

FEREC DEGRE

Détection Et Géoréférencement Réseaux Enterrés

RAPPORT D'ÉTUDE

mai 2022

N° NOVA : 21-OU-0074

Le Cerema est un établissement public sous la tutelle du ministère de la Transition écologique, présent partout en métropole et dans les Outre-mer grâce à ses 26 implantations et ses 2400 agents. Détenteur d'une expertise nationale mutualisée, le Cerema accompagne l'État et les collectivités territoriales pour la transition écologique, l'adaptation au changement climatique et la cohésion des territoires par l'élaboration coopérative, le déploiement et l'évaluation de politiques publiques d'aménagement et de transport. Doté d'un fort potentiel d'innovation et de recherche incarné notamment par son institut Carnot Clim'adapt, le Cerema agit dans 6 domaines d'activités : Expertise & ingénierie territoriale, Bâtiment, Mobilités, Infrastructures de transport, Environnement & Risques, Mer & Littoral.

Site web : www.cerema.fr

FEREC DEGRE

Détection Et Géoréférencement Réseaux Enterrés

mai 2022

Commanditaire : Fondation FEREC

Auteurs : David Guilbert, Christophe Heinkélé, Rakeeb Jauffer

Responsable du rapport :

David GUILBERT - Direction territoriale ouest - Agence d'Angers - ENDSUM
Tél : +33(0)2 41 79 13 90 - Fax : +33(0)2 41 44 32 76
Courrier : david.guilbert@cerema.fr
Cerema Ouest DLAn - 23 avenue amiral Chauvin - CS 20069 - 49136 Les Ponts de Cé Cedex

Historique des versions du document :

Version	Date	Commentaire
1	mars 2022	Création du document
2	mai 2022	Précision sur le chapitre 2 et 4

Références

Partenaire(s) : Logiroad (Thierry Chateau), ESEO (Jérôme Tissier), Université Gustave Eiffel (Xavier Dérobert et Amine Ihamouten)

Nom	Service	Rôle	Date	Visa
David Guilbert	ENDSUM	Auteur	30/05/2022	
Christophe Heinkélé	ENDSUM	Auteur	30/05/22	
Rakeeb Jauffer	ENDSUM	Auteur	30.05.22	 (signature)
Cyrille Fauchard	ENDSUM	Valideur		
Patrick Ingles	Agence d'Angers	Valideur	01/06/22	

Table des matières

1	Contexte et objectifs	7
2	Description des travaux menés	9
2.1	Rappel principe du radar géophysique	9
2.1.1	Configuration monostatique	9
2.1.2	Configuration bistatique	9
2.1.3	Radar à impulsion	10
2.1.4	Radar à saut de fréquences	10
2.1.5	Comparatif radar à impulsion et radar à saut de fréquences	11
2.1.6	Données GPR	12
2.2	Base de données de signaux	12
2.3	Détection des réseaux enterrés	13
2.4	Estimation du diamètre et de la profondeur des réseaux enterrés	16
3	Un outil pour l'annotation des données : labelGPR	19
3.1	Représentation des données radar	19
3.1.1	Génération d'images	19
3.1.2	Pré-Traitements de radargrammes	19
3.2	Une interface d'annotation	19
3.2.1	Description de l'outil	19
3.2.2	Format des données radar pris en compte	20
3.2.3	Classes d'annotations actuelles	20
3.3	Évolutions envisagées	21
3.3.1	Détourage d'hyperboles	21
3.3.2	Méthodes automatiques	21
4	Résultats expérimentaux	22
4.1	Détection	22
4.1.1	Base de données numériques	22
4.1.2	Base de données réelles	23

4.2	Estimation du rayon et de la profondeur du réseau enterré	25
5	Utilisation de l'aide de la FEREC dans le projet	27
6	Impact	28
6.1	Apport et retombées pour la collectivités	28
6.2	Publications et autres éléments de communication auxquels le projet et ses résultats ont donné lieu	28
7	Perspectives ouvertes par le projet	29

1 Contexte et objectifs

La gestion des réseaux enterrés est aujourd’hui un enjeu important pour tout un ensemble d’acteurs qui œuvrent à proximité des infrastructures urbaines. En France, les réseaux enterrés représentent environ 2,8 millions de km linéaire d’après la Fédération Nationale des Entreprises de Détection de Réseaux Enterrés (FNEDRE 10/09/2021).

Le vieillissement des réseaux enterrés entraîne une perte de fonctionnalité, de disponibilité et de réduction du niveau de service qui impacte les opérateurs et les usagers, notamment pour les systèmes d’eau potable. En France, il existe au total environ 875 000 km de réseau d’eau potable (OFB Les mémos collection des synthèses eau de France avril 2021), dont plus de 60 % du réseau a été posé après 1970, avec un pourcentage estimé de 25 % de pertes en eau. Pour les 297 000 km linéaires de réseaux d’assainissement et les 95 225 km linéaires de réseaux pluviaux (Les enjeux de l’eau synthèse de l’étude publié par l’UIE 2017), l’estimation est inconnue mais pourrait être considérée comme similaire. De plus, ces pertes en eau peuvent entraîner l’érosion dans les sols, le décompactage puis la création de cavités sous les structures routières ou dans les zones urbaines. Des accidents mortels en 2007 et 2008 ont conduit à la modification de la réglementation du travail au voisinage des réseaux de canalisations. Depuis le 1^{er} juillet 2012, cela inclut une législation, quatre décrets et une norme NF S 70-003. La responsabilité des gestionnaires a été renforcée. Trois niveaux définissent désormais la précision de la localisation d’une canalisation : la classe A signifie que l’incertitude maximale de localisation en x , y et z est inférieure à 40 cm pour les réseaux rigides ou 50 cm pour les réseaux flexibles. La localisation des réseaux enterrés sensibles doivent répondre à la classe A selon le calendrier du tableau 1.1.

