre λ ont été étudiées, avec la variation des amplitudes des sources en fonction de λ , données sur la figure 4.5. Le paramètre λ minimal donnant 4 sources a été utilisé pour la figure 4.4. L'évolution de la distance entre le réseau et les sources en fonction de λ est donnée figure 4.6, dans un cas où le modèle de source \mathbf{g} est normalisé, ou non. Il est clair ici qu'il est nécessaire de normaliser \mathbf{g} pour éviter des forts biais dans l'estimation de la position de la source, confirmant les résultats de la section 3.1 pour le cas de la localisation de plusieurs sources.

4.3 Modèle inconditionnel

G. Chardon, *Gridless covariance matrix fitting methods for three dimensional acoustical source localization*, *Journal of Sound and Vibration*, 2023

Le problème CMF du chapitre précédent peut également être résolu par cet algorithme. La mesure à estimer étant une distribution de puissance, elle est positive, ce qui mène à résoudre le problème suivant

$$(\hat{\mu}, \hat{\sigma}^2) = \underset{\mu \in \mathcal{M}, \sigma^2 \in \mathbf{R}_+}{\operatorname{argmin}} f_{\text{CMF}}(\mu, \sigma^2). \quad (4.5)$$

où \mathcal{M} est l'ensemble des mesures de Radon positives sur Ω , et

$$f_{\text{CMF}}(\mu, \sigma^2) = \left\| \mathbf{R}(\mu, \sigma^2) - \hat{\Sigma} \right\|_{\text{Fro}}^2 \quad (4.6)$$

$$\mathbf{R}(\mu, \sigma^2) = \int_{\Omega} \mathbf{C} d\mu + \sigma^2 \mathbf{I} \quad (4.7)$$

avec $\mathbf{C}(\mathbf{x}) = \mathbf{g}(\mathbf{x})\mathbf{g}(\mathbf{x})^H$ la covariance générée par une source au point \mathbf{x} de puissance 1.




Figure 4.5 – Amplitude des sources en fonction de λ .

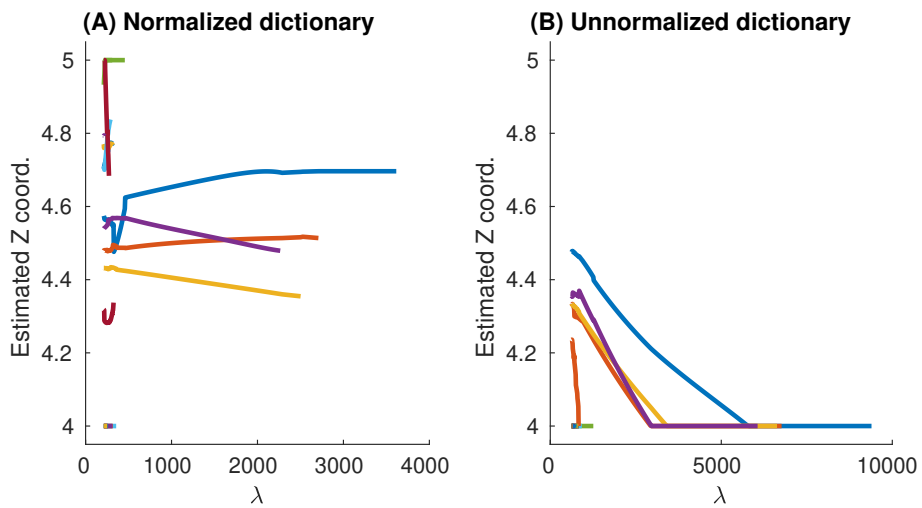


Figure 4.6 – Distance réseau-sources en fonction de λ , pour (a) dictionnaire normalisé, (b) dictionnaire non normalisé.

L'implémentation de l'algorithme SFW pour ce problème nécessite uniquement l'adaptation au cas matriciel, ce qui se fait sans peine. J'ai également testé les problèmes d'optimisation COMET [43, 44] de la forme

$$f_{\text{COMET1}}(\mu, \sigma^2) = \left\| \mathbf{R}^{-1/2} (\mathbf{R} - \hat{\Sigma}) \hat{\Sigma}^{-1/2} \right\|_{\text{Fro}}^2 \quad (4.8)$$

$$= \text{tr} (\hat{\Sigma}^{-1} \mathbf{R}) + \text{tr} (\hat{\Sigma} \mathbf{R}^{-1}) + C_1 \quad (4.9)$$

$$f_{\text{COMET2}}(\mu, \sigma^2) = \left\| \mathbf{R}^{-1/2} (\mathbf{R} - \hat{\Sigma}) \right\|_{\text{Fro}}^2 \quad (4.10)$$

$$= \text{tr} (\mathbf{R}) + \text{tr} (\hat{\Sigma} \mathbf{R}^{-1} \hat{\Sigma}) + C_2 \quad (4.11)$$

avec C_1 et C_2 constantes. Le critère COMET1 peut être vu comme une approximation du maximum de vraisemblance, et est asymptotiquement efficace. Le critère COMET2 ne nécessite pas l'inversion de $\hat{\Sigma}$ et sera donc préféré quand le nombre d'échantillons est du même ordre de grandeur que le nombre de microphones, voire plus petit.

Ces fonctions objectif ne contiennent pas de termes explicites de parcimonie comme dans le problème BLASSO. Pour les résultats expérimentaux, un nombre d'itérations fixé a priori limite le nombre de sources identifiées (et le temps de calcul), à la manière de Matching pursuit. Dans le cas de la dimension finie, il a été montré que minimiser le critère COMET2 est équivalent à un problème LASSO [46], il est donc probable qu'une équivalence avec le problème de BLASSO puisse être obtenue dans le cas sans grille.

4.3.1 Simulations

Les performances de l'algorithme SFW pour la minimisation des trois critères (CMF, COMET1 et COMET2) sont comparées à des méthodes de l'état de l'art, ou des modifications mineures de méthodes basées sur des grilles :

- Orthogonal Beamforming (OBF) dans sa version sans grille [47]
- OMP
- CLEAN-SC (CSC) [48] et High Resolution Clean-SC (HRCSC) [19], dans des versions sans grilles
- MUSIC.

Les performances d'estimation des puissances sont également données pour des puissances obtenues par le problème CMF réduit aux positions de sources estimées par COMET2 (COMET2LS).

Les résultats obtenus montrent que le seul concurrent des méthodes proposées est MUSIC, pour des SNR élevés. Nous avons observé qu'à faible SNR, les méthodes proposées ont une meilleure résolution que MUSIC, expliquant ses mauvaises performances.

4.3.2 Application expérimentale

Ces méthodes sont appliquées sur les données expérimentales, confirmant les résultats des simulations. Les estimations obtenues par la méthode basée sur l'évolution différentielle [49, 50] sont également données. Cette méthode semble présenter de bonnes performances, ce qui est attendu compte tenu qu'elle est basée sur la minimisation globale du critère CMF. Cependant, sa complexité algorithmique élevée (plusieurs minutes pour la résolution d'un problème, en comparaison avec quelques secondes pour SFW), empêche de tracer des courbes de performances en temps raisonnables.

4.4 Conclusion

D'une manière analogue au chapitre précédent, c'est l'utilisation d'un algorithme basé sur des bases théoriques solides qui permet d'atteindre les meilleures performances pour la localisation de sources sans grille, même si quelques libertés sont prises dans son application (en particulier arrêt au bout d'un nombre spécifié d'itérations).

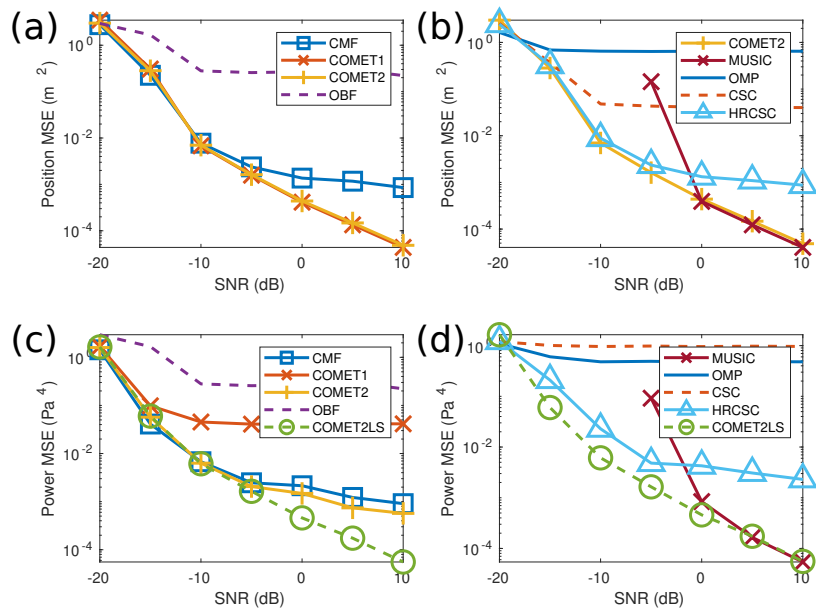


Figure 4.7 – Erreurs d'estimation des positions et puissances en fonction du SNR.

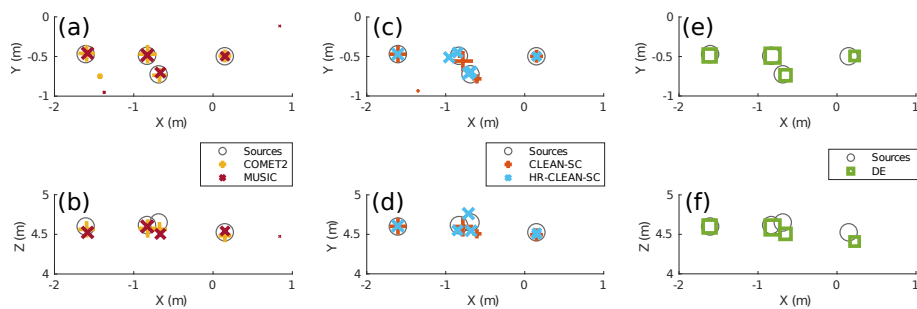


Figure 4.8 – Localisation de quatres sources sur données réelles.

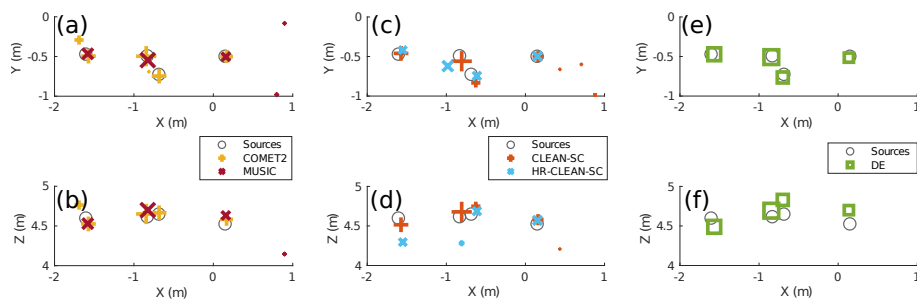


Figure 4.9 – Localisation de quatres sources sur données réelles, avec ajout de bruit, SNR = -10 dB

Une limitation de cet algorithme est le coût croissant de ses itérations, la dimension des problèmes d'optimisation à résoudre étant linéaire en fonction de l'itération. Néanmoins, l'accélération de ce type d'algorithme fait l'objet de travaux [51, 52] qui permettraient l'application à des problèmes plus complexes que les quatre sources considérées ici.

Enfin, les analyses théoriques du BLASSO se formulent généralement en terme de stabilité de l'estimation des emplacements et amplitudes des sources (par ex, [53]), c'est à dire de donner une borne sur les erreurs en fonction d'une borne sur la norme du bruit, généralement sous haute probabilité. À ma connaissance, les performances du BLASSO (ou des problèmes COMET en dimension infinie) n'ont pas encore été étudiées sous un angle statistiques, par exemple en quantifiant le biais et la variance des estimations, par exemple avec du bruit gaussien, et en les comparant avec des bornes d'estimateurs (cf. les figures de ce chapitre à propos des performances estimées des méthodes). Je pense qu'il serait intéressant d'analyser ce genre de méthode sous cet angle.

Chapitre 5

Deux problèmes moins classiques

Les deux chapitres précédents traitent de problèmes de localisation de sources plutôt classiques : les sources sont supposées décorréées, et les mesures sont obtenues à partir d'un réseau de microphones fixe. Dans ce chapitre, deux problèmes un peu plus originaux sont traités. D'abord, la localisation de sources pouvant être corrélées (par exemple, spatialement séparées mais émettant le même signal, ou une source et sa réflexion par un mur). La contribution de notre travail a été le développement et la validation expérimentale d'un algorithme rapide pour la localisation de telles sources, les méthodes de l'état de l'art en acoustique étant très coûteuses en calcul.

Ensuite, l'utilisation de mesures asynchrones (par exemple, en déplaçant un réseau au cours de la manipulation) est étudiée, dans le cas simple d'une source. Les bornes de Cramér-Rao et l'estimateur par maximum de vraisemblance sont calculés, permettant d'une part de quantifier l'intérêt de telles mesures, et d'autre part de proposer un algorithme de localisation efficace. Des mesures expérimentales confirment la supériorité de la méthode proposée par rapport à l'état de l'art, notamment une méthode basée sur de la complétion de matrice.

5.1 Localisation de sources corrélées

G. Chardon, F. Ollivier, J. Picheral, *Localization of sparse and coherent sources by Orthogonal Least Squares*, *Journal of the Acoustical Society of America*, 2019

Dans les chapitres précédents, quand le modèle inconditionnel était utilisé, les sources étaient supposées décorréées. Ceci permet d'écrire la matrice de covariance des mesures comme la somme de termes de rang 1 correspondant chacun à une source, et seules les puissances des sources sont à estimer, sans nécessité d'estimer les corrélations entre les signaux de chaque source.

Dans le cas de sources corrélées, de nouvelles méthodes doivent être développées. Remarquons tout d'abord que dans le cas de méthodes basées sur des grilles, le nombre d'inconnues est élevé au carré par rapport au cas de sources décorréées. Il est donc nécessaire de développer des méthodes rapides pour pouvoir traiter des grilles de dimensions pertinentes pour les applications.

Les méthodes de l'état de l'art sont généralement basées sur DAMAS [54], ou de l'optimisation convexe ou non-convexe [55]. Dans les deux cas, la taille du problème à résoudre limite les applications à des grilles réduites.

La méthode que nous avons proposée est basée sur l'algorithme OLS (Orthogonal Least Squares) [56], permettant une estimation rapide de la position des sources et de leur matrice de covariance. En effet, la complexité est en $O(LN^2K)$, où L est la taille de la grille, N le nombre de microphones, et K le nombre d'itérations. De façon surprenante, la complexité reste linéaire en fonction de la taille de la grille, alors que la matrice de covariance recherchée contient L^2 coefficients (certes quasiment tous nuls). Ceci est rendu possible par le fait que pour une matrice semi-définie positive, le support des coefficients de la matrice est contrôlé par le support de sa diagonale.

5.1.1 Algorithme

L'algorithme que nous avons développé fait partie de la famille des algorithmes gloutons : à chaque itération de l'algorithme, une nouvelle source est identifiée, jusqu'à un critère d'arrêt tel qu'un nombre de




Figure 5.1 – Illustration de l'évolution du support de la matrice de covariance estimée au cours de l'algorithme.

sources fixé a priori.

Le déroulement de l'algorithme est le suivant :

- Le résidu est initialisé à la matrice de covariance des mesures, et l'ensemble des sources à l'ensemble vide.
- Une nouvelle source est identifiée.
- Le résidu est mis à jour, en retirant les contributions des sources identifiées à la matrice de covariance
- Les itérations sont arrêtés quand un critère d'arrêt est atteint.

La figure 5.1 illustre la manière dont le support de la matrice de covariance évolue au cours des itérations : à chaque itération, un terme diagonal est ajouté, correspondant à la puissance de la source, ainsi que les termes hors diagonale modélisant les corrélations avec les sources précédemment identifiées.

Une nouvelle source est identifiée en projetant le résidu sur l'espace engendré par les matrices de covariances possibles pour les sources déjà identifiées et la source à tester. Cette étape d'identification se rapproche de celle de l'algorithme OLS, par opposition à l'algorithme OMP, où la projection est faite uniquement sur la source à tester. Ce choix permet une implémentation plus efficace, l'orthogonalisation des matrices de rang 1 pour le calcul de la projection se réduisant à l'orthogonalisation des vecteurs sources.

La mise à jour du résidu fait intervenir une projection similaire. Des astuces de calcul permettent un calcul rapide des quantités mises en jeu, aboutissant à une complexité d'une itération en $O(LN^2)$, linéaire en fonction de la taille de la grille. La complexité totale est $O(LN^2K)$.

Un post-traitement permet d'identifier les groupes de sources corrélées.

5.1.2 Validation expérimentale

La méthode est validée par des résultats expérimentaux à partir de mesures obtenues dans la chambre anéchoïque de l'Institut Jean le Rond d'Alembert. Plusieurs cas sont considérés, où seule la méthode proposée est capable de donner des résultats en temps et mémoire raisonnables. Les sources sont cherchées dans un plan, comportant 80 000 points.

Sources non corrélées

Le critère de la formation de voie et les sources identifiées par CMF-OLS sont donnés sur la figure 5.2. Les différents symboles représentent les groupes de sources corrélées. Le nombre d'itérations, 4, est choisi en inspectant la décroissance de l'énergie du résidu, donnée sur la figure 5.2. De même, le choix du nombre de groupes de sources est choisi en inspectant les valeurs propres de la matrice de covariance des sources estimées.

Le temps de calcul est ici de 1.4s. La prise en compte de la totalité des termes de la matrice de covariance des sources possibles nécessiterait ici 25Go de mémoire.

Paires de sources corrélées

Ici, les sources sont réparties en deux paires de sources corrélées. La figure 5.4 montre que CMF-OLS est capable d'identifier les paires corrélées. La figure 5.5 donne les deux groupes de sources identifiés par




Figure 5.2 – Localisation bidimensionnelle de quatres sources décorréées par CMF-OLS.




