



# Réplication de Réseaux par Lien pour des Jumeaux Numériques Adaptatifs

Samir Si-Mohammed, Fabrice Théoleyre

## ► To cite this version:

Samir Si-Mohammed, Fabrice Théoleyre. Réplication de Réseaux par Lien pour des Jumeaux Numériques Adaptatifs. CORES 2026 - 11es Rencontres Francophones sur la Conception de Protocoles, l'Évaluation de Performances et l'Expérimentation des Réseaux de Communication, Jun 2026, Mandelieu-la-Napoule, France. <hal-05597828v2>

**HAL Id: hal-05597828**

**<https://hal.science/hal-05597828v2>**

Submitted on 27 Apr 2026

**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 CC BY 4.0 - Attribution - International License

# Réplication de Réseaux par Lien pour des Jumeaux Numériques Adaptatifs

Samir Si-Mohammed<sup>1</sup> et Fabrice Théoleyre<sup>2</sup>

<sup>1</sup>CRAN, Université de Lorraine, Vandoeuvre-lès-Nancy, France

<sup>2</sup>ICube, CNRS / Université de Strasbourg, Illkirch, France

---

Les jumeaux numériques ont récemment émergé comme un paradigme transformateur dans les réseaux sans fil, offrant des perspectives prometteuses pour améliorer l'efficacité et l'adaptabilité des réseaux. En répliquant numériquement le réseau physique, ils permettent d'analyser la copie numérique pour optimiser le réseau physique. Malgré les efforts consacrés à la modélisation et à la simulation des réseaux sans fil, leur précision reste souvent insuffisante dans des environnements réels. Les conditions du monde réel, telles que les obstacles physiques et les phénomènes complexes de propagation radio, sont particulièrement difficiles à reproduire sans campagnes de mesures locales coûteuses en ressources. Pour relever ce défi, nous proposons une approche légère et basée sur les données pour la modélisation des réseaux sans fil. Plus précisément, nous utilisons le Packet Delivery Ratio (PDR) afin d'entraîner des modèles de prédiction de qualité spécifiques à chaque lien. En entraînant les modèles individuellement pour chaque lien, nous capturons efficacement l'hétérogénéité du réseau et obtenons une précision de prédiction élevée. De plus, nous introduisons une approche dynamique et adaptative permettant de sélectionner en continu le modèle le plus pertinent pour la prédiction.

**Mots-clefs :** Internet des Objets, Expérimentation, Apprentissage Automatique, Évaluation de Performance.

---

## 1 Introduction

Les réseaux sans fil sont devenus un élément essentiel de la vie moderne, offrant une connectivité continue dans l'espace. Les performances des réseaux sans fil sont toutefois intrinsèquement dynamiques. Les liaisons radio sont soumises à des interférences variables, à des obstacles physiques et à la mobilité, ce qui conduit à des comportements asymétriques, erratiques et avec pertes [1]. En conséquence, les approches traditionnelles de gestion statiques ou basées sur des règles peinent à s'adapter à des conditions réseau volatiles. Les systèmes sans fil modernes nécessitent des solutions intelligentes et basées sur les données, capables de réagir aux dynamiques en temps réel. Dans ce contexte, les Jumeaux Numériques (JNs) sont de plus en plus adoptés dans les réseaux sans fil. Un Jumeau Numérique (JN) est une réplique numérique en temps réel d'un système physique, continuellement synchronisée avec son homologue réel. Un défi majeur dans la construction de JNs efficaces réside dans la fidélité de la réplique numérique. La modélisation précise de l'environnement radio reste un défi, en particulier la qualité des liens. Les JNs basés sur la simulation reposent souvent sur des modèles approchés, qui peinent à capturer l'hétérogénéité des environnements réels sans une calibration manuelle importante. Pour être à la fois précis et pratiques, les JNs s'appuient sur une approche orientée données afin de refléter la variabilité réelle des liens sans fil. Ils doivent rester suffisamment légers pour un usage évolutif dans des scénarios dynamiques.

