



HAL
open science

Compensation des Erreurs d'Identification d'Utilisateurs dans l'Allocation Stochastique de Ressources pour Réseaux Aloha Hétérogènes

Alix Jeannerot, Malcolm Egan, Léo Chetot, Jean-Marie Gorce

► **To cite this version:**

Alix Jeannerot, Malcolm Egan, Léo Chetot, Jean-Marie Gorce. Compensation des Erreurs d'Identification d'Utilisateurs dans l'Allocation Stochastique de Ressources pour Réseaux Aloha Hétérogènes. GretsI 2023, Aug 2023, Grenoble, France. hal-04257479

HAL Id: hal-04257479

<https://inria.hal.science/hal-04257479>

Submitted on 25 Oct 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.



Distributed under a Creative Commons Attribution 4.0 International License

Compensation des Erreurs d'Identification d'Utilisateurs dans l'Allocation Stochastique de Ressources pour Réseaux Aloha Hétérogènes

Alix JEANNEROT¹ Malcolm EGAN² Léo CHETOT¹ Jean-Marie GORCE¹

¹Univ Lyon, INSA Lyon, Inria, CITI, EA3720, 69621 Villeurbanne, France

²Univ Lyon, Inria, INSA Lyon, CITI, EA3720, 69621 Villeurbanne, France

Résumé – Dans les protocoles d'accès au canal de type Aloha, une question clé est de savoir comment les dispositifs doivent utiliser les ressources (créneaux temporels) sans coordination. Une solution standard à ce problème est d'assumer que tous les dispositifs ont la même probabilité d'être actif et consiste donc à sélectionner uniformément aléatoirement une ressource lorsqu'un dispositif a besoin de transmettre. Or, en pratique, l'activité des dispositifs est hétérogène, il devient alors intéressant de considérer des sélections non uniformes de ressources afin d'améliorer les performances du réseau.

Abstract – In MAC protocols like Aloha, a key question is how devices should utilize resources (time slots) without coordination. One standard solution is to assume that all users are equally likely to be active and thus consists in picking uniformly at random a resource when a device needs to transmit. In practice, all devices are not equally likely to transmit, thus it is interesting to consider non-uniform resource allocation in order to increase the performances of the network.

1 Introduction

L'allocation de ressources est un problème central pour les réseaux d'accès sans fil, en particulier pour les systèmes d'accès massifs pour la 6G, où un grand nombre d'appareils cherchent à transmettre des données vers un point d'accès. Dans la 5G-NR et NB-IoT, les trames sont décomposées en ressources temps-fréquence. Un problème principal consiste donc à déterminer, au sein d'une trame, sur quels créneaux temporels doivent être assignés les utilisateurs.

Afin d'éviter une signalisation trop importante dans un système à accès aléatoire, il est souhaitable de fournir aux appareils une politique de sélection de créneau temporel [4, 8, 7]. Cela signifie que lorsqu'un appareil a des données à transmettre, une signalisation de contrôle limitée est nécessaire pour déterminer quelles ressources l'appareil doit utiliser. La sélection d'une politique, souvent basée sur une variante d'ALOHA (par exemple, [4, 5]), est généralement basée sur un critère tel que le débit attendu du système, la probabilité d'interruption...

Une hypothèse courante dans l'étude des protocoles d'accès au canal est de considérer que tous les dispositifs ont la même probabilité d'être actif. Or dans les systèmes IoT guidés par les événements (par exemple), les dispositifs nécessitent de transmettre des données de manière sporadique. Le débit attendu dépend donc de la distribution d'activité des utilisateurs, qui régit la probabilité qu'un appareil donné soit actif dans une trame et peut varier d'un appareil à l'autre. En général, la distribution d'activité peut ne pas être parfaitement connue, en raison d'une estimation imparfaite des dispositifs actifs dans chaque trame. En effet, l'estimation des appareils actifs, fait actuellement l'objet de recherches actives [3, 1].

