

L'apport de l'apprentissage automatique pour résoudre les contraintes liées à la mobilité dans le cadre des communications D2D

Chérifa BOUCETTA¹, Hassine MOUNGLA¹ et Hossam AFIFI²

¹Université Paris Descartes, Paris, France

²Télécom SudParis, Institut Mines-Télécom, Évry, France

7.1. Introduction

Les communications appareil-à-appareil ou *Device-to-Device* (D2D), telles qu' introduites par le *3rd Generation Partnership Project* (3GPP) dans la version 12, sont basées sur la proximité géographique. Les équipements d'un utilisateur (UE) sont capables de détecter et de communiquer avec d'autres UE situés dans leurs voisinages (Huo *et al.* 2017). Les communications D2D offrent plusieurs avantages, tels que l'optimisation de l'utilisation du spectre et l'amélioration du débit global et de la latence. Elles sont appliquées dans différents environnements pour une utilisation à la fois commerciale et publique.

La norme 3GPP a défini plusieurs cas d'utilisation dans le domaine de la sécurité publique. En effet, il est nécessaire de maintenir les communications dans des environnements caractérisés par une absence ou une faible couverture, tels que dans les trains

souterrains, en cas de catastrophes naturelles à grande échelle ou bien en cas de coupures de courant. Ainsi, une capacité supplémentaire doit être fournie en cas de besoin et en particulier dans les grandes régions métropolitaines (Deng *et al.* 2015).

La découverte directe D2D est l'un des services définis conjointement avec la communication D2D et la synchronisation D2D. Ce service permet aux UE d'identifier les utilisateurs et les applications qui se trouvent à proximité.

Deux modèles de découverte ont été définis :

- le modèle A est basé sur les « annonces » où les UE diffusent des informations ;
- le modèle B est basé sur le principe requête/réponse et est utilisé lorsque l'UE a besoin d'une information spécifique.

La station de base des réseaux mobiles basés sur les technologies *Long Term Evolution* (LTE), connue sous le nom eNB (*evolved Node B*), peut faire partie de la découverte directe D2D, que ce soit par la diffusion de la liste des ressources disponibles ou bien par la gestion de l'allocation des ressources (Luo et Li 2012).

Ainsi, deux types d'allocation de ressources sont définis : le type A et le type B. Dans le type B, appelé planifié ou « Scheduled », les utilisateurs D2D sont connectés à l'eNB qui gère l'allocation des ressources. Tandis que dans le type A, appelé « UE-selected », les paramètres sont préconfigurés dans les UE. Ces derniers sont autonomes et sélectionnent indépendamment les ressources pour échanger les différents messages afin de réaliser une découverte D2D dans des intervalles de temps discrets et ce, durant une durée fixe (appelée aussi période de découverte).

Un troisième type d'allocation des ressources basé sur les deux types introduits précédemment peut être identifié : les UE récupèrent le pool des ressources disponibles de l'eNB et chacun d'entre eux sélectionne les ressources nécessaires en fonction de ses besoins et indépendamment de ses voisins (Deng *et al.* 2015).

Dans la découverte D2D, et comme tout autre service de communication, la variation du nombre d'utilisateurs affecte les performances du réseau. En effet, les utilisateurs mobiles consomment les ressources d'une manière très différente selon leurs emplacements, le type d'application et les services réseaux offerts. Ceci entraîne des variations importantes des profils d'utilisation du réseau et des profils de densité des utilisateurs en fonction de chaque emplacement.

Afin de prédire la densité des utilisateurs en temps réel et par la suite améliorer les performances du processus de découverte pour les environnements dynamiques, nous

vectorielle de support SVR (Basak *et al.* 2007). Dans la littérature, les problématiques de recherche des réseaux mobiles et d'apprentissage profond ont été étudiées de manière essentiellement indépendante. Ce n'est que récemment que des croisements entre les deux thématiques de recherche ont émergé.

Généralement, la SVR est une approche d'apprentissage automatique (*machine learning*) utilisée dans le traitement de données volumineux des jeux parce qu'elle n'utilise que peu d'échantillons (appelés vecteurs de support) de l'ensemble de données d'apprentissage, ce qui réduit sensiblement le temps de traitement. En outre, la SVR ne se base que sur des exigences de calcul minimales, contrairement aux autres outils de régression, tels que les réseaux neuronaux artificiels (RNA), qui nécessitent plus de temps de traitement, une configuration plus complexe et un manque de généralité.

Le modèle de prédiction proposé est basé sur des traces réelles fournies par « Orange Sénégal ». Dans une étude antérieure, nous avons défini trois classes de profil de densité d'UE des stations de base en fonction du modèle de fluctuation durant la journée. Chaque profil représente une utilisation spécifique des ressources. Ensuite, nous avons implémenté un générateur de trafic réaliste en nous basant sur les modèles de densité déjà définis. Enfin, ce générateur est utilisé afin de prévoir l'évolution de la densité de l'UE dans chaque zone et par la suite adapter la probabilité de transmission dans le processus de découverte des voisins.

Dans ce chapitre, nous présentons dans la section 7.2 la communication D2D et les travaux sur les futurs réseaux mobiles. Ensuite, nous introduisons dans la section 7.3 les techniques d'apprentissage automatique et ses applications. Nous détaillons dans la section 7.4 l'approche proposée et nous enchaînons (section 7.5) avec les résultats expérimentaux. Une conclusion (section 7.6) clôture ce chapitre et illustre les travaux futurs.

7.2. La communication D2D et l'évolution des réseaux

Deux phases sont distinguées dans le cadre d'une communication D2D : une phase de découverte, durant laquelle le périphérique D2D détecte les périphériques compatibles dans son voisinage. Alors que, dans la deuxième phase d'échange de données, les équipements configurent les liaisons D2D pour envoyer les données.

Dans la littérature (Doppler *et al.* 2009 ; Fodor *et al.* 2012 ; Lei *et al.* 2012) et comme le montre la figure 7.1, deux modes D2D ont été proposés : le mode distribué où les UE communiquent directement entre eux et sont organisés de manière complètement distribuée, ainsi, le réseau est auto-organisé sans contrôle de l'infrastructure.

Dans le deuxième mode, nommé le mode assisté, une infrastructure réseau est nécessaire pour la configuration de la communication D2D. Dans les sections 7.2.1 et 7.2.2, nous détaillons les deux phases de découverte et de communication de données qui peuvent être gérées selon l'un des deux modes : soit en utilisant une approche distribuée, soit une approche assistée par le réseau.