Échéance classe A	2020	2026	2032
Réseaux sensibles	Unités urbaines	Zones rurales	
Réseaux non sensibles		Unités urbaines	Zones rurales

TABLE 1.1 – Les grandes dates de la réglementation pour la classe A

Récemment, le rapport 2019 du groupe SMA (Société d’assurance mutuelle contre les accidents du travail et les accidents corporels survenus du fait de l’exécution des travaux) relevait une absence et une insuffisance de localisation des réseaux enterrés. Le rapport de 2020 « Sécurité des réseaux de distribution de gaz naturel » fait état de 3046 endommagements au cours de l’année 2019. Ce rapport évoque aussi les endommagements « différés » dus à des évolutions possibles des remblais dans le temps ce qui nécessiterait une actualisation des données de localisation ou une détection des modifications de la subsurface. L’événement tragique de la rue de Trévise à Paris en 2019 illustre le cas des endommagements « différés ». Le manque d’informations fiables et précises génère des risques technologiques permanents et entraîne régulièrement des dommages sur réseaux qui peuvent se transformer en situations dramatiques. Ainsi, pour les gestionnaires, il devient primordial de cartographier de manière la plus complète et la moins intrusive possible les réseaux en subsurface.

Concernant toujours la localisation, la technique radar GPR est déjà connue et reconnue des professionnels du domaine. Néanmoins, de nouveaux développements et intégrations sont fortement attendus notamment sur tous les aspects « haute résolution » de l’auscultation, la mesure à grand rendement et l’aide à la décision.

Le programme de travail envisagé était le suivant :

- Constitution de bases de données :
 - issues de modélisation ;
 - de sites connues ;
 - relevé réel ;
- développement d’algorithme de détection ;

- développement d’algorithme d’estimation de la profondeur et du diamètre;
- évaluation des algorithmes.

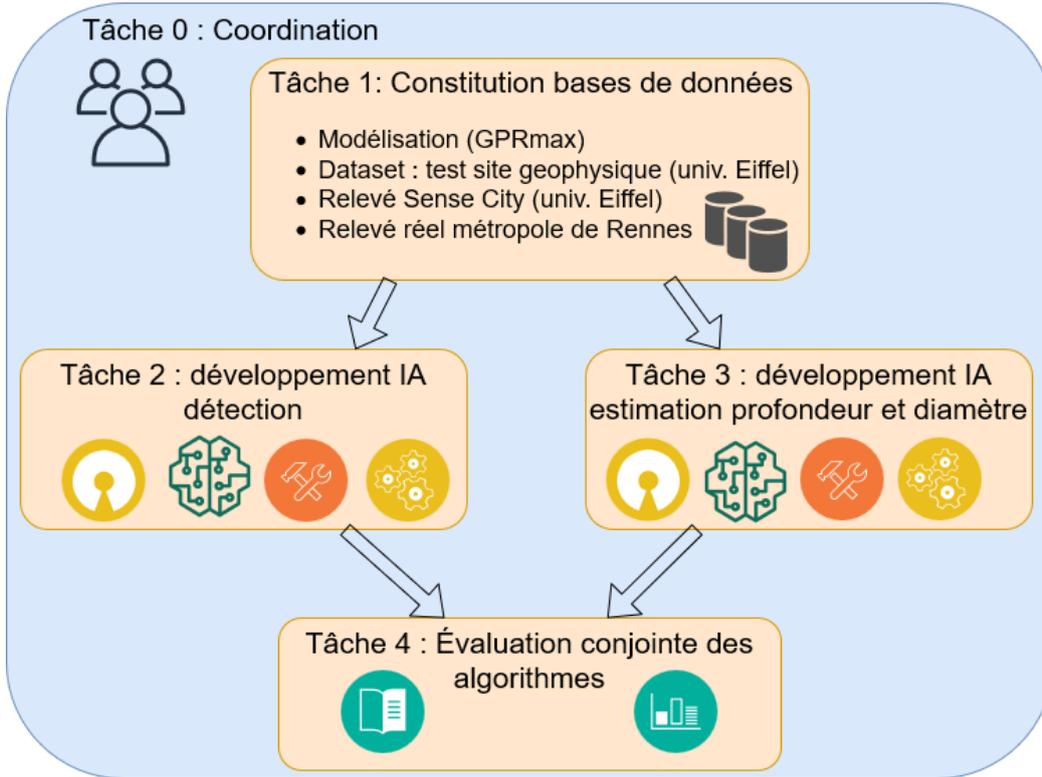


FIGURE 1.1 – Programme de travail envisagé

2 Description des travaux menés

2.1 Rappel principe du radar géophysique

Le radar géophysique, initialement de nature à impulsion, appelé aussi GPR pour « Ground Penetrating Radar », est utilisé depuis une vingtaine d'années en génie civil pour réaliser des opérations d'auscultation dans le flux du trafic. Cette technique utilise le principe de propagation d'ondes électromagnétiques pour évaluer la géométrie et les propriétés diélectriques d'un milieu stratifié grâce à une antenne (ou réseaux d'antennes) orientée(s) vers la chaussée. Le GPR présente l'avantage d'être une technique « grand rendement », le plus souvent sans contact. Il fournit une mesure en continu de l'épaisseur des couches de chaussée, mais permet aussi l'analyse des interfaces de chaussées, décollements, fissures significatives entre couches de manière indirecte, détection de réseaux, teneur en eau, porosité et surtout ne faisant plus appel à des sources radioactives.

Les ondes électromagnétiques se réfléchissent partiellement à la rencontre d'un contraste diélectrique (interface, défaut ou toute autre hétérogénéité) et s'atténuent suivant les propriétés des milieux.

L'auscultation radar est généralement réalisée à l'aide de l'un des deux types de radar suivants :

- le radar à impulsion, qui délivre un signal temporel, aisément interprétable utilisé de manière opérationnelle sur les chantiers ;
- le radar à saut de fréquences (ou à impulsions synthétiques), qui délivre un signal fréquentiel ; il était utilisé surtout dans un contexte de recherche (en « laboratoire ») ; du fait des évolutions technologiques, l'utilisation de ce radar est en plein essor.

À ces deux techniques radar, on associe deux configurations de mesures possibles : le mode monostatique ([Spagnolini \(1997\)](#)) et le mode bistatique (ou multistatique [Liu \(2007\)](#)).

2.1.1 Configuration monostatique

Dans une configuration de mesures en mode monostatique, l'antenne d'émission sert également d'antenne de réception. Dans des applications « chaussées », les mesures sont généralement effectuées à incidence normale : le signal rétrodiffusé par le milieu est mesuré. L'inconvénient majeur de cette configuration est lié à l'existence d'un signal transitoire, qui apparaît en début d'enregistrement. Ce dernier représente le signal propagé sur toute la hauteur d'antenne. Son influence dépend fortement du type d'antenne utilisé. Pour s'affranchir de son influence, des procédures de calibrage sont proposées dans la littérature ([Lambot et al. \(2004\)](#); [Guan et al. \(2017\)](#)).