Dans nos travaux récents [2], nous avons montré que les algorithmes d'optimisation stochastiques utilisées dans [8, 7] sont sensibles aux erreurs d'identifications. Pour atténuer l'impact du biais découlant de ces erreurs, l'échantillonnage pré-

férentiel est utilisé afin de réduire le biais introduit. Face à la difficulté de calculer exactement le poids de correction, des heuristiques ont été proposées, cependant ces derniers reposent sur une connaissance parfaite des probabilités d'activité que suivent les utilisateurs du réseau. Dans cet article, après avoir rappelé le fonctionnement et l'intérêt de l'allocation stochastique de ressources, nous étudions un autre type d'heuristique que ceux proposés dans [2] ne nécessitant pas la connaissance exacte des probabilités d'activité. Cela est intéressant puisque en pratique ces probabilités d'activité sont estimées à l'aide d'estimateurs possédant une certaine variance.

2 Modèle

Considérons un réseau à créneaux temporels composé d'un point d'accès (AP) et de N dispositifs (aussi appelés utilisateurs, appareils ou nœuds) équipés d'une antenne unique et partageant une fréquence commune. Les transmissions s'effectuent sur des trames de tailles fixes durant lesquelles chaque dispositif n est actif avec une probabilité p_n . L'activité de chaque dispositif est représenté par la variable aléatoire $X_n \sim \text{Ber}(p_n)$ et la distribution de probabilité jointe par $p_{\mathbf{X}}$. Nous considérons que les dispositifs sont mutuellement indépendants, donc :

$$p_{\mathbf{X}}(\mathbf{x}) = \prod_{n=1}^N p_n^{x_n} (1 - p_n)^{1-x_n}, \mathbf{x} \in \{0, 1\}^N. \quad (1)$$

Dans la trame t , l'activité de tous les dispositifs est noté par $\mathbf{X}^t = [X_1^t, \dots, X_N^t]^T$. Les vecteurs d'activités \mathbf{X}^t sont mutuellement indépendants : $\mathbf{X}^{t'}, t' \neq t$.

2.1 Protocole de Transmission

Le protocole de transmission, une variante de Frame Slotted Aloha [5], est décrit dans Alg. 1. Dans chaque trame t les utili-

sateurs actifs choisissent un créneau sur lequel transmettre en fonction d'une matrice d'allocation de ressource \mathbf{A}^t . Les éléments de cette matrice, A_{ij}^t , $i \in \{1, \dots, N\}$, $j \in \{1, \dots, K\}$ représentent la probabilité que le dispositif i sélectionne le créneau j , sous contrainte que $\sum_j A_{ij}^t = 1$, $i = 1, \dots, N$ (puisque chaque utilisateur actif transmet une seule fois par trame). Contrairement aux protocoles Aloha classiques la sélection du créneau de transmission ne suit pas forcément une loi uniforme. Cette matrice peut être optimisée trame après trame dans le but de maximiser un objectif.

Algorithme 1 : Protocole de transmission dans la trame t en fonction de \mathbf{A}^t

(Liaison descendante) Signal de synchronisation marquant le début de la trame.

tant que Vrai faire

Chaque dispositif actif i tire aléatoirement un créneau k_i selon la distribution de probabilité définie par la ligne i de \mathbf{A}^t .

Chaque dispositif actif i envoie ses données dans le créneau choisi k_i .

AP decode les données et estime \mathbf{X}^t (les utilisateurs actifs dans la trame).

AP calcule \mathbf{A}^{t+1} sur la base de l'estimation de \mathbf{X}^t .

AP envoi \mathbf{A}^{t+1} aux dispositifs.

fin

2.2 Objectif d'Optimisation

L'objectif principal de cet article est l'optimisation de la matrice d'allocation de ressources \mathbf{A} (le superscript t est enlevé pour alléger la notation lorsque le numéro de trame n'est pas important). Ce problème a été récemment adressé dans [8, 7] lorsque le vecteur d'activité est connu parfaitement dans chaque trame. On cherche à maximiser le débit du réseau :

$$T(\mathbf{A}) = \mathbb{E}_{\mathbf{X}}[T^{\mathbf{X}}(\mathbf{A})], \quad (2)$$

où $T^{\mathbf{X}}(\mathbf{A})$ est défini par :

$$T_n(\mathbf{A}; \mathbf{X}) = \sum_{k=1}^K X_n A_{nk} \prod_{\substack{m=1 \\ m \neq n}}^N (1 - X_m A_{mk})$$

$$T^{\mathbf{X}}(\mathbf{A}) = \sum_{n=1}^N T_n(\mathbf{A}; \mathbf{X})$$

Cet objectif peut être interprété comme étant la proportion de créneaux dans lesquels un seul utilisateur transmet; nous cherchons donc à éviter au maximum les collisions.

