



HAL
open science

Cartographie du canal par réduction de dimension et réseaux triplets

Taha Yassine, Luc Le Magoarou, Baptiste Chatelier, Stéphane Paquelet,
Matthieu Crussière

► **To cite this version:**

Taha Yassine, Luc Le Magoarou, Baptiste Chatelier, Stéphane Paquelet, Matthieu Crussière. Cartographie du canal par réduction de dimension et réseaux triplets. 2023. hal-04188506

HAL Id: hal-04188506

<https://hal.science/hal-04188506>

Preprint submitted on 25 Aug 2023

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

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

Cartographie du canal par réduction de dimension et réseaux triplets

Taha YASSINE^{1,2} Luc LE MAGOAROU² Baptiste CHATELIER^{1,2} Stéphane PAQUELET¹ Matthieu CRUSSIÈRE^{1,2}

¹Institut de Recherche & Technologie bcom, Cesson-Sévigné, France

²Univ Rennes, INSA Rennes, CNRS, IETR –UMR 6164, F-35000 Rennes, France

Résumé – La cartographie du canal est une technique émergente dont le but est d’apprendre à partir des canaux estimés une carte sur laquelle des utilisateurs proches spatialement apparaissent proches également. Contrairement aux méthodes classiques de localisation, la cartographie se veut non-supervisée. La méthode proposée se base sur une mesure de distance adaptée aux vecteurs de canaux. L’exploitation de cette mesure de distance permet de structurer un réseau de neurones dit basé sur un modèle. Initialisé de manière intelligente, ce réseau est par la suite entraîné en mode triplet pour permettre d’améliorer ses performances. Ses performances sont évaluées sur une base de données de canaux synthétiques générée grâce à l’outil Sionna.

Abstract – Channel charting is an emerging technique whose aim is to learn a chart from estimated channels, on which spatially close users appear to be close as well. In contrast to conventional localization methods, channel charting is intended to be unsupervised. The proposed method is based on a distance measure adapted to channel vectors. The exploitation of this distance measure allows for the structuring of a neural network known as a model-based network. Initialized intelligently, this network is subsequently trained in triplet mode to improve its performance. Its performance is evaluated on a synthetic channel database generated using the Sionna library.

1 Introduction

L’utilisation de techniques d’apprentissage automatique dans le contexte des systèmes de télécommunication devient de plus en plus répandu. La capacité de ce type d’approches à modéliser des problèmes complexes en apprenant à partir de données est ce qui les rends attrayants, là où les méthodes classiques basées sur l’étude théorique de ces mêmes problèmes peinent face à leur complexité. La localisation d’utilisateur par empreinte digitale (fingerprinting) en est un exemple. En effet, une base de données de vecteurs de canaux et de leurs positions associées permet d’entraîner des modèles capables de prédire les positions de canaux non-observés lors de l’entraînement.

La cartographie du canal a été récemment proposée comme alternative non-supervisée à la localisation [5]. En effet, elle permet d’apprendre une carte des positions des utilisateurs qui soit la plus cohérente possible en termes de voisinages spatiaux. Elle se base sur des techniques de réduction de dimension pour proposer un modèle capable de projeter un vecteur de canal sur cette carte.

Contributions. Dans ce papier, la méthode basée sur un modèle proposée dans [7] est détaillée et évaluée sur une nouvelle base de données synthétiques. Cette méthode a pour avantages :

- Une initialisation intelligente basée sur une mesure de distance adaptée aux canaux et combinée à une méthode de réduction de dimension.
- Un réseau de neurones basé sur le modèle de cette même distance.
- Un entraînement en mode triplet exploitant l’horodatage des canaux pour améliorer les performances.

2 Formulation du problème

La cartographie du canal est une méthode d’apprentissage non supervisée qui, dans le contexte d’un système de communication sans fil, vise à associer à chaque canal de propagation un

vecteur de faible dimension s’interprétant comme la position de l’utilisateur correspondant sur une carte. Elle s’inscrit dans la famille plus générale des méthodes de réduction de dimension puisque cette carte est caractérisée par sa petite dimension par rapport à celle du canal. En effet, les modèles physiques de propagation suggèrent que les observations du canal sont régies par l’hypothèse de la variété : les données de grande dimension apparente sont en réalité déterminés par un nombre réduit de paramètres. Ces paramètres sont étroitement liés aux positions depuis lesquels les signaux sont émis. L’objectif de la cartographie devient donc de projeter les canaux de grande dimension sur un espace de plus petite dimension, typiquement 2 ou 3, de manière à compresser l’information qu’ils contiennent et à la réduire à quelque chose qui s’apparente à une position. En particulier, une carte est considérée de bonne qualité si les voisinages spatiaux des émetteurs y sont préservés.