2.1.2 Configuration bistatique

Pour cette configuration, les antennes d'émission et de réception sont déportées l'une de l'autre d'une certaine distance. Les mesures sont réalisées à incidence oblique. Selon la distance, le couplage entre les antennes d'émission et de réception peut induire des modifications du diagramme de rayonnement. Dans cette configuration, on observe en début d'enregistrement le signal de l'antenne émettrice ; on parle d'onde directe dans l'air. L'onde directe peut être aisément éliminée par fenêtrage temporel dès lors que les antennes sont suffisamment surélevées au-dessus de la surface à ausculter.

On parle également de configuration quasi-monostatique lorsque le radar dispose d'antennes d'émission et de réception distinctes, et très proches l'une de l'autre (par exemple, le système GSSI). En surélevant le système antennaire d'une hauteur suffisante, l'onde directe se détache du premier écho réfléchi et peut être aisément filtrée. La configuration de mesures devient similaire à la configuration monostatique précédente ; on parle par la suite de conditions quasi-monostatiques. Par comparaison avec le mode monostatique, le calibrage du système devient simplifié.

2.1.3 Radar à impulsion

Le radar à impulsion est composé d'un générateur d'impulsions, d'une (ou plusieurs) antenne(s) émettrice(s) et d'une (ou plusieurs) antenne(s) réceptrice(s). Ce radar permet d'envoyer des impulsions à intervalles réguliers, à une fréquence de répétition appelée « PRF » (Pulse Repetition Frequency). Après passage dans l'antenne, cette impulsion génère une onde électromagnétique qui se réfléchit au sein du milieu (Fig. 2.1). On peut noter que ce type de radar est déjà utilisé au Cerema pour faire des expertises routières. Sa vitesse d'acquisition est suffisante pour faire de la mesure sur route à des vitesses de l'ordre de 70 km h^{-1} avec une acquisition tous les 20 cm environ.

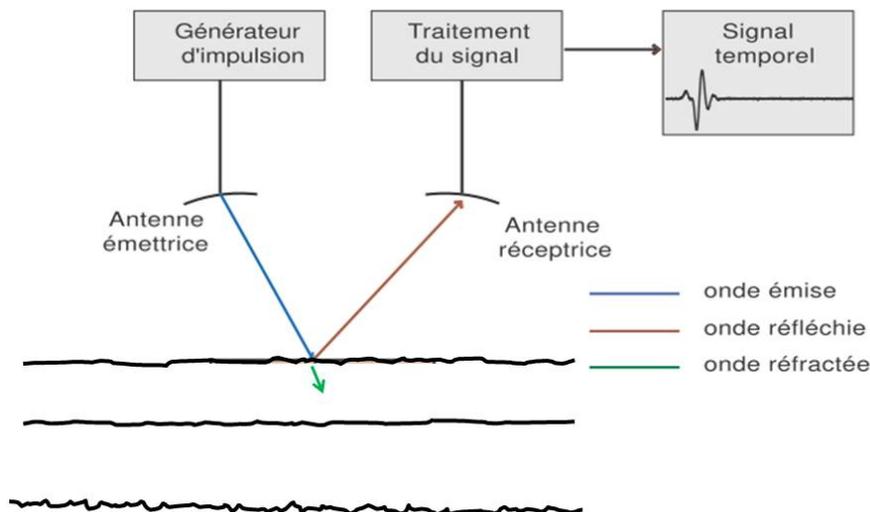


FIGURE 2.1 – Schéma synoptique d'un radar à impulsion.

2.1.4 Radar à saut de fréquences

Le radar à saut de fréquences est constitué d'un analyseur de réseaux vectoriels (Vectorial Network Analyser en anglais, VNA), d'une (ou plusieurs) antenne(s) émettrice(s) large(s) bande(s) et d'une (ou plusieurs) antenne(s) réceptrice(s) large(s) bande(s). Le VNA émet séquentiellement des ondes monofréquences de même amplitude sur une certaine largeur de bande de fréquences (Fig. 2.2). Le système obtenu permet de reconstruire une impulsion temporelle synthétique par transformée de Fourier inverse (TFI). La bande de fréquences utilisée pour ce type de radar est davantage limitée par les antennes utilisées. Généralement, on utilise pour ce type de radar des antennes ultra larges bandes pouvant être comprises entre 0,1 GHz et 10 GHz. L'avantage de ce type de radar réside dans sa souplesse d'utilisation (choix de la bande de fréquences, du pas d'échantillonnage fréquentiel). Le paramétrage du VNA permet d'obtenir un très bon rapport signal sur bruit. Dans le domaine de la chaussée, l'hétérogénéité du matériau (ensemble de granulats mélangés par un liant hydraulique ou bitumineux) peut venir limiter la montée en fréquence et l'élargissement de la bande. Balayant tout le spectre de fréquences, des basses aux hautes fréquences, le VNA est capable de voir les objets enfouis en profondeur et d'avoir une bonne résolution pour de petits objets enfouis en surface en même temps.

Les inconvénients principaux de ce type de radar restent son prix élevé (qui a tendance à diminuer avec le développement des technologies) et sa capacité à faire de la mesure en continu sur une route. En effet, l'analyseur de réseaux vectoriels émet séquentiellement des ondes monofréquences sur toute la bande de fréquences souhaitée. Cette procédure a un certain coût temporel lors de la mesure. Plus le nombre d'ondes monofréquences émises augmentent, plus le temps de mesure (pour une bande de fréquences donnée) est important. À ce jour, les mesures réalisées avec un radar à saut de fréquences peuvent être conduites à une vitesse réduite par rapport au radar à impulsion ce qui limite l'insertion du véhicule porteur dans le flot de circulation.