Le problème de l'allocation de ressource est donc de trouver une matrice d'allocation qui maximise $T(\mathbf{A})$:

$$\mathbf{A}^* = \arg \max_{\mathbf{A} \in \mathbb{R}_+^{N \times K}; \sum_k A_{n,k} = 1} T(\mathbf{A})$$

L'objectif $T(\mathbf{A})$ n'est pas convexe en \mathbf{A} . Nous pouvons aussi souligner que les procédés présentés dans cet article ne se limitent pas à la maximisation du débit; en changeant d'objectif, il devient possible de, par exemple, maximiser l'équité proportionnelle.

3 Optimisation par Montée de Gradient en Ligne

Tel qu'observé dans [8, 7], le problème (2) peut être vu comme un problème d'optimisation stochastique. Si l'on connaît parfaitement les vecteurs d'activité $\mathbf{X}^1, \mathbf{X}^2, \dots$, alors il est possible de converger avec probabilité 1 vers un point stationnaire en utilisant une montée de gradient en ligne. Soit :

$$\mathcal{H} = \{\mathbf{A} \in \mathbb{R}_+^{N \times K} : \sum_{k=1}^K A_{n,k} = 1, n = 1, \dots, N\} \quad (3)$$

et $\Pi_{\mathcal{H}}[\cdot]$ l'opérateur de projection vers le point de \mathcal{H} le plus proche en norme Euclidienne. Pour un \mathbf{X} donné, il est possible de calculer un gradient stochastique $g(\mathbf{A}; \mathbf{X})$ ayant pour éléments $g(\mathbf{A}; \mathbf{X})_{ql}$, $q \in \{1, \dots, N\}$, $l \in \{1, \dots, K\}$ [8] :

$$g(\mathbf{A}; \mathbf{X})_{ql} = X_q \prod_{\substack{m=1 \\ m \neq q}}^N (1 - X_m A_{ml}) - \sum_{\substack{n=1 \\ n \neq q}}^N X_q X_n A_{nl} \prod_{\substack{m=1 \\ m \neq n \\ m \neq q}}^N (1 - X_m A_{ml}). \quad (4)$$

Dans ce cas, $g(\mathbf{A}; \mathbf{X})$ est une estimation non biaisée de $\nabla T(\mathbf{A}) = \mathbb{E}_{\mathbf{X}}[\nabla_{\mathbf{A}} T^{\mathbf{X}}(\mathbf{A})]$.

Algorithme 2 : Algorithme d'optimisation stochastique avec identification sans erreur.

Choisir une matrice d'allocation initiale $\mathbf{A}^0 \in \mathbb{R}^{N \times K}$ telle que $\sum_{k=1}^K A_{n,k}^0 = 1$, $n = 1, \dots, N$, et une séquence de pas $\{\alpha^t\}$ avec $\alpha^t > 0$
 $t \leftarrow 0$.

tant que non convergé faire

Sur la base de \mathbf{X}^t , calculer une estimation non biaisée $g(\mathbf{A}^t; \mathbf{X}^t)$ de $\nabla_{\mathbf{A}^t} T(\mathbf{A}^t)$

$\mathbf{A}^{t+1} \leftarrow \Pi_{\mathcal{H}}[\mathbf{A}^t + \alpha^t g(\mathbf{A}^t; \mathbf{X}^t)]$

$t \leftarrow t + 1$

fin

Cependant, si les vecteurs d'activité \mathbf{X}^t contiennent des erreurs, alors cette estimation de gradient est biaisée, ce qui entraîne la convergence vers une solution sous-optimale et induit une perte de performance.