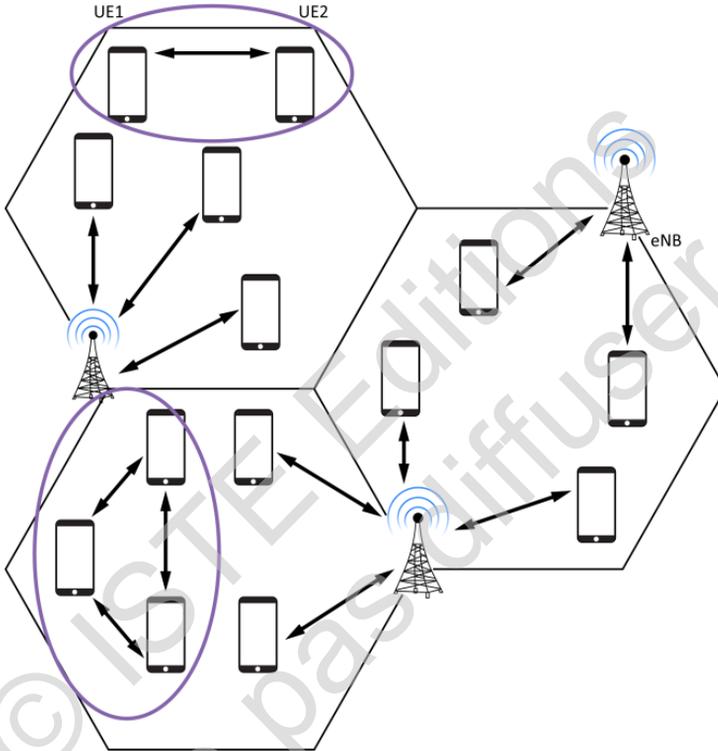


Figure 7.1. Communication appareil à appareil entre UE1 et UE2 en tant que sous-couche à un réseau cellulaire

7.2.1. La phase de découverte dans les communications D2D

La phase de découverte peut être centralisée (basée sur l'infrastructure réseau) ou distribuée, appelée aussi directe.

7.2.1.1. L'approche directe

Selon 3GPP ProSe (3GPP 2014), deux modèles de découverte directe ont été identifiés : le premier modèle (A), « Je suis là (*I'm here*) », se base sur une diffusion

inconditionnelle d'un message *Hello*. Tandis que le second modèle (B) s'appuie sur la méthode requête/réponse. En effet, un périphérique UE peut effectuer une découverte directe de son environnement en fonction de l'application et du rôle de la découverte : par exemple, dans la découverte en mode active, le périphérique annonce sa présence et le service qu'il propose alors que dans la découverte d'une application de surveillance, l'UE reste en mode passif et surveille uniquement les informations spécifiques dans les domaines d'intérêt annoncés autour de lui.

L'approche de découverte directe présente plusieurs avantages tels que la flexibilité et l'évolutivité, parce qu'elle se base sur les positions des équipements et la radio locale.

7.2.1.2. L'approche centralisée

Cette approche implique au moins une ou plusieurs entités réseau dans la procédure de découverte. Puisque le réseau d'opérateurs possède une vision plus large du trafic global et du contexte de mobilité UE, les approches de découverte centralisée visent à exploiter les ressources des réseaux d'opérateurs mobiles sur la micro et la macro mobilité afin de fournir des informations de détection plus précises. Il est à noter que cette approche de découverte n'est pas conforme à la définition de base de D2D en tant que communication sans infrastructure entre deux périphériques, mais elle est toujours considérée comme un modèle de découverte alternatif pour les services de proximité par la norme 3GPP.

7.2.2. La phase d'échange de données dans les communications D2D

Après la phase de découverte du voisinage, les UE établissent des liens de communication pour l'échange de données. Ces liens diffèrent des liens des réseaux cellulaires classiques et peuvent être utilisés pour le déchargement. Comme le montre la figure 7.1, la transmission des données peut être effectuée soit directement entre les périphériques D2D (schéma de transmission direct), soit *via* un chemin optimisé contrôlé par l'opérateur en passant par l'eNB (système de transmission contrôlé). Sur la base de ces deux schémas, la communication entre les périphériques peut s'effectuer au mieux (pas de prise en charge de la QoS et liaisons sans connexion) ou avec la QoS (établissement de supports de données LTE dédiés) parce que l'opérateur fournit un traitement basé sur les services D2D, les flux de trafic de données, le nombre d'abonnés, etc.

Dans une communication LTE classique (3GPP 2012 ; Jeong *et al.* 2013), les flux de données entre deux appareils sont mis en place *via* l'établissement de supports de données. Un support de données est composé d'un support radio entre le périphérique

et l'eNB, un support EPC (*Evolved Packet Core*) entre l'eNB et le réseau Core et des filtres de paquets sur les périphériques. L'établissement d'un support de données consiste à configurer une connexion PDN (*Packet Data Network*) en spécifiant la passerelle PDN et à attribuer une adresse IP aux périphériques communicants.

Dans le cas d'une communication D2D, il n'est pas nécessaire d'établir un support de données entre les périphériques lorsque le schéma de communication est un déchargement D2D direct. Ainsi, les données sont échangées directement sur la liaison radio entre les appareils et seul l'adressage physique est utilisé pour identifier la source et la destination. Alors que, dans le cas d'un système de déchargement contrôlé, un support D2D dédié avec des ressources radio spécifiques allouées par l'eNB doit être configuré. Dans ce dernier cas, le support dédié créé est composé uniquement d'un support radio, sans support EPC où les flux de données ne transitent qu'entre l'eNB et les périphériques qui utilisent la même adresse IP que celle attribuée pour leurs supports LTE créés lors de la première connexion au réseau.

7.2.3. Enquêtes sur les futurs réseaux mobiles

Les nouvelles générations de réseaux mobiles émergents tel que la 5G et plus intègrent une foule de nouvelles techniques afin de pallier aux différentes limitations de performances des déploiements actuels, et ainsi répondre aux nouvelles exigences des techniques de communication. Les progrès réalisés à ce jour dans ce domaine ont été résumés dans plusieurs travaux d'état de l'art, tutoriaux et des articles de magazines, par exemple (Andrews et al. 2014 ; Gupta et Kumar Jha 2015 ; Agiwal et al. 2016 ; Panwar et al. 2016 ; Mao et al. 2017).

Andrews et al. soulignent les différences entre la 5G et les architectures de réseaux mobiles antérieures, effectuent un examen complet des techniques de la 5G et discutent des problèmes de recherche auxquels font face les développements futurs (Andrews et al. 2014). Agiwal et al. passent en revue les nouvelles architectures des réseaux 5G, étudient les technologies sans fil émergentes et signalent les problèmes de recherche restant non résolus (Agiwal et al. 2016). Gupta et Kumar Jha examinent également les travaux existant sur les architectures de réseau cellulaire 5G, proposant ensuite un cadre qui intègre des ingrédients de mise en réseau tels que la communication D2D (*Device-to-Device*), les petites cellules, le Cloud informatique et l'Internet des objets (IdO) (Gupta et Kumar Jha 2015).

Le réseautage mobile intelligent devient un domaine de recherche populaire et les travaux connexes ont été examinés dans la littérature, par exemple (Bkassiny et al. 2013 ; Abu Alsheikh et al. 2014 ; Buda et al. 2016 ; Keshavamurthy et Ashraf 2016 ;

Bui *et al.* 2017, Jiang *et al.* 2017). Les techniques d'apprentissage automatique pourraient apporter davantage de solutions.