Figure 5.3 – Décroissance du résidu et valeurs propres des matrices de covariances estimées.

CMF-OLS, en comparaison avec les corrélations qui auraient été obtenues avec la formation de voies pour sources corrélées.

Réflexions

Enfin, l'identification de réflexions est testée sur un cas avec un unique réflecteur (cf. figure 2.2), et deux sources décorréées. La figure 5.6 montre que CMF-OLS est capable d'identifier les deux sources images, corrélées avec les sources réelles correspondantes.

En conclusion, cette méthode permet la localisation de source conjointement à l'estimation de leurs covariance dans des temps raisonnables. La limite principale de la méthode est le manque de garanties théoriques sur les estimations obtenues.

5.2 Utilisation de réseaux asynchrones

G. Chardon, Maximum likelihood estimators and Cramér-Rao bounds for the localization of an acoustical source with asynchronous arrays, *Journal of Sound and Vibration*, 2023

Les performances de localisation de sources sont bien entendu limitées par la configuration spatiale des sources et des microphones. Par exemple, pour un réseau de microphones plan, l'estimation de la distance entre le réseau et la source est très souvent entachées d'erreurs importantes. Autre exemple, les performances de localisation et de résolution de sources dans un plan parallèle au réseau sont limitées par l'ouverture du réseau.

L'utilisation de réseaux de grande taille, ou combinant différents angles de vue, permet d'améliorer les performances, au prix d'une complexité expérimentale plus importante. Alternativement, il a été proposé d'utiliser plusieurs mesures obtenues par un même réseau, déplacé au cours de la manipulation. En exploitant les matrices de covariances obtenues pour chaque sous-réseau, il est espéré que les performances de




Figure 5.4 – Localisation de deux paires de sources corrélées. Les paires sont indiquées par des croix \times et $+$




Figure 5.5 – Groupes de sources identifiées, et corrélations données par la formation de voie pour sources corrélées.




Figure 5.6 – Localisation de deux sources et de leurs sources images

localisation de source soient améliorées.

Dans la littérature, plusieurs types de méthodes se rencontrent :

- le traitement des données de chaque sous-réseau en parallèle, puis la fusion des résultats obtenus [57, 58, 59, 60, 61],
- la construction d'une matrice de covariance simulant l'utilisation d'une antenne complète synchrone, suivie par la localisation de sources [62, 63, 64, 65],
- et des méthodes consistant à traiter les données conjointement sans complétion de matrice, qu'on rencontre surtout dans un formalisme bayésien [66].

Dans la première classe de méthodes, plusieurs stratégies de fusion ont été proposées pour combiner les sorties de la formation de voie : moyennage arithmétique ou géométrique, minimum, etc. De même, de nombreux algorithmes de complétion de matrices ont été testés pour la construction de la matrice de covariance globale.

Ma contribution à ce problème a été l'étude du cas de la localisation d'une source, en utilisant deux modèles. Dans le premier modèle (strict), la puissance de la source est supposée constante entre les mesures, et dans le deuxième (relaxé), elle est autorisée à varier. Ceci peut, par exemple, aider à traiter le cas de sources non isotropes. En effet, dans les cas où le diagramme de directivité de la source peut-être supposé constant dans les directions des capteurs d'un même réseau, mais de valeurs différentes entre les réseaux, les différents réseaux auraient l'illusion d'observer la source, mais émettant des puissances différentes.

Les bornes de Cramér-Rao sont calculées dans les deux cas, ainsi que l'estimateur par maximum de vraisemblance. Les performances sont comparées aux méthodes de l'état de l'art. Un résultat marquant est que dans le cas étudié ici, les méthodes de complétion de matrices ne permettent pas d'améliorer les performances de localisation.

5.2.1 Bornes de Cramér-Rao

Les bornes de Cramér-Rao (BCR) permettent d'évaluer a priori les performances d'estimation atteignables par un estimateur non biaisé : ce sont des bornes inférieures à la variance de n'importe quel estimateur non biaisé. Il existe d'autres types de bornes, souvent plus précises que les BCR (Barankin, etc.), mais la simplicité de calcul des BCR, notamment pour des modèles gaussiens (formule de Bangs dans le cas où les paramètres agissent sur la matrice de covariance [67, 68]), les rend très attractives.

Un exemple de valeurs numériques des BCR est donné pour la configuration de source et de microphones de la figure 5.7, avec deux sous-réseaux parallèles placés autour de la zone d'intérêt. Sur la figure 5.8, les BCR sur la position et la puissance sont données en fonction de la fréquence, pour :

- le cas synchrone (B_x^c et B_p^c), où plusieurs réseaux mesurent le champ acoustique simultanément, permettant de construire une matrice de covariance complète,
- le cas asynchrone strict (B_x^s et B_p^s), où un réseau est positionné à des emplacements différents au cours de la mesure. L'estimation est faite en supposant la puissance de la source constante au cours des mesures.
- et le cas asynchrone relaxé (B_x^r et B_p^r), utilisant le même dispositif de mesure que le cas précédent, mais permettant à la puissance de la source de varier entre les mesures.

À basse fréquence, les BCR pour le modèle asynchrone strict et le modèle synchrone sont semblables. Dans ce régime, l'amplitude des signaux reçus apporte beaucoup d'information comparativement à la phase, variant lentement avec la position en basse fréquence. Les BCR pour le modèle relaxé sont nettement plus hautes, l'amplitude relative entre les sous-réseaux ne pouvant pas être exploitée. À haute fréquence, c'est la phase qui apporte le plus d'informations, creusant les différences de performances entre le modèle synchrone et le modèle asynchrone strict, qui ne peut exploiter l'information de phase entre les réseaux. Les performances des modèles strict et relaxé se rejoignent, l'information donnée par l'amplitude perdant de l'importance face à la phase.

Sur la figure 5.9, la BCR pour le modèle synchrone, et les ratios entre BCR asynchrones strict/synchrone, et relaxé/strict sont donnés. On peut observer que la perte de performances pour l'estimation de la position est significative dans certaines zones, tandis que les performances restent semblables dans d'autres. Pour le




Figure 5.7 – Configuration de réseaux utilisée dans les simulations. La croix indique la position de la source pour la figure 5.8

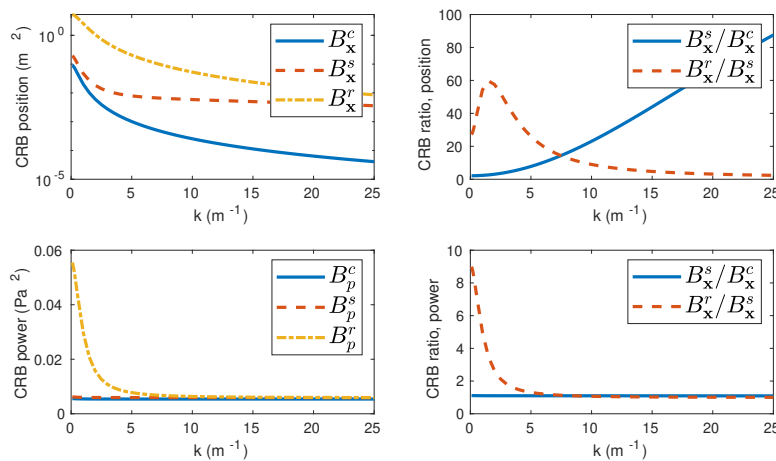


Figure 5.8 – BCR pour le cas de réseaux parallèles, en fonction de la fréquence, pour une source à (0.1, 0.2, 0.0). Graphiques du haut : position. Bas : puissance. Gauche : BCR pour les réseaux synchrones, et asynchrones strict et relaxé. Droite : ratio entre les BCR du modèle strict et des réseaux asynchrone, et ratio entre les modèles asynchrones strict et relaxé.

modèle relaxé, la perte de performance par rapport au modèle strict est significative dans une petite zone de l'espace entre les sous-réseaux. Les performances en estimation de la puissance restent similaires pour les trois modèles.

D'autres configurations peuvent être étudiées, avec des conclusions similaires. L'utilisation de microphones de référence, conservant la même position entre les mesures, en est un cas particulier. Un exemple est donné sur la figure 5.10, où dans la configuration de gauche, 4 positions sont communes aux deux sous-réseaux, tandis que la configuration de droite, semblable, ne contient pas de microphone communs. Les BCR données sur la figure 5.11 pour ces deux configurations montrent que les BCR pour les deux configurations sont quasi-identiques. L'utilisation de microphones de référence n'a donc pas d'effet significatif sur les performances de localisation attendues.

5.2.2 Maximum de vraisemblance

L'estimateur par maximum de vraisemblance pour la localisation de la source est maintenant donné pour les deux modèles. Dans le cas d'un réseau synchrone, les résultats du chapitre 3 montrent que le maximum de vraisemblance consiste à estimer la position en maximisant la sortie de la formation de voie pour la formulation IV du vecteur directeur, puis estimer la puissance avec la formulation III.

Dans le cas du modèle asynchrone strict, l'estimation de la position et la puissance ne peuvent être effectuées successivement. Il est nécessaire de les estimer conjointement en résolvant le problème d'optimi-




Figure 5.9 – BCR pour le cas de réseaux parallèles, en fonction de la position. Haut : position. Bas : puissance. Gauche : synchrone. Milieu : ratio entre modèle strict et synchrone. Droite : ratio entre modèle relaxé et strict. Les positions des microphones sont indiquées par des cercles et des croix.




Figure 5.10 – Configurations de réseaux avec (gauche) et sans (droite) microphones de référence.




Figure 5.11 – BCR pour les réseaux avec et sans référence. Haut : position. Bas : puissance. Gauche : avec référence. Milieu : sans référence. Droite : ratio entre les deux cas. Les positions des microphones sont indiquées par des cercles et des croix.

sation

$$(\hat{\mathbf{x}}^s, \hat{p}^s) = \underset{\mathbf{x} \in \Omega, p \in \mathbf{R}_+}{\operatorname{argmin}} \sum_{j=1}^J S_j \left(-\frac{p \mathbf{g}_j(\mathbf{x})^H \hat{\Sigma}_j \mathbf{g}_j(\mathbf{x})}{\sigma^2 (\sigma^2 + p \|\mathbf{g}_j(\mathbf{x})\|^2)} + \log(\sigma^2 + p \|\mathbf{g}_j(\mathbf{x})\|^2) \right) \quad (5.1)$$

Pour le modèle relaxé, il est de nouveau possible d'effectuer l'optimisation en deux temps, avec la position $\hat{\mathbf{x}}^r$ obtenue en maximisant

$$B(\mathbf{x}) = \sum_{j=1}^J S_j \left(\frac{\mathbf{g}_j(\mathbf{x})^H \hat{\Sigma}_j \mathbf{g}_j(\mathbf{x})}{\|\mathbf{g}_j(\mathbf{x})\|^2 \sigma^2} - \log \frac{\mathbf{g}_j(\mathbf{x})^H \hat{\Sigma}_j \mathbf{g}_j(\mathbf{x})}{\|\mathbf{g}_j(\mathbf{x})\|^2 \sigma^2} \right) \quad (5.2)$$

puis en estimant les puissances par

$$\hat{p}_j = \frac{1}{\|\mathbf{g}_j(\hat{\mathbf{x}}^r)\|_2^2} \left(\frac{\mathbf{g}_j(\hat{\mathbf{x}}^r)^H \hat{\Sigma}_j \mathbf{g}_j(\hat{\mathbf{x}}^r)}{\|\mathbf{g}_j(\hat{\mathbf{x}}^r)\|_2^2} - \sigma^2 \right), \quad (5.3)$$

Si la puissance de la source est en réalité constante, elle peut par être exemple être estimée par une moyenne pondérée des puissances estimées

$$\hat{p}^r = \frac{\sum_{j=1}^J S_j \hat{p}_j}{\sum_{j=1}^J S_j}. \quad (5.4)$$

5.2.3 Simulations et résultats expérimentaux

Des résultats de simulations sont donnés pour le cas de la configuration de la figure 5.7. Les EQM de la position et la puissance sont tracés sur la figure 5.12 en fonction de la fréquence pour

- le maximum de vraisemblance en versions stricte et relaxée,
- diverses stratégies de fusion de cartes de beamforming (somme, produit, minimum),
- la complétion de matrice [65].

Les méthodes de complétion de matrice incluant un terme de continuité du champ acoustique entre les réseaux ne sont pas utilisées ici, les réseaux étant éloignés de distances rendant cette contrainte inopérante.

Les meilleures performances sont obtenues avec le maximum de vraisemblance strict, qui atteint les BCR. Aucune des autres méthodes (moyenne géométrique ou minimum des critères de formation de voie, ou complétion de matrice de covariance) n'atteint les BCR.

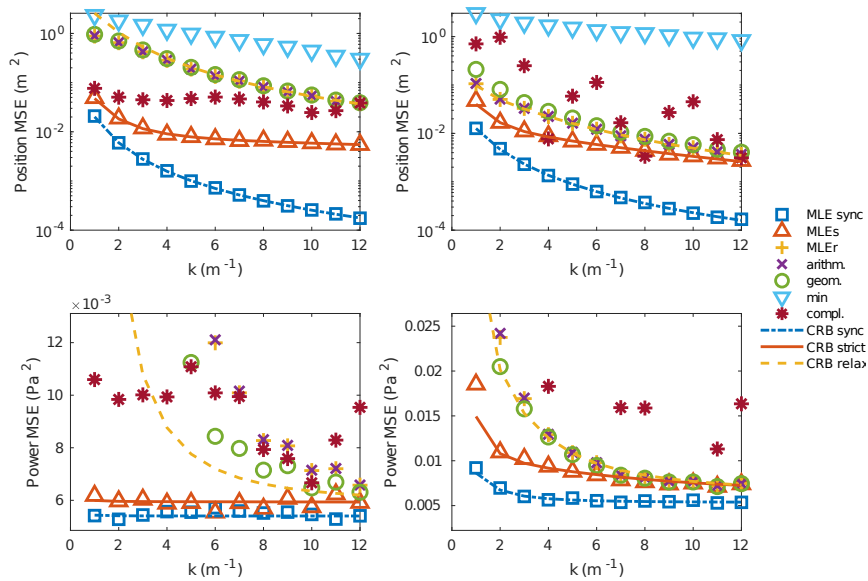


Figure 5.12 – EQM pour la position (haut) et puissance (bas) en fonction de la fréquence, pour les réseaux parallèles. Gauche : source à $(0.1, 0, 0.2)$. Droite : source à $(-1, 0, -1)$.

Des résultats expérimentaux, pour deux configurations géométriques données figure 5.13, ont été obtenus. Pour le cas de réseaux parallèles, avec la source placée au centre, les performances du modèle strict sont clairement supérieures, avec une variance plus faible. Pour l'autre source, les différences de performances sont moins claires.

De même pour des réseaux en L, les différences de performances dépendent de la position de la source. Dans les deux cas, les résultats sont cohérents avec les BCR calculées plus haut.

5.2.4 Conclusion

L'étude de ce cas simple de localisation d'une source à partir de mesures asynchrones a permis d'obtenir plusieurs résultats : Premièrement, le calcul des BCR montre qu'il est illusoire d'atteindre les performances de réseaux synchrones à partir de réseaux asynchrones, en particulier pour l'estimation de la position de la source. D'autre part, ce même calcul de BCR montre que l'utilisation de microphones de référence n'a pas d'impact particulier sur les performances. Le calcul des estimateurs par maximum de vraisemblance montre que parmi les méthodes de l'état de l'art, la fusion par moyenne arithmétique correspond à un modèle relaxé de sources, et qu'il est possible d'améliorer les performances en utilisant le modèle strict, bien que plus complexe à mettre en oeuvre. Enfin, les résultats de simulations et d'expériences ont montré la supériorité des approches proposées par rapport à l'état de l'art, y compris la méthode de complétion de matrice de covariance.

5.3 Conclusion

Les contributions de ce chapitre sont de nature différentes. Pour la localisation de sources corrélées, c'est un algorithme heuristique qui permet l'application de la localisation de sources à des cas avec corrélations. Il serait évidemment utile d'avoir des garanties théoriques sur l'algorithme obtenu, où de développer un autre algorithme mieux justifié. Les résultats expérimentaux sont néanmoins intéressants.

Pour le cas de l'utilisation de réseaux asynchrones, comme pour l'étude de la formation de voies, c'est le maximum de vraisemblance qui donne une méthode de localisation présentant de bonnes performances. En particulier, la méthode basée sur de la complétion de matrice n'atteint pas les BCR. La complétion de matrices reste une méthode très populaire pour l'utilisation de réseaux asynchrones, mais il est probable




Figure 5.13 – Configuration de l'expérience. Gauche : réseaux parallèles. Droite : réseaux en L. La source 1 est indiquée par un cercle, la source 2 par un carré.

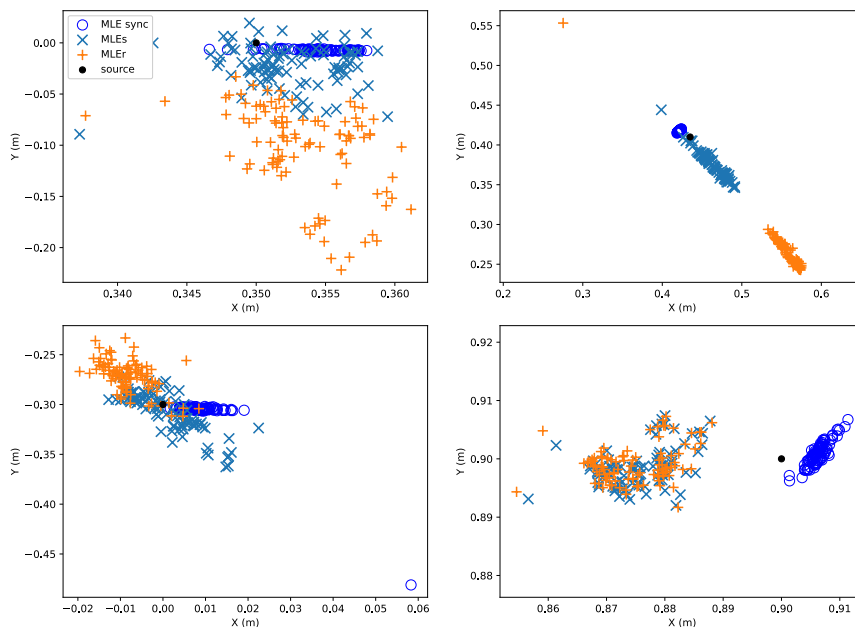


Figure 5.14 – Estimation des positions sur une centaine de mesures. Gauche : réseaux parallèles. Droite : réseaux en L. Haut : source 1. Bas : source 2.

que comme dans ce cas particulier, elle ne soit finalement pas meilleure que d'autres méthodes encore à développer.

