

Méthode de modélisation non supervisée du canal satellite mobile par chaînes de Markov

Clémence ALASSEUR¹, Lionel HUSSON¹, Sandro SCALISE², Harald ERNST²

¹Supélec, département Télécommunications
Plateau de Moulon, 91192 Gif-sur-Yvette, France

²DLR (German Aerospace Centre) Institute for Communications and Navigation
Postfach 1116, 82230 Wessling, Germany
clemence.alasseur@supelec.fr, lionel.husson@supelec.fr
sandro.scalise@dlr.de, harald.ernst@dlr.de

Résumé – Nous développons une méthode de modélisation de l’atténuation du canal satellite mobile par chaînes de Markov valable lorsque les conditions de propagation évoluent (fréquence de transmission, environnement). L’estimation des paramètres du modèle du canal satellite est non supervisée contrairement aux modèles existants. Pour cela, nous employons une méthode de type MCMC (Monte Carlo Markov Chain) à sauts réversibles qui permet d’évaluer la moyenne a posteriori des paramètres du modèle ainsi que la segmentation des observations. Un modèle du canal satellite mobile en bande Ku est obtenu pour un contexte urbain. Le modèle présente de très bonnes performances : les données expérimentales et simulées ont les mêmes caractéristiques statistiques.

Abstract – We develop a modelling method for the attenuation of the land mobile satellite channel (LMSC) resorting to hidden Markov models. The proposed modelling approach makes it possible to illustrate the variations of the channel and remains valid even if the frequency of communications or the environment changes. Contrary to existing models, the estimation of the parameters is unsupervised. A reversible jump MCMC method is used to evaluate the a posteriori mean of the parameters of the model and to segment the series of observations. By applying this method, a land mobile channel model in Ku band is obtained in an urban environment. This model presents very good performances because the experimental and simulated data have the same statistical characteristics.

1 Introduction

Nous nous intéressons au comportement statistique des canaux satellites mobiles dans le cadre de la conception des nouveaux systèmes. Des systèmes, Inmarsat, Thuraya, XM Radio opèrent déjà dans les bande L et S pour de la diffusion radio ou téléphonie mobile. Les futurs systèmes explorent la possibilité d’utiliser les bandes Ku, Ka, Q et V pour lesquelles très peu d’études et de données sont disponibles. L’utilisation de bandes de fréquence plus élevée permettrait en effet d’accommoder la demande en services large bande et de pallier à la congestion des systèmes aux fréquences plus basses. Ces bandes de fréquence supérieures à 10 GHz sont influencées par les conditions météorologiques et il est nécessaire d’établir des modèles de ces canaux.

Une première classe de modèles est fondée sur les observations du canal et la modélisation de leur distribution. Ces modèles [1, 2] sont efficaces quand les conditions de propagation sont stationnaires ou quasi-stationnaires. Ils sont donc inadaptés au cas de la transmission mobile. Une deuxième classe de modèles est basée sur une approche par chaînes de Markov cachées (HMM) [3, 4]. Chaque condition de propagation est alors associée à un état de la chaîne de Markov. Pour des conditions fixes de propagation, des petites variations du niveau du signal, dues aux irrégularités des obstacles, aux multi-trajets et à la scintillation sont constatées. Elles sont représentées par une densité de probabilité associée à l’état considéré. Enfin, l’évolution des conditions de propagation, induite par la mobilité du récepteur, est modélisée par les transitions d’un état à l’autre

de la chaîne de Markov. Ces modèles supposent un nombre d’états fixe pour l’HMM et font appel à des densités de probabilité telles que les distributions de Rice, Rayleigh ou Loo [1] etc.