Nous nous concentrons ici sur l'aspect **réplication** des JNs pour les réseaux sans fil, qui constitue la base sur laquelle peuvent être construites ultérieurement des fonctionnalités de plus haut niveau telles que l'optimisation, les tests de configuration et la maintenance prédictive. Nous proposons spécifiquement un modèle de lien *agnostique*, indépendant de la technologie radio ou du type de trafic sous-jacent. Notre méthode utilise des événements observés pour entraîner des modèles légers et individualisés pour chaque lien, basés sur le PDR. Afin d'assurer la robustesse dans des environnements dynamiques, nous introduisons un mécanisme de sélection dynamique identifiant en continu le modèle le plus pertinent pour une prédiction précise.

## 2 État de l'Art

Dans le contexte des réseaux sans fil, les JNs peuvent être conçus pour modéliser l'environnement radio avec une grande précision. D'importants efforts ont été consacrés récemment aux approches basées sur le lancer de rayons (*e.g.*, [2, 3]) pour les JNs réseau, visant à reproduire la propagation des signaux dans des environnements complexes avec une grande fidélité. Bien que ces approches très précises puissent convenir à certaines applications, nous estimons qu'il est également essentiel de développer des JNs plus légers, capables de fonctionner avec des mesures moins intrusives.

Comme souligné dans l'introduction, la réplication précise de la qualité des liens radio est essentielle pour construire des JNs fiables. À cette fin, les modèles de qualité de lien jouent un rôle clé dans les capacités prédictives nécessaires à des tâches telles que l'allocation de ressources. De nombreux modèles de propagation radio ont été développés pour des scénarios spécifiques tels que les environnements urbains, véhiculaires ou en tunnel [4]. Toutefois, ces modèles nécessitent une calibration à partir de données issues de déploiements réels pour offrir des performances réalistes. Des modèles synthétiques et entièrement basés sur les données seraient donc très bénéfiques.

Après une mesure initiale de la qualité du lien, un JN doit s'appuyer sur un modèle prédictif. Différentes approches ont été proposées dans la littérature, utilisant des algorithmes d'apprentissage automatique traditionnels ou des réseaux neuronaux pour prédire l'évolution du PDR [5, 6]. Cependant, la plupart de ces études supposent l'utilisation d'un modèle unique et uniforme pour l'ensemble des liens. Étant donné l'existence de catégories distinctes de liens aux caractéristiques variées, nous plaçons pour l'utilisation de modèles entraînés par lien afin d'améliorer significativement la précision des prédictions.

## 3 Prédictions de Qualité des Liens

Certains liens affichent des performances élevées et stables, tandis que d'autres présentent une forte dynamique. Par conséquent, l'utilisation d'un modèle unique pour répliquer tous les liens sans fil conduit souvent à des résultats sous-optimaux. Nous souhaitons prédire individuellement la valeur du PDR de chaque lien.

### 3.1 Méthodologie

Nous mesurons en continu le PDR observé sur un lien, résultant en des séries temporelles de mesures, notées  $[x_1, x_2, \dots, x_n]$ . Chaque observation représente le taux de livraison (PDR) moyen sur un intervalle de temps  $T$  (par défaut 50 secondes). Cette approche permet de capturer les dépendances temporelles, telles que les tendances et la saisonnalité, et d'améliorer ainsi la précision des prédictions futures de PDR. Le problème de prédiction de PDR est alors formulé comme une tâche d'apprentissage supervisé, où la valeur courante est estimée à partir des  $w$  observations précédentes.

Dans notre approche, le modèle de prédiction utilisé peut-être quelconque, adapté aux caractéristiques du lien radio. Nous nous focalisons ici sur **le choix du modèle idéal, adapté à la situation**. Nous avons considéré dans notre évaluation les modèles suivants : Support Vector Regression, Gradient Boosting, Decision Trees, Adaboost, Extra Trees.