Deuxième partie

Encadrements de thèses

Chapitre 6

Introduction

Cette section présente les différentes thèses que je co-encadre, ou ai co-encadrées. Une lecture attentive du chapitre 1 fait ressortir que toutes ces thèses sont des thèses CIFRE. Cette particularité n'est pas le fruit d'un goût immodéré pour les applications industrielles, ou d'une peur panique à l'idée de présenter un candidat au concours de l'école doctorale, mais plutôt la conséquence d'opportunités qui se sont présentées à moi, et la préférence pour une autre sujet d'un candidat retenu au concours de l'école doctorale STIC.

Voici quelques points positifs de ces expériences d'encadrement de thèses CIFRE :

- La découverte de sujets, ou de méthodes, auquel je n'aurai pas été confronté en restant dans mes thématiques habituelles présentées dans la partie précédente. Je pense, par exemple, au transport optimal que nous avons utilisé dans la thèse de Manon Mottier pour le traitement de données RADAR.
- Le confort financier des contrats d'accompagnement, mettant à l'abri du besoin.
- les échanges avec les industriels, avec leurs objectifs différents des nôtres, permettant de garder le contact avec les applications possibles de nos recherches.

Parmi les points moins satisfaisants, je citerais :

- Un contrôle partiel sur le déroulement de la thèse, avec la nécessité de rester aligné avec les objectifs de l'entreprise, avec parfois des changements de thématique en cours de thèse pas forcément prévus.
- un partage du temps pas toujours bien équilibré dans le temps de travail du doctorant CIFRE entre l'avancement de son travail de thèse et des tâches données par l'entreprise, ce qui explique (parmi d'autres raisons hors de notre contrôle) des thèses parfois un peu étirées.

Les sujets traités dans ces thèses sont :

- la conception de stratégies d'échantillonnage temporel pour des réseaux commutés et l'estimation de l'occupation d'une voiture par mesures de réponses impulsionnelles pour la thèse de Pierre Avital
- le désentrelacement et l'identification d'émetteurs RADAR pour Manon Mottier
- l'explicabilité du gradient boosting pour la classification et la régression pour Émilien Boizard
- et la séparation de sources pour la décomposition de bruit de turbomachine pour Sarah Roual.

Les sujets abordés peuvent sembler assez variés, en tout cas peu cohérents avec les travaux présentés dans la section précédente. Je prétend que cette incohérence n'est que superficielle. Les travaux de Pierre en optimisation de séquences d'échantillonnage peuvent être rapprochés de mes travaux en optimisation de réseaux de microphones, mais dans un cas temporel plutôt que spatial. Les travaux de Manon sur l'utilisation du transport optimal pour l'analyse de signaux RADAR mettent en jeu des signaux modélisés par des mesures, comme les méthodes de localisation sans grille. Émilien utilise un algorithme de gradient boosting inspiré par l'algorithme Frank-Wolfe utilisé pour ces mêmes méthodes de localisation. La cohérence des travaux de Sarah est plus évidente, avec l'utilisation de réseaux de microphones pour la séparation de sources acoustiques.

Le contexte et les résultats de ces quatre thèses sont détaillés dans les chapitres suivants. Les figures de ces chapitres ont bien entendu été produites par les doctorants.

Chapitre 7

Pierre Avital

La thèse de Pierre Avital était en collaboration avec Valeo, équipementier automobile. Pierre était encadré à parts égales par José Picheral, directeur de thèse, et moi-même. La thèse de Pierre s'est déroulée sur successivement deux axes. Dans un premier temps, nous avons étudié des problèmes d'échantillonnage, dans le cas particulier de réseaux de capteurs équipés d'un seul convertisseur analogique-numérique, commutant entre les capteurs au cours d'une acquisition, le cas (b) de la figure 7.1. Dans un deuxième temps, le problème de la détection de passagers dans un véhicule à partir de balises UWB (Ultra Wide Band) a été étudié.

7.1 Séquences d'échantillonnage pour réseaux commutés

P. Avital, G. Chardon, J. Picheral, Design of switching sequences for sine parameters estimation on switched antenna arrays, Signal Processing, 2021

Une application visée au départ de la thèse était la localisation d'un smartphone, en vue de l'ouverture d'une voiture sans contact. La méthode de base pour l'estimation de la distance entre le véhicule et un smartphone consiste à estimer la puissance transmise entre le véhicule et la clé ou un smartphone. Cette technique est sujette à des attaques par relais, simulant la proximité de la clé.

Une première solution étudiée par Valeo était l'estimation du temps de trajet entre le véhicule et la balise. Les travaux de la thèse se sont finalement orientés vers la localisation explicite de la balise par des méthodes de localisation de sources nécessitant donc l'estimation d'amplitudes et phases de signaux. Une limite technologique identifiée était l'encombrement et la puissance limitée disponible dans le véhicule, ce qui a amené à étudier le cas d'un réseau de K transmetteurs reliés à un unique convertisseur analogique-numérique. De plus, la technologie choisie, le bluetooth, ne permettait pas de fixer la fréquence d'émission. La localisation de la source nécessite donc l'estimation de cette fréquence. Des premières simulations ont fait apparaître que les performances d'estimation étaient très dépendantes de la façon dont les échantillons étaient répartis sur les différents transmetteurs.

La première contribution de la thèse a été l'analyse des performances atteignables par différentes stratégies de commutation entre antennes, en se basant sur les bornes de Cramér-Rao. Le modèle de signal est le suivant : les K capteurs mesurent K sinusoïdes de fréquence ω commune, mais d'amplitudes A_k et phases ϕ_k différentes. L'action du commutateur fait qu'à chaque instant d'échantillonnage, multiple de la période d'échantillonnage T_s , un seul signal peut être mesuré. Nous faisons également l'hypothèse d'un bruit blanc additif complexe gaussien de variance $2\sigma^2$. Le vecteur \mathbf{x}_k des N_k échantillons pour le signal k s'écrit donc :

$$\mathbf{x}_k = (A_k \exp(i\omega_j t_{k,n} + i\phi_k) + b_{k,n})_{n=1, \dots, N_k} \quad (7.1)$$

avec $t_{k,n}$ l'instant d'échantillonnage du n -ième échantillon du signal k , et $b_{k,n}$ le bruit. Les BCR se calculent simplement en profitant de la formule de Slepian pour l'information de Fisher d'un modèle gaussien à moyenne paramétrée.

Les critères de comparaison considérés étaient la BCR pour la fréquence (Γ_ω), et la somme des BCR pour les amplitudes (Γ_A) et les phases réduites (Γ_ϕ) (critère de A-optimalité [69]), obtenues en soustrayant la phase moyenne, non informative sur la direction d'arrivée. Le calcul de ces critères prend en compte la perte d'échantillons au moment de la commutation entre deux canaux.

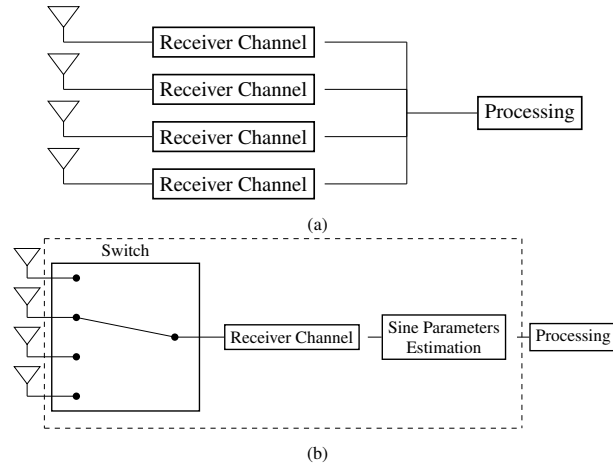


Figure 7.1 – Deux dispositifs de réseaux de capteurs, avec (a) un récepteur pour chaque élément du réseau, (b) un seul récepteur pour réseau commuté.

Deux cas ont été étudiés. Dans le premier, la fréquence d'émission est supposée connue. Les critères obtenus sont

$$\Gamma_A = \sum_{k=1}^K \frac{\sigma^2}{N_k} \quad (7.2)$$

$$\Gamma_\phi = \frac{K-1}{K} \sum_{k=1}^K \frac{\sigma^2}{A_k^2 N_k} \quad (7.3)$$

qui sont simplement fonctions du niveau de bruit σ^2 , des amplitudes A_k et du nombre d'échantillon par transmetteur N_k .

Dans le cas où la fréquence doit elle aussi être estimée, la BCR sur la fréquence est

$$\Gamma_\omega = \frac{\sigma^2}{\sum_{k=1}^K A_k^2 N_k \Lambda_k} \quad (7.4)$$

où $\Lambda_k = \frac{1}{N_k} \sum_{n=1}^{N_k} (t_{k,n} - \bar{t}_k)^2$ dépend des dispersions des instants d'échantillonnage pour chaque transmetteur, les $t_{k,n}$ étant les instants d'échantillonnage pour le capteur k , et \bar{t}_k leur moyenne.

Le critère pour les phases est

$$\Gamma'_\phi = \overbrace{\frac{K-1}{K} \sum_{k=1}^K \frac{\sigma^2}{A_k^2 N_k}}^{\Gamma_\phi} + \overbrace{\Gamma_\omega \sum_{k=1}^K (\bar{t}_k - \bar{t})^2}_{\Gamma_2} \quad (7.5)$$

avec \bar{t} la moyenne des moyennes \bar{t}_k . On y voit apparaître la BCR Γ_ϕ du cas de la fréquence connue, auquel s'ajoute le terme noté Γ_2 , produit de la BCR de la fréquence, de la variance des instants moyens d'échantillonnage sur chaque canal, et du nombre de canaux. Les performances attendues sont évidemment moins bonnes que dans le cas de la fréquence connue, à cause du terme Γ_2 positif. Néanmoins, par l'utilisation de motifs d'échantillonnages tels que les instants moyens d'échantillonnage sur chaque transmetteur soient égaux, il est remarquable que l'incertitude sur la fréquence n'a pas d'influence sur la BCR des phases.

Sous l'hypothèse que les amplitudes A_k soient identiques de valeur A , que le nombre total d'échantillons soit un multiple de K et que la commutation ne fait pas perdre d'échantillons, une stratégie de commutation présentant les propriétés suivantes permettrait de minimiser simultanément les trois BCR Γ_A , $\Gamma'_\phi = \Gamma_\phi + \Gamma_2$ et Γ_ω :

- les nombres d'échantillons N_k sur chaque canaux sont égaux, pour minimiser Γ_A et Γ_ϕ ,




Figure 7.2 – Stratégie de commutation identifiée comme la plus performante. Les canaux sont parcourus dans un ordre fixé, inversé à mi-chemin de la fenêtre de mesure.

- le dénominateur de la CRB Γ_ω , qui s'écrit dans ce cas $A^2 \sum_{k=1}^K \sum_{n=1}^{N_k} (t_{k,n} - \bar{t}_k)^2$ est maximal,
- et les termes $(\bar{t}_k - \bar{t})^2$ sont nuls, annulant Γ_2 .

Les deux dernières conditions sont obtenues en utilisant des motifs d'échantillonnage symétriques par rapport au temps moyen de la fenêtre dans laquelle sont pris les échantillons. En effet, un calcul élémentaire permet de montrer (de façon similaire au théorème de la variance totale) que

$$\sum_{k=1}^K \sum_{n=1}^{N_k} (t_{k,n} - \bar{t})^2 = \sum_{k=1}^K \sum_{n=1}^{N_k} (t_{k,n} - \bar{t}_k)^2 + \sum_{k=1}^K N_k (\bar{t}_k - \bar{t})^2 \quad (7.6)$$

Le terme de gauche étant constant à longueur d'observation fixée, les motifs symétriques, vérifiant $\bar{t}_k = \bar{t}$ maximisent donc le dénominateur de la BCR Γ_ω (premier terme du membre de droite) tout en annulant Γ_2 .

Une exploration de stratégies de commutation possibles a abouti au choix de parcourir les transmetteurs en aller-retour, avec des nombres d'échantillons égaux pour chaque transmetteur, comme montré sur la figure 7.2, qui vérifie les conditions données plus haut. Cette stratégie atteint les mêmes performances à grand nombre de transmetteurs et grande durée d'observation que l'utilisation d'un convertisseur par transmetteur, à nombre d'échantillons totaux constant.

Le critère Γ'_ϕ est tracé figure 7.3 en fonction de la taille des blocs pour différentes stratégies de commutation : la stratégie identifiée plus haut, une variante sans symétrie, une recherche exhaustive (et longue) de la meilleure stratégie, et des stratégies naïves de commutation (à chaque échantillon, ou mesure de chaque canal par blocs successifs). La borne inférieure $\Gamma_{\phi,\min}$ correspond au cas où la fréquence est connue. La stratégie choisie atteint les mêmes performances que la recherche exhaustive, qui aboutit à la même stratégie.

Cette étude se limite au cas d'une fréquence unique, le cas de fréquences multiples n'ayant pas été abordé. Néanmoins, ce modèle peut prendre en compte de cas de plusieurs sources, tant qu'elles émettent à la même fréquence.

7.2 Détection de passager par UWB

Dans un deuxième temps, les travaux de Pierre se sont portés sur la détection de passagers dans un véhicule par l'utilisation de balises UWB. La méthode adoptée a été la classification de réponses impulsionnelles entre balises par SVM. Une particularité du travail a été la prise en compte d'invariances par translation et par rotation de phase des réponses impulsionnelles, avec l'utilisation d'un noyau particulier.

Les premiers résultats expérimentaux ont été obtenus par Pierre en plein confinement, avec un dispositif expérimental prenant place dans son salon. Des résultats ont ensuite été obtenus sur un véhicule réel, schématisé sur la figure 7.4. Les réponses impulsionnelles entre la balise 14 et les balises 11 et 12 sont enregistrées, dans la bande passante des balises. Cette mesure de réponse impulsionnelle est prévue par le protocole de communication utilisé. Chaque réponse impulsionnelle est composée de 1024 échantillons




Figure 7.3 – Critère Γ_ϕ' pour l'estimation des phases pour les différentes stratégies testées.

complexes. En raison de particularités du protocole et de l'absence de synchronisation entre balises, l'amplitude des réponses impulsionnelles et leur emplacement dans le temps ne portent pas d'information. De plus, le système ne pouvant pas stocker plus de 60 échantillons. Il a été choisi de se limiter aux 5 échantillons précédant le maximum de la réponse, et aux 55 échantillons suivants.

Des jeux d'entraînement, de validation et de test sont collectés en variant l'occupation du véhicule (de 0 à 3 personnes) et le réglage du siège conducteur (quatre positions ont été considérés, dont une apparaît uniquement dans le jeu de test).

La méthode SVM avec noyau gaussien

$$k(\mathbf{x}, \mathbf{y}) = \exp(-\gamma \|\mathbf{x} - \mathbf{y}\|_2^2) \quad (7.7)$$

a été retenue. Le paramètre γ a été réglé par validation croisée en exploitant le jeu de validation.

En plus de la norme ℓ_2 (cas A dans les résultats), d'autres métriques sont utilisées dans le noyau gaussien, afin de garantir l'invariance par phase des réponses impulsionnelles. L'hypothèse est ici faite que l'application d'un terme de phase global à la réponse impulsionnelle ne doit pas avoir d'influence sur le résultat de la classification. La classification doit donc être aveugle à un tel terme de phase global.

— norme ℓ_2 entre les valeurs absolues des RI (B) :

$$k_B(\mathbf{x}, \mathbf{y}) = \exp(-\gamma \||\mathbf{x}| - |\mathbf{y}|\|_2^2) \quad (7.8)$$

où la valeur absolue est appliquée terme à terme aux éléments de \mathbf{x} et \mathbf{y} .

— norme ℓ_2 après application de termes de phases tels que la phase de la moyenne des RI soit nulle (C) :

$$k_C(\mathbf{x}, \mathbf{y}) = \exp(-\gamma \|e^{-i\phi_x} \mathbf{x} - e^{-i\phi_y} \mathbf{y}\|_2^2) \quad (7.9)$$

avec $\phi_x = \angle \sum_{n=1}^{60} x_n$, la phase de la moyenne des échantillons de \mathbf{x} , et de même pour ϕ_y .

— valeur minimale de la norme ℓ_2 en appliquant un terme de phase à une des RI (D) :

$$k_D(\mathbf{x}, \mathbf{y}) = \min_{\phi \in [0, 2\pi[} \exp(-\gamma \|e^{i\phi} \mathbf{x} - \mathbf{y}\|_2^2), \quad (7.10)$$

le minimum étant atteint pour $\phi = \angle \mathbf{x}^H \mathbf{y}$.

Il est à noter que dans le dernier cas, le noyau n'est pas semi-défini positif, ce qui ne nous empêchera pas de l'utiliser.

La figure 7.5 donne les performances de classification de l'occupation du véhicule (pourcentage d'estimations de l'ensemble des sièges occupés correctes), dans le cas où la configuration de test (pas les données !) se retrouve dans le jeu d'apprentissage. Le cas où la configuration n'a pas été vue dans l'apprentissage (ici, un réglage du siège conducteur différent des réglages utilisés dans l'apprentissage) est donné figure 7.6.