Dans cet article, nous déterminons un HMM pour le canal satellite mobile puisque les variations de la puissance reçue présentent des propriétés Markoviennes sous-jacentes évidentes. L’originalité de notre approche est de limiter le nombre d’hypothèses sur le modèle pour pouvoir l’appliquer à tous types d’environnement et effectuer une évaluation non-supervisée du modèle. Le nombre d’états de la chaîne de Markov ainsi que la forme des densités de probabilité ne sont pas fixés a priori. La partie 2 présente la méthodologie d’estimation de modèle proposée. Cette méthode est basée sur des outils MCMC (Monte Carlo Markov Chain). Nous constatons, enfin, que notre méthode permet une segmentation très précise des observations et les résultats obtenus sont illustrés dans la partie 3.

2 Identification du modèle

Nous considérons deux séries temporelles (y_t, z_t) où (y_t) représente les observations du gain normalisé du canal et $z_t \in \{1, \dots, k\}$ indique l’état associé à l’observation y_t , k étant le nombre d’états du modèle. Chaque observation y_t est alors une réalisation possible de la chaîne de Markov à l’instant t selon la distribution associée $f_{i/z_t=i}$. Le but poursuivi est l’estimation du nombre d’états k , la segmentation des observations $\{z_t\}$, l’estimation des paramètres de l’HMM, i.e. le nombre d’états

de la chaîne k les distributions $\{f_i\}_1^k$ et la matrice de transition $A = (a_{i,j})_1^k$.

Les méthodes MCMC permettent de simuler des données selon une distribution d'intérêt lorsque l'échantillonnage direct est irréalisable. Pour cela, elles ont recours à des distributions instrumentales plus simples et génèrent des données distribuées selon ces distributions. Pour certaines conditions, il est prouvé [4] que la distribution des données simulées tend vers la distribution d'intérêt.

La méthode de sauts réversibles (Reversible Jump-MCMC)[4] est une extension des méthodes MCMC et permet de faire évoluer la dimension de l'espace des données. A chaque itération de la méthode RJ-MCMC de nouveaux paramètres approchés du modèle sont produits. Ces paramètres (à l'exclusion des tous premiers trop dépendants des conditions initiales) permettent d'estimer les paramètres effectifs du modèle HMM après convergence de la méthode.

2.1 Modèle a priori

Richardson et Green [6] ont développé une méthode RJ-MCMC sur un mélange de distributions gaussiennes, Robert et al. [7] étendent cette méthode à des modèles HMM avec des distributions gaussiennes de moyenne nulle. Notre travail porte sur la généralisation de [7] à un modèle HMM de gaussiennes de moyenne non nulle et à l'utilisation de cette méthode sur le signal de puissance du canal satellite. L'hypothèse des moyennes nulles est inadaptée à notre cas puisque le signal du canal est très clairement un signal non centré. L'hypothèse des lois gaussiennes indique notre confiance que les états puissent être identifiés uniquement par leur moyenne et leur variance. Ce choix paraît raisonnable puisque nous disposons d'aucune connaissance a priori sur la séquence d'observations. Dans une première étape, la méthode développée permet de déterminer le meilleur modèle HMM de gaussiennes. Elle détermine ainsi le nombre d'états, la moyenne et la variance de chaque distribution gaussienne, la matrice de transition entre les états ainsi que la segmentation du signal (y_t) en différents groupes ($(y_t)_i$), c'est-à-dire l'estimation de la séquence cachée du modèle (z_t). L'hypothèse des gaussiennes est alors relaxée, et les distributions $f_i(y)$ estimées à partir des sous-groupes ($(y_t)_i$).