### 3.2 Prédictions Continues

Les prédictions sont réalisées de manière itérative : nous utilisons les valeurs prédites comme des observations afin de pouvoir établir des prédictions à plus long-terme, *i.e.*, à l'horizon de  $p$  intervalles.

Plus précisément, à l'intervalle  $i$ , nous commençons par prédire la valeur suivante à partir des  $w$  dernières valeurs observées. Nous procédons ensuite de manière itérative en utilisant la valeur prédite comme dernière observation pour produire la prédiction suivante. Nous conservons une séquence de taille fixe  $w$  et supprimons ainsi la première valeur de la séquence précédente. Ainsi, après avoir prédit  $\hat{x}(i+1)$ , la prédiction suivante est calculée à partir des entrées  $(x_{i-w+1}, \dots, x_i, \hat{x}(i+1))$ , en considérant  $\hat{x}(i+1)$  comme une valeur observée. Ce processus est répété  $p$  fois afin de générer une séquence de  $p$  prédictions.

Nous notons  $\hat{X}(i)$  l'ensemble des prédictions correspondant aux différents pas de prédiction (jusqu'à  $p$ ) à l'intervalle  $i$ . La matrice  $\hat{X}(i)$  représente les valeurs prédites pour les différents horizons de prédiction. À

chaque instant  $i$ , le modèle prédit jusqu'à  $p$  valeurs futures, formant une structure diagonale. La matrice de prédiction est définie comme suit :

$$\hat{X}(i) = \begin{bmatrix} \hat{x}_{1,1} & \hat{x}_{1,2} & \cdots & \hat{x}_{1,p} & \cdots & \hat{x}_{1,i} \\ & \hat{x}_{2,2} & \cdots & \hat{x}_{2,p} & \cdots & \hat{x}_{2,i} \\ & & \ddots & \vdots & & \vdots \\ & & & \hat{x}_{p,p} & \cdots & \hat{x}_{p,i} \end{bmatrix}$$

Les éléments de la matrice correspondent : (i) aux **lignes**, qui représentent le pas de prédiction (c'est-à-dire l'horizon temporel de la prédiction), et (ii) aux **colonnes**, qui représentent l'intervalle de temps  $i$ . À chaque intervalle  $i$ , le modèle utilise les  $w$  dernières valeurs issues de la série réelle (ou des valeurs précédemment prédites) et génère récursivement une séquence de prédictions.

### 3.3 Approche 1 : Modèle fixe

Dans cette approche, nous sélectionnons pour chaque lien le meilleur modèle de prédiction (`BestMod(link)`) à la fin de la phase d'apprentissage, en supposant que la qualité du lien est relativement stable. Puis lors du fonctionnement :

1. chaque nouvelle observation est ajoutée à la série temporelle du lien considéré ;
2. les paramètres du modèle `BestMod` pour ce lien sont réajustés à partir de cette observation en calculant l'erreur entre la prédiction réalisée et l'observation reportée ;

### 3.4 Approche 2 : Modèle adaptatif

Nous proposons une approche auto-adaptative de sélection de modèles, dans laquelle le modèle le plus performant est choisi dynamiquement à chaque itération ( $R = 1$ ), et non plus fixée à la fin de l'apprentissage. Cette stratégie permet de modifier à la fois le modèle utilisé et ses paramètres au cours du temps. Pour cela, tous les modèles candidats sont exécutés en parallèle et évalués en continu.

À chaque intervalle de temps, l'erreur de prédiction de chaque modèle est calculée sur les  $q$  dernières prédictions. Le modèle ayant obtenu les meilleures performances récentes est alors sélectionné. L'hypothèse sous-jacente est qu'un modèle performant à court terme est susceptible de rester pertinent pour les prédictions suivantes.

