

Modèle physique variationnel pour l'estimation de réponses impulsionnelles de salles

Louis LALAY Mathieu FONTAINE Roland BADEAU

Laboratoire Traitement et Communication de l'Information,
Institut Polytechnique de Paris, 19 Place Marguerite Perey, 91120 Palaiseau, France

Résumé – Estimer la réponse impulsionnelle d'une salle est essentiel pour des tâches comme la déréverbération, qui améliore la reconnaissance automatique de la parole. La plupart des méthodes existantes reposent soit sur du traitement du signal statistique, soit sur des réseaux de neurones profonds s'inspirant du traitement du signal. Cependant, la combinaison des modélisations statistique et physique reste largement inexploré en estimation de réponse impulsionnelle de salle. Cet article¹ propose une approche novatrice intégrant les deux aspects à travers un modèle physique. La réponse de salle est décomposée en paramètres interprétables : un bruit blanc gaussien modulé par une décroissance exponentielle dépendante de la fréquence (modélisant l'absorption des murs) et un filtre autorégressif (modélisant par exemple la réponse du microphone). L'optimisation d'une fonction d'énergie libre variationnelle permet une estimation pratique des paramètres. Nous montrons que, connaissant les signaux secs et réverbérants, la méthode proposée surpasse la déconvolution classique dans des environnements bruités, comme le confirment les mesures objectives.

Abstract – Room impulse response estimation is essential for tasks like speech dereverberation, which improves automatic speech recognition. Most existing methods rely on either statistical signal processing or deep neural networks designed to replicate signal processing principles. However, combining statistical and physical modeling for room impulse response estimation remains largely unexplored. This paper proposes a novel approach integrating both aspects through a theoretically grounded model. The room response is decomposed into interpretable parameters: white Gaussian noise modulated by a frequency-dependent exponential decay (e.g. modeling wall absorption) and an autoregressive filter (e.g. modeling microphone response). The optimization of a variational free-energy cost function enables practical parameter estimation. As a proof of concept, we show that given dry and reverberant speech signals, the proposed method outperforms classical deconvolution in noisy environments, as validated by objective metrics.

1 Introduction

L'estimation de réponse impulsionnelle de salle (RIR, de l'anglais *Room Impulse Response*) est une tâche cruciale qui trouve des applications en adaptation acoustique [12] et en reconnaissance automatique de la parole (ASR) [17] par exemple. Une autre tâche clé liée à l'estimation de la RIR est la déréverbération, qui améliore les performances de l'ASR. Cependant, comme la déconvolution avec une RIR dégradée est très sensible, la plupart des méthodes de déréverbération évitent l'estimation explicite de la RIR et estiment directement le signal sec en utilisant des approches de traitement du signal [6], des approches stochastiques [14, 19], ou des réseaux neuronaux profonds (DNN) [5, 8].

Les techniques d'estimation de la RIR ont évolué au fil des décennies, introduisant divers modèles. L'un des premiers modèles a été proposé par Schröder dans [18], où la RIR est représentée comme le produit d'un bruit blanc gaussien et d'une exponentielle décroissante. Plus tard, Polack [16] a démontré que la composante gaussienne varie lentement dans le domaine fréquentiel, conduisant à une estimation plus précise de la RIR. Bien que ces modèles capturent efficacement la réverbération tardive, ils peinent à représenter avec précision les réflexions précoces. Pour palier cette limitation, Komatsu *et al.* [11] ont introduit un modèle de processus gaussien spatio-temporel qui prend en compte à la fois les réverbérations précoce et tardive. D'autres méthodes, comme celle de [20], estiment la RIR en formulant des problèmes d'optimisation,




FIGURE 1 : Aperçu du modèle physique variationnel de réverbération proposé pour l'estimation de RIR (VPR-RIR)

en intégrant une régularisation par transport optimal.