7.3. Contexte de l'apprentissage automatique et profond

L'apprentissage automatique (*Machine Learning*) apporte une valeur ajoutée dans de nombreux domaines d'application, à savoir : l'efficacité des systèmes/réseaux tels que l'énergie, la sécurité informatique (détection des spams, analyse des menaces, etc.) (Aono *et al.* 2018), la reconnaissance d'images (numériques, satellitaires, écritures manuscrites), la gestion de l'environnement, l'Internet des objets (Li *et al.* 2018), les voitures autonomes (Liu *et al.* 2017a), la reconnaissance de la voix, etc. (Chen *et al.* 2014 ; Huo *et al.* 2017 ; Wu *et al.* 2017).

De ce fait, les techniques d'apprentissage automatique sont basées essentiellement sur les outils de l'intelligence artificielle (réseaux de neurones, arbres de décision, règles d'association), en vue d'aboutir à une analyse prédictive à partir d'une masse de données hétérogènes. De surcroît, ces techniques permettent de réaliser des corrélations entre les différents événements afin de générer des décisions. En d'autres termes, il s'agit de définir un modèle de données et d'effectuer des prédictions à partir de données en se basant sur des statistiques récoltées.

Récemment, une catégorie de méthodes d'apprentissage automatique qui est basée sur les réseaux de neurones artificiels profonds s'est avérée être spécifiquement adaptée aux vastes quantités de données d'apprentissage et peut se révéler éminemment meilleure que les méthodes alternatives. Cette catégorie répond au nom « d'apprentissage profond » (« deep learning »). Ce dernier a réalisé différents exploits sur plusieurs domaines de l'intelligence artificielle (Hinton 2012 ; Xiaohui 2017).

Le *Deep Learning* se base sur un réseau neuronal profond composé de dizaines, voire de centaines de couches de neurones, chacune recevant et interprétant les informations de la couche précédente et des séries de calculs propositionnels complexes. Les algorithmes d'apprentissage profond fonctionnent avec un apprentissage à plusieurs niveaux de détail. Ainsi, nous passons de paramètres de bas niveau à des paramètres de plus haut niveau à travers les différentes couches et les différents niveaux correspondant à différents niveaux d'abstraction des données. Une extension du réseau de neurones est la mémoire à long terme (LSTM). Elle a pour but de prédire l'état futur en fonction des états précédents. L'avantage de ce modèle est la différence entre le nombre d'entrées et de sorties.

Il existe différents modèles d'apprentissage profonds dans la littérature, notamment « Deep Belief Network » (DBN) (Hinton *et al.* 2006 ; Le Roux et Bengio 2010),

« Stacked AutoEncoder » (SAE) (Vincent *et al.* 2010) et « Convolutional Neural Networks » (CNN) (Lecun *et al.* 1998). Récemment, les CNN se sont avérés être une bonne alternative par rapport à d'autres modèles d'apprentissage profond orientés prédiction (Dieleman *et al.* 2015 ; Hosseini *et al.* 2017 ; Wang *et al.* 2017), orientés classification et orientés détection (Cao *et al.* 2018).

L'apprentissage automatique utilise le réseau neuronal profond pour extraire des caractéristiques pertinentes à partir d'une masse de données comme le montre la figure 7.2. En effet, le réseau neuronal profond se situe à la dernière étape de l'apprentissage automatique, et la règle d'apprentissage présente l'algorithme qui génère le modèle à partir des données d'apprentissage. Ces algorithmes nécessitent des quantités croissantes de données pour augmenter l'efficacité des processus d'apprentissage. En d'autres termes, plus le volume de données est important (sources multimodales), plus ce processus devient efficace. Ainsi, ce processus est considéré comme robuste et performant au vu de sa précision très élevée dans l'optimisation et la prévision de décisions.

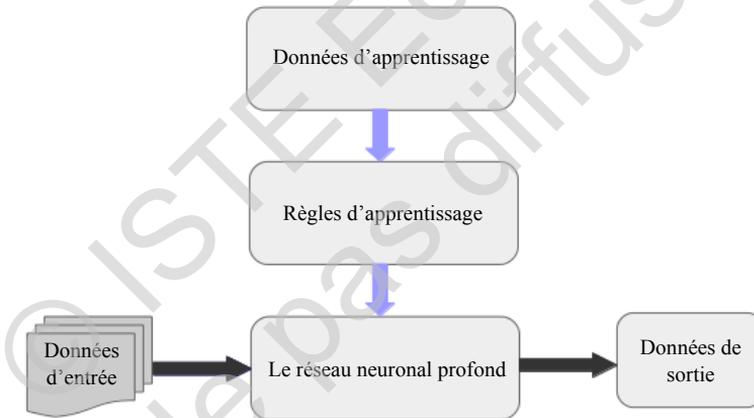


Figure 7.2. Processus d'apprentissage automatique

7.3.1. Aperçus de l'apprentissage profond et de ses applications

L'ère des Big Data suscite un vif intérêt pour l'apprentissage profond dans différentes disciplines de la recherche (Chen et Lin 2014 ; Najafabadi *et al.* 2015 ; Gheisari *et al.* 2017 ; Hordri *et al.* 2017) ; ainsi, un nombre croissant d'état de l'art et de travaux de recherche font leur apparition, par exemple (Deng 2014).

Lecun *et al.* donnent un aperçu sur l'apprentissage profond, présentent plusieurs modèles populaires et examinent le potentiel des réseaux de neurones profonds (Lecun *et al.* 1998). Schmidhuber quant à lui entreprend une étude encyclopédique sur l'apprentissage profond, probablement la plus complète à ce jour, couvrant l'évolution, les méthodes, les applications et les problèmes de recherche ouverts (Schmidhuber 2015).

Liu *et al.* résument les principes sous-jacents de plusieurs modèles d'apprentissage profonds et examinent les évolutions de l'apprentissage profond dans des applications, telles que le traitement de la parole, la reconnaissance de formes, et la vision par ordinateur (Liu *et al.* 2017).

Zhang *et al.* étudient les développements de l'apprentissage profond pour les systèmes de recommandation (Zhang *et al.* 2017), qui pourrait jouer un rôle important dans de la publicité mobile.

Comme l'apprentissage profond devient de plus en plus populaire, Goodfellow *et al.* fournissent un tutoriel complet sur l'apprentissage profond dans un livre qui couvre les connaissances préalables, les principes sous-jacents et les applications populaires (Goodfellow *et al.* 2016).

Un autre domaine d'application de l'apprentissage profond est la communication dans les réseaux dans lequel se positionne notre approche proposée. Cette dernière exploite l'apprentissage automatique dans la découverte D2D. Ainsi, nous présentons dans ce qui suit les différentes techniques et applications de l'apprentissage automatique qui permettent de présenter l'approche consistant à adapter dynamiquement la probabilité de la transmission dans la communication D2D.

7.3.2. Types d'apprentissage automatique

L'objectif principal de l'apprentissage automatique est de trouver un modèle à partir des données collectées. Il consiste à extrapoler une loi à partir d'un ensemble des faits expérimentaux avec une mesure de qualité. Pour cela, l'ensemble des données est divisé en deux catégories :

- *ensemble d'apprentissage* : utilisé pour apprendre le modèle ;
- *ensemble de test* : utilisé pour apprendre la qualité.