De manière formelle, dans un scénario MIMO OFDM, une carte est définie par l’application \mathcal{F} reliant des canaux $\{\mathbf{h}_i\}_{i=1}^N$, correspondant à des signaux transmis depuis les positions $\{\mathbf{p}_i\}_{i=1}^N$, à leurs projections $\{\mathbf{z}_i\}_{i=1}^N$.

$$\mathcal{F}: \mathbb{C}^M \rightarrow \mathbb{R}^d$$

$$\mathbf{h}_i \mapsto \mathcal{F}(\mathbf{h}_i) = \mathbf{z}_i.$$

$M = N_r \times N_s$ correspond à la dimension des canaux où N_r et N_s sont le nombre d’antennes du récepteur (station de base) et le nombre de sous-porteuses respectivement. d correspond à la dimension de la carte.

3 Méthode proposée

Les techniques d’apprentissage profond peuvent être exploitées dans le but de concevoir des modèles capables d’apprendre \mathcal{F} . Les méthodes dites basées sur un modèle sont particulièrement intéressantes dans ce contexte. En effet, la structure des réseaux de neurones utilisés par ces dernières est guidée par les principes physiques sous-jacents au problème étudié et est donc supposée mieux adaptée à la tâche. Dans ce contexte, nous proposons un modèle combinant trois aspects et adapté à la tâche de cartographie du canal telle que décrite dans la section 2.

1. **Mesure de distance** : La méthode proposée repose grandement sur une estimation de la distance entre utilisateurs à partir du canal de propagation s'établissant entre eux et la station de base, estimé par celle-ci. Cette distance se doit de refléter correctement les voisinages spatiaux. La distance euclidienne classique n'exhibe pas cette propriété. Une distance mieux adaptée est celle proposée dans [3]. Elle est définie par

$$d^*(\mathbf{h}_i, \mathbf{h}_j)^2 = 2 - 2 \frac{|\mathbf{h}_i^H \mathbf{h}_j|}{\|\mathbf{h}_i\|_2 \|\mathbf{h}_j\|_2}. \quad (1)$$

Cette mesure, dérivée de la physique de la propagation, supprime la dépendance à la phase globale variant à une très petite échelle (de l'ordre de la longueur d'onde). Elle est donc plus robuste et préserve mieux les voisinages. La première étape dans notre approche consiste à calculer la matrice de distance d'un sous-ensemble de canaux en se basant sur d^* comme décrit dans ce qui suit.

2. **Encodeur basé sur un modèle** : L'encodeur représente le bloc central de notre modèle. Il est constitué d'un sous-ensemble de canaux récoltés et représentatifs de la distribution des données. Ces canaux sont organisés dans une matrice \mathbf{D} . Une matrice de distance de ceux-ci est ensuite calculée. Celle-ci est donnée en entrée à un algorithme d'apprentissage de variété tel que Isomap [6]. Ce type d'algorithmes permet d'approcher la variété sous-jacente aux données à partir de leur matrice de distance. Isomap, en particulier, construit une matrice des plus proches voisins sur laquelle il se base pour calculer ses projections. Ces projections sont organisées dans une matrice \mathbf{Z} de même nombre de colonnes que \mathbf{D} et avec un nombre de lignes correspondant à la dimension choisie pour la carte d . Le calcul de ces 2 matrices constitue l'étape d'initialisation du modèle. Pour un canal \mathbf{h} quelconque, sa position sur la carte \mathbf{z} est obtenue en appliquant l'algorithme 1. La première opération consiste à calculer le vecteur des




FIGURE 1 : Encodeur hybride.