Ces modèles n'estiment pas conjointement les informations spatiales, temporelles et fréquentielles, malgré leur corrélation théorique. Le travail de [3] est une première tentative d'introduction d'un modèle spatio-temporel et dépendant de la fréquence. Sa première application a démontré qu'étant donnée une RIR réelle, il permet une estimation précise du temps de réverbération après une atténuation de 60dB (RT₆₀) [1].

Nous proposons dans cet article² une formulation variationnelle utilisant le modèle physique de [3] pour des RIR. Nous

¹Financé par l'ANR SAROUMANE (ANR-22-CE23-0011)

²Code accessible sur GitHub : <https://github.com/LouisLalay/VPR-RIR>

dérivons un critère d'énergie libre variationnelle qui sera utilisé pour estimer les paramètres du modèle. En particulier, la distribution variationnelle est supposée être une gaussienne dont la moyenne est la RIR cible. Dans cette première approche, nous supposons que les signaux secs et réverbérés sont connus, ce qui peut être vu comme une sous-tâche de l'adaptation acoustique. Le signal observé est corrompu par un bruit additif pour tester la robustesse de notre approche. Les résultats montrent la nette robustesse de la technique proposée par rapport à d'autres techniques classiques de déconvolution [2], selon divers critères caractéristiques de la réverbération (RT₆₀, *energy decay relief*, *energy decay curve*, etc.).

2 Méthode

Dans cette section, nous décrivons le modèle choisi, puis nous présentons le modèle de mélange considéré pour les expériences, et enfin l'approche variationnelle utilisée pour estimer les paramètres du modèle à partir des observations.

2.1 Modèle de RIR et de mélange

Soit $y \in \mathbb{R}^T$ le signal mesuré, $s \in \mathbb{R}^{L_s}$ le signal source et $h \in \mathbb{R}^{L_h}$ la réponse impulsionnelle de salle, de longueurs respectives T , L_s et L_h , telles que $T = L_h + L_s - 1$. Nous considérons dans le domaine temporel le modèle de mélange suivant :

$$y = s * h + w, \quad (1)$$

où $w \in \mathbb{R}^T$ est un bruit blanc gaussien additif de variance σ_w^2 . Nous modélisons le vecteur aléatoire h comme dans [1] :

$$h = G^{-1} E^{-1} P^{-1} \epsilon \quad (2)$$

où les composantes sont définies comme suit :

- $\epsilon[u] \sim \mathcal{N}(0, \sigma_\epsilon^2)$ pour $u = 0, \dots, L_h - 1$ (bruit blanc gaussien i.i.d.);
- $G = \text{Toep}(g)$, $g \in \mathbb{R}^{L_g}$, matrice triangulaire inférieure;
- $E = \text{Diag}(\{e^{au}\}_{u=0}^{L_h-1})$, $a \geq 0$, matrice diagonale;
- $P = \mathcal{P}_{L_h}(p)$ avec $p_0 = 1$, $p \in \mathbb{R}^{L_p}$, matrice triangulaire inférieure.

Toutes les matrices sont carrées et de taille $L_h \times L_h$, correspondant à la longueur de la RIR en nombre d'échantillons. $\text{Toep}(b)$ et $\text{Diag}(b)$ désignent respectivement la matrice de Toeplitz triangulaire inférieure et la matrice diagonale générée à partir d'un vecteur b . $\mathcal{P}_{L_h}(p)$ est une matrice carrée de taille L_h générée par p . La matrice $\mathcal{P}_4(p)$ est par exemple construite comme décrit ci-dessous, avec $L_h = 4$, $p = [p_0, p_1]$ où $p^{*n} = p * p^{*(n-1)}$ avec $p^{*0} = \delta$ (où δ désigne l'impulsion unitaire au temps 0) et $p^{*n}[:, l]$ le vecteur tronqué des l premiers éléments de p^{*n} .

$$\mathcal{P}_4([p_0, p_1]) = \begin{pmatrix} p^{*0}[:, 4] & p^{*1}[:, 4] & p^{*2}[:, 4] & p^{*3}[:, 4] \\ 1 & 0 & 0 & 0 \\ 0 & p_0 & 0 & 0 \\ 0 & p_1 & p_0^2 & 0 \\ 0 & 0 & 2p_0p_1 & p_0^3 \end{pmatrix}.$$