Pour fonctionner, une méthode MCMC utilise un modèle a priori. La méthode RJ-MCMC proposée, basée sur [7], permet de simuler les paramètres du modèle selon leur distribution conjointe. Comme les observations sont supposées, dans un premier temps, issues d'un HMM à densités normales, la distribution des observations est donc

$$\sum_{i=1}^k \pi_i \mathcal{N}(\mu_i, \sigma_i^2) \quad (1)$$

où π est le vecteur propre associé à la valeur propre 1 de la matrice de transition A . Les données μ et σ^2 sont respectivement la moyenne et la variance des lois normales. A partir de [6] et [7], la distribution conjointe de ces variables peut s'écrire :

$$p(k, A, z, \mu, \sigma, y) = p(k) p(A/k) \times p(z/k, A) p(\mu/k) p(\sigma/k) p(y/\mu, \sigma, z). \quad (2)$$

Les inconnues sont issues de distributions a priori appropriées ([6, 7]): k est échantillonné à partir de la distribution discrète uniforme sur $[1 \dots k_{max}]$, avec k_{max} le nombre maximum possible d'états. Les lignes de A sont indépendantes et distribuées selon la loi de Dirichlet $\mathcal{D}(\delta, \delta, \dots, \delta)$ avec $\delta = 1$. Les moyennes et variances sont elles aussi indépendantes et a priori distribuées respectivement selon une loi normale $\mu_i \sim \mathcal{N}(\xi, \kappa^{-1})$ et une loi Gamma $\sigma_i^2 \sim \mathcal{G}(\alpha, \beta)$. Pour rendre les a priori plus robustes, un hyper a priori paramètre est utilisé: β n'est pas une constante mais est issu d'une loi Gamma $\beta \sim \mathcal{G}(g, h)$ avec $g = 0.2$ et $h = 10/R^2$. R correspond à l'amplitude des variations des observations y_t , i.e. $R = y_{max} - y_{min}$. Les autres paramètres sont initialisés par les valeurs constantes suivantes $\alpha = 2$, $\xi = y_{min} + R/2$ et $\kappa = R^{-2}$. La distribution conjointe a priori complète est donc égale à

$$p(\eta, k, A, z, \mu, \sigma, y) = p(\beta) p(k) p(A/k, \delta) p(z/A, k) p(\mu/k, \eta) p(\sigma/k, \eta) p(y/\mu, \sigma, z) \quad (3)$$

avec $\eta = (\alpha, \beta, \xi, \kappa)$ le vecteur des hyper-paramètres. La distribution (3) a priori est la distribution d'intérêt utilisée par la méthode MCMC.

2.2 Déroulement de la méthode

Le déroulement de l'algorithme est précédé d'une phase où tous les paramètres sont initialisés selon leur loi a priori. Chaque itération se déroule ensuite en quatre étapes. La première est la mise à jour de la matrice de transition A , la deuxième la mise à jour des moyennes μ et variances σ^2 . La troisième étape consiste à actualiser la séquence cachée (z_t). Enfin la dernière étape est la proposition d'une division ou d'une fusion d'un état en deux. Ceci implique la diminution ou l'augmentation de la taille du modèle k .

A chaque itération des nouvelles valeurs des paramètres sont adoptées et constitue des réalisations d'une chaîne de Markov. Cette chaîne définie par la méthode précédemment décrite vérifie, par construction, la propriété de balance détaillée ([5]) avec la distribution a priori. Elle est également irréductible et aperiodique. Une chaîne de Markov qui satisfait à la condition de balance détaillée avec une certaine distribution admet alors cette distribution comme distribution invariante. L'existence de ces propriétés de la chaîne implique la convergence de l'estimateur de Monte-Carlo vers les paramètres du modèle ([5]).

Nous proposons une amélioration dans l'identification de la séquence cachée par le biais d'un vecteur d'occupation moyenne. En effet, à la fin du processus RJ-MCMC, le calcul de l'estimateur de Monte-Carlo doit être fait sur des données correspondant aux mêmes états. C'est pourquoi la labellisation des états cachés doit être cohérente tout au long des itérations de la méthode. Richardson et Green [6] effectuent l'identification des états par le biais des moyennes croissantes alors que Robert et al. [7] proposent quand à eux une classification en fonction des variances croissantes du fait qu'ils emploient des gaussiennes centrées. Ces deux critères ne sont pas satisfaisants si les moyennes ou les variances des états sont proches. De plus, la méthode visée doit être capable d'identifier soit des états de même moyenne et de variance différente soit de moyenne différente et de variance égale. Nous proposons donc, entre les

itérations, pour garder la cohérence, de l'étiquetage des états cachés, de considérer un vecteur d'occupation moyenne qui force la segmentation à chaque itération à prendre en compte les étiquetages précédents.