Figure 7.4 – Schéma de la voiture équipée de balises UWB. Les trois balises utilisées sont entourées.




Figure 7.5 – Taux de succès de la classification en fonction de la taille de l'ensemble d'apprentissage.

Dans les deux cas, la variante (D) donne les meilleurs résultats, avec un besoin de données d'apprentissage réduit par rapport aux autres méthodes, et une meilleure robustesse. Ce besoin réduit peut être expliqué par une meilleure prise en compte de l'invariance par phase, sans toutefois perdre l'information qu'elle contient.

Il est regrettable que, vu les résultats expérimentaux encourageants, nous n'ayons pas pu donner une justification solide à cette prise en compte de l'invariance de phase pour la classification par SVM.




Figure 7.6 – Taux de succès de la classification pour une configuration de l’habitable non vue dans l’apprentissage.

Chapitre 8

Manon Mottier

Les travaux de thèse de Manon se sont déroulés en collaboration avec Atos, sous la direction de Frédéric Pascal. L'objectif de ces travaux est l'identification d'émetteurs RADAR présents dans un environnement à partir de mesures passives du spectre électromagnétique. Les impulsions recueillies sont ensuite segmentées et analysées, puis décrites par des paramètres tels que temps d'arrivée, durée, fréquence, énergie, etc. Les données à traiter se présentent sous la forme d'un tableau de données décrivant le signal reçu, et mélangeant des impulsions de plusieurs sources, tel que

$$\begin{pmatrix} t_1 & t_2 & t_3 & \cdots & t_N \\ d_1 & d_2 & d_3 & \cdots & d_N \\ f_1 & f_2 & f_3 & \cdots & f_N \end{pmatrix} \quad (8.1)$$

où les t_n sont les temps d'arrivée des impulsions, les d_n les durées d'impulsions, et les f_n leurs fréquences. Ces données sont fournis par le matériel du partenaire industriel, leur estimation n'entre pas dans le cadre de la thèse.

De manière classique, l'approche adoptée a été de d'abord séparer les impulsions RADAR, puis de classer ces impulsions séparées. De façon moins classique, ce sont des méthodes basées sur l'utilisation de distances de transport optimal entre loi de probabilités qui ont été utilisées, avec comme avantages attendus par rapport à l'état de l'art une utilisation plus souple et une robustesse à des motifs temporels des impulsions complexes.

Dans ces travaux, les signaux reçus et les classes d'émetteur RADAR sont modélisés par des lois de probabilité. Les méthodes proposées sont basées sur l'utilisation de distances de transport optimal, qui permettent de quantifier la similarité entre des lois de probabilités.

8.1 Une introduction rapide au transport optimal

Il existe de nombreuses distances, ou divergences, entre lois de probabilité, par exemple la distance de variation totale, ou la divergence de Kullback-Leibler. Ces distances et divergences ont cependant la propriété d'être très sensibles à une modification mineure de la loi de probabilité. Par exemple, la distance de variation totale entre deux masses de Dirac de poids 1 sera de 0 si elles sont co-localisées, de 2 sinon, quelque soit la distance les séparant.

On se limitera ici à des lois de probabilité discrètes, par exemple

$$\nu = \sum_{n=1}^N a_n \delta_{x_n} \text{ et } \mu = \sum_{m=1}^M b_m \delta_{y_m}. \quad (8.2)$$

Un plan de transport $\mathbf{P} \in \mathbf{R}^{N \times M}$ entre ν et μ est défini par ses coefficients P_{nm} quantifiant la masse prise en x_n déplacée en y_m . La consistance avec les lois ν et μ est garantie par $\mathbf{P}\mathbf{1}_M = \mathbf{a}$ et $\mathbf{P}^T\mathbf{1}_N = \mathbf{b}$. Un plan de transport a un coût

$$C(\mathbf{P}) = \sum_{n=1}^N \sum_{m=1}^M C_{nm} P_{nm} \quad (8.3)$$

où C_{nm} est le coût de déplacement d'une unité de masse de x_n à y_m (par exemple, la distance euclidienne entre x_n et y_m).




Figure 8.1 – Illustration du transport entre lois de probabilités.




Figure 8.2 – Tracé de trois clusters issus d’HDBSCAN dans le plan temps-niveau.

La distance de transport optimal est définie par le coût minimal de transport

$$\mathbf{P}^* = \underset{\mathbf{P} \in \mathbf{R}_+^{N \times M}}{\operatorname{argmin}} C(\mathbf{P}) \text{ sous contrainte que } \mathbf{P}\mathbf{1}_M = \mathbf{a}, \mathbf{P}^T\mathbf{1}_N = \mathbf{b}. \quad (8.4)$$

Le problème (8.4) est un problème linéaire.

De nombreuses variantes de la distance de transport optimal ont été proposées. En particulier, il est possible de régulariser le problème (8.4) par un terme d’entropie du plan de transport \mathbf{P} , ce qui permet l’utilisation d’algorithmes rapides parallélisables [70]. Une autre variante permet de prendre en compte des déséquilibres entre les poids [71].

La figure 8.1 donne une illustration sur un exemple simple : la distance de transport entre les lois du haut et du milieu sera faible, les lois étant réparties de manière similaire sur l’axe des abscisses. La distance entre les lois du milieu et du bas sera elle plus élevée, les déplacements nécessaires pour transporter la loi du milieu vers celle du bas étant plutôt longs.

8.2 Désentrelacement d’impulsions RADAR

M. Mottier, G. Chardon, F. Pascal, *Deinterleaving RADAR emitters with optimal transport distances*, IEEE Transactions on Aerospace and Electronic Systems, 2024

Le désentrelacement consiste à séparer les impulsions de plusieurs émetteurs RADAR à partir d’un flux d’impulsions mélangées. Ce problème est plutôt difficile, les émetteurs exhibant des caractéristiques de

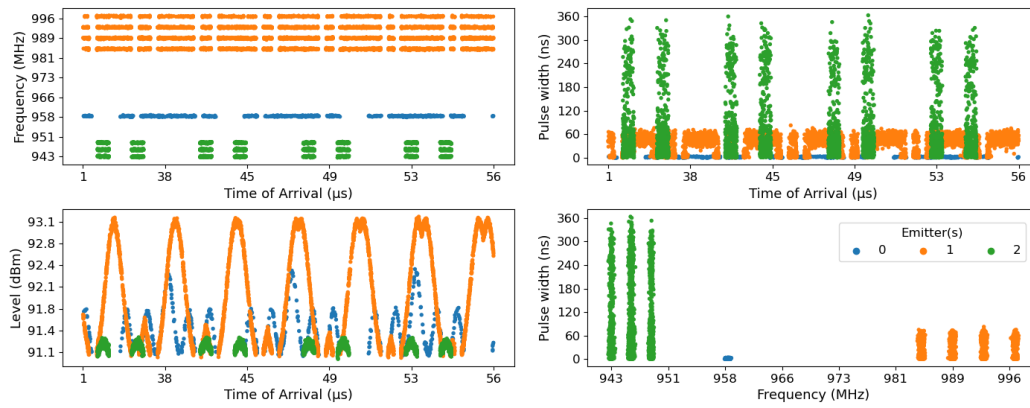


Figure 8.3 – Tracé des impulsions de trois émetteurs dans différents plans. La couleur indique l'émetteur.

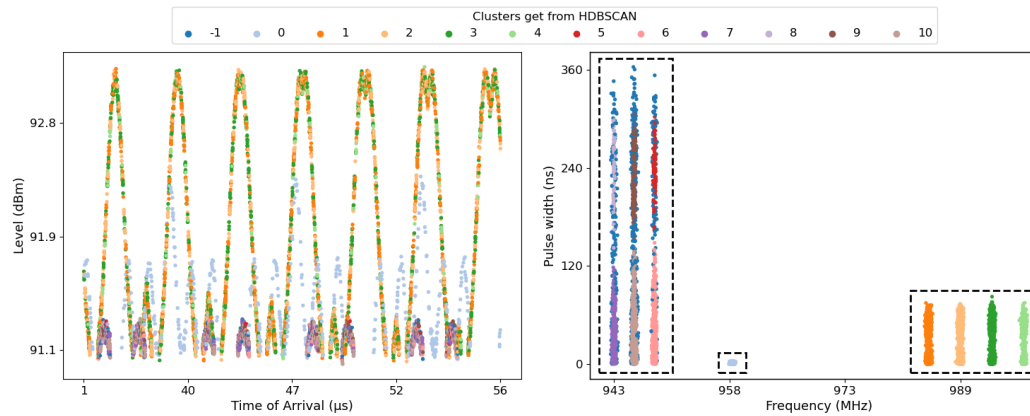


Figure 8.4 – Regroupement des impulsions par HDBSCAN. Un émetteur peut être représenté par plusieurs clusters.

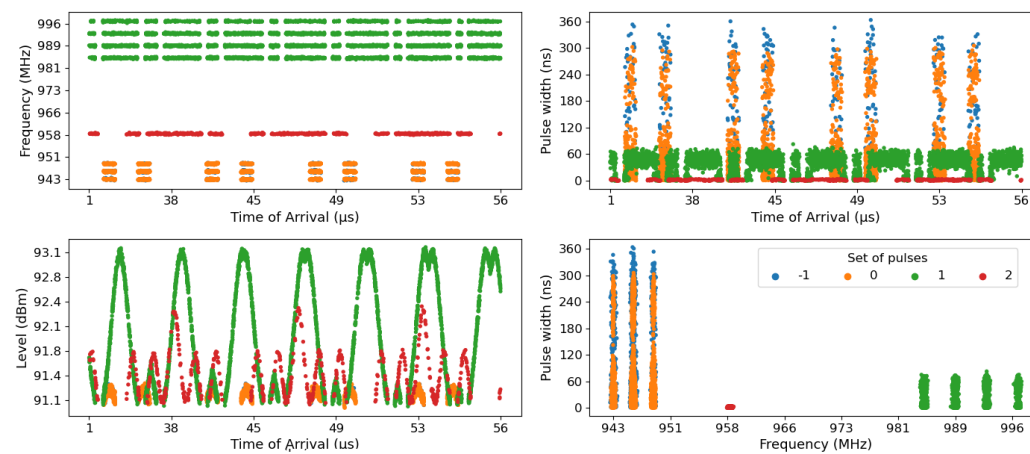


Figure 8.5 – Impulsions après regroupement final.

plus en plus complexes : ils peuvent émettre sur plusieurs fréquences, avec des temps inter-impulsions de structures complexes voire aléatoires, etc.

Nous ferons tout de même les hypothèses suivantes :

- Les impulsions correspondant à un émetteur sont réparties sur plusieurs clusters dans le plan fréquence-durée d'impulsions : un émetteur ne peut émettre que sur un nombre fini de fréquences et de durée d'impulsions.
- les impulsions provenant d'un émetteur sont reçues sur des intervalles de temps similaires pour chacun de ces clusters : un émetteur RADAR balaye l'espace de façon régulière.
- ces clusters ne contiennent que des impulsions d'un seul émetteur : différents émetteurs n'utilisent pas les mêmes fréquences ou durées d'impulsion.

Ces conditions peuvent paraître restrictives, elle sont cependant moins rigides que des hypothèses généralement faites sur les émetteurs, tels que des périodes de répétition d'impulsions suivant des motifs particuliers et répétés, ou des émetteurs émettant sur une seule fréquence [72, 73]. La figure 8.3 donne un exemple de données vérifiant ces hypothèses.

L'approche adoptée consiste dans un premier temps à effectuer un clustering dans le plan durée d'impulsion-fréquence, par exemple par HDBSCAN [74]. La figure 8.4 montre les clusters obtenus. Cependant, un seul émetteur peut être représenté par plusieurs clusters.

Ces clusters sont ensuite regroupés en utilisant la deuxième hypothèse donnée ci-dessus, par un clustering hiérarchique utilisant des distances de transport optimal [75].

Comme le montre la figure 8.2, les temps d'arrivée des impulsions des clusters d'un même RADAR (ici clusters 3 et 4) sont semblables. Les impulsions d'un cluster d'un autre radar (cluster 0) auront une distribution temporelle des impulsions différente. Une distance de transport optimal entre les lois empiriques définies par les impulsions des clusters peut donc être utilisée pour quantifier la similarité des structures temporelles de deux clusters. Dans l'algorithme de clustering hiérarchique, les regroupements sont effectués sous condition que les temps d'arrivée des deux clusters à fusionner puissent être considérés comme étant tirés selon la même loi de probabilité temporelle, en utilisant un test de Kolmogorov-Smirnov. Dans le cas contraire, les clusters sont conservés, et l'algorithme progresse en traitant les clusters restants.

Une variante de l'algorithme permet de prendre en compte des cas où les estimations des paramètres des impulsions sont bruitées et risquent de fusionner des clusters à la première étape.

Le regroupement final des impulsions est donné sur la figure 8.5, où on voit que les impulsions ont été correctement regroupées dans trois clusters associés aux trois émetteurs, sauf quelques impulsions ayant été identifiées comme aberrantes par HDBSCAN.

La comparaison avec les méthodes de l'état de l'art, basées sur l'analyse des intervalles entre impulsions, est favorable à la méthode proposée. De plus, des simulations numériques ont montré sa robustesse par rapport aux erreurs d'estimation des caractéristiques des impulsions ou aux impulsions aberrantes.

8.3 Identification d'émetteurs RADAR

M. Mottier, G. Chardon, F. Pascal, *RADAR Emitter Classification with Optimal Transport Distances*, European Signal Processing Conference (EUSIPCO), 2022

Une fois les émetteurs séparés, ils peuvent être identifiés. La méthode utilisée est ici très simple, et consiste à calculer la distance de transport optimal entre des classes théoriques et les données, représentées toutes deux par des lois de probabilités, puis de sélectionner la classe minimisant le coût de transport. Cela correspond au maximum de vraisemblance dans le cas de bruit additif gaussien sur les caractéristiques des impulsions et de distance de transport régularisé par l'entropie [76].

Quelques exemples de classes théoriques sont données sur la figure 8.6, dans le plan fréquence-intervalles. On remarque la présence d'émetteurs ayant un nombre fixé de fréquences ou d'intervalles possibles, et deux émetteurs dont les intervalles inter impulsions sont aléatoires. On notera que cette représentation s'intéresse uniquement à la proportion d'apparition de chaque caractéristiques, et ne prend pas en compte l'ordre de leurs apparitions.




Figure 8.6 – Exemples de représentations de classes d'émetteurs RADAR dans le plan inter-
valle inter-impulsions et fréquence.




Figure 8.7 – Modélisation de la loi des intervalles inter-impulsions en fonction du taux de
perte α .

Un aspect assez original de ce travail est la prise en compte de la perte possible d'impulsions (d'énergie trop faible pour être détectées, ou mal assignées lors de l'étape de désentrelacement) dans la loi de probabilité des intervalles entre temps d'arrivées des impulsions, améliorant la robustesse vis à vis de ces pertes.

Un exemple d'une telle modélisation est donné sur la figure 8.7, avec un RADAR ayant comme intervalles inter-impulsions des cycles de la forme 40ms, 50ms, 50ms. La distribution du haut donne la loi des intervalles sans perte, celle du milieu avec un taux de perte de 25%, celle du bas de 50%.

Par rapport à d'autres méthodes, par exemple basée sur du deep learning [77, 78], l'ajout de nouvelles classes à la base de donnée RADAR est élémentaire, et ne nécessite pas un réapprentissage. Des simulations montrent que cette méthode serait robuste vis à vis des pertes d'impulsions et des erreurs d'estimation des caractéristiques. Une sensibilité forte aux outliers a été observée. Cependant, les données utilisées pour l'étape d'identification proviennent fréquemment d'un désentrelacement, qui a été l'occasion de supprimer les points aberrants.

Chapitre 9

Emilien Boizard

Ce travail de thèse est en collaboration avec meilleursagents.com, plus précisément l'équipe de science des données. Une des activités de meilleursagents.com est la mise à disposition du public et des professionnels d'estimations de prix immobiliers, tant sur une échelle macro, par des cartes de prix, que sur une échelle micro, par l'estimation du prix de biens immobiliers en particulier.

Une des limites des méthodes d'estimation actuelles est l'impossibilité d'expliquer cette estimation à l'utilisateur. Le but de la thèse est de développer une méthode d'explication particulière, qui consiste à sélectionner dans l'ensemble d'apprentissage des éléments représentatifs ayant des caractéristiques similaires à l'élément faisant l'objet d'une classification ou d'une régression. Ainsi, pour un utilisateur de l'outil d'estimation, l'estimation obtenue sera justifiée par des exemples de biens de caractéristiques proches, et de prix de vente similaires à l'estimation proposée. Cette manière d'expliquer les résultats de l'estimation sera probablement mieux perçue par un utilisateur moyen que les techniques courantes d'explicabilité, par exemple basées sur l'influence des caractéristiques sur l'estimation. En effet, expliquer à l'utilisateur l'estimation de son bien en lui indiquant que la situation de son bien au troisième étage ajoute 300 € du mètre carré sera moins convaincant que de lui montrer différents biens similaires au sien.

Nous nous intéressons en particulier aux méthodes de gradient boosting [79].

9.1 Gradient Boosting

Pour un problème de régression, le gradient boosting consiste à estimer une fonction f de Ω dans \mathbf{R} à partir de données d'apprentissage $\{(\mathbf{x}_n, y_n)\}_n$. Des estimations \hat{f}_t sont construites itérativement de la façon suivante :

- à l'itération t , on calcule le gradient de la fonction de perte par rapport aux valeurs que prend la fonction f_{t-1} aux points d'apprentissage. Les valeurs du gradient sont notées $g_{n,t}$.
- un arbre de régression h_t est appris à partir des données $\{(\mathbf{x}_n, g_{n,t})\}$, avec une fonction de perte ℓ_2 . Cet arbre permet d'étendre le gradient à tout Ω . Il s'écrit $h_t(\mathbf{x}) = \sum_{k=1}^K b_{k,t} \mathbf{1}_{A_{k,t}}(\mathbf{x})$, avec les sous-ensembles $A_{k,t}$ partitionnant l'espace, et $b_{k,t}$ les valeurs que h_t prend sur ces sous-ensembles.
- l'estimation de f est mise à jour par $\hat{f}_t = \hat{f}_{t-1} + \gamma_t h_t$, avec γ_t un pas fixé a priori, ou déterminé à chaque itération.