3. **Fonction de coût triplet** : L'avantage des méthodes d'apprentissage profond réside dans leur capacité à "apprendre" à partir de données. En effet, un réseau de neurones peut être entraîné grâce à la descente de gradient, implémentée efficacement via rétropropagation. Pour ce faire, il est nécessaire de calculer une fonction de coût qui quantifie l'erreur du modèle. Dans le cas de l'apprentissage supervisé, cette fonction de coût reflète l'écart entre la valeur prédite et la valeur cible. D'autre part, les méthodes de cartographie étant non-supervisées, elles se doivent de dépendre uniquement des données d'entrée. Une base de données d'entraînement étiquetée n'est donc pas envisageable. Il est donc nécessaire de quantifier l'erreur du modèle d'une autre manière, dans un contexte d'apprentissage non-supervisé. L'apprentissage contrastif en général, et les réseaux triplets en particulier, permettent d'entraîner un réseau en proposant une fonction de coût qui ne dépend que des entrées. Les réseaux triplets ont initialement été proposés dans le contexte de la cartographie par [1]. Un ensemble de données de triplets est construit et donné en entrée au modèle. Chaque triplet est constitué d'un exemple de base \mathbf{h} , d'un exemple proche \mathbf{h}^+ et d'un exemple éloigné \mathbf{h}^- . Le modèle calcule leurs projections respectives \mathbf{z} , \mathbf{z}^+ et \mathbf{z}^- . La fonction de coût triplet est définie par

$$L(\mathbf{z}, \mathbf{z}^+, \mathbf{z}^-) = \max(0, d^+ - d^- + m), \quad (2)$$

où $d^+ = \|\mathbf{z} - \mathbf{z}^+\|_2$, $d^- = \|\mathbf{z} - \mathbf{z}^-\|_2$ et m est paramètre de marge. L'idée est donc de mesurer la distance entre l'exemple de base et l'exemple proche, puis entre l'exemple de base et l'exemple éloigné. Minimiser (2) revient à rapprocher l'exemple de base de l'exemple proche, et de l'éloigner de l'exemple éloigné. La figure 2 représente le réseau triplet prenant en entrée les 3 éléments d'un triplet et rendant leur projections. Les encodeurs permettant de les projeter étant 3 répliques identiques de celui présenté à la section précédente et partageant les poids.




FIGURE 2 : Réseau triplet.

modules des corrélations entre la canal à positionner sur la carte \mathbf{h} et les colonnes de \mathbf{D} . Les k modules les plus importants sont ensuite conservés et les autres éléments mis à 0. Finalement, après une opération de normalisation l_1 , le vecteur est multiplié par la matrice \mathbf{Z} afin d'obtenir une combinaison convexe de ses éléments pondérés par les modules. Il est ensuite assez facile de distinguer la structure de réseau de neurones qui émane de cet algorithme, ses poids étant $\theta = \{\mathbf{D}, \mathbf{Z}\}$. En effet, les étapes 1 et 5 sont des multiplications matricielles séparées par les étapes 2, 3 et 4 qui elles sont des opérations non-linéaires dérivables. Il est également intéressant de noter que les étapes 1 et 2 sont équivalentes au calcul de d^* . On obtient ainsi un modèle d'apprentissage profond guidé par des principes physiques incarnés par la mesure de distance d^* .

Algorithme 1 : Encodeur proposé

Entrées : Sous-ensemble \mathbf{D} de vecteurs du canal, carte correspondante \mathbf{Z} , vecteur \mathbf{h} à projeter

- 1 Corrélation : $\mathbf{a} \leftarrow \mathbf{D}^H \mathbf{h}$
- 2 Module : $\mathbf{b} \leftarrow |\mathbf{a}|$
- 3 Seuillage dur : $\mathbf{c} \leftarrow \text{HT}_k(\mathbf{b})$
- 4 Normalisation : $\mathbf{d} \leftarrow \mathbf{c} / \|\mathbf{c}\|_1$
- 5 Somme pondérée : $\mathbf{z} \leftarrow \mathbf{Zd}$

Sorties : $\mathbf{z} = \mathcal{F}(\mathbf{h})$

pour un émetteur donné se déplaçant à une vitesse peu variable, 2 observations du canal proches dans le temps correspondent à des positions de transmission proches spatialement avec une très forte probabilité. Pourvu que cette information temporelle soit disponible, il est assez facile construire un triplet, un exemple proche étant, pour un exemple donné, une observation se situant en deçà d'un seuil temporel, et à l'opposé, un exemple éloigné étant une observation se situant au delà de ce seuil.