La méthode proposée dans cet article est une extension de [7]:

- Elle est étendue au cas d'un mélange de gaussiennes de moyenne variable.
- Un nouveau système d'identification des états est proposé pour que la segmentation soit cohérente tout au long des itérations de la méthode.
- Elle est accélérée en supprimant la possibilité de naissance ou mort d'un état car le nombre de données considérées est très important.

Après convergence de l'algorithme, les paramètres de l'HMM sont estimés. L'hypothèse des lois gaussiennes est alors élargie: à partir de la segmentation obtenue, les distributions finales des états sont évaluées pour une précision plus importante.

3 Résultats

La méthode décrite dans la section a été appliquée sur des signaux simulés à partir d'un modèle HMM connu. Nous considérons le modèle à trois états estimé par [8]. La méthode permet d'évaluer correctement le nombre d'états et les distributions estimées sont très proches en terme de la distance du χ^2 des distributions proposées par [8].

La méthode est ensuite appliquée à des données réelles et mesurées en bande Ku en environnement urbain selon le protocole décrit par [8]. La méthode détecte quatre états, la segmentation et les distributions correspondantes sont illustrées par les figures 1 et 2.




FIG. 1: Séquence d'observations (a) et sa segmentation (b).

Pour les données mesurées et simulées à partir du modèle obtenu, des statistiques pertinentes sont représentées aux figures

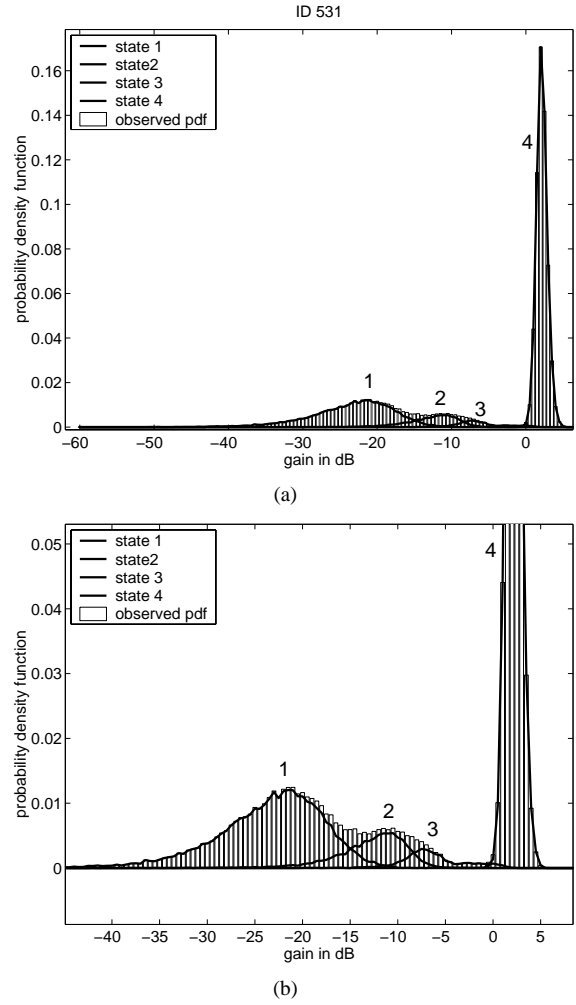


FIG. 2: Illustration de la distribution des données expérimentales ainsi que des quatre distributions obtenues après estimation du modèle (a) et un zoom sur ces mêmes distributions (b).