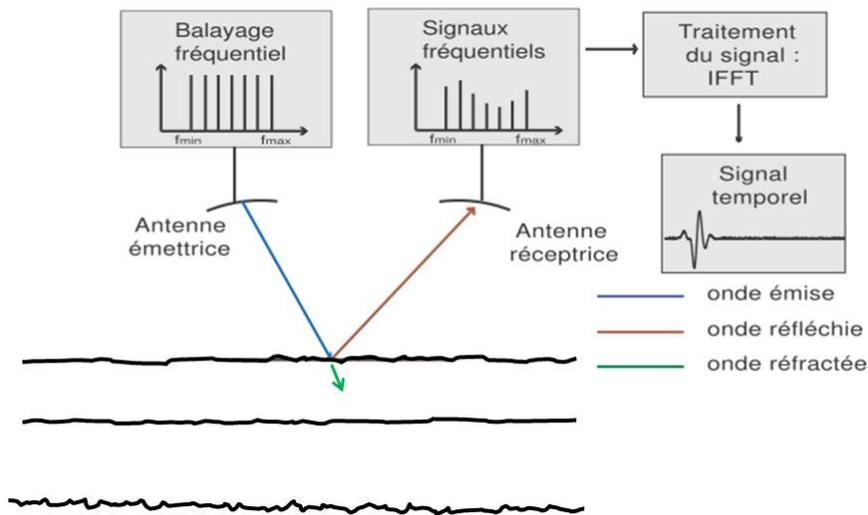


FIGURE 2.2 – Schéma synoptique d'un radar à saut de fréquences

2.1.5 Comparatif radar à impulsion et radar à saut de fréquences

Il est possible de couvrir une large gamme de fréquences avec un seul radar à saut de fréquences contrairement au radar à impulsion. Pour les applications GPR, le résultat est un appareil capable de pénétrer profondément dans le sol tout en produisant des images haute résolution (Fig. 2.3). Le rapport signal sur bruit des radars à saut de fréquences est également beaucoup plus faible que celui des radar à impulsions. Lors de la comparaison de cibles profondes, les balayages des radars pulsés deviennent granuleux et difficiles à interpréter. Les images radars à saut de fréquences restent assez claires pour toute la profondeur de balayage en raison de leur gain positif lorsqu'elles sont converties dans le domaine temporel.

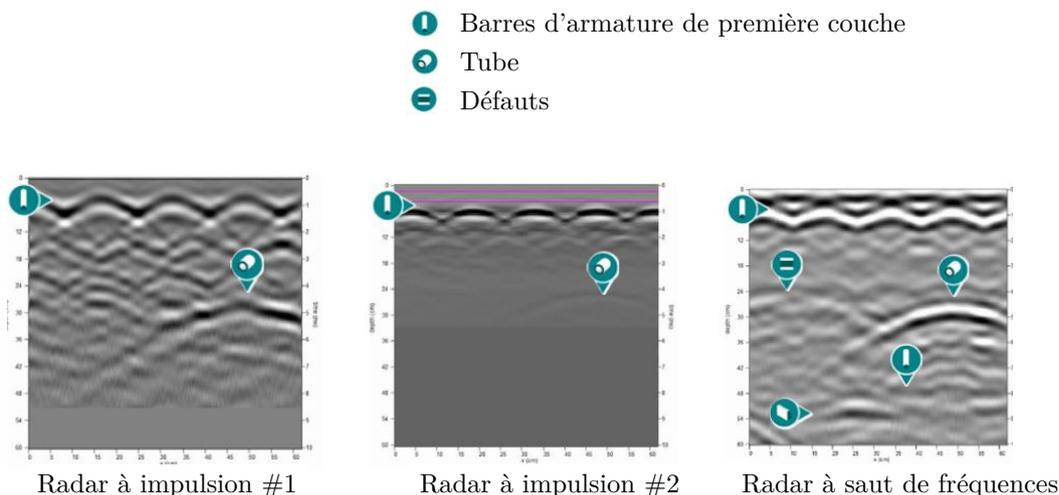


FIGURE 2.3 – Comparaison entre le radar à impulsion et le radar à saut de fréquences
<https://www.pcte.com.au/construction-test-and-measure-october-2017>.

Les radars à saut de fréquences sont une approche pour fournir un signal avec la gamme de fréquences la plus large possible. Il existe d'autres approches notamment en utilisant des antennes multifréquences (souvent deux fréquences) pour les radars à impulsions. En règle générale, ces deux approches ont tendance à rendre l'équipement plus compliqué et plus coûteux.

Les fabricants de radar à impulsion continuent d'améliorer la vitesse des équipements, permettant un empilement plus rapide. L'empilement a d'abord été utilisé dans les données sismiques, en tant que processus qui fait la moyenne des signaux collectés au même endroit pour réduire le bruit aléatoire, améliorant ainsi le rapport signal sur bruit. L'empilement peut être appliqué aux données radar à la fois pendant la collecte des données et pendant le traitement des données post-acquisition. La théorie de l'empilement est qu'au lieu de simplement collecter un signal et de l'enregistrer, plusieurs signaux sont collectés et moyennés ensemble. Ainsi, le bruit aléatoire est éliminé et seuls les signaux répétitifs subsistent. Les fabricants de radar à impulsion développent des antennes capables d'un taux d'empilement élevé qui réduit le bruit enregistré. Cette technique est un moyen de fournir efficacement des données abordables, de haute qualité et à bande passante accrue aux utilisateurs.

2.1.6 Données GPR

Dans cette étude, le GPR est principalement utilisé pour la recherche des réseaux souterrains sans perturber le sol.

Une trace, un signal ou une forme d'onde radar unique est appelée A-scan. Le A-scan fournit des informations sur la configuration du sous-sol. C'est une fonction temporelle qui représente la réponse au signal émis. Il est à noter que le temps et la profondeur sont liés l'un à l'autre par la vitesse de propagation.

Un ensemble de formes d'ondes radar consécutives le long d'une direction sélectionnée, comme le montre la Fig. 2.5, représente un B-scan ou radargramme. Par conséquent, la visualisation d'un B-scan permet d'obtenir une vue en deux dimensions le long d'une direction spécifique. Le B-scan représente une coupe-temps et peut être considéré comme une visualisation d'une coupe verticale du sous-sol. La matrice de signaux est souvent présentée comme une image en niveau de gris, dont l'interprétation visuelle donne des informations géométriques sur la structure auscultée.

Si une valeur le long de l'axe temporel est fixée comme constante, la visualisation du domaine horizontal est appelée C-scan. Le mode d'affichage C-scan fournit une carte d'amplitude d'une coupe du sous-sol. Lorsqu'une zone est étudiée, par exemple en collectant des données le long d'une grille régulière, le mode de visualisation C-scan peut être utile pour détecter les taches homogènes, qui se caractérisent par une réflectivité élevée en termes d'amplitudes de signal. En raison de l'utilisation de plusieurs antennes ou de plusieurs passages, l'acquisition et les traitements des C-scans sont coûteux. L'amélioration des technologies tend à rendre l'utilisation des C-scans plus abordable. Lors de l'acquisition, le lobe de rayonnement de l'antenne ne permet pas de faire une mesure ponctuelle. Tous les objets rencontrés appartenant au lobe de rayonnement renvoient des échos, même s'ils ne se trouvent pas exactement à la verticale de l'antenne. Tous les échos reçus sont quand même affichés, les échos provenant d'un objet positionné latéralement, et donc parcourant une plus grande distance, sont estimés à une profondeur plus grande qu'ils ne le sont en réalité. Ce qui se traduit sur un B-scan pour un objet ponctuel, par un écho de forme hyperbolique et sa position réelle se trouve à l'apex de l'hyperbole.