Le surapprentissage est évité en limitant la complexité des fonctions h_t et le nombre d'itérations. Ces méthodes, plutôt aisées à mettre en oeuvre, sont très performantes sur des données tabulaires [80].

Le point de départ de nos travaux est l'observation que, dans le cas de régression par gradient boosting avec comme fonction de perte la norme ℓ_2 , l'estimation pour un échantillon peut s'écrire comme une combinaison linéaire des valeurs des échantillons de l'ensemble d'apprentissage. Cependant, cette combinaison linéaire n'est pas garantie d'avoir des poids positifs. De plus, pour les membres de l'ensemble d'apprentissage, les poids de décomposition se concentrent sur ce même élément, que nous interprétons comme du sur-apprentissage. Cet effet est visible sur la figure 9.1.

9.2 Le cas de la régression

Dataset	Cat	XGB	Sklearn	ExpGB
Abalone	4.46e0	4.55e0	4.45e0	4.33e0
Ailerons	2.26e-8	2.56e-8	2.39e-8	2.26e-8
Bike_sharing_demand	1.29e3	1.55e3	1.56e3	1.40e3
Brazilian_houses	1.28e-1	1.30e-1	1.32e-1	1.28e-1
CPU_act	4.94e0	4.82e0	4.94e0	4.77e0
Diamonds	2.76e5	2.97e5	2.85e5	2.67e5

Table 9.1 – Erreurs d'estimation (EQM) sur quelques jeux de données. La méthode proposée est ExpGB.

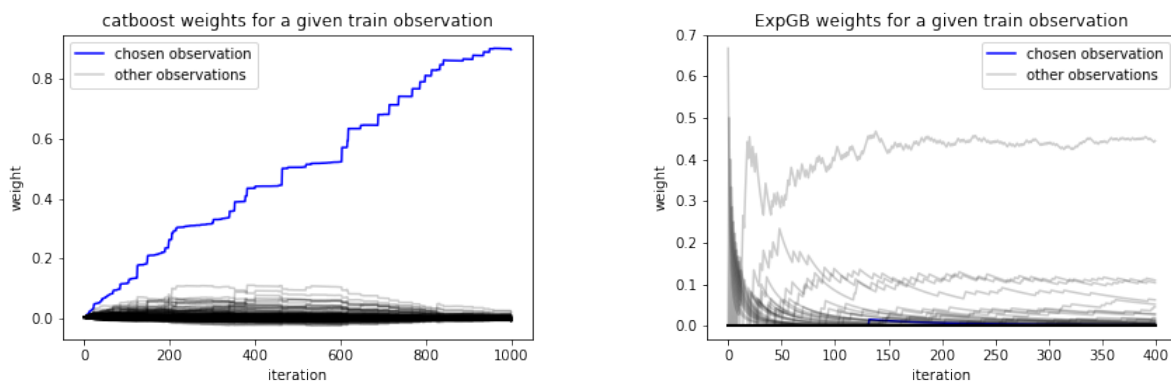





Figure 9.1 – Poids de décomposition de l'estimation pour un élément de l'ensemble d'apprentissage. Gauche : gradient boosting (catboost). Droite : méthode proposée. Les poids de décomposition de la prédiction sur la propre valeur de l'échantillon testé est en trait épais.



(a)



(b)



(c)

Figure 9.2 – Sélection d'éléments comparables à un élément de test. Les caractéristiques de l'élément testé sont données par la flèche verte, celles des comparables par les disques bleus. La prédiction est donnée par le carré violet. Ligne du haut : méthode proposée. Ligne du milieu : échantillons ayant des prix similaires. Ligne du bas : distance de Mahalanobis entre les caractéristiques.

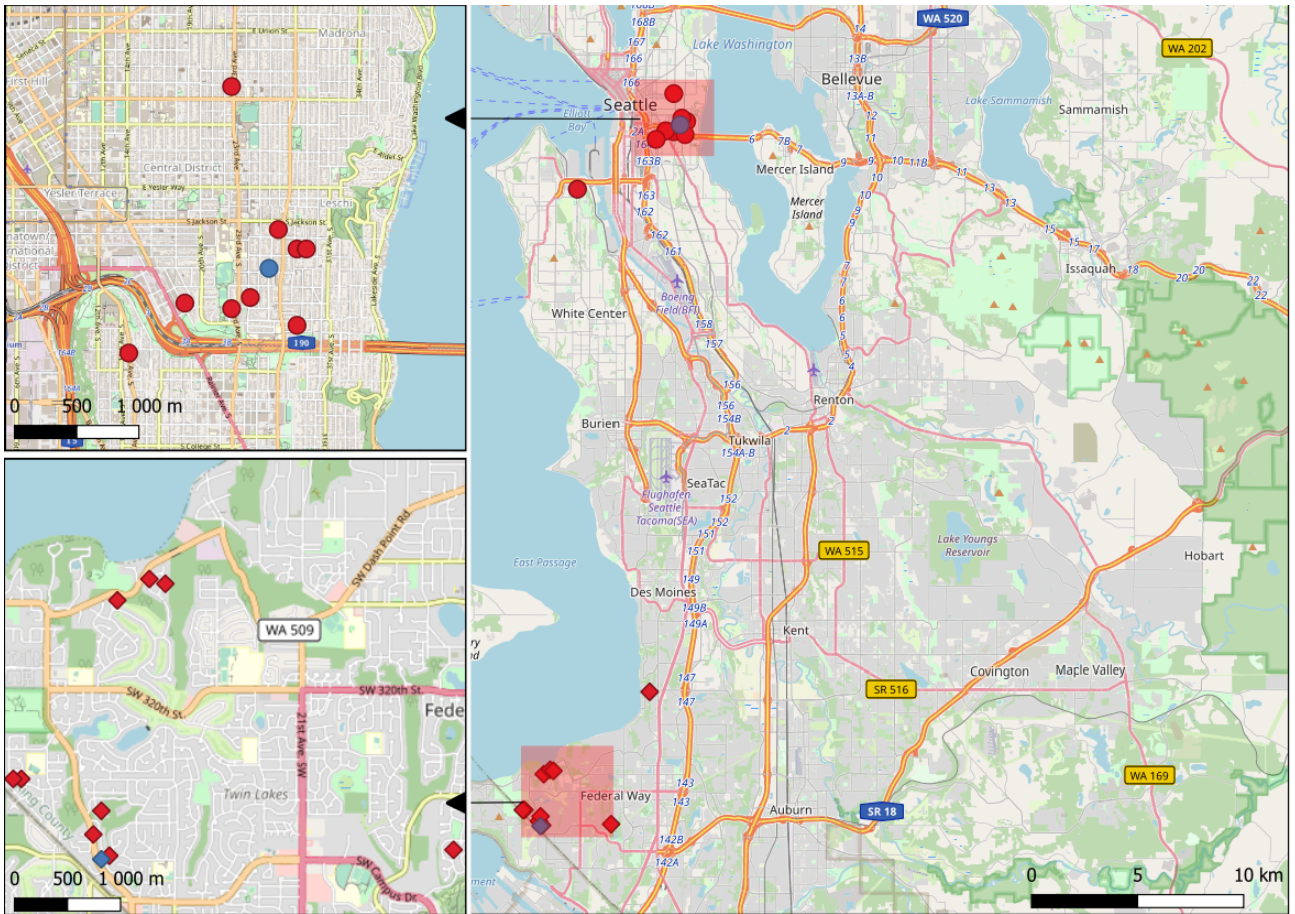


Figure 9.3 – Exemple sur de l'estimation immobilière. Les échantillons comparables à deux biens de même prix sont indiqués.

Dataset	Cat	XGBoost	ExpGB	ExpGBlog
MNIST pair/impair	0.986	0.987	0.960	0.978
MNIST chiffre	0.973	0.976	0.9390	0.964
MagicTelescope	0.865	0.862	0.840	0.861
UjilIndoorLoc bât. + étage	0.848	0.886	0.774	0.780
UjilIndoorLoc bât.	0.998	0.987	0.967	0.982

Table 9.2 – Performance de classification

L'algorithme que nous avons proposé consiste à suivre l'algorithme de Frank-Wolfe [81]. L'algorithme du gradient boosting est modifié de la façon suivante : au lieu d'utiliser l'arbre h_t pour la mise à jour de \hat{f}_t , l'algorithme proposé utilise un nouvel arbre g_t . Dans un sous-ensemble où h_t est positif, g_t prendra la plus grande valeur des y_n de ce sous-ensemble. Inversement, g_t prendra la plus petite valeur y_n dans un sous-ensemble où h_t est négatif. La mise à jour est alors obtenue par $\hat{f}_t = (1 - \alpha_t)\hat{f}_{t-1} + \alpha_t g_t$, avec α_t un pas décroissant. Cet algorithme garantit que les poids restent positifs. En effet, en supposant qu'une estimation à l'itération $t - 1$ pour un échantillon de test se décompose comme

$$\hat{f}_{t-1} = \sum_{n=1}^N w_{n,t-1} y_n, \quad (9.1)$$

l'estimation à l'itération suivante sera

$$\hat{f}_t = \sum_{n=1}^N w_{n,t} y_n, \quad (9.2)$$

avec $w_{n,t} = (1 - \alpha_t)w_{n,t-1}$, sauf pour l'échantillon d'apprentissage n^* ayant la valeur maximale, ou minimale, dans l'ensemble $A_{k,t}$ dans lequel se situe \mathbf{x} , pour qui $w_{n^*,t} = (1 - \alpha_t)w_{n^*,t-1} + \alpha_t$.

Cette nouvelle contrainte et cet algorithme présentent des performances compétitives par rapport à l'état de l'art en gradient boosting, comme le montrent les résultats du tableau 9.1.

En plus des performances comparables aux algorithmes de l'état de l'art, l'algorithme proposé permet de sélectionner, parmi l'ensemble d'apprentissage, des éléments comparables à l'élément testé, c'est à dire de caractéristiques similaires, et de valeur prédite similaire.

Ces éléments comparables sont obtenus en sélectionnant les éléments de l'ensemble d'apprentissage ayant les poids de décomposition les plus similaires à l'élément testé, au sens de la norme ℓ_1 . Les caractéristiques des éléments extraits pour le cas d'un jeu de données d'estimation immobilière dans la région de Seattle sont données figure 9.2. Les premières colonnes représentent les caractéristiques des échantillons, et la dernière le prix. La distribution des caractéristiques et des réponses est représentée par un histogramme. Les caractéristiques de l'élément testé sont données par la flèche verte, et les caractéristiques des 10 plus proches éléments de l'ensemble d'apprentissage sont indiquées par les disques bleus. La prédiction est donnée par le carré violet.

La première ligne donne les résultats de la méthode proposée, la deuxième les éléments ayant les prix les plus proches, et la troisième les éléments ayant les plus proches caractéristiques, au sens de la métrique de Mahalanobis. La méthode proposée permet d'extraire des éléments de l'ensemble d'apprentissage plus similaires que la proximité du prix ou des caractéristiques.

Un exemple plus visuel est donné sur la figure 9.3, où les emplacements géographiques des membres de l'ensemble d'apprentissage les plus similaires à deux maisons de même prix sont reportés sur une carte.

9.3 Le cas de la classification

E. Boizard, G. Chardon, F. Pascal, *Enhancing the Explainability of Gradient Boosting Classification through Comparable Samples Selection*, EUSIPCO, Lyon, France, 2024




Figure 9.4 – Reconnaissance de chiffres sur MNIST. Gauche : échantillons les plus similaires. Droite : choix aléatoire dans la classe.

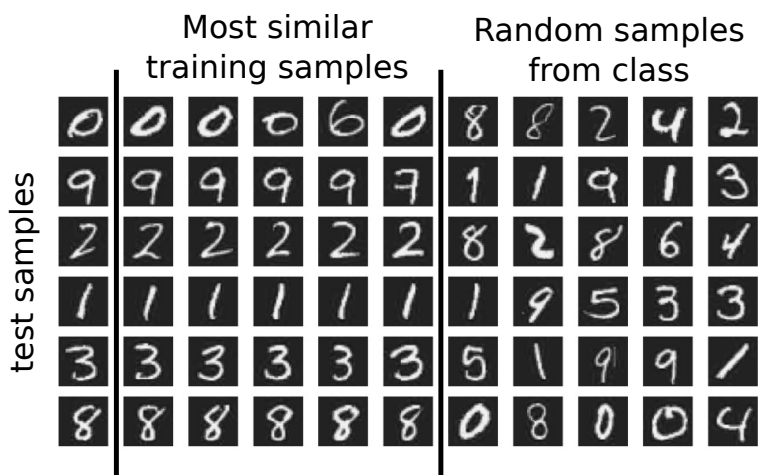


Figure 9.5 – Reconnaissance pair-impair sur MNIST. Gauche : échantillons les plus similaires. Droite : choix aléatoire dans la classe.




Figure 9.6 – Localisation d'un équipement wifi mobile, sur six cas, avec indication des cinq plus proches membres de l'ensemble d'apprentissage.

Une approche similaire peut être utilisée pour la classification, vue comme l'estimation des probabilités d'appartenance aux K classes. Dans les applications classiques du gradient boosting pour la classification, les probabilités $(p_1(\mathbf{x}), \dots, p_K(\mathbf{x}))$ sont transformées en

$$F_k(\mathbf{x}) = \log p_k(\mathbf{x}) - \frac{1}{K} \sum_{l=1}^K \log p_l(\mathbf{x}). \quad (9.3)$$

Dans cette nouvelle représentation, les valeurs $F_k(\mathbf{x})$ peuvent prendre des valeurs réelles arbitraires. La transformation inverse, le *softmax*

$$p_k(x) = \frac{e^{F_k(\mathbf{x})}}{\sum_{l=1}^K e^{F_l(\mathbf{x})}}, \quad (9.4)$$

a pour image l'ensemble des vecteurs de probabilité (de termes positifs et de somme 1). Le problème formulé avec les $F_k(\mathbf{x})$ ne nécessite donc plus de contrainte. Notre algorithme étant capable de prendre en compte des contraintes, il permet d'utiliser les probabilités directement.

Les performances de classification sur quelques jeux de données sont collectées dans le tableau 9.2, avec deux variantes pour la méthode proposée, utilisant le vrai gradient de l'entropie croisée formulé en fonction des probabilités, l'autre prenant en compte le gradient obtenu après la transformation (9.3), utilisé dans les algorithmes classiques de gradient boosting. Les jeux de données sont MNIST, avec une tâche de reconnaissance des chiffres, ou de leur parité seule, MagicTelescope, un jeu de données de physique des particules, et UjilIndoorLoc [82], une tâche de localisation à partir de données de puissance wifi dans trois bâtiments. Les performances en reconnaissance du bâtiment et de l'étage, ou du bâtiment seul, sont données. Comme dans le cas de la régression, les performances restent semblables à l'état de l'art.

L'extraction des similaires est ici obtenue en comptant le nombre de fois qu'un élément de l'ensemble d'apprentissage tombe dans la même feuille que l'élément testé et appartienne à la classe dont la probabilité dans cette feuille est la plus grande.

La figure 9.4 donne des exemples de comparables, et des échantillons pris au hasard dans la classe estimée, pour 6 échantillons de test MNIST pour la tâche de reconnaissance du chiffre. Les comparables sont bien plus ressemblants à l'élément de test, que les échantillons aléatoires.

La figure 9.5 montre le cas plus marquant de l'estimation de la parité. Alors que la tâche d'apprentissage

ne prend pas en compte le chiffre lui-même, les éléments comparables sont du même chiffre que l'élément de test (sauf quelques cas pathologiques, mais dont la forme reste similaire).

Enfin, dans le cas du jeu de données UjilndoorLoc, 6 exemples de localisation donnés figure 9.6, avec les 5 plus proches éléments de l'ensemble d'apprentissage. Ici également, les comparables sont physiquement proches de l'élément testé alors que les coordonnées ne sont pas prises en compte dans l'apprentissage ou l'inférence.

Notons enfin que le coût d'extraction de ces similaires est quasiment nul, l'extraction réutilisant des informations disponibles au cours de l'inférence. Des approches par exemple basées sur des plus proches voisins avec des distances appropriées nécessiteraient de parcourir toute la base et de calculer ces distances, un coût prohibitif pour des données de grandes dimensions, en terme de caractéristiques ou de nombre d'échantillons.

Chapitre 10

Sarah Roual

La thèse de Sarah Roual a débuté en mars 2023, avec l'équipe d'acoustique de Safran Tech, après un stage de Sarah dans cette même équipe. Cette thèse est co-encadrée par Charles Soussen, directeur de thèse, et moi-même à parts égales. L'encadrant industriel est Claude Sensiau, expert acoustique Safran.

L'objectif de la thèse de Sarah est la séparation des sources de bruit d'une turbomachine. Quantifier la puissance de ces sources permet d'orienter les efforts de réduction du bruit de ces turbomachines. Les travaux de stage et de début de thèse de Sarah se sont basés sur l'utilisation de la factorisation en matrices non négatives [83], exploitant la diversité des spectres et des directivités des sources lors de changement de régime ou de fréquence, et des a priori sur le spectre des sources.

La suite des travaux de thèse de Sarah s'orientera vers des décomposition de tenseurs ou de matrices de covariance, pour par exemple exploiter non seulement les spectres reçus sur chaque microphones, mais également les corrélations entre microphones [84].

Il est prévu que les méthodes développées soient testées sur des données réelles, obtenues lors de manipulation actuellement en cours de conception.

Une difficulté identifiée à la thèse est la faible disponibilité de données réelles de turbomachines. Cette difficulté n'est cependant pas de nature à entraver l'avancement de la thèse, les méthodes développées pouvant être validées sur les données expérimentales "académiques".