Le modèle de RIR repose sur des hypothèses physiques et peut être décomposé en quatre parties. Tout d'abord, ϵ est le bruit blanc gaussien de base qui est filtré pour obtenir la RIR. Ensuite, la matrice de Toeplitz G , paramétrée par le vecteur g de longueur $L_g < L_h$, implémente un filtre qui modélise la réponse du microphone. La matrice diagonale E représente l'absorption moyenne de la salle, paramétrée par le coefficient d'absorption a . Enfin, la matrice P représente l'absorption dépendante de la fréquence des murs, paramétrée par le filtre p de longueur $L_p < L_h$. Avec trois matrices pour modéliser le filtre global, nous pouvons imposer $g_0 = 1$ et $p_0 = 1$ sans perte de généralité tout en conservant de bonnes propriétés en termes d'inversion et de calculs de déterminants. Le lien entre les propriétés physiques de la salle et les paramètres du modèle n'est pas clairement défini mais pourra être étudié dans des travaux futurs.

2.2 Estimation des paramètres

Nous adoptons une approche variationnelle pour estimer les paramètres du modèle. Soit $\theta = \{g, a, p, \sigma_\epsilon, \sigma_w\}$ l'ensemble des paramètres du modèle que nous cherchons à estimer. La distribution cible, dans le cadre de la méthode d'approximation du champ moyen, pour h que nous cherchons à approcher est donnée par $q^*(h[u]) = \mathcal{N}(\mu_h[u], r_h[u])$. Soit $z = \{\mu_h, r_h\}$ l'ensemble des paramètres optimaux de la distribution, où μ_h, r_h sont les vecteurs contenant les composantes $\mu_h[u], r_h[u]$ respectivement. L'énergie libre variationnelle (VFE) associée à ce problème est définie comme suit [7] :

$$\mathcal{L}(q, \theta) = \mathbb{E}_{q(z)} \left[\ln \frac{\mathbb{P}(y, z | \theta, s)}{q(z)} \right]. \quad (3)$$

En combinant le modèle stochastique de la RIR dans les Eqs. (2) et (1), nous obtenons une forme explicite pour l'Eq. (3) :

$$\begin{aligned} \mathcal{L}(q, \theta) = & -\frac{1}{2} \left(T \ln(2\pi\sigma_w^2) + \frac{\mathbb{E}_{q(z)} [\|y - s * h\|_2^2]}{\sigma_w^2} \right) \\ & - \frac{1}{2} (L_h \ln(\sigma_\epsilon^2) - L_h(L_h - 1)a) \\ & - \frac{1}{2\sigma_\epsilon^2} (\|V\mu_h\|_2^2 + \text{Tr}(VR_hV^\top)) \\ & + \frac{1}{2} \left(\sum_{u=0}^{L_h-1} \ln r_h[u] + L_h \right) \end{aligned} \quad (4)$$

où $^\top$, $\text{Tr}(\cdot)$ désignent respectivement la transposition et l'opérateur trace, $\|\cdot\|_2$ représente la norme euclidienne d'un vecteur réel, $V = PEG$, $R_h = \text{Diag}(r_h)$, et

$$\begin{aligned} \mathbb{E}_{q(z)} [\|y - s * h\|_2^2] = & \|y\|_2^2 - 2 \sum_{t=0}^{T-1} y[t](\mu_h * s)[t] \\ & + \sum_{t=0}^{T-1} (r_h * s^2)[t] + (\mu_h * s)^2[t]. \end{aligned}$$

Nous cherchons à maximiser cette fonction par rapport à z et θ . Cela peut être formulé comme un problème d'optimisation :

$$(z, \theta) = \underset{z, \theta}{\text{argmax}} \mathcal{L}(q, \theta). \quad (5)$$

Nous procédons ensuite à l'estimation des paramètres par descente de gradient sur la fonction $-2\mathcal{L}$. Dans les expériences, nous utilisons l'optimisateur Adam [10] pour résoudre ce problème. Notez qu'un algorithme variationnel d'espérance-maximisation [7] peut également être adapté pour estimer les paramètres, ce que nous laissons pour des travaux futurs.