2.2 Base de données de signaux

GprMax [Warren et al. \(2016\)](#) est un logiciel open source qui simule la propagation des ondes électromagnétiques. Il utilise l'algorithme de Yee pour résoudre les équations de Maxwell en 3D à l'aide de la méthode Finite-Difference Time-Domain (FDTD : méthode de calcul de différences finies dans le domaine temporel permettant de résoudre les équations de Maxwell). Il est conçu pour simuler un radar à pénétration de sol (GPR) et peut être utilisé pour modéliser la propagation des ondes électromagnétiques dans des domaines tels que l'ingénierie, la géophysique, l'archéologie et la médecine. Il existe un large éventail d'applications, notamment : l'évaluation d'infrastructures critiques telles que les ponts et les routes, la localisation de services publics enfouis, la cartographie des glaciers, la recherche de mines antipersonnel et la détection de tumeurs dans le corps humain.

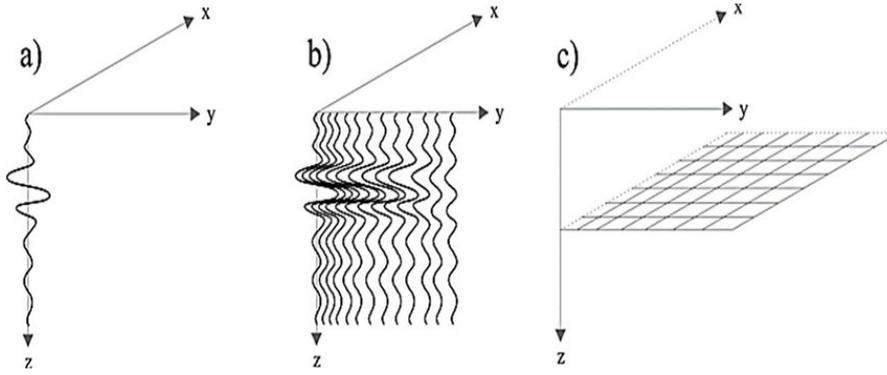


FIGURE 2.4 – Visualisation de données GPR : (a) A-scan, (b) B-scan et (c) C-scan.

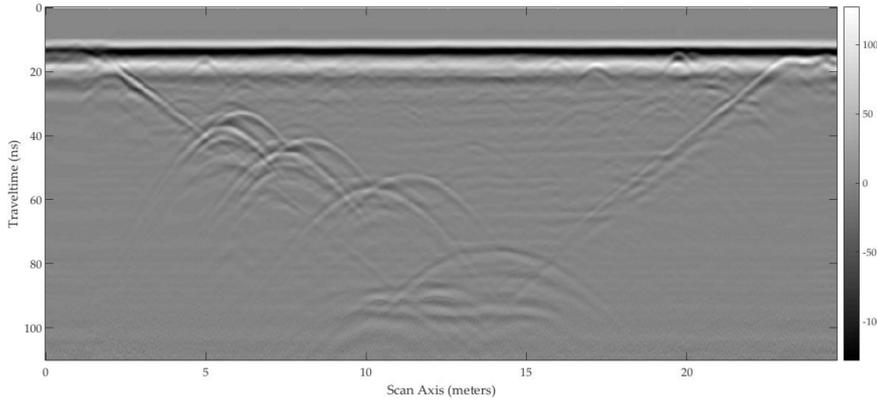


FIGURE 2.5 – B-scan ou radargramme avec des réseaux enterrés.

2.3 Détection des réseaux enterrés

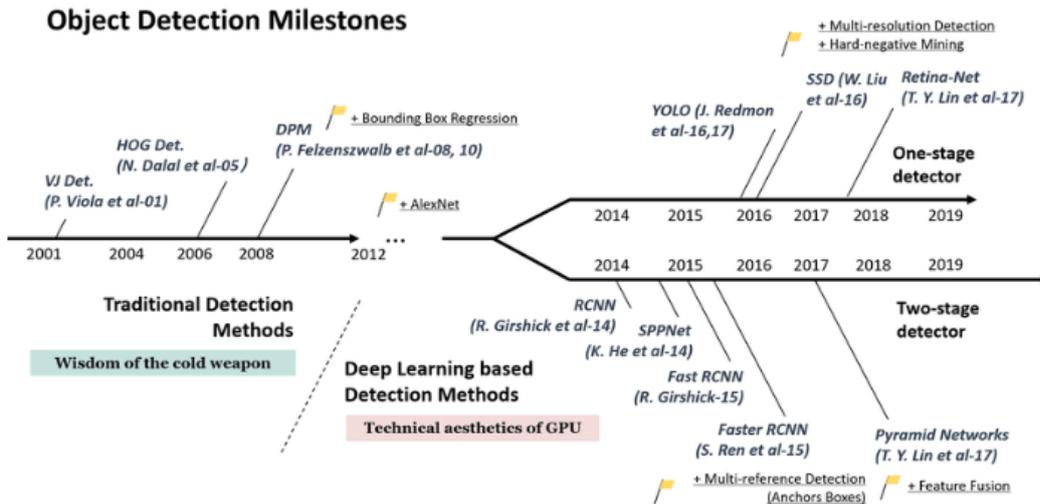


FIGURE 2.6 – Chronologie des principaux algorithmes de détection d'objets [Zou et al. \(2019\)](#)

Il est généralement admis [Zou et al. \(2019\)](#) que lors de ces deux dernières décennies, deux périodes marquent l'évolution des algorithmes de détection. Une première période de détection d'objets dite « traditionnelle » se situe avant 2014 et une période de détection d'objets basée sur l'apprentissage profond qui se situe après 2014, comme le montre la Fig. 2.6. La grande différence entre ces deux périodes réside dans le choix des caractéristiques. Comme le montre la Fig. 2.7, l'apprentissage automatique se