Pour résumer, le modèle proposé combine ces 3 aspects qui, ensembles, lui permettent d'apprendre des cartes de meilleures qualité. En effet, le réseau de neurones est initialisé de manière intelligente en construisant les matrices \mathbf{D} et \mathbf{Z} plutôt que de l'initialiser aléatoirement comme fait habituellement. De plus, sa structure est basée sur une mesure de distance conçue pour refléter les voisinages locaux des canaux. Pour finir, le réseau est entraîné dans une configuration triplet en exploitant l'information temporelle résultant de la procédure de récolte des canaux.

Il est important à noter qu'un avantage non négligeable de cette approche comparé à l'utilisation d'Isomap exclusivement est la projection à la volée. En effet, Isomap a besoin que l'entièreté des canaux soit disponible au moment de calculer sa projection. Ainsi, pour projeter une nouvelle observation, il faudra recalculer la projection de toutes les autres observations, là où la méthode hybride permet de projeter des canaux un à un indépendamment du reste de la base de données. Un autre avantage est celui de la faible complexité calculatoire du réseau de neurone. Comparé à des approches similaires [1], celui-ci est composé d'un nombre de paramètres relativement faible permettant un entraînement et une inférence rapides et économes en ressources.

4 Expériences

4.1 Scénario

Nous proposons d'évaluer les performances de notre approche sur des données synthétiques générées en utilisant le modèle de lancer de rayon de la librairie Sionna [2]. Le scénario considéré est celui d'un utilisateur se déplaçant à vitesse constante en milieu urbain en suivant une trajectoire prédéfinie. Le milieu considéré est celui du campus de l'INSA de Rennes modélisés en 3D. Les données de cette modélisation ont été générées grâce à l'outil libre OpenStreetMap [4]. La station de base est équipée d'un UPA 8×8 et se situe 10 m au dessus du toit d'un bâtiment. La communication s'opère sur une fréquence porteuse de 3.5 GHz en OFDM en considérant 16 sous-porteuses.

4.2 Génération des données

Les positions d'émission sont espacées de 5 cm tout au long de la trajectoire. Pour un utilisateur se déplaçant à une vitesse de 1.4 m/s (marche normale), cela correspond à une fréquence d'échantillonnage de 28 échantillons/s. Pour générer la base de données de triplets nécessaire à l'entraînement du modèle, l'horodatage des canaux récoltés est utilisé comme décrit dans la section 3. Le seuil temporel est fixé à 100 s. Pour chaque exemple, 20 triplets sont générés en sélectionnant à chaque fois un exemple proche et un exemple éloigné différents, permettant ainsi d'augmenter virtuellement la taille de la base de données. En résulte un ensemble de 168000 triplets dont 80% est utilisé pour entraîner le modèle, le reste servant à évaluer les performances.

4.3 Mesures de performance

Une carte du canal peut être exploitée par d'autres applications en aval, pour lesquelles une connaissance de la position relative des utilisateurs est clé. De ce fait, la qualité de la carte apprise influe grandement sur les performances de cette application. La cartographie étant une tâche non-supervisée, il est difficile d'évaluer sa qualité puisque les métriques standards dans le contexte des tâches d'apprentissage ne conviennent pas. Il est alors important de choisir des métriques qui reflètent convenablement les caractéristiques d'une bonne carte. Comme mentionné plus haut, une carte se doit de bien conserver les voisinages spatiaux locaux des emplacements d'émission. Deux mesures de performances reviennent fréquemment dans la littérature : la *fiabilité* et la *continuité* [5].

4.3.1 Fiabilité

La fiabilité reflète combien de canaux correspondant à des points proches sur la carte apprise ont des emplacements d'émission également proches dans l'espace géographique d'origine. Elle est notée TW et définie pour une taille de voisinage K par

$$TW(K) = 1 - \frac{2}{NK(2N-3K-1)} \sum_{i=1}^N \sum_{j \in \mathcal{U}_K^i} \max(0, (r(i,j) - K)).$$

Sa valeur est comprise entre 0 (pire cas) et 1 (meilleur cas).