Parmi les problèmes typiques adressés par l'apprentissage automatique :

- la régression : prédire une valeur à partir d'autres valeurs ;

- le clustering : mettre les choses/les gens dans des groupes naturels ;
- le filtrage collaboratif : recommander des articles aux utilisateurs en fonction des comportements antérieurs.

Les techniques de *Machine Learning* peuvent être classifiées en trois catégories selon la méthode d'apprentissage :

- *apprentissage supervisé* : l'ensemble d'apprentissage contient la liste des entrées avec des sorties correctes {input, correct output} ;
- *apprentissage non supervisé* : l'ensemble d'apprentissage contient uniquement des entrées sans les sorties correctes {input} ;
- *apprentissage par renforcement* : se base sur un ensemble d'entrées, quelques outputs et la qualité du résultat. {Input, correct output, grade for this output}.

L'apprentissage supervisé est très similaire au processus dans lequel un humain apprend des choses.

7.3.3. La régression linéaire et la classification

Nous distinguons deux types d'application de l'apprentissage supervisé : la classification et la régression.

La classification : elle se base sur la recherche littérale des classes auxquelles appartiennent les données d'apprentissage qui se présentent sous la forme suivante : {input, class}.

Parmi les applications basées sur la classification, nous citons :

- service de filtrage des spams → classification des e-mails spams ou non spam (régulier) ;
- service de reconnaissance des nombres → classification des images de 0 à 9 ;
- service de reconnaissance faciale → classification des images faciales.

La régression linéaire : l'objectif principal de la régression linéaire est de prédire des valeurs à partir d'autres valeurs. Un exemple d'application est de prédire la taille des gens à partir de leurs données personnelles (compte bancaire, numéro de téléphone, adresse, etc.). Ainsi, plus on a des données d'entrée, plus on a de chance d'obtenir un modèle plus proche de la réalité.

La différence entre la classification et la régression est que la classification détermine à quel groupe les données d'entrée appartiennent. Ensuite, la sortie correcte de la classification est donnée en catégories. En revanche, la régression se base sur la prédiction et considère les valeurs pour la sortie correcte dans les données d'apprentissage.

7.3.3.1. La classification linéaire avec SVM

Le SVM (*Support Vector Machine*) appartient à la catégorie des *classificateurs linéaires* (qui utilisent une séparation linéaire des données), et dispose de sa propre méthode pour trouver la frontière entre les catégories. En effet, il utilise des critères géométriques. Supposons que nous disposions d'un ensemble d'échantillons d'apprentissage qui contient des vecteurs dans un espace de d -dimensions : $(x_i \in \mathbb{R}^d, i=1,2,\dots,N)$, avec l'étiquette d'une classe $y_i \in \{-1,1\}$. Ainsi, le classificateur SVM (Hearst *et al.* 1998) est représenté par une fonction $f(x, \alpha) \rightarrow y$, avec α étant le paramètre du classificateur.

D'une manière générale, l'approche SVM consiste à chercher un hyperplan qui maximise la distance entre les échantillons de l'apprentissage et l'hyperplan de séparation comme suit :

- des échantillons étiquetés $y_i \in \{-1,1\}$ sont localisés de chaque côté de l'hyperplan ;
- l'hyperplan doit maximiser la **marge**, c'est-à-dire la distance minimale entre les vecteurs d'entraînement et l'hyperplan. Ces vecteurs sont appelés **vecteurs supports**.

L'hyperplan est défini par $w \cdot x + b = 0$ avec w et b qui sont les paramètres de l'hyperplan. Les vecteurs qui ne sont pas dans cet hyperplan sont déterminés par : $w \cdot x + b \geq 0$ d'où le SVM est défini comme suit :

$$f(x, \alpha) = \text{sgn}(w \cdot x + b)$$

Afin de chercher un hyperplan, il faut estimer les paramètres b et w en se basant sur l'équation [7.1] :

$$y_i(w \cdot x_i + b) > 0, \text{ avec } i = 1,2, \dots, N \quad [7.1]$$

La distance entre l'échantillon d'entraînement le plus proche et l'hyperplan séparateur peut être égale à $\frac{1}{\|w\|}$, avec une simple remise à l'échelle des paramètres de l'hyperplan et b telle que :

$$\min(y_i(w \cdot x_i + b)) \geq 1, \text{ avec } i = 1,2, \dots, N \quad [7.2]$$

La marge géométrique entre les deux classes est donnée par la quantité. Par conséquent, la maximisation de la marge conduit à un problème d'optimisation sous la contrainte suivante :

$$\left\{ \begin{array}{l} \text{minimiser : } \frac{1}{\|w\|^2} \\ \text{sujet de : } y_i(w \cdot x_i + b) \geq 1, \text{ avec } i = 1, 2, \dots, N \end{array} \right\} \quad [7.3]$$

7.3.3.2. La régression vectorielle de support (SVR)

La régression vectorielle de support (SVR) utilise les mêmes principes que SVM pour la classification mais avec quelques différences. Comme son nom l'indique, SVR utilise des valeurs continues au lieu de classification dans SVM. Son principe est de trouver la règle de régression linéaire la plus « plate » possible, sous certaines contraintes. Cependant, l'idée principale est de minimiser l'erreur et individualiser l'hyperplan qui maximise la marge. Ainsi, une marge de tolérance (*epsilon*) est définie comme une approximation du SVM.

7.4. La découverte dynamique

Dans cette section, nous décrivons une nouvelle approche basée sur les outils de l'apprentissage automatique, notamment SVM et SVR qui améliorent les performances du processus de découverte pour les environnements dynamiques. Nous considérons l'approche de découverte directe vu les avantages qu'elle présente par rapport à l'approche centralisée. Cependant, le principal défi pour la découverte D2D est l'augmentation de l'envoi de messages lors des procédures de découverte et de surveillance. En particulier, la découverte d'UE consommerait beaucoup d'énergie pour la transmission périodique permanente de messages de découverte. Ces algorithmes d'apprentissage automatique visent principalement à prédire la densité des utilisateurs dans les cellules afin de réduire le nombre de messages et l'énergie consommée. En effet, la solution donne aux UE la possibilité de modifier leurs probabilités de transmission au besoin afin de réduire le temps requis pour la découverte des autres UE. Ainsi, elle permet d'améliorer et de maintenir les performances réseaux, voire les améliorer durant la phase de découverte dans le cadre de scénarios en dehors des couvertures réseaux.

7.4.1. Prédiction temps réel de la densité des utilisateurs

Nous définissons un modèle basé sur SVR pour la prédiction de la densité des utilisateurs au sein des cellules (Hammami 2018). Compte-tenu d'un échantillon de N séries temporelles (l'historique de la densité de l'UE des cellules concernées) noté $e(x_i, y_i)^N$ où SVR vise à trouver une fonction linéaire qui associe x_i avec y_i dans un

espace de fonctionnalité (avec une dimension plus élevée). Dans notre proposition, nous tirons profit de la fonction de base radiale (RBF : *Radial Basis Function*) comme fonction du noyau car pertinente avec les séries temporelles non linéaires (comme dans notre cas) à cause de sa capacité de généralisation et de sa capacité de cartographie non linéaire dans un espace infini de fonctionnalités.