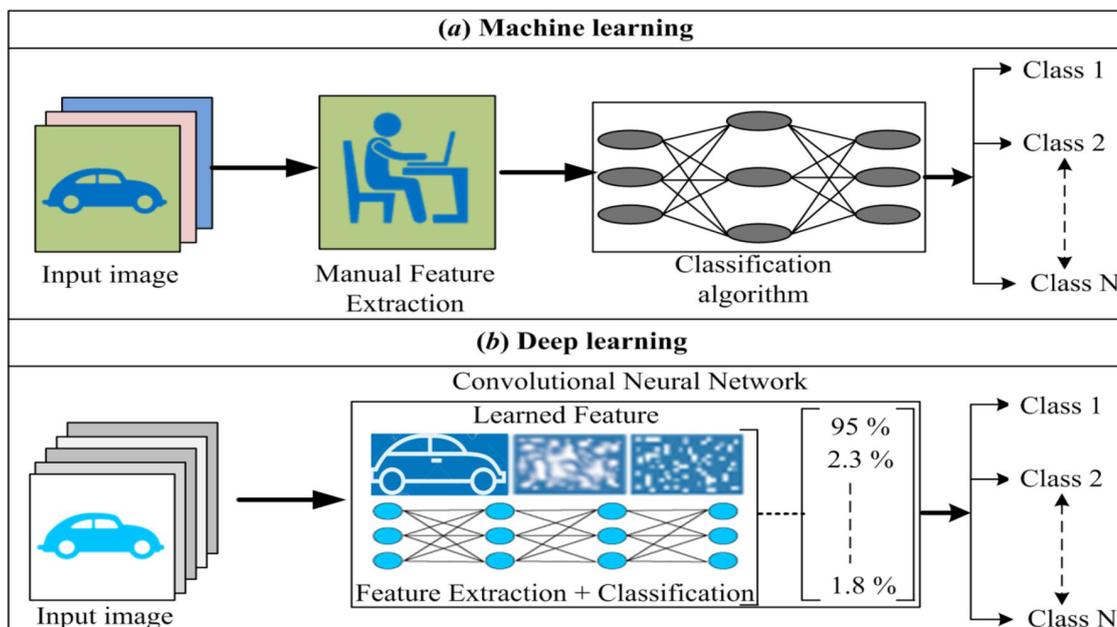


FIGURE 2.7 – Comparaison entre l'apprentissage automatique et l'apprentissage profond Chandradeep et al. (2021)

base sur des caractéristiques extraites manuellement alors que l'apprentissage profond intègre la sélection des caractéristiques.

Plusieurs méthodes de détection automatique d'hyperbole sur des Bscans ont été développées (Terrasse (2017)). Souvent la première étape consiste à effectuer un ou plusieurs pré-traitements du signal. Ces pré-traitements visent entre autres :

- à supprimer l'arrière plan qui correspond à l'écho de surface et les échos des différentes couches (Al-Nuaimy et al. (2000); Sezgin et al. (2004); Pasolli et al. (2008); Liu et al. (2010); Wang & Su (2011); Birkenfeld (2010));
- à appliquer un gain variable sur le signal pour compenser l'atténuation de la puissance du signal (Al-Nuaimy et al. (2000); Pasolli et al. (2008); Birkenfeld (2010));
- la réduction du bruit par filtrage (Al-Nuaimy et al. (2000); Pasolli et al. (2008); Ji et al. (2009); Birkenfeld (2010)).

Seul ou en plus des pré traitements déjà cités, d'autres traitements peuvent être appliqués avec l'objectif d'obtenir des caractéristiques plus saillantes pour détecter les hyperboles. Par exemple Al-Nuaimy et al. (2000) utilise la densité spectrale de puissance selon la méthode de Welch, Delbo et al. (2000) réalise la transformée de Fourier en ondelettes discrètes.

La transformée de Hough est utilisée dans Golovko (2007); Harkat et al. (2016) pour la détection d'hyperboles. Mais l'inconvénient majeur de cette méthode est la complexité de calcul et la génération de résultats aléatoires. L'ajustement automatique de l'hyperbole est une autre technique basée sur la méthode des moindres carrés pour ajuster la forme de l'hyperbole à une équation analytique Al-Nuaimy et al. (2000). Cependant, cette méthode n'identifie principalement qu'une seule hyperbole dans les images non bruitées et n'est pas applicable aux images contenant des hyperboles superposées. De plus, une approche de reconnaissance de formes supervisée basée sur le descripteur de HOG (histogramme de gradient orienté) et l'algorithme d'apprentissage Viola-Jones basé sur des caractéristiques de type Haar ont également été utilisées Terrasse (2017). Cependant encore une fois, ces algorithmes souffrent de nombreuses fausses alarmes et nécessitent une extraction de caractéristiques complexe.

Dans ce contexte, plusieurs chercheurs ont proposé des algorithmes de détection d'hyperbole supportés par des réseaux de neurones convolutifs Feng et al. (2020); Li et al. (2020) (en anglais CNN pour Convolutional Neural Networks). Le CNN ignore l'étape standard de sélection des caractéristiques nécessaire à l'apprentissage automatique et « apprend » à la place les représentations automatiques des

fonctionnalités des objets enterrés directement à partir des images GPR Bscan. J. Feng (Feng *et al.* (2020)) a appliqué les réseaux de neurones convolutifs basés sur les régions qui sont une famille de modèles d'apprentissage automatique pour la détection d'objets. Faster R-CNN fait partie de cette famille et intègre l'extraction des régions d'intérêt dans le réseau neuronal lui-même pour accélérer la détection d'objet. L'application de Faster R-CNN par Feng *et al.* (2020) sur des Bscans bruts a permis d'obtenir des performances de plus de 90 % de détection. Cependant, le nombre d'échantillons d'apprentissage était énorme et Faster-RCNN n'est pas encore compatible pour une détection en temps réel en raison de son délai de traitement. Cependant, il a le potentiel d'être déployé en tant que modèle de post-traitement. D'autre part, pour faciliter la détection automatique des hyperboles en temps réel, Y. Li (Li *et al.* (2020)) a introduit une technique basée sur Yolo-3 qui a produit une précision des résultats de test supérieure à 80 % à partir de seulement 300 données d'apprentissage. Dans l'ensemble, les performances et la robustesse de ces modèles variaient en fonction des techniques de pré-traitement du signal pendant ou après l'acquisition, de la stratégie d'annotation et des algorithmes d'apprentissage automatique adoptés. L'inconvénient le plus courant des modèles d'apprentissage profond existants était un nombre plus élevé de faux positifs, car toute hyperbole formée par des effets de diffusion et de bruit peut être détectée. Cela se traduit par une faible précision globale des modèles. Pendant ce temps, les faux négatifs sont plus élevés lorsque plusieurs hyperboles se chevauchent en raison de la densité des canalisations. Cependant, la distinction des tuyaux individuels n'est pas obligatoire dans la perspective de la sécurité de l'excavation, mais la détection du tuyau supérieur est importante. Dans ce contexte, en considérant les défis de détection et les avantages de Faster-RCNN par ses performances et ses caractéristiques, deux approches d'annotation différentes sont proposées. De plus, une seule hyperbole et plusieurs hyperboles superposées non séparables ont été considérées comme une seule cible. Ceci est fait parce que, du point de vue de la sécurité, la détection d'un ou plusieurs tuyaux dans le même emplacement ou la même tranchée est suffisante pour tracer la limite de sécurité des actifs de service pendant l'excavation. Pour minimiser les faux positifs (dus aux effets de réflexions multiples), le sous-sol ou l'écho d'une interface de couche est également inclus dans la stratégie d'annotation. Deux scénarios sont donc envisagés :