2.3 Contrainte de cohérence sur g

En théorie, le filtre g devrait couper les basses et hautes fréquences car il représente la réponse du microphone, qui est un filtre passe-bande physique. Cependant, nos études préliminaires montrent que cette contrainte n'était pas respectée au cours des itérations, conduisant parfois à une mauvaise estimation de la RIR. Pour résoudre ce problème, nous imposons deux zéros, à la fréquence nulle et à la fréquence de Nyquist, dans la fonction de transfert du filtre pour obtenir une meilleure estimation. La matrice G_{old} devient $G = G_1 G_0$ avec $G_1 = G_{old}$ et $G_0 = \text{Toep}([1, 0, -1])$.

De plus, pour garantir la cohérence du modèle, le filtre g est stabilisé pour maintenir G^{-1} numériquement stable. La version stable de g est obtenue en plaçant tous les pôles de module supérieur à 1 à l'intérieur du cercle unité, c'est à dire en les remplaçant par l'inverse de leur conjugué. Le changement de gain global du filtre n'est pas compensé.

Les paramètres sont initialisés avec $PEG = I_{L_h}$, $R_h = I_{L_h}$, $\mu_h = \delta$, $\sigma_w = 1$, $\sigma_\epsilon = 1$. L'étape de normalisation garantit que g est stable, que a est strictement positif et que r_h est strictement positif pour assurer la cohérence avec le modèle. Nous résumons l'approche itérative proposée dans l'Algorithme 1.

Algorithme 1 : Estimation de la RIR proposée

- 1: **Initialisation** : initialiser θ, z
 - 2: Nombre d'itérations I
 - 3: Optimisateur Adam, tous les paramètres θ, z , $lr = 1e - 3$
 - 4: **for** $i = 1$ à I **do**
 - 5: Construire P, E, G en utilisant les paramètres actuels θ
 - 6: Normaliser les paramètres
 - 7: Optimisateur : remise à zéro des gradients
 - 8: Calculer la fonction de coût : $-\mathcal{L}(q, \theta)$
 - 9: Rétropropagation
 - 10: Mettre à jour θ, z
 - 11: **end for**
 - 12: **Retour** : θ, z
-

3 Configuration expérimentale

Cette section décrit les données, les métriques et les méthodes utilisées dans notre évaluation. Nous estimons la RIR à partir d'un signal de parole réverbéré, en ajoutant du bruit pour évaluer la robustesse de notre approche.

3.1 Jeux de données

Jeu de données de parole Dans toutes les expériences, nous utilisons une seule source audio, 87-8000, sélectionnée aléatoirement dans le jeu de données LibriSpeech [15], tronquée à 2 s. La fréquence d'échantillonnage originale est de 16 kHz, mais pour notre évaluation, nous l'avons réduite à 8 kHz. Des

expériences préliminaires menées à 16 kHz et 8 kHz ont donné des résultats similaires, nous avons donc opté pour la version 8 kHz pour des raisons d'efficacité algorithmique.

Jeu de données de RIR Pour démontrer la robustesse de notre algorithme, nous utilisons des RIR réelles avec des valeurs de RT_{60} inférieures à 250 ms. Les RIR proviennent de la base de données *Aachen Impulse Response* [9]. Nous avons utilisé 30 RIRs enregistrées dans 5 salles différentes pour 6 configurations de haut-parleurs et de microphones dans chaque cas. Nous considérons 1000 échantillons de RIR, correspondant à 125 ms. Ce choix est principalement dû au coût de calcul élevé de notre système et parce que nous souhaitons nous concentrer sur l'estimation des premières réflexions, qui est l'aspect le plus difficile de l'estimation de la RIR, plutôt que sur la réverbération tardive.