Les réseaux à fonctions de base radiales (RBF) sont des modèles connexionnistes simples à mettre en œuvre et assez intelligibles, et sont très utilisés pour la régression et la discrimination. Leurs propriétés théoriques et pratiques ont été étudiées en détail dans la littérature. Le tableau 7.1 décrit quelques exemples de fonctions du noyau utilisées dans la littérature.

Les fonctions du noyau	Équation
Linear	$K(x_i, x_j) = \langle x_i, x_j \rangle + b$
Polynomial	$K(x_i, x_j) = \langle x_i, x_j \rangle^d + b$
Sigmoid	$K(x_i, x_j) = \text{tang}(\langle x_i, x_j \rangle) + b$
RBF	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2)$

Tableau 7.1. Exemples de fonctions du noyau SVR

La prédiction se déroule en deux temps : la première étape étant l'entraînement, dans laquelle nous analysons et utilisons l'historique de la densité des utilisateurs ; la seconde étant le test, dans laquelle les paramètres du modèle sont optimisés.

L'efficacité de la prédiction SVR est entérinée en utilisant des données de test extraites à l'avant de l'ensemble de données d'« Orange Dakar ». L'efficacité de la prédiction basée sur la SVR est mesurée par deux indicateurs majeurs : le coefficient de corrélation au carré ainsi que la mesure de l'erreur quadratique moyenne (MSE). Au préalable de ce travail et dans le cadre d'une étude antérieure (Hammami *et al.* 2016), nous avons inféré et classé à partir d'une grande collection de données fournie par « Orange Sénégal », trois classes de profil de densité d'UE des stations de base qui ont été extraites. Chaque type de profil de station de base appartient à un modèle spécifique de fluctuation de charge et d'utilisation du réseau qui dépend de la nature de son emplacement. La classification de profil de la station de base installée dans la ville de Dakar est également prise en compte. Le profil « charge de nuit » représente les zones résidentielles, celui de « charge de jour » représente la plupart des secteurs d'activité et le profil « charge constante » est lié aux zones mixtes. Une collection de modèles de densité des UE est inférée des données Dakar afin d'être incorporée dans ns-3 dans le but d'implémenter un générateur de trafic réaliste. L'outil est utilisé afin

de prédire l'évolution de la densité de l'UE dans chaque zone et ensuite utiliser les valeurs prédites pour l'algorithme de découverte directe.

7.4.2. La découverte dynamique : l'algorithme

La découverte de voisinage direct dans les communication D2D souffre de flexibilité quant aux environnements ambiants de communication. Cette dernière repose sur des paramètres fixes prédéfinis, notamment la probabilité de transmission. La norme 3GPP stipule que le canal utilisé pour la découverte est mi-duplex et l'ensemble des UE utilisent la même probabilité de transmission préconfigurée et définie dans le pool de ressources de découverte pour le mode sélectionné par l'UE. Néanmoins, l'utilisation de valeurs de probabilité de transmission adaptatives sélectionnées en fonction de la taille du groupe en temps réel pourrait améliorer considérablement la performance de l'ensemble du processus.

La probabilité de transmission optimale θ est ainsi calculée (Ben Mosbah 2016) :

$$\theta = \left\{ \begin{array}{ll} 1 & \text{Si } N_u < \frac{N_r(N_t-2) + N_t}{N_t-1} \\ \frac{2N_r + N_t(N_u-1) - \sqrt{4N_r(N_r-N_t) + N_t^2(N_u-1)^2}}{2N_u} & \text{Autrement} \end{array} \right\} \quad [7.4]$$

Nous proposons un algorithme qui utilise les modèles de densité d'utilisateur prédits afin de déterminer la valeur de probabilité de transmission θ fournissant la meilleure performance de découverte.

L'algorithme défini est exécuté toutes les heures et tient compte du nombre d'utilisateurs prédits N_u pour cette zone pendant cette période de la journée. À l'aide de la formule [7.4], nous calculons la valeur optimale de la probabilité de transmission dans la découverte en temps réel. À chaque période (par exemple au début de chaque heure), l'algorithme tient en compte la zone géographique pour déterminer le type de trafic. L'algorithme consulte sa base de données réelle enregistrée de trafic similaire, lance le calcul de la moyenne et obtient le nombre d'utilisateurs prédits dans la zone pour cette heure et ce trafic spécifique. À noter que les profils de densité d'utilisateurs utilisés pendant ce processus sont extraits des traces réelles du réseau. Par conséquent, il donne une idée précise sur le nombre réel d'UE présents dans le réseau. Sur la base de cette information, la probabilité de transmission optimale θ est calculée périodiquement chaque heure (où le nombre prévu d'UE pourrait changer) afin d'obtenir les meilleures performances de découverte. Nous avons démontré l'efficacité de cette proposition à travers les performances énergétiques et la réduction des délais de découverte qui ont été considérablement améliorés.

7.5. Résultats expérimentaux

Dans cette section, nous présentons les évaluations de la méthode d'apprentissage proposée utilisant des simulations sous ns-3 (Rouil *et al.* 2017). Nous utilisons un scénario extrait de l'étude des traces de l'opérateur « Orange Sénégal » (Hammami *et al.* 2016) que nous avons intégré dans ns-3 en tant que modèles de densité d'équipement utilisateur (UE) réalistes, afin d'étudier l'efficacité de l'approche proposée.

7.5.1. Les hypothèses générales

Le tableau 7.2 récapitule la liste des paramètres réseau ainsi que leurs valeurs utilisées pour nos simulations. Des ensembles de modèles de densité UE sont extraits des données de Dakar pour être intégrés à ns-3 afin de mettre en œuvre un outil générateur de trafic réaliste. L'outil est ensuite utilisé pour générer un modèle réaliste dans l'optique de former le modèle SVR et prédire l'évolution de la densité des UE dans chaque zone (Ben Mosbah 2016). Ceci afin d'utiliser les valeurs prédites pour l'algorithme de découverte D2D directe.

Paramètres	Valeurs
Puissance d'émission de l'UE	23 dBm
Modèle de propagation utilisé	Cost231 (Damasso 1999)
Bande passante disponible	50 RB
Fréquence porteuse	700 MHz
Période de découverte	0,32 s
Nombre de retransmission	0
Nombre de répétitions	1
Nombre de paires de blocs de ressources	4
Nombre de sous-cadres	5
Nombre total de ressources	20
Nombre total de Nœud B évolué (eNB)	3
Découverte début	2
Total des simulations par scénario	100

Tableau 7.2. Paramètres de simulation et valeurs

Nous avons considéré deux scénarios à faible et à haute densité de profil « charge de jour ». Ils sont présentés dans les sections 7.5.2 et 7.5.3.