- Modèle Faster RCNN avec l'annotation d'hyperbole à partir du sommet. Dans ce premier scénario d'annotation, l'étiquetage de l'hyperbole n'inclut pas l'écho de la surface, comme le montre la figure 2.8a ;
- Modèle Faster RCNN avec l'annotation d'hyperbole incluant l'écho de surface. Le deuxième scénario d'annotation prend en compte l'écho de la surface dans l'étiquetage.

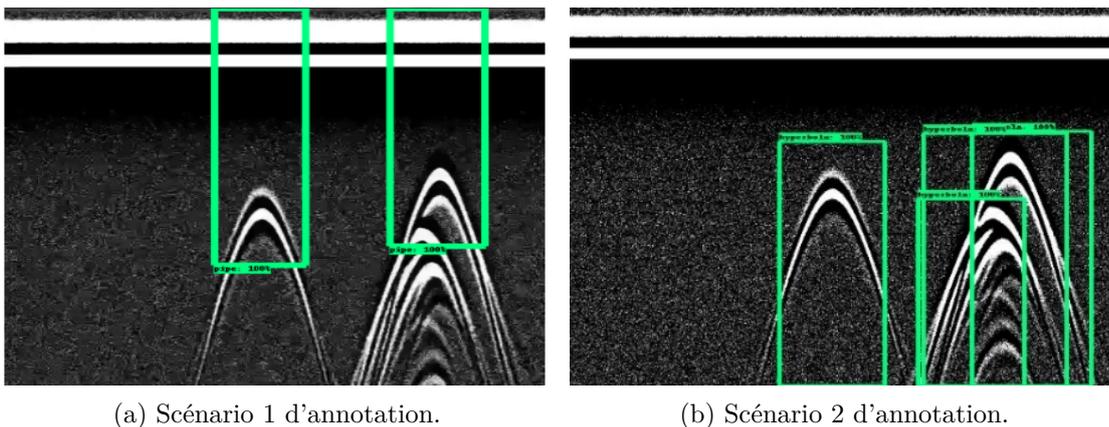


FIGURE 2.8 – Les deux scénarii d'annotation prenant en compte ou non l'écho de surface.

Mesure de l'efficacité de la détection

Les algorithmes de détection sont évalués en analysant les résultats des prédictions obtenues sur un jeu de données dont nous connaissons la vérité. Nous comptons notamment les nombres de :

Vrais positifs le nombre de fois où le modèle prédit correctement la classe positive c'est-à-dire que l'objet est correctement détecté ;

Faux positifs le nombre de fois où le modèle prédit la classe positive alors que le résultat attendu était la classe négative c'est-à-dire qu'un objet est détecté alors qu'il n'est pas présent en réalité ;

Faux négatifs le nombre de fois où le modèle prédit la classe négative alors que le résultat attendu était la classe positive c'est-à-dire que le modèle ne détecte pas d'objet alors qu'il y en a un présent dans la réalité.

À partir de ces statistiques, deux indicateurs sont généralement calculés : la précision et le rappel.

Précision proportion des items pertinents parmi l'ensemble des items proposés, c'est une indication de l'exactitude des prédictions par un pourcentage de détections correctes ;

$$\text{Précision} = \frac{\text{Vrais positifs}}{\text{Vrais positifs} + \text{Faux positifs}}$$

Rappel proportion des items pertinents proposés parmi l'ensemble des items pertinents, c'est une indication de l'exhaustivité et donne la capacité du modèle à prédire l'ensemble des résultats attendus.

$$\text{Rappel} = \frac{\text{Vrais positifs}}{\text{Vrais positifs} + \text{Faux négatifs}}$$

Dans la réalité, il est extrêmement peu probable que les coordonnées (x, y) de notre boîte englobante prédite correspondent exactement aux coordonnées (x, y) de la boîte englobante de référence (la réalité). Il devient alors difficile de dire quand une prédiction est vraie ou fausse. Pour cette raison, nous devons définir un seuil d'acceptabilité concernant le chevauchement entre les cadres de délimitation prédits et les boîtes englobantes représentant la vérité terrain. Pour cela, le recouvrement qui existe entre le résultat prédit et le résultat attendu est calculé et est appelé Intersection Over Union (IoU). L'IoU est donné comme le rapport entre la zone d'intersection entre la boîte englobante proposée et la boîte englobante de référence et la zone d'union des deux (Fig. 2.9). L'IoU varie de 0,0 à 1,0. La valeur est zéro lorsqu'il n'y a pas d'intersection et IoU est de 1,0 si les deux boîtes englobantes se chevauchent entièrement. Si une boîte englobante proposée qui a un chevauchement IoU au-delà d'un seuil déterminé avec n'importe quelle boîte englobante de référence reçoit une étiquette d'objet positive. Un score d'objet négatif est attribué à une boîte englobante non positive lorsque le chevauchement IoU est inférieur à un seuil. Ce score signifie que la boîte englobante est classée comme arrière-plan.

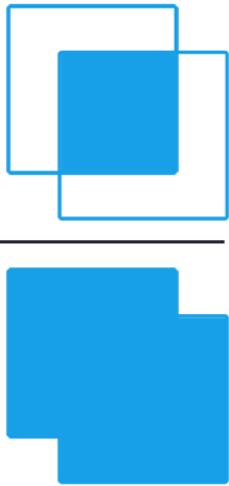
$$\text{IoU} = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$


FIGURE 2.9 – Le calcul de l'intersection sur Union consiste à diviser la zone de chevauchement entre les boîtes englobantes par la zone d'union (<https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>).