L'erreur d'un modèle au pas de temps  $i$  est calculée, pour chaque horizon de prédiction  $j \in [1, p]$ , en comparant les valeurs prédites aux valeurs réelles sur les  $q$  derniers intervalles. L'erreur globale correspond à la somme des erreurs quadratiques moyennes associées à chaque horizon de prédiction :

$$error^{model}(i) = \sum_{j=1}^p \left( \frac{1}{q} \sum_{k=i-q}^i (x_k - \hat{x}_{k,j}^{model})^2 \right)^2 \quad (1)$$

Le modèle minimisant cette erreur est sélectionné comme `BestModel` pour les itérations suivantes. Les prédictions au cours du cycle de vie du réseau peuvent donc provenir de modèles différents, évitant toute dépendance à un modèle unique susceptible de devenir inefficace face à l'évolution des conditions réseau.


## 4 Évaluation

Nous avons conduit nos expériences sur le testbed FIT IoT-Lab de SLICES-FR, où nous avons déployé un réseau sans fil composé de neuf noeuds sur le site de Grenoble. Chaque noeud est équipé d'un microcontrôleur M3 exécutant un firmware basé sur le système d'exploitation Contiki. Les noeuds communiquent via un réseau IEEE 802.15.4 utilisant le protocole 6LoWPAN, chaque noeud diffusant un paquet de 30 octets à tous les autres noeuds toutes les secondes. Le protocole IEEE 802.15.4 met en oeuvre le mécanisme CSMA/CA au niveau MAC. Le réseau a fonctionné pendant 24 heures, durant lesquelles nous avons collecté des séries temporelles et des statistiques en nous concentrant sur les temps de transmission et de réception.

Notre métrique principale est le PDR, défini comme le rapport entre le nombre de paquets reçus avec succès et le nombre total de paquets envoyés. Les liens sont considérés comme asymétriques : le lien de A vers B est distinct de celui de B vers A. Chaque lien est représenté par une séquence binaire indiquant la réception ou la perte de chaque paquet. Ces séquences sont ensuite agrégées sur des intervalles de temps de durée  $T = 50$  secondes afin de générer des séries temporelles représentant le nombre de paquets correctement reçus par intervalle. Pour simuler le comportement d'un JN réel, nous avons divisé les mesures de PDR collectées en deux ensembles de données : 33% (environ huit heures de déploiement) pour l'entraînement des modèles et les 66% restants (environ seize heures) pour les tests. L'ensemble de test représente les données futures projetées qu'un réseau réel transmettrait à son JN.

Afin d'évaluer les performances des modèles, nous avons utilisé la métrique MSE, qui quantifie l'écart entre les valeurs prédites et les valeurs réelles durant la phase de test. La MSE globale de chaque modèle est obtenue en moyennant les valeurs de MSE sur l'ensemble des liens du réseau. Afin d'affiner notre analyse, nous avons fait varier l'horizon de prédiction de 1 à 20 pas, testant ainsi la capacité de chaque modèle à prévoir la réception de paquets sur un horizon allant de 50 à 1000 secondes. Cela nous a permis d'évaluer l'efficacité des modèles à la fois pour des prédictions à court et à moyen terme.

#### 4.1 Modèle adaptatif vs modèle fixe



**FIGURE 1 :** Comparaison des approches adaptative et fixe.

Nous avons utilisé dans ce qui suit la métrique MAE afin de présenter plus simplement les résultats. Comme l'illustre la Figure 1, qui présente une vue globale des performances sur l'ensemble des liens, la méthode adaptative surpasse systématiquement l'approche à modèle fixe à chaque pas de prédiction. Les performances obtenues mettent en évidence une erreur de prédiction globalement faible, en particulier pour les premiers pas de prédiction. L'erreur au pas 1 reste très limitée, soulignant l'efficacité de la méthode adaptative pour les prédictions à court terme. À mesure que l'horizon de prédiction s'allonge, l'erreur augmente progressivement, ce qui est attendu dans un cadre de prédictions récursives, mais demeure

contenue sur l'ensemble des horizons considérés.