7.5.2. Trafic avec une faible densité d'utilisateurs

Nous considérons un scénario de profil de densité d'utilisateurs du matin dans une zone caractérisée par des fluctuations d'utilisation dues à la présence d'établissements d'enseignement supérieur. En conséquence, un profil de trafic du matin est pris en compte. Dans des conditions normales, la zone serait desservie par trois eNB, mais dans ce scénario, elles ont été rendues inutilisables (en raison, par exemple, de pertes de connectivité de *backhaul*). Les équipements utilisateur sont déployés de manière aléatoire, comme illustré dans la figure 7.3. Le nombre maximal d'utilisateurs aux heures de pointe est de 50, 75 et 100.

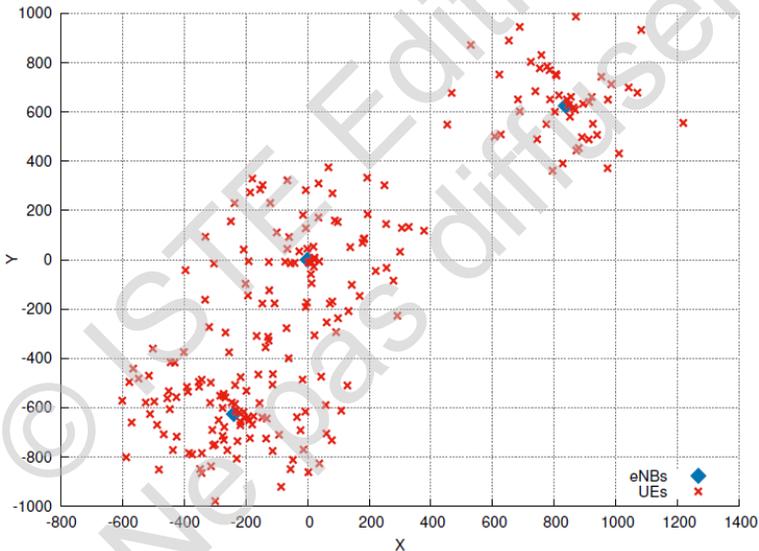


Figure 7.3. Exemple de position des nœuds pour le scénario de trafic du matin avec une faible densité d'utilisateurs

7.5.3. Trafic avec une haute densité d'utilisateurs

Contrairement au scénario décrit précédemment, nous considérons une zone géographique dense (plus précisément un quartier d'affaire de Dakar) couvert par treize eNB, comme indiqué sur la figure 7.4. Cette zone pourra accueillir un profil de trafic avec une concentration plus élevée d'UE déployés.

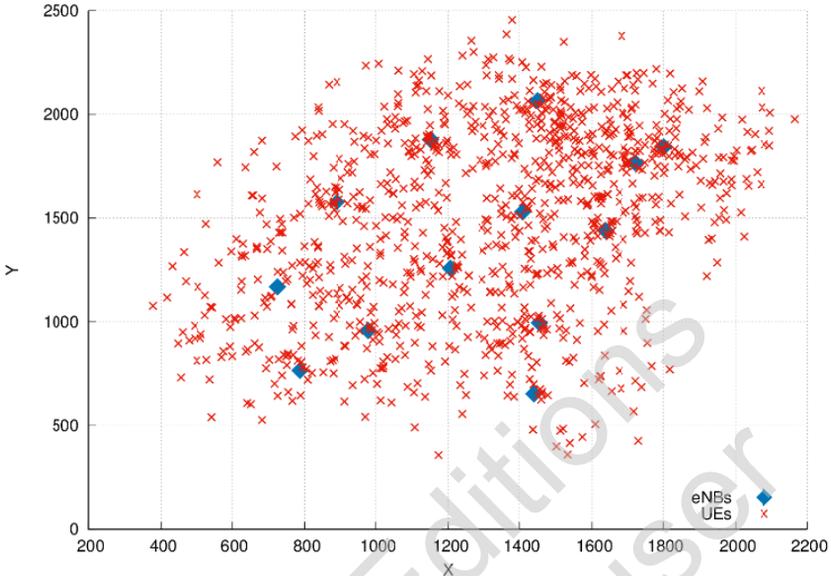


Figure 7.4. Exemple de position des nœuds pour le scénario de trafic du matin avec une haute densité d'utilisateurs

Les résultats de la simulation sont illustrés dans les figures 7.4, 7.5 et 7.6. Chacune d'elles indique le nombre de messages et le temps (mesuré en périodes) jusqu'à la découverte de tous les UE de la zone (ou jusqu'à expiration de la période de découverte de 60 secondes). Pour l'algorithme 3GPP, la probabilité de transmission est invariable pendant toute la simulation et peut être égale à 0,25, 0,5, 0,75 ou 1. Toutefois, notre algorithme utilise les informations relatives au nombre prévu d'utilisateurs pour ajuster la probabilité de transmission correspondante de manière dynamique. Les UE peuvent calculer leur propre probabilité de transmission dans le temps. Le mécanisme de découverte envisagé permet de réaliser des économies d'énergie et d'éviter les pertes de paquets importantes, grâce à la réduction du nombre de messages transmis.

Nous pouvons observer une augmentation de l'activité du réseau qui atteint un pic vers midi. Les courbes valident le fait que nous simulons un trafic du matin. Nous pouvons également noter que, pendant les heures où le nombre d'UE est faible, il existe un compromis direct entre le temps requis pour effectuer la découverte et le nombre de messages envoyés. Nous pouvons voir comment notre algorithme établit un équilibre entre les deux mesures.

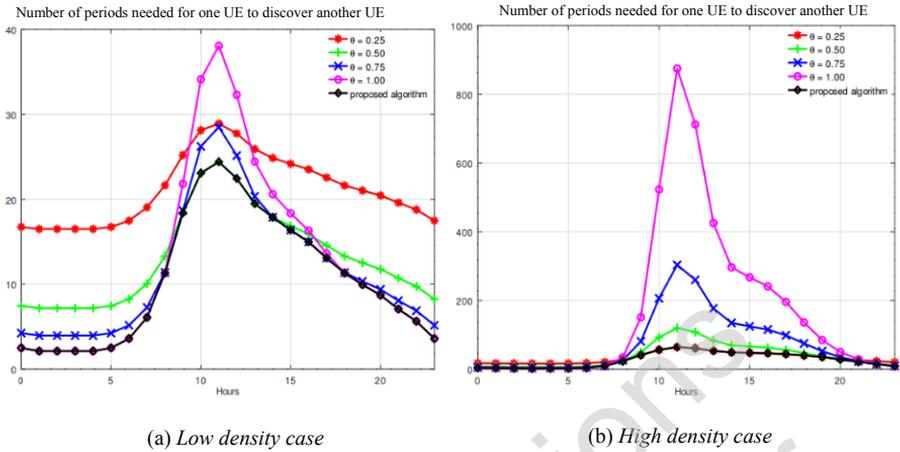


Figure 7.5. Nombre de périodes nécessaires afin d’accomplir la découverte

En ce qui concerne les messages, seule la configuration avec une probabilité de transmission de 0,25 offre de meilleures performances à certains moments, et à ces moments-là, la métrique temporelle affiche de meilleurs résultats pour notre algorithme.