Un réacteur moderne typique est esquissé sur la figure 10.1. Les trois sources y sont indiquées, la source *soufflante* pouvant de plus être décomposée en une contribution aval et une contribution amont.

10.0.1 Décomposition en matrices non-négatives informée

S. Roual, C. Sensiau, G. Chardon, *Informed Source Separation for Turbofan Broadband Noise Using Non-Negative Matrix Factorization*, Forum Acusticum, Turin, Italy, 2023

Les premiers travaux se sont basés sur des mesures du spectre de bruit selon plusieurs directions. La matrice \mathbf{X} regroupant ces mesures de spectres, chaque colonne étant une direction, et chaque ligne une




Figure 10.1 – Schéma d'une turbomachine moderne.

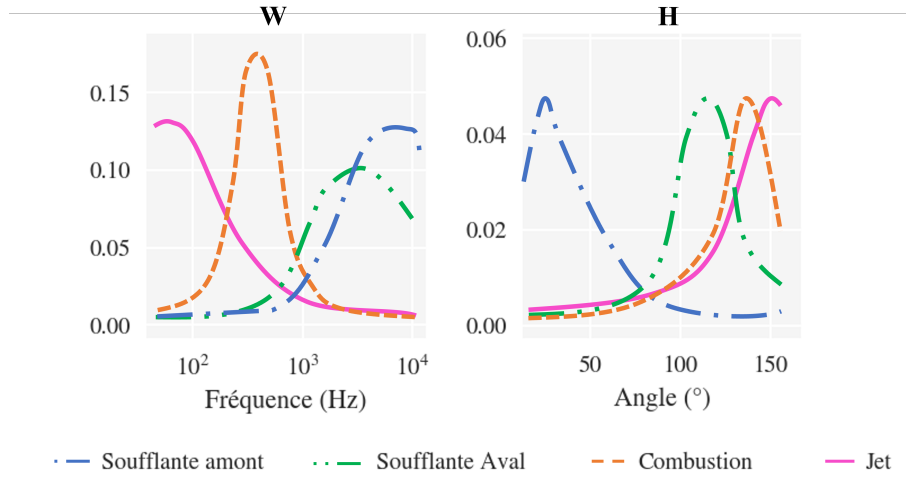


Figure 10.2 – Formes typiques des spectres et directivités des sources.

fréquence. Cette matrice est supposée être décomposable comme

$$\mathbf{X} = \mathbf{W}\mathbf{H} \quad (10.1)$$

où les colonnes \mathbf{W}_k de \mathbf{W} représentent les spectres des quatre sources, et les colonnes de \mathbf{H} la contribution de chacune de ces sources selon chaque direction. Les formes typiques des colonnes de \mathbf{W} et \mathbf{H} sont données figure 10.2.

Les termes de \mathbf{X} étant des densités spectrales de puissance, c'est la divergence d'Itakura-Saito qui est privilégiée pour l'estimation de \mathbf{W} et \mathbf{H} . En effet, cette divergence correspond au maximum de vraisemblance pour des sources gaussiennes. Avec

$$d(x, y) = \frac{x}{y} - \log \frac{x}{y} - 1, \quad (10.2)$$

les estimations des puissances et directivités sont obtenues en résolvant le problème

$$(\hat{\mathbf{W}}, \hat{\mathbf{H}}) = \underset{\mathbf{W} \geq 0, \mathbf{H} \geq 0}{\operatorname{argmin}} \sum_{f=1}^N \sum_{n=1}^N d(\mathbf{X}_{fn}, (\mathbf{W}\mathbf{H})_{fn}), \quad (10.3)$$

\geq représentant ici une inégalité terme à terme.

Les résultats de la figure 10.3 et du tableau 10.1 montrent les limites de cette application simple de la NMF : en particulier, les sources de jet et de combustion ne sont pas correctement estimées.

Pour améliorer les performances d'estimation, des a priori sont ajoutés sur la forme spectrale de ces sources. Ces informations peuvent être déduites des données disponibles chez Safran pour des moteurs de conception semblable. Un terme de régularisation est ajouté au problème (10.3) :

$$(\hat{\mathbf{W}}, \hat{\mathbf{H}}) = \underset{\mathbf{W} \geq 0, \mathbf{H} \geq 0}{\operatorname{argmin}} \sum_{f=1}^F \sum_{n=1}^N d(\mathbf{X}_{fn}, (\mathbf{W}\mathbf{H})_{fn}) + \sum_{k=1}^K \frac{\lambda_k}{2} \|\mathbf{W}_k - \bar{\mathbf{W}}_k\|_2^2 \quad (10.4)$$

où les $\bar{\mathbf{W}}_k$ sont les modèles pour chaque source, et les λ_k règlent, pour chaque source, le compromis entre les données et le modèle a priori. Les modèles $\bar{\mathbf{W}}_k$ sont construits à partir d'un mélange de résultats de campagnes de mesure précédentes sur des moteurs similaires, et de connaissances métier. Les paramètres λ_k sont pour l'instant déterminés à la main, mais une modélisation de la variabilité des motifs spectraux autour de leur moyennes $\bar{\mathbf{W}}_k$ permettrait un réglage plus rigoureux.

L'ajout de ces a priori permet effectivement d'améliorer les performances, en particulier pour le bruit de jet. Ces premiers travaux ont permis de valider l'approche sur des cas simples, et sont amenés à être développés, par exemple en prenant en compte plusieurs régimes de fonctionnement, ou en permettant à la forme spatiale des sources de varier suivant la fréquence.

Source	Puissance	IS-NMF	IS-NMF + a priori
Jet	77	3.46	0.88
Core	80	1.1	0.7
Fan Inlet	91	0.04	0.02
Fan Exhaust	91	0.46	0.40

Table 10.1 – Erreur (dB) d'estimation de la puissance des sources, pour NMF sans et avec information a priori.

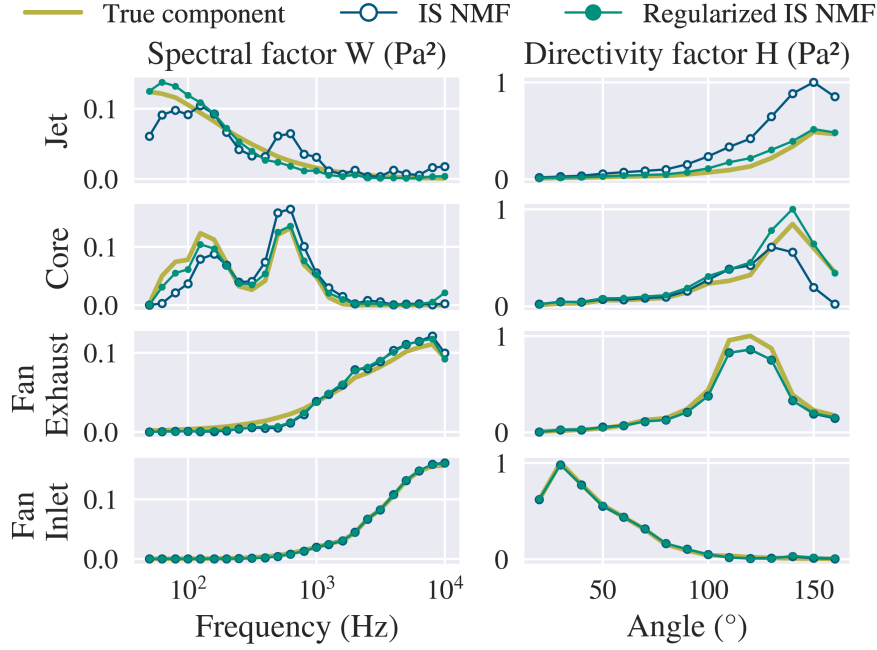


Figure 10.3 – Spectre et directivités estimées, avec et sans a priori.

10.1 Décomposition de matrices de covariances

Dans les résultats précédents, seule la puissance mesurée sur chaque direction a été exploitée. Or, les corrélations entre mesures sont une source d'information importante. Ces corrélations correspondent aux termes hors-diagonaux de la matrice de covariance des mesures. Comme précisé précédemment, dans le cas de sources gaussiennes, cette matrice contient toute l'information disponible, il est donc préférable de l'exploiter intégralement, en non seulement sa diagonale.

Ces corrélations sont utilisées dans PSDTF, ou Multichannel NMF [84, 85]. Nous nous plaçons ici à une fréquence donnée, mais à plusieurs régimes de fonctionnement, où les sources auront des puissances différentes. En supposant les sources décorréelées, les matrices de covariances des mesures Σ_m se décomposent comme

$$\Sigma_m = \sum_{k=1}^K p_{mk} \mathbf{R}_k \quad (10.5)$$

où p_{mk} est la puissance de la source k au régime m , et \mathbf{R}_k la matrice de covariance spatiale de la source k .

Ces quantités sont estimées en résolvant le problème

$$((\hat{p}_{mk}), (\hat{\mathbf{R}}_k)) = \underset{p_{mk} \geq 0, \mathbf{R}_k \succ 0}{\operatorname{argmin}} \sum_{m=1}^M \left[\operatorname{tr} \left(\left(\sum_{k=1}^K p_{mk} \mathbf{R}_k \right)^{-1} \hat{\Sigma}_m \right) + \log \det \left(\sum_{k=1}^K p_{mk} \mathbf{R}_k \right) \right] \quad (10.6)$$

de maximum de vraisemblance, dont (10.3) est un cas particulier pour des matrices diagonales. $\succ 0$ désigne




Figure 10.4 – Erreurs d'estimation des puissances des sources par NMF et PSDTF, en fonction de la fréquence.

ici la semi-définie positivité des matrices. Les matrices $\hat{\Sigma}_m$ sont des estimations des matrices de covariances Σ_m (*Sample Covariance Matrix*), obtenues par l'équation (2.4). Nous avons utilisé l'algorithme multiplicatif de [84], garantissant la semi-définie positivité des matrices \mathbf{R}_k à chaque itération.

L'utilisation des matrices de covariances complètes permet de tirer profit au mieux de la diversité spatiale des sources, même si les modèles de sources ne sont pas connus.

Des premières comparaisons entre NMF et PSDTF pour ce problème ont été faites sur des mesures expérimentales, avec cinq sources dans une salle de réunion de CentraleSupélec, émettant du bruit blanc avec des puissances tirées aléatoirement sur trente "régimes", mesurées par huit microphones. La métrique de performance choisie est l'erreur quadratique moyenne d'estimation de la puissance de chaque source à chaque microphone et à chaque régime.

Les EQM sont tracées dans la figure (10.4) en fonction de la fréquence. Elles montrent que PSDTF permet d'atteindre de meilleures performances d'estimation des puissances des sources. Rappelons que cette estimation se fait sans connaissance a priori d'un modèle de source.

Un campagne de mesures est en cours sur un dispositif plus proche du cas applicatif, avec l'utilisation de quatre sources de directivités semblables à celle des sources d'un turboréacteur, mesurées par 32 microphones dans une salle traitée acoustiquement sur le site de Safran Tech, visible figure 10.5.

10.2 Perspectives de la thèse

La suite de la thèse consistera d'une part à approfondir les modèles de décomposition, pour prendre en compte le maximum d'information. On pourra notamment ajouter la dimension fréquentielle au problème de décomposition de matrices de covariance. D'autre part, des décompositions comme (10.1) font l'hypothèse que la directivité des sources est constante selon la fréquence, ce qui est physiquement peu probable. L'utilisation de décompositions permettant un relâchement de cette contrainte permettrait de rester au plus près de la physique du problème[86].

D'autre part, l'application de ces méthodes à des données réelles est nécessaire pour une validation complète de la méthode. Plusieurs défis se présentent ici. Comme toujours, l'utilisation de données réelles est rarement élémentaire (quand on en a!).




Figure 10.5 – Dispositif expérimental pour la validation de la méthode PSDTF.

Troisième partie

Perspectives

Chapitre 11

Perspectives acoustiques

Les directions possibles de recherche en localisation de sources (ou imagerie acoustique en général) sont nombreuses, les spécificités de ce domaine amènent à l'existence d'une multitude de problèmes différents. On peut identifier quatre axes, certains déjà explorés, mais qui méritent approfondissement :

- la localisation de sources ne rayonnant pas de façon isotrope dans l'espace,
- la prise en compte des corrélations entre sources,
- l'identification de sources étendues,
- et l'utilisation de réseaux asynchrones

Comme pour mes travaux passés, l'objectif est de proposer des méthodes basées sur des fondations théoriques solides, d'analyser leurs performances par rapport à l'état de l'art et des bornes (BCR ou autres), et de les appliquer sur des données réelles.

Quelques remarques sur la nécessité de jeux de données de validation, l'application à des cas réels, et l'apprentissage concluent ces perspectives acoustiques.

11.1 Sources directives

Les méthodes présentées dans les chapitres 3, 4 et 5 font toutes l'hypothèse que le modèle de source est décrit uniquement par la position de la source. Ceci est le cas pour des sources monopolaires (rayonnant de façon identique dans toutes les directions), mais des sources plus complexes existent. En général, le rayonnement $p(\mathbf{x})$ d'une source quelconque peut être décomposé sur des harmoniques sphériques, par exemple pour une source à l'origine, en coordonnées sphériques,

$$p(\mathbf{x}) = \sum_{l=0}^{\infty} \sum_{m=-l}^l a_{lm} Y_{lm}(\theta, \phi) h_l(kr) \quad (11.1)$$

où les Y_{lm} sont les harmoniques sphériques, les h_l les fonctions de Hankel sphérique et k le nombre d'onde. Le diagramme de directivité de la source est caractérisé par les coefficients a_{lm} .

Pour un monopole, seul le coefficient d'ordre $l = 0$ est actif. Un haut-parleur non bafflé peut être raisonnablement modélisé par un dipole, où seuls les coefficients pour $l = 1$ sont actifs, liés par des relations de phase particulières, et dont les amplitudes relatives pilotent la direction du dipôle. Le mode de vibration principal d'un diapason rayonne lui comme un quadropole, avec les coefficients pour $l = 0$ et $l = 2$ actifs.

J'avais proposé, sans suite, une variante de MUSIC permettant de prendre en compte de telles sources [87]. Avec Étienne Monier, alors en stage de M2, nous avons pu mettre en valeur quelques difficultés liées à la localisation de sources de directivités complexes [88]. En particulier, une surestimation de la complexité du diagramme de rayonnement (par exemple, incluant les termes pour $l = 1$ alors que la source est monopolaire) a pour conséquence la singularité de la matrice d'information de Fisher, et donc une mauvaise estimation de la position et des coefficients de décomposition de la source. Cet effet est dû à la possibilité de transporter la décomposition (11.1) en un autre point de référence, avec de nouveaux coefficients a_{lm} (Théorème de Graf). En particulier, un monopole peut être bien approximé par une source constituée d'un monopole et d'un dipole légèrement déplacés.

Ces travaux n'ont pas encore eu de suite. Il reste encore à valider expérimentalement les résultats obtenus, et aussi à considérer des modèles permettant de rendre identifiable les paramètres des sources,

par exemple en ajoutant des contraintes de phases entre les ordres de décomposition, ou en sélectionnant les ordres intervenant dans la décomposition. Pour ces choix de modèles, on pourra alors procéder comme précédemment, en étudiant les performances atteignables et en dérivant le maximum de vraisemblance dans le cas d'une source, et en étendant au cas de plusieurs sources avec un formalisme sans grille. Pour le cas des dipôles, on peut penser à une approche alternative consistant à manipuler des mesures définies sur le produit cartésien du volume des sources Ω et des directions possibles du dipôle (ici la sphère, ou plus précisément le plan projectif $P^2(\mathbf{R})$).

La localisation de sources directives a fait depuis peu l'objet de plusieurs travaux [89, 90, 91], il paraît opportun d'approfondir les travaux engagés dans cette voie, en suivant la démarche déjà utilisée dans les résultats précédents, basée sur de solides bases statistiques.

11.2 Sources corrélées

L'algorithme CMF-OLS permet l'imagerie de sources corrélées avec des temps de calcul raisonnables. Il y a ici une opportunité de vérifier expérimentalement si l'hypothèse de décorrélation des sources généralement faite en imagerie acoustique est vérifiée dans les cas d'application des méthodes de l'état de l'art. On peut par exemple prévoir que CLEAN-SC [48], qui à chaque itération nettoie la matrice de covariance des mesures non seulement de la source identifiée, mais également de tout ce qui pourrait y être corrélé, risque de sous-estimer, voir ne pas identifier, des sources acoustiques corrélées à une source précédemment identifiée.

Il est raisonnable de penser que dans les conditions expérimentales courantes, de telles corrélations peuvent apparaître, par la présence de réflexions sur des structures mécaniques, ou par la corrélation spatiale inhérente aux phénomènes de turbulence [92].

Sur le plan algorithmique, la similarité entre les algorithmes gloutons de type Matching Pursuit et l'algorithme de Frank Wolfe [93] laisse à penser qu'une formulation de la localisation de sources corrélées sans grille permettrait d'aboutir à un algorithme semblable à CMF-OLS, mais justifié par la résolution d'un problème d'optimisation. Cet algorithme contribuerait encore à découpler la complexité du problème numérique de la taille de la zone à imager. Des premiers essais semblent montrer que la contrainte de SDP pourrait rendre la conception d'un tel algorithme non triviale, les termes intervenant dans la décomposition de la solution (en suivant [45]) étant beaucoup moins simple que des masses de Dirac comme dans le cas de sources non corrélées.

11.3 Sources étendues

Un sujet lié au problème des sources corrélées et celui des sources étendues [94, 95]. Comme le problème des sources directives, le problème des sources étendues pose des difficultés fondamentales. En effet, une distribution sphérique de sources cohérentes ne peut pas être distinguée d'une source monopolaire placée en son centre. Les champs acoustiques générés par ces deux distributions de sources sont invariants par rotation, ce qui entraîne la même propriété pour le champ généré, qui sera alors nécessairement monopolaire.