(3–5). Ces statistiques sont la fonction de répartition (*CDF*), l'*AFD* (Average Fade Duration), et le *LCR* (Level Crossing Rate). *AFD*(x) est la durée moyenne d'un événement d'évanouissement où toutes les valeurs successives du gain du canal qui le constituent sont inférieures à x . *LCR*(x) est le nombre moyen d'événements d'évanouissement inférieurs à x par unité de temps. La fonction de répartition, l'*AFD* et le *LCR* sont liés par l'expression (4):

$$AFD(x) = \frac{CDF(x)}{LCR(x)}. \quad (4)$$

L'accord entre la fonction de répartition (figure 3) pour les données simulées et les données expérimentales est très satisfaisant. De même, l'*AFD* simulé et expérimental (figure 4) présentent de très grandes similitudes. Les *LCR* (figure 5) correspondent aux données segmentées sur les quatre états du modèle. La qualité des *LCR* simulés par rapport aux expérimentaux pour les quatre états est très bonne. L'*AFD* et la fonction de répartition des quatre états, ne figurant pas ici, présentent les mêmes qualités. Le modèle de canal obtenu par notre méthode est donc performant et la méthode d'estimation de ce modèle doit pouvoir être appliquée à d'autres environnements sans aucune modification.




FIG. 3: Fonction de répartition globale.




FIG. 4: Durée moyenne globale des évanouissements.

4 Conclusion

Une méthode d'estimation de modèle du canal satellite mobile est proposée dans ce papier. Cette méthode fait appel à des outils de reversible jump MCMC. Contrairement aux modèles existants, cette méthode permet une estimation non supervisée du modèle et ne postule pas le nombre d'états du canal a priori. La méthode est appliquée à des signaux expérimentaux mesurés en bande Ku en milieu urbain. Le modèle ainsi obtenu permet d'obtenir des statistiques très proches de celles des signaux observés. Le modèle est donc de bonne qualité en vue de son utilisation pour des systèmes de communications.

Références

[1] C. Loo. *A Statistical Model of a Land Mobile Satellite Link*. IEEE Trans. on Vehicular Technoogy, Vol. 34, No. 3, pp. 122–127, Aug. 1985.




FIG. 5: Level Crossing Rate correspondant à chaque état détecté.

- [2] H. Suzuki. *A Statistical Model for Urban Radio Propagation*. IEEE Trans on Communications, Vol. 25, No. 7, July 1977.
- [3] E. Lutz, D. Cygan, M. Dippold, F. Dolainsky, W. Papke. *The Land Mobile Satellite Communication Channel*. IEEE Trans. on Vehicular Technoogy, Vol. 40, No. 2, pp. 375–386, May 1991.
- [4] Y. Karasawa, K. Kimura, K. Minamisono. *Analysis of Availability Improvement in LMSS by Means of Satellite Diversity Based on Three-State Propagation Channel Model*. IEEE Trans. On Vehicular Technology, Vol. 46, No. 4, Nov. 1997.
- [5] C.P. Robert, G. Casella. *Monte Carlo statistical methods, 2nd edition*. Springer texts in Statistics, 2004.
- [6] S. Richardson and P.J. Green. *On Bayesian Analysis of Mixtures with an Unknown Number of Components*. J. Royal Statistics Society, Series B, vol 59, no. 4, pp. 731–792, 1997.
- [7] C.P. Robert, T. Ryden, D.M. Titterington. *Bayesian Inference in Hidden Markov Models through reversible jump Markov chain Monte Carlo*. J. Royal Stat. Society, Series B, Vol. 62, pp 57–75, 2000.
- [8] S. Scalise, J. Kunisch, H. Ernst, J. Siemons, G. Harles and J. Hörle. *Measurement Campaign for the Land Mobile Satellite Channel in Ku-Band*. Proc. of the 5th EMPSC Workshop, Beveno/Stresa, Italy, Sept. 2002.