3.1 Procédé de Réduction du Biais

La cause majeur de perte de performance est due au biais introduit dans les étapes de montée de gradient à cause de la détection d'utilisateur imparfaite. Afin de compenser ce biais il est possible d'utiliser l'échantillonnage préférentiel [6]. Considérons la fonction de poids $w : \mathbf{x} \mapsto w(\mathbf{x})$ avec $\mathbf{x} \in \{0, 1\}^N$ défini par :

$$w(\mathbf{x}) = \frac{\Pr(\mathbf{X} = \mathbf{x})}{\Pr(\hat{\mathbf{X}} = \mathbf{x})}, \quad (5)$$

où \mathbf{X} est le vecteur d'activité sans erreurs et $\hat{\mathbf{X}}$ est son estimation; e.g., obtenu par un algorithme de détection d'utilisateur tel que GAMP[1].

Une propriété importante du poids $w(\mathbf{x})$ est que pour tout $\mathbf{A} \in \mathbb{R}^{N \times K}$,

$$\begin{aligned} \mathbb{E}_{\mathbf{x}}[g(\mathbf{A}; \mathbf{X})] &= \sum_{\mathbf{x}} g(\mathbf{A}; \mathbf{x}) \Pr(\mathbf{X} = \mathbf{x}) \\ &= \sum_{\mathbf{x}} g(\mathbf{A}; \mathbf{x}) \frac{\Pr(\mathbf{X} = \mathbf{x})}{\Pr(\hat{\mathbf{X}} = \mathbf{x})} \Pr(\hat{\mathbf{X}} = \mathbf{x}) \\ &= \mathbb{E}_{\hat{\mathbf{X}}} [w(\hat{\mathbf{X}})g(\mathbf{A}; \hat{\mathbf{X}})]. \end{aligned} \quad (6)$$

Autrement dit, $w(\hat{\mathbf{X}})g(\mathbf{A}; \hat{\mathbf{X}})$ est une estimation non biaisée de $\nabla T(\mathbf{A})$, si $w(\mathbf{x}) < \infty$, $\forall \mathbf{x}$ tel que $\Pr(\mathbf{X} = \mathbf{x}) > 0$. De ce fait, il est possible de compenser le biais introduit par les erreurs et de maintenir la convergence de Alg. 2 en utilisant ce poids dans l'étape de mise à jour. Cette dernière devient :

$$\mathbf{A}^{t+1} \leftarrow \Pi_{\mathcal{H}}[\mathbf{A}^t + \alpha^t w(\mathbf{x})g(\mathbf{A}^t; \hat{\mathbf{X}}^t)] \quad (7)$$

Comme démontré dans [2], ce nouvel algorithme possède des garanties de convergence sous certaines conditions habituelles sur la séquence de pas α^t .

3.2 Étape de Mise à Jour Proposée

Si le poids (5) permet de garantir la convergence, il est cependant difficile le calculer :

- (i) le numérateur se base sur une distribution qui n'est pas parfaitement connue ou difficile à échantillonner (par exemple, une Bernoulli multivariée)
- (ii) le dénominateur se base sur une distribution postérieure qui peut être difficile à calculer suivant la complexité de l'algorithme utilisé pour la détection d'utilisateurs

La distribution utilisée au dénominateur peut être estimée en observant la sortie de l'algorithme de détection d'utilisateurs et en calculant une approximation de Monte-Carlo. Nous supposons donc cette distribution comme connue. La distribution de probabilité utilisée au numérateur peut typiquement être estimé par un algorithme espérance-maximisation. Si les conditions pour que cet algorithme fonctionne sont satisfaites, il nous fournira un estimateur de la distribution avec une certaine variance. Il est donc raisonnable de supposer que l'on peut avoir accès à une distribution $\tilde{\mathbf{X}} \sim \text{Ber}(\tilde{\mathbf{p}})$, où $\tilde{p}_i = p_i + \mathcal{N}(0, \sigma^2)$, \tilde{p}_i étant forcé à être dans $[0, 1]$, et donc à un poids \tilde{w} de la forme :

$$\tilde{w}(\mathbf{x}) = \frac{\Pr(\tilde{\mathbf{X}} = \mathbf{x})}{\Pr(\hat{\mathbf{X}} = \mathbf{x})}. \quad (8)$$

Nous proposons donc d'utiliser la mise à jour suivante :

$$\mathbf{A}^{t+1} \leftarrow \Pi_{\mathcal{H}}[\mathbf{A}^t + \alpha^t \tilde{w}(\mathbf{x})g(\mathbf{A}^t; \hat{\mathbf{X}}^t)] \quad (9)$$

Le biais introduit par cette nouvelle mise à jour n'est pas 0 puisque le poids \tilde{w} ne permet pas de débiaiser complètement le gradient. Cependant comme présenté dans la section 4, des gains intéressants peuvent tout de même être obtenus suggérant que le biais introduit par \tilde{w} est plus faible que celui introduit par la détection imparfaite.