Jeu de données de bruit Comme notre modèle dans l'équation (1) prend en compte un bruit gaussien, nous avons décidé d'ajouter du bruit au signal de parole réverbéré. Le bruit provient du jeu de données WHAMR! [13]. Pour chacune des 30 RIRs, un échantillon de bruit de même durée que le signal réverbéré est tiré de WHAMR!, puis on ajuste la puissance du bruit afin d'obtenir le rapport signal à bruit voulu. Nous avons testé plusieurs niveaux de bruit, allant de 20 dB à -3 dB.

3.2 Métriques et description des tâches

Nous considérons l'erreur absolue moyenne entre une RIR estimée $\tilde{h}$ et la RIR de référence h pour diverses caractéristiques acoustiques $m \in \{\text{EDC}, \text{EDR}, \text{RT30}\}$ que nous notons Δ_m et qui représentent respectivement la courbe de décroissance énergétique, le relief de décroissance énergétique, et le temps de réverbération à 30 dB. Nous considérons également l'erreur quadratique moyenne (MSE).

3.3 Méthodes

Nous testons dans nos expériences l'approche proposée et deux méthodes de référence :

- VPR-RIR : notre modèle physique variationnel pour la réverbération et l'estimation de la réponse impulsionnelle de salle. Nous regroupons l'initialisation des paramètres et la procédure dans l'Algorithme 1.
- DEC : *déconvolution spectrale* où y, h, s sont considérés dans le domaine temps-fréquence, ce qui donne pour chaque point f, t leurs coefficients de Fourier $H_{f,t}$, $Y_{f,t}$ et $S_{f,t}$, pour lesquels les opérations suivantes sont calculées : $H_{f,t} = Y_{f,t}/S_{f,t}$.
- CBF : le filtrage inter-bandes défini dans [2] avec les paramètres suivants : $K = 1$ bande, $n_{fft} = 512$, 50% de recouvrement et une fenêtre de Hann.

4 Résultats et discussions

Le tableau 1 présente les résultats d'erreur pour les 5 configurations de bruit choisies. Pour des raisons de clarté de lecture, l'erreur quadratique moyenne est affichée en pourcentage de la puissance moyenne de la RIR de référence. Il en est de même pour l'écart de temps de réverbération, qui est exprimé en pourcentage du RT_{30} de référence. Les résultats montrent

que VPR-RIR surpasse les deux méthodes de référence, DEC et CBF, pour toutes les métriques et tous les niveaux de SNR inférieurs à 20 dB.

Ces expériences initiales démontrent que VPR-RIR a le potentiel d'estimer une RIR et d'extraire des paramètres acoustiques associés. De futures expériences pourraient être réalisées avec des RIR plus longues et des temps de réverbération plus variés pour confirmer ces résultats.

TABLE 1 : Écarts entre la RIR de référence et l'estimation pour les 3 modèles considérés pour 5 SNR différents. Les scores sont présentés sous la forme médiane $\pm$ écart type.