On voit aussi réapparaître le problème de corrélation entre les sources, une source étendue ne générant pas le même champ suivant les corrélations à l'intérieur de l'étendue.

Sous l'hypothèse que ces difficultés soient contournées, les méthodes sans grilles pourraient ici être mises à profit, sous deux formes. Dans une formulation paramétrique, l'étendue des sources pourrait être modélisée par des formes géométriques simples paramétrées, l'espace sur laquelle les mesures sont définies étant enrichie par ces paramètres (comme pour le cas de la localisation de dipôles ci-dessus). Dans une formulation non paramétrique, un problème de BLASSO avec variation totale [96, 97] pourrait être considéré, posant moins de contraintes sur les formes des distributions spatiales des sources, mais des défis algorithmiques sont à prévoir.

11.4 Réseaux asynchrones

Le chapitre 5 a donné une analyse de l'utilisation de réseaux asynchrones dans le cas particulier d'une source à localiser. C'est un premier pas vers des méthodes de localisation efficaces, tant en performance qu'en temps de calculs. En effet, en général les méthodes basées sur la complétion de matrice sont plus lentes, et paraissent moins précises. Il reste encore à trouver les bons arguments à même de convaincre les promoteurs de ces méthodes qu'elles ne peuvent pas donner de meilleures performances que les celles basées sur l'exploitation directe des matrices de covariance associées à chaque sous-réseau (qualifié d'"intrusives" dans certaines publications). La théorie de l'estimation statistique donne une réponse simple : ces matrices de covariance partielles sont une statistique suffisante pour l'estimation des paramètres des sources, il est donc illusoire de chercher de l'information en reconstruisant une matrice de covariance complète.

11.5 Diffusion des méthodes et jeux de données de référence

En général, une limite des publications de l'état de l'art en localisation de source ou imagerie acoustique (par ex., dans *Journal of Sound and Vibration*, *Journal of the Acoustical Society of America*, *Applied Acoustics*, etc.) est la comparaison souvent partielle avec l'état de l'art, sur des jeux de données propres aux auteurs. Ceci empêche une comparaison équitable entre les multiples méthodes de la littérature. On trouve tout de même quelques articles présentant de telles comparaisons, mais sur des cas limités ou synthétiques [18, 98]. On ne trouve cependant pas de jeux de données et de tâches standard comme on pouvait par exemple le voir dans le domaine de la séparation de sources audio avec SiSEC.

Je pense qu'il est important de construire des jeux de données réelles, balayant un large spectre de configurations de sources, de réseaux de microphones, de tâches, etc., avec le code associé regroupant les méthodes de l'état de l'art (les miennes en particulier...), pour que les auteurs puissent donner des comparaisons pertinentes entre les méthodes qu'ils proposent et l'état de l'art.

11.6 Application à des cas réels

Les méthodes présentées dans ce document, ainsi que les perspectives de ce même chapitre, ont été, ou devraient être, validées sur des données réelles. Cependant, ces données expérimentales représentent des cas plutôt académiques, dans un environnement contrôlé, avec un nombre réduit de sources. Pour convaincre les utilisateurs de méthodes de localisation de sources acoustiques, il est nécessaire de démontrer la pertinence de ces méthodes dans des cas pratiques plus proches des réelles applications. Il est nécessaire pour cela de lancer des collaborations avec des expérimentateurs, sur le plateau de Saclay comme ailleurs, comme j'ai déjà eu l'occasion de le faire avec François Ollivier.

11.7 Et l'apprentissage ?

Il est évidemment impossible de ne pas parler de méthodes basées sur l'apprentissage étant donnée la quantité de travaux récents sur ce sujet, tant en général que pour l'acoustique.

Les quelques essais de déconvolution ou de localisation de sources basées sur du deep learning ne m'ont pas semblé très convaincants [99, 100, 101, 102, 103], la comparaison avec l'état de l'art étant souvent incomplète. De plus, en comparaison avec des applications en vision par ordinateur par exemple, de telles méthodes nécessitent des apprentissages très lourds, en raison

- du manque de structure dans le modèle direct (en général, pas de structure de convolution)
- de configurations de réseaux moins contraintes qu'une grille régulière de pixel comme pour une image
- de la nécessité de prise en compte d'un grand nombre de fréquences
- et enfin de la grande dimension des problèmes, par exemple pour la localisation de source en 3D ou l'estimation de covariances.

Ces observations ne sont pas l'expression d'un refus catégorique d'appliquer des méthodes de machine learning à l'imagerie acoustique, mais je pense qu'il est pour l'instant plus efficace de développer des méthodes dont on comprend le fonctionnement.

Chapitre 12

Chaire Forvia

Les années prochaines de ma carrière vont être profondément colorées par la chaire de recherche Forvia dont je suis le porteur. Cette chaire a pour thème la fusion de capteurs pour des systèmes d'aide à la conduite. Les capteurs considérés sont, par exemple, des caméras, des RADAR, LIDAR, des capteurs internes à l'habitacle, etc., Deux directions de recherche sont pour l'instant clairement identifiées et développées plus bas. D'autres thèmes, comme par exemple la surveillance de l'intérieur de l'habitacle ou de la conduite sont en discussion, mais pas encore arrêtés.

À noter que contrairement au chapitre précédent, l'utilisation d'image et d'audio, en particulier, rend le deep learning particulièrement pertinent pour ces applications.

12.1 Fusion de données caméra-RADAR

La multiplication des capteurs et de la puissance de calcul embarquée sur les véhicules automobiles permet de proposer des systèmes d'aide à la conduite de plus en plus perfectionnés.

Ces systèmes nécessitent une connaissance précise de l'état du véhicule et de son environnement. Cette connaissance peut, par exemple, être acquise par de la fusion de données caméra-RADAR, pour des véhicules équipés de caméras, fournissant des images de l'environnement du véhicule, et de capteurs RADAR, permettant la détection d'objets, et l'estimation de leur distance et vitesse radiale relatives au véhicule. Caméra et RADAR sont complémentaires. En effet, une caméra sera sensible à la couleur, la texture, la forme, permettant d'identifier un objet, tandis qu'un RADAR pourra estimer précisément sa distance et sa vitesse. Ainsi, fusionner les données provenant des caméras et des RADAR permet une caractérisation complète de l'environnement du véhicule.

La fusion de données RADAR et image a fait l'objet de nombreuses publications, avec comme applications la détection et classification des objets entourant le véhicule (autres véhicules, piétons, mobilier urbain, etc.), ou l'estimation de leurs trajectoires. Cependant, les méthodes de l'état de l'art ne permettent pas d'estimer l'incertitude des quantités estimées, et sont lourdes en temps de calculs. De plus, les estimations de distances obtenues par RADAR présentent des limitations, notamment par rapport au LIDAR. Les points RADAR sont peu denses, ils présentent des erreurs non négligeables, et de nombreux points aberrants apparaissent.

Un objectif de la chaire est de contribuer à la robustesse de la fusion de données caméra-RADAR [104]. La méthodologie proposée se place en rupture avec l'état de l'art, d'une part en utilisant une modélisation tridimensionnelle des points d'intérêt, là où la plupart des travaux récents considèrent une vue de face ou de haut de la scène, et d'autre part, en prenant en compte la dynamique des images et points RADAR. Cette méthodologie pourra se baser sur l'interprétation des points RADAR et des images comme des marginales de la configuration tridimensionnelle de l'environnement [105], et sur des algorithmes de tracking de nuages de points [106].

Les résultats attendus sont une amélioration de l'estimation de l'environnement du véhicule, une meilleure robustesse aux points RADAR aberrants, et une demande en puissance de calcul réduite. Cette réduction de puissance de calcul est rendue possible par l'utilisation directe des points RADAR de densité réduite, propriété le plus souvent perçue comme une limite du RADAR.

12.2 Autocalibration de réseaux de caméras

Certains véhicules sont équipés de caméra observant l'environnement suivant plusieurs directions. La position et l'orientation des caméras par rapport à la structure de la voiture doit être connue avec précision. Or, la géométrie du réseau de caméra peut varier au cours de l'existence du véhicule, suite à des déformations de sa structure, etc. à court et à long terme.

Le développement de méthodes d'autocalibration permettrait l'estimation de la géométrie du réseau de caméra par rapport à son évolution à long terme, c'est à dire la mise à jour, en temps réel, de l'orientation des caméras.

Ce sujet d'importance a fait l'objet de nombreux travaux, généralement limités au cas d'une caméra, nécessitant la présence de référence connues (cibles en damier [107], structure du véhicule dans le champ de vision [108] etc.) ou un environnement particulièrement structuré (marquages de la chaussée [109], monde "Manhattan" [110]). L'objectif du projet est de mener cette autocalibration dans un environnement quelconque (par exemple, route de campagne ou offroad), sans nécessité de références artificielles ou de structures particulières de l'environnement. De plus, il est important de pouvoir rendre compte de l'incertitude de l'estimation de la géométrie du réseau de caméras.

La méthodologie envisagée se base sur l'exploitation du déplacement du véhicule, des chevauchements des champs de vision des caméras, ainsi que l'estimation bayésienne [111] ou le filtrage de Kalman sur des groupes de Lie [112] permettant d'estimer les incertitudes de calibration.

Bibliographie

- [1] H. Krim and M. Viberg, "Two decades of array signal processing research : the parametric approach," *IEEE Signal Processing Magazine*, vol. 13, pp. 67–94, July 1996.
- [2] M. Pesavento, M. Trinh-Hoang, and M. Viberg, "Three More Decades in Array Signal Processing Research : An optimization and structure exploitation perspective," *IEEE Signal Processing Magazine*, vol. 40, pp. 92–106, June 2023. Conference Name : IEEE Signal Processing Magazine.
- [3] R. Merino-Martínez, P. Sijtsma, M. Snellen, T. Ahlefeldt, J. Antoni, C. J. Bahr, D. Blacodon, D. Ernst, A. Finez, S. Funke, T. F. Geyer, S. Haxter, G. Herold, X. Huang, W. M. Humphreys, Q. Leclère, A. Malgoezar, U. Michel, T. Padois, A. Pereira, C. Picard, E. Sarradj, H. Siller, D. G. Simons, and C. Spehr, "A review of acoustic imaging methods using phased microphone arrays : Part of the "Aircraft Noise Generation and Assessment" Special Issue," *CEAS Aeronautical Journal*, vol. 10, pp. 197–230, Mar. 2019.
- [4] P. Stoica and A. Nehorai, "Performance study of conditional and unconditional direction-of-arrival estimation," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 38, pp. 1783–1795, Oct. 1990.
- [5] B. Picinbono, "Second-order complex random vectors and normal distributions," *IEEE Trans. on Signal Process.*, vol. 44, pp. 2637–2640, Oct. 1996. Conference Name : IEEE Transactions on Signal Processing.
- [6] E. Lehmann and G. Casella, *Theory of Point Estimation*. Springer, second ed., 1998. Chapter 6.
- [7] J. Shao, *Mathematical Statistics*. Springer, second ed., 2003. Chapter 2.
- [8] A. Renaux, P. Forster, E. Chaumette, and P. Larzabal, "On the high-SNR conditional maximum-likelihood estimator full statistical characterization," *IEEE Transactions on Signal Processing*, vol. 54, no. 12, pp. 4840–4843, 2006.
- [9] T. F. Brooks and W. M. Humphreys, "A deconvolution approach for the mapping of acoustic sources (DAMAS) determined from phased microphone arrays," *Journal of Sound and Vibration*, vol. 294, pp. 856–879, July 2006.
- [10] T. Yardibi, J. Li, P. Stoica, and L. N. Cattafesta, "Sparsity constrained deconvolution approaches for acoustic source mapping," *The Journal of the Acoustical Society of America*, vol. 123, pp. 2631–2642, May 2008.
- [11] E. Sarradj, "Three-Dimensional Acoustic Source Mapping with Different Beamforming Steering Vector Formulations," *Advances in Acoustics and Vibration*, vol. 2012, p. e292695, June 2012. Publisher : Hindawi.
- [12] M. Polichetti, V. Baron, J. I. Mars, and B. Nicolas, "Multiplane deconvolution in underwater acoustics : Simultaneous estimations of source level and position," *JASA Express Letters*, vol. 1, p. 076001, July 2021.
- [13] T. Padois and A. Berry, "Two and Three-Dimensional Sound Source Localization with Beamforming and Several Deconvolution Techniques," *Acta Acustica united with Acustica*, vol. 103, p. 10, 2017.
- [14] D. Sun, C. Ma, J. Mei, and W. Shi, "Improving the resolution of underwater acoustic image measurement by deconvolution," *Applied Acoustics*, vol. 165, p. 107292, 2020.

- [15] H. Ding, Y. Bao, Q. Huang, C. Li, and G. Chai, "Three-dimensional localization of point acoustic sources using a planar microphone array combined with beamforming," *Royal Society Open Science*, vol. 5, no. 12, 2018.
- [16] L. Chen, Y. Xiao, and T. Yang, "Application of the improved fast iterative shrinkage-thresholding algorithms in sound source localization," *Applied Acoustics*, vol. 180, p. 108101, 2021.
- [17] T. Padois and A. Berry, "Orthogonal matching pursuit applied to the deconvolution approach for the mapping of acoustic sources inverse problem," *The Journal of the Acoustical Society of America*, vol. 138, pp. 3678–3685, Dec. 2015.
- [18] G. Herold and E. Sarradj, "Performance analysis of microphone array methods," *Journal of Sound and Vibration*, vol. 401, pp. 152–168, Aug. 2017.
- [19] P. Sijtsma, R. Merino-Martinez, A. M. Malgoezar, and M. Snellen, "High-resolution CLEAN-SC : Theory and experimental validation," *International Journal of Aeroacoustics*, vol. 16, pp. 274–298, July 2017. Publisher : SAGE Publications.
- [20] E. Sarradj, "A fast signal subspace approach for the determination of absolute levels from phased microphone array measurements," *Journal of Sound and Vibration*, vol. 329, pp. 1553–1569, Apr. 2010.
- [21] L. Gilquin, S. Bouley, J. Antoni, T. Le Magueresse, and C. Marteau, "Sensitivity analysis of two inverse methods : Conventional Beamforming and Bayesian focusing," *Journal of Sound and Vibration*, vol. 455, pp. 188–202, Sept. 2019.
- [22] H.-G. Raumer, C. Spehr, T. Hohage, and D. Ernst, "Weighted data spaces for correlation-based array imaging in experimental aeroacoustics," *Journal of Sound and Vibration*, vol. 494, p. 115878, Mar. 2021.
- [23] Y. Zhou, V. Valeau, J. Marchal, F. Ollivier, and R. Marchiano, "Three-dimensional identification of flow-induced noise sources with a tunnel-shaped array of MEMS microphones," *Journal of Sound and Vibration*, vol. 482, p. 115459, Sept. 2020.
- [24] W. Ma, H. Bao, C. Zhang, and X. Liu, "Beamforming of phased microphone array for rotating sound source localization," *Journal of Sound and Vibration*, vol. 467, p. 115064, Feb. 2020.
- [25] X. Wang, B. Quost, J.-D. Chazot, and J. Antoni, "Iterative beamforming for identification of multiple broadband sound sources," *Journal of Sound and Vibration*, vol. 365, pp. 260–275, Mar. 2016.
- [26] T. Padois, J. Fischer, C. Doolan, and O. Doutres, "Acoustic imaging with conventional frequency domain beamforming and generalized cross correlation : a comparison study," *Applied Acoustics*, vol. 177, p. 107914, June 2021.
- [27] J. Fischer and C. Doolan, "Improving acoustic beamforming maps in a reverberant environment by modifying the cross-correlation matrix," *Journal of Sound and Vibration*, vol. 411, pp. 129–147, Dec. 2017.
- [28] S. Fortunati, F. Gini, M. S. Greco, and C. D. Richmond, "Performance Bounds for Parameter Estimation under Misspecified Models : Fundamental Findings and Applications," *IEEE Signal Processing Magazine*, vol. 34, pp. 142–157, Nov. 2017.
- [29] R. Schmidt, "Multiple emitter location and signal parameter estimation," *IEEE Transactions on Antennas and Propagation*, vol. 34, pp. 276–280, Mar. 1986.
- [30] R. Roy and T. Kailath, "ESPRIT-estimation of signal parameters via rotational invariance techniques," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 37, pp. 984–995, July 1989.
- [31] P. Richtárik and M. Takáč, "Iteration Complexity of Randomized Block-Coordinate Descent Methods for Minimizing a Composite Function," *arXiv :1107.2848 [math, stat]*, July 2011. arXiv : 1107.2848.
- [32] T. Hohage, H.-G. Raumer, and C. Spehr, "Uniqueness of an inverse source problem in experimental aeroacoustics," *Inverse Problems*, vol. 36, p. 075012, July 2020. Publisher : IOP Publishing.