De manière générale, la méthode adaptative se révèle systématiquement plus précise que l'approche à modèle unique. Cette supériorité constante traduit sa capacité à s'adapter aux variations dynamiques des conditions de lien et à sélectionner le modèle le plus pertinent au cours du temps. La robustesse observée sur l'ensemble des liens souligne ainsi la polyvalence de l'approche et son potentiel pour une utilisation dans des environnements réseau hétérogènes et évolutifs.

Par manque d'espace, nous n'avons présenté ici qu'une figure agrégée, toutefois, des analyses plus détaillées par classe de qualité de lien (selon la valeur moyenne du PDR) montrent des tendances similaires et différentes selon la qualité des liens : les liens de qualité statique sont plus faciles à reproduire, ce qui implique une erreur de prédiction plus faible. Plus la qualité du lien est dynamique, plus l'erreur croît.

Bien que l'approche adaptative implique un coût de calcul plus élevé qu'un modèle fixe unique, la simplicité et l'efficacité des modèles sous-jacents rendent l'apprentissage continu pleinement envisageable. En pratique, la consommation de ressources reste compatible avec les contraintes de gestion des réseaux, tout en offrant un gain significatif en précision de prédiction.

## 5 Conclusion et Perspectives

Dans cet article, nous avons proposé une approche auto-adaptative servant de fondation à un JN pour les réseaux sans fil, permettant une réplique précise et légère. Notre méthode repose sur une modélisation individualisée par lien et une sélection dynamique des modèles, démontrant une forte adaptabilité aux conditions variées des réseaux sans fil. Les travaux futurs porteront sur l'évaluation à grande échelle, l'intégration de métriques supplémentaires telles que la latence, et l'amélioration des capacités de généralisation du JN.

## Références

- [1] Kannan Srinivasan et al. The  $\beta$ -factor : measuring wireless link burstiness. In *Conference on Embedded Network Sensor Systems (Sensys)*, pages 29–42. ACM, 2008.
- [2] NVidia. Omniverse platform. <https://docs.nvidia.com/aerial/aerial-dt/>.
- [3] Davide Villa et al. Colosseum as a Digital Twin : Bridging Real-World Experimentation and Wireless Network Emulation. *IEEE Transactions on Mobile Computing*, pages 1–17, 2024.
- [4] F.A. Rodríguez-Corbo et al. Propagation models in vehicular communications. *IEEE Access*, 9:15902–15913, 2021.
- [5] Hanane Benadji, Lynda Zitoune, and Véronique Vèque. Predictive modeling of loss ratio for congestion control in iot networks using deep learning. In *GLOBECOM*, pages 2814–2819. IEEE, 2023.
- [6] Tao Liu and Alberto E. Cerpa. Data-driven link quality prediction using link features. *ACM Trans. Sen. Netw.*, 10(2), jan 2014.

## Remerciements

Ce travail a été partiellement subventionné par le programme ANR PEPR Networks of the Future - DONUTS (ref. ANR-22-PEFT-00010).

## Reproductibilité

Pour garantir la reproductibilité, notre implémentation est mise à disposition publiquement (<https://github.com/SamirSim/Wireless-Link-Quality-Prediction>), incluant les scripts et la configuration utilisés dans cet article. Les paramètres utilisés dans notre évaluation sont illustrés dans la Table 1.

| Paramètre | Signification                                                 | Valeur                       |
|-----------|---------------------------------------------------------------|------------------------------|
| $T$       | Intervalle de temps pour le calcul du nombre de paquets reçus | 50 secondes                  |
| $w$       | Intervalle de fenêtre glissante                               | $w \in \{3, 5, 10, 15, 20\}$ |
| $p$       | Horizon de prédiction                                         | $p = 20$ intervalles         |
| $q$       | Intervalle de fenêtre glissante passée                        | $q = 5$ intervalles          |
| $R$       | Fréquence de recalibrage                                      | $R = 1$ intervalle           |

**TABLE 1 :** Signification et valeur des différents paramètres du modèle utilisé pour l'évaluation.