Méthode	$\Delta_{RT30} \downarrow$ (%)	$\Delta_{EDC} \downarrow$	$\Delta_{EDR} \downarrow$	MSE $\downarrow$ (%)
VPR-RIR	89 $\pm$ 50	0.01 $\pm$ 0.01	1.37 $\pm$ 0.23	11 $\pm$ 2
DEC	97 $\pm$ 54	0.09 $\pm$ 0.06	1.03 $\pm$ 0.28	25 $\pm$ 23
CBF	96 $\pm$ 53	0.11 $\pm$ 0.06	1.09 $\pm$ 0.27	25 $\pm$ 21
SNR : 20 dB				
VPR-RIR	95 $\pm$ 53	0.03 $\pm$ 0.03	1.50 $\pm$ 0.24	14 $\pm$ 6
DEC	97 $\pm$ 54	0.32 $\pm$ 0.10	1.91 $\pm$ 0.48	248 $\pm$ 229
CBF	97 $\pm$ 54	0.33 $\pm$ 0.10	1.92 $\pm$ 0.49	245 $\pm$ 206
SNR : 10 dB				
VPR-RIR	95 $\pm$ 51	0.05 $\pm$ 0.03	1.58 $\pm$ 0.36	18 $\pm$ 9
DEC	98 $\pm$ 54	0.44 $\pm$ 0.08	2.77 $\pm$ 0.63	1245 $\pm$ 1146
CBF	98 $\pm$ 54	0.44 $\pm$ 0.07	2.76 $\pm$ 0.65	1217 $\pm$ 1026
SNR : 3 dB				
VPR-RIR	96 $\pm$ 53	0.15 $\pm$ 0.10	1.97 $\pm$ 0.38	41 $\pm$ 51
DEC	97 $\pm$ 54	0.45 $\pm$ 0.06	3.24 $\pm$ 0.67	2223 $\pm$ 2215
CBF	96 $\pm$ 55	0.46 $\pm$ 0.07	3.24 $\pm$ 0.69	2432 $\pm$ 2081
SNR : 0 dB				
VPR-RIR	97 $\pm$ 53	0.22 $\pm$ 0.13	2.30 $\pm$ 0.49	71 $\pm$ 75
DEC	79 $\pm$ 53	0.46 $\pm$ 0.06	3.71 $\pm$ 0.74	4611 $\pm$ 3712
CBF	65 $\pm$ 52	0.48 $\pm$ 0.06	3.76 $\pm$ 0.76	4808 $\pm$ 3949
SNR : -3 dB				

5 Conclusion et perspectives

Dans cet article, nous avons proposé une nouvelle méthode pour estimer des réponses impulsionnelles de salles (RIR), dérivée d'un modèle de réverbération stochastique basé sur la physique présenté dans [3]. Notre approche repose sur une formulation variationnelle, qui permet non seulement une estimation précise de la RIR, mais fournit également le filtre correspondant utilisé pour modéliser la RIR. Les résultats obtenus à partir de signaux réverbérés et bruités démontrent l'efficacité de notre estimateur robuste de RIR par rapport aux méthodes de référence traditionnelles.

Dans nos travaux futurs, cette méthode pourra être étendue à des tâches d'adaptation acoustique plus complexes. Le processus de mélange peut être représenté comme un produit de matrices, rendant possible l'application d'une approche variationnelle pour estimer les paramètres pertinents. De plus, nous prévoyons d'essayer d'améliorer la vitesse de convergence, par exemple via un algorithme d'espérance-maximisation où les paramètres sont mis à jour de manière alternée. Une autre direction pour les travaux futurs consiste à adapter l'approche proposée à la récente théorie ondulatoire statistique, qui établit les propriétés statistiques des solutions de l'équation des ondes dans des domaines bornés [4].