4 Simulations

Nous évaluons le débit résultant pour deux scénarios. Le premier considère que l'algorithme de détection d'utilisateurs peut être abstrait par un canal binaire symétrique. Ainsi, chaque utilisateur a une probabilité p_{nip} d'être détecté comme actif alors qu'il ne l'était pas et une probabilité identique de ne pas être détecté alors qu'il était actif. Le second scénario fait usage d'un algorithme de détection d'utilisateur se basant sur des algorithmes à passage de messages approximatés [1]. La détection se base des pilotes uniques associés à chaque utilisateurs qui transmettent ces derniers lors d'une phase d'annonce avant de transmettre leur données. Cela permet d'effectuer à la fois l'estimation du canal et la détection des utilisateurs actifs. En fonction du SNR du pilote, l'algorithme de détection d'utilisateurs fera plus ou moins d'erreurs.

Pour ces deux scénarios, nous considérons un réseau composé de $N = 20$ utilisateurs, chaque trame étant composée de $K = 5$ créneaux. Chaque utilisateurs suit une probabilité d'activité. Les utilisateurs sont mutuellement indépendants. L'optimisation se déroule sur 2000 trames et les résultats sont moyennés sur 20 exécutions. L'espace \mathcal{H} étant relativement grand et la fonction $T(\mathbf{A})$ non-convexe, nous assumons que l'AP peut effectuer l'optimisation pour plusieurs matrices parallèle et envoyer celle donnant les meilleurs performances. Les matrices \mathbf{A}^0 candidates sont tirées aléatoirement dans \mathcal{H} . Nous présentons le débit résultant de diverse méthodes :

- l'utilisation de Alg.2 avec une détection parfaite des utilisateurs,
- l'utilisation de Alg.2 avec une détection imparfaite des utilisateurs
- l'utilisation de Alg.2 avec une détection imparfaite des utilisateurs mais avec la mise à jour utilisant le poids de correction exact 7
- l'utilisation de Alg.2 avec une détection imparfaite des utilisateurs mais avec la mise à jour utilisant le poids de correction inexact pour différentes valeurs d'écart type.
- la matrice que donnerai le protocole Aloha $\mathbf{A}_{\text{Aloha}}$: la matrice constante $A_{ij} = \frac{1}{K} \forall i, j$.
- une allocation gloutonne \mathbf{A}_h ou les utilisateurs les plus actifs possèdent un créneaux pour eux seuls.

4.1 Erreurs Symétriques

Dans cette section nous considérons que l'algorithme permettant de détecter les utilisateurs se comporte comme un canal binaire symétrique. Les probabilités d'activité des utilisateurs sont tirées aléatoirement dans $\mathcal{U}_{[0,0.45]}$. Les performances des différentes méthodes sont présentées dans la Fig.1 Il est intéressant de remarquer que si l'on réalise l'optimisation sans chercher à compenser les erreurs (ligne bleue, marqueurs ronds), on subit une perte de débit de l'ordre de 6% par trame pour $p_{\text{nip}} = 0.2$. Si cette politique de transmission est appliquée pour de nombreuses trames cela peut engendrer une quantité non négligeable de paquets perdus. Nos méthodes, même en ne possédant pas exactement la probabilité d'activité des utilisateurs permettent de compenser entre 50% et 100% de la perte débit induite par les erreurs de détections. Il est intéressant de




FIGURE 1 : Performances lorsque le lien entre \mathbf{X} et $\hat{\mathbf{X}}$ est un canal binaire symétrique. L'aire ombragée représente \pm l'écart type.

noter que pour de faibles valeurs de p_{flip} , l'optimisation de la matrice \mathbf{A} permet de bénéficier de l'hétérogénéité du réseau et peut ainsi permettre de dépasser largement le débit donné par une politique Aloha classique.