Ce qui peut être plus important, notre algorithme montre un comportement plus prévisible (avec des valeurs plus cohérentes pour un certain nombre de messages et de temps requis) que les algorithmes 3GPP.

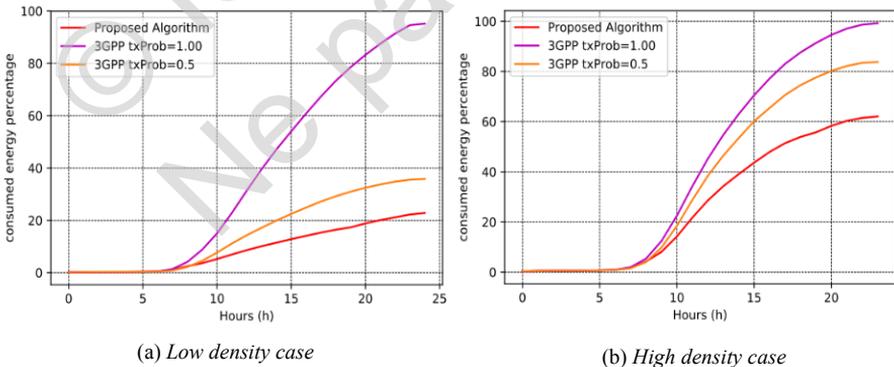


Figure 7.6. Pourcentage d’énergie consommée pour les deux cas de figure : faible et haute densité

7.6. Conclusion

Dans ce chapitre, un modèle basé sur l'apprentissage automatique a été proposé dans un contexte de communication D2D ayant pour objectif l'optimisation des ressources réseaux.

Nous avons tenu compte de l'historique des densités d'utilisateurs de traces réelles d'opérateur visant à optimiser le processus de découverte en définissant une probabilité de transmission optimisée pour chaque configuration de découverte. Nous avons exploité les traces de réseaux réelles et avons proposé un algorithme proactif qui a prédit le nombre d'utilisateurs dans une zone spécifique et régulé pro-activement la probabilité de transmission afin d'optimiser les transmissions pour une meilleure efficacité.

En premier lieu, les modèles de densité d'utilisateurs ont été extraits et synthétisés, variant entre différentes zones en fonction de leurs emplacements géographiques et de leurs types de trafic (c'est-à-dire, industriel, résidentiel et mixte). Ils ont été utilisés pour créer un historique du nombre d'utilisateurs situés autour de la zone pendant chaque heure de la journée. Ensuite, ces modèles de densité ont été intégrés dans notre algorithme afin de calculer la probabilité de transmission optimisée pour chaque période.

Il s'avère que l'apprentissage automatique réalise les objectifs fixés et mentionnés ci-dessus avec davantage d'efficacité que les modèles/algorithmes classiques qui pourraient être limités en termes de précision.

En outre, les communications entre périphériques (D2D) sont toujours en cours de standardisation. Les communications véhiculaires (V2X) en font partie et ont été introduites récemment (3GPP, version 14) dans le cadre des communications D2D afin de permettre aux véhicules de communiquer efficacement (par exemple de véhicule à véhicule, véhicule à infrastructure et piétons). Cela peut entraîner des exigences plus strictes en termes de retards et de pertes de transmission en raison de la forte mobilité liée aux réseaux véhiculaires. D'autre part, des algorithmes plus avancés peuvent être conçus à base d'apprentissage automatique avancé couplé à une grande analyse de données, de sorte à ce que l'algorithme lui-même évolue au fil du temps pour refléter les différents changements dans les comportements des utilisateurs, nous pensons en particulier à l'apprentissage profond à plusieurs couches.

7.7. Bibliographie

3GPP (2012). Feasibility study for evolved Universal Terrestrial Radio Access (UTRA) and Universal Terrestrial Radio Access Network (UTRAN). Rapport, 3GPP.

- 3GPP (2014). Architecture enhancements to Support Proximity Services (ProSe). Rapport, 3GPP.
- Abu Alsheikh, M., Lin, S., Niyato, D., Tan, H.P. (2014). Machine learning in wireless sensor networks: Algorithms, strategies, and applications. *IEEE Communications Surveys & Tutorials*, 16(4), 1996–2018.
- Agiwal, M., Roy, A., Navrati Saxena, N. (2016). Next generation 5G wireless networks: A comprehensive survey. *IEEE Communications Surveys & Tutorials*, 18(3), 1617–1655.
- Andrews, G.F., Buzzi, S., Choi, W., Hanly, S.V., Lozano, A., Soong, A., Zhang, J.C. (2014). What will 5G be?. *IEEE Journal on selected areas in communications*, 32(6), 1065–1082.
- Aono, Y., Hayashi, T., Wang, L., Moriai, S. *et al.* (2018). Privacy-preserving deep learning via additively homomorphic encryption. *IEEE Transactions on Information Forensics and Security*, 13(5), 1333–1345.
- Basak, D., Pal, S., Patranbis, D.C. (2007). Support vector regression. *Neural Information Processing-Letters and Reviews*, 11(10), 203–224.
- Ben Mosbah, A. (2016). Context-aware mechanisms for device discovery optimization. Thèse de doctorat, Télécom SudParis et Université Pierre et Marie Curie, Paris, 1279–1284.
- Bkassiny, M., Li, Y., Jayaweera, S.K. (2013). A survey on machine-learning techniques in cognitive radios. *IEEE Communications Surveys & Tutorials*, 15(3), 1136–1159.
- Buda, T.S., Assem, H., Xu, L., Raz, D., Margolin, U., Rosensweig, E., Lopez, D.R., Corici, M.I., Smirnov, M., Mullins, R. (2016). Can machine learning aid in delivering new use cases and scenarios in 5G?. Dans *Network Operations and Management Symposium (NOMS)*. IEEE/IFIP, Istanbul, 1279–1284.
- Bui, N., Cesana, M., Hosseini, S.A., Liao, Q., Malanchini, I., Widmer, J. (2017). A survey of anticipatory mobile networking: Context-based classification, prediction methodologies, and optimization techniques. *IEEE Communications Surveys & Tutorials*, 1790–1821.
- Cao, X., Zhou, F., Xu, L., Meng, D., Xu, Z., Paisley, J. (2018). Hyperspectral image classification with Markov random fields and a convolutional neural network. *IEEE Transactions on Image Processing*, 27(5), 2354–2367.
- Chen, X., Lin, X. (2014). Big data deep learning: challenges and perspectives. *IEEE access*, 2, 514–525.
- Chen, Y., Lin, Z., Zhao, X., Wang, G., Gu, Y. (2014). Deep learning-based classification of hyperspectral data. *IEEE Journal of Selected topics in applied earth observations and remote sensing*, 7(6), 2094–2107.
- Damasso, E. (1999). Digital mobile radio towards future generation systems: COST action 231. Rapport, Commission Européenne, Bruxelles.