- [33] C. L. Lawson and R. J. Hanson, *Solving Least Squares Problems*. Society for Industrial and Applied Mathematics, 1995.
- [34] M. Slawski and M. Hein, "Non-negative least squares for high-dimensional linear models : Consistency and sparse recovery without regularization," *Electronic Journal of Statistics*, vol. 7, pp. 3004–3056, 2013.
- [35] V. Duval and G. Peyré, "Sparse regularization on thin grids I : the Lasso," *Inverse Problems*, vol. 33, p. 055008, Mar. 2017.
- [36] A. Xenaki and P. Gerstoft, "Grid-free compressive beamforming," *The Journal of the Acoustical Society of America*, vol. 137, pp. 1923–1935, Apr. 2015. Publisher : Acoustical Society of America.
- [37] C. Ekanadham, D. Tranchina, and E. P. Simoncelli, "Recovery of Sparse Translation-Invariant Signals With Continuous Basis Pursuit," *IEEE Transactions on Signal Processing*, vol. 59, pp. 4735–4744, Oct. 2011. Conference Name : IEEE Transactions on Signal Processing.
- [38] Y. Park, W. Seong, and P. Gerstoft, "Block-sparse two-dimensional off-grid beamforming with arbitrary planar array geometry," *The Journal of the Acoustical Society of America*, vol. 147, pp. 2184–2191, Apr. 2020.
- [39] V. Duval and G. Peyré, "Sparse spikes super-resolution on thin grids II : the continuous basis pursuit," *Inverse Problems*, vol. 33, p. 095008, aug 2017.
- [40] B. Mamandipoor, D. Ramasamy, and U. Madhow, "Newtonized Orthogonal Matching Pursuit : Frequency Estimation Over the Continuum," *IEEE Transactions on Signal Processing*, vol. 64, pp. 5066–5081, Oct. 2016. Conference Name : IEEE Transactions on Signal Processing.
- [41] Y. Yang, Z. Chu, Y. Yang, and S. Yin, "Two-dimensional Newtonized orthogonal matching pursuit compressive beamforming," *The Journal of the Acoustical Society of America*, vol. 148, pp. 1337–1348, Sept. 2020. Publisher : Acoustical Society of America.
- [42] Q. Denoyelle, V. Duval, G. Peyré, and E. Soubies, "The sliding Frank–Wolfe algorithm and its application to super-resolution microscopy," *Inverse Problems*, vol. 36, p. 014001, Dec. 2019. Publisher : IOP Publishing.
- [43] B. Ottersten, P. Stoica, and R. Roy, "Covariance Matching Estimation Techniques for Array Signal Processing Applications," *Digital Signal Processing*, vol. 8, pp. 185–210, July 1998.
- [44] P. Stoica, P. Babu, and J. Li, "SPICE : A Sparse Covariance-Based Estimation Method for Array Processing," *IEEE Transactions on Signal Processing*, vol. 59, pp. 629–638, Feb. 2011.
- [45] C. Boyer, A. Chambolle, Y. D. Castro, V. Duval, F. de Gournay, and P. Weiss, "On representer theorems and convex regularization," *SIAM Journal on Optimization*, vol. 29, no. 2, pp. 1260–1281, 2019.
- [46] C. R. Rojas, D. Katselis, and H. Hjalmarsson, "A Note on the SPICE Method," *IEEE Transactions on Signal Processing*, vol. 61, pp. 4545–4551, Sept. 2013.
- [47] E. Sarradj, "Three-dimensional gridless source mapping using a signal subspace approach," in *BEBEC 2022, Berlin, Germany*, 2022.
- [48] P. Sijtsma, "CLEAN based on spatial source coherence," *International Journal of Aeroacoustics*, vol. 6, pp. 357–374, May 2007.
- [49] A. M. N. Malgoezar, M. Snellen, R. Merino-Martinez, D. G. Simons, and P. Sijtsma, "On the use of global optimization methods for acoustic source mapping," *The Journal of the Acoustical Society of America*, vol. 141, pp. 453–465, Jan. 2017. Publisher : Acoustical Society of America.
- [50] B. von den Hoff, R. Merino-Martínez, D. G. Simons, and M. Snellen, "Using global optimization methods for three-dimensional localization and quantification of incoherent acoustic sources," *JASA Express Letters*, vol. 2, p. 054802, May 2022.

- [51] P.-J. Bénard, Y. Traonmilin, J.-F. Aujol, and E. Soubies, "Estimation of off-the grid sparse spikes with over-parametrized projected gradient descent : theory and application," *Inverse Problems*, vol. 40, p. 055010, Mar. 2024. Publisher : IOP Publishing.
- [52] J.-B. Courbot and B. Colicchio, "A fast homotopy algorithm for gridless sparse recovery," *Inverse Problems*, vol. 37, p. 025002, Jan. 2021. Publisher : IOP Publishing.
- [53] J.-M. Azaïs, Y. de Castro, and F. Gamboa, "Spike detection from inaccurate samplings," *Applied and Computational Harmonic Analysis*, vol. 38, pp. 177–195, Mar. 2015.
- [54] T. Yardibi, J. Li, P. Stoica, N. S. Zawodny, and L. N. Cattafesta, "A covariance fitting approach for correlated acoustic source mapping," *The Journal of the Acoustical Society of America*, vol. 127, no. 5, pp. 2920–2931, 2010.
- [55] T. F. Brooks and W. M. Humphreys, "Extension of DAMAS phased array processing for spatial coherence determination (DAMAS-C)," *AIAA paper*, vol. 2654, p. 2006, 2006.
- [56] S. Chen, S. A. Billings, and W. Luo, "Orthogonal least squares methods and their application to non-linear system identification," *International Journal of Control*, vol. 50, no. 5, pp. 1873–1896, 1989.
- [57] P. Castellini and A. Sassaroli, "Acoustic source localization in a reverberant environment by average beamforming," *Mech. Syst. Signal Process.*, vol. 24, pp. 796–808, Apr. 2010.
- [58] R. Porteous, Z. Prime, C. J. Doolan, D. J. Moreau, and V. Valeau, "Three-dimensional beamforming of dipolar aeroacoustic sources," *J. Sound Vib.*, vol. 355, pp. 117–134, Oct. 2015.
- [59] L. Kleine-Wächter, J. Ocker, D. Döbler, C. Puhle, and G. Herold, "Investigations on beamforming in the wind tunnel using multiple microphone array measurements," in *BEBEC 2018, Berlin, Germany*, 2018.
- [60] D. Evans, M. Hartmann, and J. Delfs, "Beamforming for point force surface sources in numerical data," *J. Sound Vib.*, vol. 458, pp. 303–319, Oct. 2019.
- [61] L. T. Lima Pereira, R. Merino-Martínez, D. Ragni, D. Gómez-Ariza, and M. Snellen, "Combining asynchronous microphone array measurements for enhanced acoustic imaging and volumetric source mapping," *Appl. Acoust.*, vol. 182, p. 108247, Nov. 2021.
- [62] L. Yu, J. Antoni, and Q. Leclere, "Spectral matrix completion by Cyclic Projection and application to sound source reconstruction from non-synchronous measurements," *J. Sound Vib.*, vol. 372, pp. 31–49, June 2016.
- [63] L. Yu, J. Antoni, H. Wu, Q. Leclere, and W. Jiang, "Fast iteration algorithms for implementing the acoustic beamforming of non-synchronous measurements," *Mech. Syst. Signal Process.*, vol. 134, p. 106309, Dec. 2019.
- [64] N. Chu, Y. Ning, L. Yu, Q. Huang, and D. Wu, "A High-Resolution and Low-Frequency Acoustic Beamforming Based on Bayesian Inference and Non-Synchronous Measurements," *IEEE Access*, vol. 8, pp. 82500–82513, 2020. Conference Name : IEEE Access.
- [65] F. Ning, J. Song, J. Hu, and J. Wei, "Sound source localization of non-synchronous measurements beamforming with block Hermitian matrix completion," *Mech. Syst. Signal Process.*, vol. 147, p. 107118, Jan. 2021.
- [66] J. Antoni, Y. Liang, and Q. Leclère, "Reconstruction of sound quadratic properties from non-synchronous measurements with insufficient or without references : Proof of concept," *J. Sound Vib.*, vol. 349, pp. 123–149, Aug. 2015.
- [67] W. J. Bangs, *Array processing with generalized beamformers*. PhD thesis, Yale University, New Haven, Connecticut, 1971.
- [68] H. L. V. Trees, *Optimum Array Processing*, ch. 8, pp. 917–1138. John Wiley and Sons, Ltd, 2002.
- [69] F. Pukelsheim, *Optimal Design of Experiments*. Society for Industrial and Applied Mathematics, 2006.

- [70] M. Cuturi, "Sinkhorn distances : Lightspeed computation of optimal transport," in *Advances in Neural Information Processing Systems* (C. Burges, L. Bottou, M. Welling, Z. Ghahramani, and K. Weinberger, eds.), vol. 26, Curran Associates, Inc., 2013.
- [71] L. Chizat, G. Peyré, B. Schmitzer, and F.-X. Vialard, "Unbalanced optimal transport : Dynamic and Kantorovich formulations," *Journal of Functional Analysis*, vol. 274, no. 11, pp. 3090–3123, 2018.
- [72] D. Milojević and B. Popović, "Improved algorithm for the deinterleaving of radar pulses," in *IEE Proceedings F (Radar and Signal Processing)*, vol. 139, pp. 98–104, IET, 1992.
- [73] K. Nishiguchi and M. Kobayashi, "Improved algorithm for estimating pulse repetition intervals," *IEEE transactions on Aerospace and Electronic Systems*, vol. 36, no. 2, pp. 407–421, 2000.
- [74] R. J. Campello, D. Moulavi, and J. Sander, "Density-based clustering based on hierarchical density estimates," in *Pacific-Asia conference on knowledge discovery and data mining*, pp. 160–172, Springer, 2013.
- [75] S. Chakraborty, D. Paul, and S. Das, "Hierarchical clustering with optimal transport," *Statistics & Probability Letters*, vol. 163, p. 108781, Aug. 2020.
- [76] P. Rigollet and J. Weed, "Entropic optimal transport is maximum-likelihood deconvolution," *Comptes Rendus Mathématique*, vol. 356, pp. 1228–1235, Nov. 2018.
- [77] L. Ding, S. Wang, F. Wang, and W. Zhang, "Specific emitter identification via convolutional neural networks," *IEEE Communications Letters*, vol. 22, no. 12, pp. 2591–2594, 2018.
- [78] M. A. Nuhoglu, Y. K. Alp, and F. C. Akyon, "Deep learning for radar signal detection in electronic warfare systems," in *2020 IEEE Radar Conference (RadarConf20)*, pp. 1–6, IEEE, 2020.
- [79] J. H. Friedman, "Greedy function approximation : A gradient boosting machine.," *The Annals of Statistics*, vol. 29, Oct. 2001.
- [80] L. Grinsztajn, E. Oyallon, and G. Varoquaux, "Why do tree-based models still outperform deep learning on typical tabular data ?," *Advances in Neural Information Processing Systems*, vol. 35, pp. 507–520, 2022.
- [81] M. Frank and P. Wolfe, "An algorithm for quadratic programming," *Naval Research Logistics Quarterly*, vol. 3, no. 1-2, pp. 95–110, 1956.
- [82] J. Torres-Sospedra, R. Montoliu, A. Martínez-Usó, J. P. Avariento, T. J. Arnau, M. Benedito-Bordonau, and J. Huerta, "UJIIndoorLoc : A new multi-building and multi-floor database for WLAN fingerprint-based indoor localization problems," in *2014 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 261–270, Oct. 2014.
- [83] C. Févotte, N. Bertin, and J.-L. Durrieu, "Nonnegative Matrix Factorization with the Itakura-Saito Divergence : With Application to Music Analysis," *Neural Computation*, vol. 21, pp. 793–830, Mar. 2009.
- [84] K. Yoshii, R. Tomioka, D. Mochihashi, and M. Goto, "Infinite positive semidefinite tensor factorization for source separation of mixture signals," in *Proceedings of the 30th International Conference on Machine Learning* (S. Dasgupta and D. McAllester, eds.), vol. 28 of *Proceedings of Machine Learning Research*, (Atlanta, Georgia, USA), pp. 576–584, PMLR, 17–19 Jun 2013.
- [85] M. Pezzoli, J. Carabias-Orti, P. Vera-Candeas, F. Antonacci, and A. Sarti, "Spherical-harmonics-based sound field decomposition and multichannel NMF for sound source separation," *Applied Acoustics*, vol. 218, p. 109888, Mar. 2024.
- [86] R. A. Borsoi, T. Imbiriba, J. C. M. Bermudez, C. Richard, J. Chanussot, L. Drumetz, J.-Y. Tournet, A. Zare, and C. Jutten, "Spectral variability in hyperspectral data unmixing : A comprehensive review," *IEEE Geoscience and Remote Sensing Magazine*, vol. 9, no. 4, pp. 223–270, 2021.
- [87] G. Chardon, "A block-sparse music algorithm for the localization and the identification of directive sources," in *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 3953–3957, 2014.

- [88] E. Monier and G. Chardon, "Cramér-rao bounds for the localization of anisotropic sources," in *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 3281–3285, 2017.
- [89] T. Lobato, R. Sottek, and M. Vorländer, "Identification of multipole sources with neural deconvolution," in *Forum Acusticum 2023*, 2023.
- [90] Z. Niu, J. Antoni, and S. Bouley, "Three-dimensional gridless imaging of aeroacoustical fields with sonons based on a hierarchical bayesian framework," in *Forum Acusticum 2023*, 2023.
- [91] S. Oertwig and H. Siller, "Validation of the source localization method sodix for coherent sound sources," in *Forum Acusticum 2023*, 2023.
- [92] J. M. Wallace, "Space-time correlations in turbulent flow : A review," *Theoretical and Applied Mechanics Letters*, vol. 4, p. 022003, Jan. 2014.
- [93] F. Locatello, R. Khanna, M. Tschannen, and M. Jaggi, "A Unified Optimization View on Generalized Matching Pursuit and Frank-Wolfe," in *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics* (A. Singh and J. Zhu, eds.), vol. 54 of *Proceedings of Machine Learning Research*, pp. 860–868, PMLR, 20–22 Apr 2017.
- [94] J. Abou Chaaya, J. Picheral, and S. Marcos, "Localization of Spatially Distributed Near-Field Sources with Unknown Angular Spread Shape," *Signal Processing*, vol. 106, pp. 259–265, Jan. 2015.
- [95] W. Xiong, J. Picheral, and S. Marcos, "Performance analysis of distributed source parameter estimator (DSPE) in the presence of modeling errors due to the spatial distributions of sources," *Signal Processing*, vol. 143, pp. 146 – 151, Feb. 2018.
- [96] E. Fernandez-Grande and L. Daudet, "Compressive acoustic holography with block-sparse regularization," *The Journal of the Acoustical Society of America*, vol. 143, pp. 3737–3746, June 2018.
- [97] Y. De Castro, V. Duval, and R. Petit, "Towards off-the-grid algorithms for total variation regularized inverse problems," *Journal of Mathematical Imaging and Vision*, vol. 65, pp. 53–81, Jan 2023.
- [98] R. Merino-Martínez, S. Luesutthiviboon, R. Zamponi, A. Rubio Carpio, D. Ragni, P. Sijtsma, M. Snelten, and C. Schram, "Assessment of the accuracy of microphone array methods for aeroacoustic measurements," *Journal of Sound and Vibration*, vol. 470, p. 115176, Mar. 2020.
- [99] T. Lobato, R. Sottek, and M. Vorländer, "Deconvolution with neural grid compression : A method to accurately and quickly process beamforming results," *The Journal of the Acoustical Society of America*, vol. 153, p. 2073, Apr. 2023.
- [100] C. Kayser, A. Kujawski, and E. Sarradj, "A fast data-driven method for inverse microphone array signal processing," *JASA Express Letters*, vol. 3, p. 042401, Apr. 2023.
- [101] A. Kujawski and E. Sarradj, "Fast grid-free strength mapping of multiple sound sources from microphone array data using a Transformer architecture," *The Journal of the Acoustical Society of America*, vol. 152, pp. 2543–2556, Nov. 2022. Publisher : Acoustical Society of America.
- [102] P. Castellini, N. Giulietti, N. Falcionelli, A. F. Dragoni, and P. Chiariotti, "A neural network based microphone array approach to grid-less noise source localization," *Applied Acoustics*, vol. 177, p. 107947, June 2021.
- [103] W. Gonçalves Pinto, M. Bauerheim, and H. Parisot-Dupuis, "Deconvoluting acoustic beamforming maps with a deep neural network," *INTER-NOISE and NOISE-CON Congress and Conference Proceedings*, vol. 263, pp. 5397–5408, Aug. 2021.
- [104] S. Yao, R. Guan, X. Huang, Z. Li, X. Sha, Y. Yue, E. G. Lim, H. Seo, K. L. Man, X. Zhu, and Y. Yue, "Radar-Camera Fusion for Object Detection and Semantic Segmentation in Autonomous Driving : A Comprehensive Review," *IEEE Transactions on Intelligent Vehicles*, pp. 1–40, 2023. arXiv :2304.10410 [cs].

- [105] F. Elvander, I. Haasler, A. Jakobsson, and J. Karlsson, "Multi-marginal optimal transport using partial information with applications in robust localization and sensor fusion," *Signal Processing*, vol. 171, p. 107474, June 2020.
- [106] Y. Guo, H. Wang, Q. Hu, H. Liu, L. Liu, and M. Bennamoun, "Deep Learning for 3D Point Clouds : A Survey," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 43, pp. 4338–4364, Dec. 2021.
- [107] Z. Xing, J. Yu, and Y. Ma, "A new calibration technique for multi-camera systems of limited overlapping field-of-views," in *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, (Vancouver, BC), pp. 5892–5899, IEEE, Sept. 2017.
- [108] J. H. Lee and D.-W. Lee, "A Hough-Space-Based Automatic Online Calibration Method for a Side-Rear-View Monitoring System," *Sensors*, vol. 20, p. 3407, Jan. 2020. Number : 12 Publisher : Multidisciplinary Digital Publishing Institute.
- [109] L. Qin, C. Lin, S. Huang, S. Yang, and Y. Zhao, "Camera calibration for the surround-view system : a benchmark and dataset," Dec. 2023. arXiv :2312.16499 [cs].
- [110] J. Jang, Y. Jo, M. Shin, and J. Paik, "Camera Orientation Estimation Using Motion-Based Vanishing Point Detection for Advanced Driver-Assistance Systems," *IEEE Transactions on Intelligent Transportation Systems*, vol. 22, pp. 6286–6296, Oct. 2021. Conference Name : IEEE Transactions on Intelligent Transportation Systems.
- [111] G. Guillet, T. Guillet, and L. Ravel, "Camera orientation, calibration and inverse perspective with uncertainties : A Bayesian method applied to area estimation from diverse photographs," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 159, pp. 237–255, Jan. 2020.
- [112] A. M. Sjoberg and O. Egeland, "Lie Algebraic Unscented Kalman Filter for Pose Estimation," *IEEE Transactions on Automatic Control*, vol. 67, pp. 4300–4307, Aug. 2022.