4.2 Détecteur par Passage de message Bayésien

Dans ce scénario, nous considérons que chacun des 20 dispositifs possède un pilote unique qui est une séquence de 10 échantillons tirés aléatoirement dans $\mathcal{CN}(0, \sqrt{P})$ ou P est la puissance d'émission commune à tout les dispositifs. Au début de la trame un créneau spécial d'annonce est utilisé par tous les dispositifs actifs dans lequel ils transmettent leurs pilotes. La station de base utilise l'algorithme GAMP décrit dans [1] pour détecter les utilisateurs actifs ainsi qu'estimer les paramètres du canal. En fonction du SNR à la réception, l'algorithme introduit plus ou moins d'erreurs dans les vecteurs d'utilisateurs actifs $\hat{\mathbf{X}}^t$. Dans la Fig.2, nous pouvons observer que si le SNR est faible, de nombreuses erreurs sont introduites, ce qui biaise l'allocation résultante. Nos méthodes permettent nettement limiter la baisse de performances. Dans cette simulation, contrairement à la simulation précédente, nous considérons que le vecteur de probabilité d'activité est $\mathbf{p} \sim \mathcal{U}_{[0,1]}$. Il est intéressant de voir que dans ce cas l'allocation gloutonne \mathbf{A}_h donne les meilleures performances.

5 Conclusion

L'allocation stochastique de ressources permet d'obtenir des gains de performance notable comparé à un protocole Aloha classique. En revanche, pour fonctionner de manière adéquate, il est nécessaire de correctement détecter les utilisateurs actifs dans chaque trame. Dans cet article, nous avons proposé un moyen de compenser ces erreurs en utilisant l'échantillonnage préférentiel. Les résultats numériques montrent que les algorithmes de montée de gradient avec échantillonnage préférentiel peuvent se montrer résistants à la variance dans l'estimation de la probabilité d'activité des dispositifs.




FIGURE 2 : Performance des différentes méthodes lorsque \mathbf{X} est estimé par GAMP.

Références

- [1] Lélio CHETOT, Malcolm EGAN et Jean-Marie GORCE : Joint identification and channel estimation for fault detection in industrial IoT with correlated sensors. *IEEE Access*, 9:116692–116701, 2021.
- [2] Alix JEANNEROT, Malcolm EGAN, Lélio CHETOT et Jean-Marie GORCE : Mitigating User Identification Errors in Resource Optimization for Grant-Free Random Access. *In IEEE VTC2023-Spring - 97th Vehicular Technology Conference*, Florence, Italy, juin 2023.
- [3] Malong KE, Zhen GAO, Yongpeng WU, Xiqi GAO et Robert SCHÖBER : Compressive sensing-based adaptive active user detection and channel estimation : Massive access meets massive MIMO. *IEEE Transactions on Signal Processing*, 68:764–779, 2020.
- [4] E. PAOLINI, G. LIVA et M. CHIANI : Coded slotted ALOHA : a graph-based method for uncoordinated massive access. *IEEE Transactions on Information Theory*, 61:6815–6832, Dec. 2015.
- [5] J.E. WIESELTHIER, A. EPHREMIDES et L.A. MICHAELS : An exact analysis and performance evaluation of framed ALOHA with capture. *IEEE Transactions on Communications*, 37(2):125–137, 1989.
- [6] Bianca ZADROZNY : Learning and evaluating classifiers under sample selection bias. *Proceedings, Twenty-First International Conference on Machine Learning, ICML 2004*, 2004, 09 2004.
- [7] C. ZHENG *et al.* : Stochastic resource allocation for outage minimization in random access with correlated activation. *In IEEE Wireless Communications and Networking Conference (WCNC)*, 2022.
- [8] Ce ZHENG, Malcolm EGAN, Laurent CLAVIER, Anders E KALØR et Petar POPOVSKI : Stochastic resource optimization of random access for transmitters with correlated activation. *IEEE Communications Letters*, 25(9):3055–3059, Sep. 2021.