- Deng, L. (2014). A tutorial survey of architectures, algorithms, and applications for deep learning. *APSIPA Transactions on Signal and Information Processing*, 3.
- Deng, L., Zhang, Y., Chen, M., Li, Z., Lee, J.Y., Zhang, Y.J., Song, L. (2015). Device-to-device load balancing for cellular networks. Dans *IEEE 12th International Conference on Mobile Ad Hoc and Sensor Systems (MASS)*. IEEE, Dallas, 19–27.
- Dieleman, S., Willet, K.W., Dambre, J. (2015). Rotation-invariant convolutional neural networks for galaxy morphology prediction. *Monthly notices of the Royal Astronomical Society*, 450(2), 1441–1459.
- Doppler, K., Rinne, M., Wijting, C., Ribeiro, C.B., Hugl, K. (2009). Device-to-device communication as an underlay to LTE-advanced networks. *IEEE Communications Magazine*, 47(12).
- Fodor, G., Dahlman, E., Mildh, G., Parkvall, S., Reider, N., Miklos, G., Turanyi, Z. (2012). Design Aspects of Network Assisted Device-to-Device Communications. *IEEE Communications Magazine*, 50, 170–177.
- Gheisari, M., Wang, G., Bhuiyan, M.Z.A. (2017). A survey on deep learning in big data. Dans *IEEE International Conference on Computational Science and Engineering (CSE) and Embedded and Ubiquitous Computing (EUC)*. IEEE, Canton, 2, 173–180.
- Goodfellow, I., Bengio, Y., Courville, A. (2016). *Deep learning*. MIT Press, Cambridge.
- Gupta, A., Kumar Jha, R. (2015). A survey of 5G network: Architecture and emerging technologies. *IEEE Access*, 3, 1206–1232.
- Hammami, S.E. (2018). Dynamic network resources optimization based on machine learning and cellular data mining. Thèse de doctorat, Télécom Sud, Paris.
- Hammami, S.E., Afifi, H., Marot, M., Gauthier, V. (2016). Network planning tool based on network classification and load prediction. Dans *Wireless Communications and Networking Conference (WCNC) 2016*. IEEE, Doha, 1–6.
- Hearst, M.A., Dumais, S.T., Osuna, E., Platt J., Scholkopf, B. (1998). Support vector machines. *IEEE Intelligent Systems and their applications*, 13(4), 18–28.
- Hinton, G.E., Krizhevsky, A., Sutskever, I. (2012). Imagenet classification with deep convolutional neural networks. Dans *NIPS'12 Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1*. Lake Tahoe, 1097–1105.
- Hinton, G.E., Osindero, S., Teh, Y.-W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527–1554.
- Hordri, N., Samar, N., Yuhaniz, S., Shamsuddin, S.M. (2017). A systematic literature review on features of deep learning in big data analytics. *International Journal of Advances in Soft Computing & Its Applications*, 9(1).

- Hosseini, M.-P., Pompilli, D., Elisevich, K., Soltanian-Zadeh, H. (2017). Optimized deep learning for EEG big data and seizure prediction BCI via internet of things. *IEEE Transactions on Big Data*, 3(4), 392–404.
- Huo, Y., Dong, X., Xu, W. (2017). 5G cellular user equipment: From theory to practical hardware design. *IEEE Access*, 5, 13992–14010.
- Jeong, Y., Soon, Y.L., Jun Park, H., Park, N.H. (2013). Solving the data overload: device-to-device bearer control architecture for cellular data offloading. *IEEE Vehicular Technology Magazine*.
- Jiang, C., Zhang, H., Ren, Y., Han, Z., Chen, K.C., Hanzo, L. (2017). Machine learning paradigms for next generation wireless networks. *IEEE Wireless Communications*, 24(2), 98–105.
- Keshavamurthy, B., Ashraf, M. (2016). Conceptual design of proactive SONs based on the big data framework for 5G cellular networks: A novel machine learning perspective facilitating a shift in the son paradigm. Dans *System Modeling & Advancement in Research Trends (SMART), International Conference*. IEEE, Moradabad, 298–304.
- Le Roux, N., Bengio, Y. (2010). Deep belief networks are compact universal approximators. *Neural computation*, 22(8), 2192–2207.
- Lecun, Y., Bottou, L., Bengio, Y., Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Lei, L., Zhong, Z., Lin, C., Shen, X. (2012). Operator Controlled Device-to-Device Communications in LTE-Advanced Networks. *IEEE Wireless Communications*, 19, 96–104.
- Li, H., Ota, K., Dong, M. (2018). Learning IoT in edge: deep learning for the internet of things with edge computing. *IEEE Network*, 32(1), 96–101.
- Liu, S., Tang, J., Wang, C., Wang, Q., Gaudiot, J.-L. (2017a). A Unified Cloud Platform for Autonomous Driving. *Computer*, 50(12), 42–49.
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., Ealsaadi, F. (2017b). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11–26.
- Luo, J., Li, X. (2012). Physical Downlink Control Channel format selection of evolved node B in Long Term Evolution system. Dans *5th International Conference on Biomedical Engineering and Informatics (BMEI)*. IEEE, Chongqing, 1494–1498.
- Mao, Y., You, C., Zhang, J., Huang, K., Letaief, K.B. (2017). A survey on mobile edge computing: The communication perspective. *IEEE Communications Surveys & Tutorials*.
- Najafabadi, M., Villanustre, F., Khoshgoftaar, T., Seliya, N., Wald, R., Muharemagic, E. (2015). Deep learning applications and challenges in big data analytics. *Journal of Big Data*, 2(1), 1.

- Panwar, N., Sharma, S., Kumar Singh, A. (2016). A survey on 5G: The next generation of mobile communication. *Physical Communication*, 18, 64–84.
- Rouil, R., Cintron, F.J., Benmosbah, A., Gamboa, S. (2017). Implementation and Validation of an LTE D2D Model for ns-3. Dans *Proceedings of the Workshop on ns-3*. ACM, Porto, 55–62.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117.
- Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y., Manzagol, P.-A. (2010). Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *Journal of Machine Learning Research*, 11, 3371–3408.
- Xiaohui, L., Liu, W., Wang, Z., Zeng, N., Liu, Y., Alsaadi, F.E. (2017). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11–26.
- Wang, L., Zhang, L., Yi, Z. (2017). Trajectory predictor by using recurrent neural networks in visual tracking. *IEEE Transactions on Cybernetics*, 47(10), 3172–3183.
- Wu, B., Li, K., Ge, F., Huang, Z., Yang, M., Siniscalchi, S.M., Lee, C.H. (2017). An End-to-End Deep Learning Approach to Simultaneous Speech Dereverberation and Acoustic Modeling for Robust Speech Recognition. *IEEE Journal of Selected Topics in Signal Processing*, 11(8), 1289–1300.
- Zhang, S., Yao, L., Sun, A. (2017). Deep learning based recommender system: A survey and new perspectives [En ligne]. Disponible à l'adresse: <http://arxiv.org/abs/1707.07435>.