4.3.2 Continuité

Inversement, la continuité reflète combien de canaux associés à des emplacements d'émission proches produisent des points sur la carte qui sont également proches. Elle est notée CT et est définie pour une taille de voisinage K par

$$CT(K) = 1 - \frac{2}{NK(2N-3K-1)} \sum_{i=1}^N \sum_{j \in \mathcal{V}_K^i} \max(0, (\hat{r}(i,j) - K)).$$

Sa valeur est comprise entre 0 (pire cas) et 1 (meilleur cas).

4.4 Résultats

Le modèle est évalué avant et après entraînement sur l'ensemble de test. Les résultats de cette évaluation en termes de TW et CT sont présentés sur la figure 4. Le modèle est initialisé avec une matrice \mathbf{D} constituée de 100 colonnes. \mathbf{Z} est alors calculée par Isomap en prenant une valeur de 5 comme nombre de voisins. Le nombre d'entrées conservées k lors de l'étape de seuillage dur est fixé à 5. Ces paramètres ont été déterminés à la main de manière à obtenir une carte de bonne qualité.

Le modèle avant entraînement atteint déjà de bonnes performances avec des valeurs de TW et CT proches de 1. Ceux-ci décroissent légèrement quand la taille du voisinage considéré augmente. L'entraînement vient donc redresser cette courbe pour la maintenir quasiment au même niveau quelque soit la taille de voisinage considérée.

La figure 3 montre les positions réelles sur la carte ainsi que les cartes du canal apprises avant et après entraînement. Celles-ci permettent de bien distinguer les différents voisinages grâce aux couleurs. L'impact de l'entraînement est aussi bien apparent puisque la carte produite après entraînement est plus raffinée.




FIGURE 3 : Cartes apprises avant et après entraînement comparées aux véritables positions. La croix rouge indique la position de la station de base.




FIGURE 4 : Performances du modèle avant et après entraînement en termes de TW et CT pour différentes tailles de voisinage.

5 Conclusion

Ce papier présente une méthode hybride de cartographie du canal faible en complexité et permettant le calcul à la volée des projections. Le modèle proposé a une structure inspirée d'une mesure de distance adaptée aux mesures du canal et est initialisé de manière intelligente. L'entraînement en mode triplet permet de raffiner ses résultats et de produire des cartes de meilleure qualité. Les cartes produites peuvent ensuite être exploitées dans des applications où la connaissance des voisinages des utilisateurs est critique telles que l'allocation de ressources ou encore le précodage.

Références

- [1] Paul FERRAND, Alexis DECURNINGE, Luis G. ORDOÑEZ et Maxime GUILLAUD : Triplet-based wireless channel charting : Architecture and experiments. *IEEE J. Sel. Areas Commun.*, 39:2361–2373, 2021.
- [2] Jakob HOYDIS, Sebastian CAMMERER, Fayçal Ait AOUDIA, Avinash VEM, Nikolaus BINDER, Guillermo MARCUS et Alexander KELLER : Sionna : An open-source library for next-generation physical layer research. mars 2022.
- [3] Luc LE MAGOAROU : Efficient channel charting via phase-insensitive distance computation. *IEEE Wireless Commun. Lett.*, 10:2634–2638, 2021.
- [4] OPENSTREETMAP CONTRIBUTORS : Planet dump retrieved from <https://planet.osm.org> . <https://www.openstreetmap.org>, 2017.
- [5] Christoph STUDER, Saïd MEDJKOUH, Emre GÖNÜLTAŞ, Tom GOLDSTEIN et Olav TIRKKONEN : Channel charting : Locating users within the radio environment using channel state information. *IEEE Access*, 6:47682–47698, 2018.
- [6] Joshua B. TENENBAUM, Vin de SILVA et John C. LANGFORD : A global geometric framework for nonlinear dimensionality reduction. *Science*, 290(5500):2319–2323, dec 2000.
- [7] Taha YASSINE, Luc LE MAGOAROU, Stéphane PAQUELET et Matthieu CRUSSIÈRE : Leveraging triplet loss and nonlinear dimensionality reduction for on-the-fly channel charting. In *2022 IEEE 23rd International Workshop on Signal Processing Advances in Wireless Communication (SPAWC)*, pages 1–5, Oulu, Finland, jul 2022. IEEE.