Références

- [1] Achille AKNIN et Roland BADEAU : Stochastic reverberation model with a frequency dependent attenuation. *In Proc. IEEE Workshop Appl. Signal Process. Audio Acoust.*, pages 351–355, 2021.
- [2] Yekutieli AVARGEL et Israel COHEN : System identification in the short-time Fourier transform domain with crossband filtering. *IEEE Transactions on Audio, Speech, and Language Processing*, 15(4):1305–1319, mai 2007.
- [3] Roland BADEAU : Common mathematical framework for stochastic reverberation models. *J. Acoust. Soc. Am.*, 145(4):2733–2745, avril 2019.
- [4] Roland BADEAU : Statistical wave field theory. *J. Acoust. Soc. Am.*, 156(1):573 – 599, juillet 2024.
- [5] Louis BAHRMAN, Mathieu FONTAINE, Jonathan LE ROUX et Gaël RICHARD : Speech dereverberation constrained on room impulse response characteristics. *In Proc. INTERSPEECH*, pages 622–626, 2024.
- [6] Arthur BELHOMME, Roland BADEAU, Yves GRENIER et Eric HUMBERT : Amplitude and phase dereverberation of harmonic signals. *In 2017 IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (WASPAA)*, pages 294–298. IEEE, 2017.
- [7] Christopher M BISHOP et Nasser M NASRABADI : *Pattern recognition and machine learning*, volume 4. Springer, 2006.
- [8] Xiang HAO, Xiangdong SU, Radu HORAUDE et Xiaofei LI : Fullsubnet : A full-band and sub-band fusion model for real-time single-channel speech enhancement. *In Proc. IEEE Int. Conf. Acoust., Speech, Signal Process.*, 2021.
- [9] Marco JEUB, Magnus SCHAFER et Peter VARY : A binaural room impulse response database for the evaluation of dereverberation algorithms. *In 2009 16th International Conference on Digital Signal Processing*, pages 1–5, Santorini, Greece, juillet 2009. IEEE.
- [10] Diederik P KINGMA et Jimmy BA : Adam : A method for stochastic optimization. *arXiv e-prints*, pages arXiv–1412, 2014.
- [11] Tatsuya KOMATSU, Gareth PETERS, Tomoko MATSUI, Ido NEVAT et Kazuya TAKEDA : Modeling room impulse response via composites of spatial-temporal Gaussian processes. *In Proceedings of Meetings on Acoustics*, volume 19. AIP Publishing, 2013.
- [12] Sungho LEE, Hyeon-Seok CHOI et Kyogu LEE : Yet another generative model for room impulse response estimation. *In Proc. IEEE Workshop Appl. Signal Process. Audio Acoust.*, pages 1–5, 2023.
- [13] Matthew MACIEJEWSKI, Gordon WICHERN, Emmett MCQUINN et Jonathan Le ROUX : WHAMR ! : Noisy and Reverberant Single-Channel Speech Separation. *In Proc. IEEE Int. Conf. Acoust., Speech, Signal Process.*, pages 696–700, mai 2020.
- [14] Tomohiro NAKATANI, Takuya YOSHIOKA, Keisuke KINOSHITA, Masato MIYOSHI et Bing-Hwang JUANG : Speech dereverberation based on variance-normalized delayed linear prediction. *IEEE Trans. ASLP*, 18(7):1717–1731, 2010.
- [15] Vassil PANAYOTOV, Guoguo CHEN, Daniel POVEY et Sanjeev KHUNDANPUR : Librispeech : An ASR corpus based on public domain audio books. *In 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 5206–5210, avril 2015.
- [16] Jean-Dominique POLACK : *La transmission de l'énergie sonore dans les salles* (The transmission of sound energy in rooms). Thèse de doctorat, Le Mans, 1988.
- [17] Anton RATNARAJAH, Ishwarya ANANTHABHOTLA, Vamsi Krishna ITHAPU, Pablo HOFFMANN, Dinesh MANOCHA et Paul CALAMIA : Towards improved room impulse response estimation for speech recognition. *In Proc. IEEE Int. Conf. Acoust., Speech, Signal Process.*, pages 1–5, 2023.
- [18] Manfred Robert SCHROEDER : Frequency-correlation functions of frequency responses in rooms. *The Journal of the Acoustical Society of America*, 34(12):1819–1823, 1962.
- [19] Kouhei SEKIGUCHI, Yoshiaki BANDO, Aditya Arie NUGRAHA, Mathieu FONTAINE, Kazuyoshi YOSHII et Tatsuya KAWAHARA : Autoregressive moving average jointly-diagonalizable spatial covariance analysis for joint source separation and dereverberation. *IEEE/ACM Trans. ASLP*, 30:2368–2382, 2022.
- [20] David SUNDSTRÖM, Filip ELVANDER et Andreas JAKOBSSON : Estimation of impulse responses for a moving source using optimal transport regularization. *In Proc. IEEE Int. Conf. Acoust., Speech, Signal Process.*, pages 921–925, 2024.