2.4 Estimation du diamètre et de la profondeur des réseaux enterrés

En plus de la large gamme d'applications GPR répertoriées dans Pajewski et al. (2013), l'estimation de la profondeur et du rayon des objets cylindriques enfouis est devenue une tâche importante, par



FIGURE 2.10 – Un exemple de calcul d’intersection sur des unions pour diverses boîtes englobantes (<https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>).

exemple pour l’estimation des armatures dans le béton Liu *et al.* (2020), pour la localisation des réseaux enterrés Liu *et al.* (2018). Cependant, quelles que soient les informations acquises à l’aide du GPR, chaque application a besoin de techniques de traitement adaptées afin d’interpréter les données GPR pour la prise de décision. Dans le cadre des conduites de services publics enterrées, l’estimation de la profondeur et du rayon a été démontrée dans la littérature à l’aide de techniques d’inversion (en anglais Full Wave Inversion, FWI) (Liu *et al.* (2018)) et d’apprentissage automatique basées sur les rayons. Cependant, cette approche a demandé de lourdes ressources de calcul.

La méthode basée sur les rayons a été utilisée dans Mechbal, Zoubaida & Khamlichi, Abdellatif (2018) pour détecter les barres d’armature enterrées, tandis que Sham & Lai (2016) l’a utilisée pour estimer la vitesse de propagation des ondes du GPR dans le béton lorsque le rayon est connu. Bien que les méthodes basées sur les rayons soient largement adoptées, l’erreur commise sur la localisation du pic dans le signal temporel a conduit à de grandes erreurs dans l’estimation du rayon Borgioli *et al.* (2008). Pendant ce temps, les techniques d’apprentissage automatique ont montré des résultats prometteurs pour les applications de services publics souterrains. En particulier, les séparateurs à vaste marge (SVM) qui sont un ensemble de techniques d’apprentissage supervisé, ont été utilisés pour la détection automatique d’hyperboles Terrasse (2017). En termes d’estimation, Jaufer *et al.* (2020b) propose d’utiliser les caractéristiques extraites de l’hyperbole et avec une version de SVM pour la régression (SVR) d’estimer le rayon et la profondeur d’objets cylindriques souterrains. Cependant, bien que cette approche ait donné de bons résultats sur des données synthétiques, elle n’a pas encore été validée sur des données réelles.

D’autre part, les réseaux de neurones artificiels (ANN) sont des outils de calcul relativement nouveaux qui ont été largement utilisés pour résoudre de nombreux problèmes complexes du monde réel. L’attractivité des ANN provient de leurs remarquables caractéristiques de traitement de l’information, adaptées principalement à la non-linéarité, au parallélisme élevé, à la tolérance aux pannes et au bruit, et aux capacités d’apprentissage et de généralisation Giannakis *et al.* (2021). Dans les applications GPR, Li *et al.* (2020) ont adopté l’ANN et l’apprentissage automatique pour la détection et la localisation des barres d’armature tandis que Giannakis *et al.* (2021) a utilisé un ANN multicouche basé sur le perceptron pour l’évaluation de la taille des barres d’armature dans le béton. Cependant, les approches n’ont été validées que sur quelques barres d’armature et la robustesse reste encore à démontrer. Étant donné que les caractéristiques d’entrée dominent fortement les performances du modèle, Jaufer *et al.* (2020b) ainsi que d’autres facteurs tels que la taille de la base de données et la morphologie de l’ensemble des données, l’objectif de cet article est donc d’évaluer les performances du modèle de régression basé sur l’ANN combiné à un ensemble de caractéristiques locales proposées par Jaufer *et al.* (2020b) pour estimer la vitesse, la profondeur et le rayon des tuyaux cylindriques enterrés considérés comme trois paramètres uniques et indépendants. Même si la vitesse est corrélée à la profondeur, la conversion de la vitesse à partir des informations de profondeur ne représente que la vitesse de groupe du milieu stratifié

entre la surface du sol et l'objet au sommet de l'hyperbole. Ainsi, pour surmonter cette limitation, la vitesse est considérée comme un paramètre indépendant dans cette étude. En raison du manque de données expérimentales appropriées à ce stade de la recherche, l'évaluation est réalisée sur des données numériques GPR (Bscan à partir de diverses configurations) créées à l'aide du logiciel gprMax (Warren et al. (2016)).

3 Un outil pour l'annotation des données : labelGPR

3.1 Représentation des données radar

Qui dit apprentissage supervisé dit annotation des données. En effet cette classe d'algorithme se base sur l'observation de nombreux exemples en terme de données et tente de s'adapter au mieux à l'ensemble de ce dernier. L'annotation des données consiste donc à adjoindre une information experte aux données traitées, de la même façon qu'un spécialiste en réalise l'interprétation et l'analyse. Cette information doit être enregistrée et stockée sous un format qui va permettre d'être utilisé par la suite pour l'apprentissage.

3.1.1 Génération d'images

Le signal brut relevé par l'appareil n'est pas une donnée interprétable par un opérateur. On le transforme toujours sous forme d'une image afin de comprendre sa signification. La première étape consiste ainsi dans le cadre de données radar à s'intéresser à leur représentation. La plus répandue est le radargramme, qui se trouve être une image représentant une partie du signal électromagnétique réfléchi par la structure auscultée. Un signal brut est souvent codé sur 12 voire 16 bits, donc la conversion en image demande de réduire à 8 bits le signal. Cela consiste à ramener les valeurs minimales à 0 et les maximales à 255 avec un rapport de proportionnalité appliquée à l'ensemble de la plage de variation.

3.1.2 Pré-Traitements de radargrammes

Malheureusement cette simple conversion est insuffisante dans la majorité des cas, surtout sur des mesures expérimentales. L'intensité du signal décroît fortement au cours du temps, car le parcours en profondeur génère une atténuation de ce dernier. Si on garde la même échelle linéaire sur la dynamique du signal, l'écho de surface, qui est maximal, gomme les variations plus faibles du signal en profondeur et le rend non distinguable à l'image. Il est donc nécessaire de traiter le signal afin de générer une image qui permette de le visualiser.

Actuellement les outils du module Python GPRpy sont utilisés pour ces pré-traitements. Les paramètres sont ainsi les mêmes appliqués à chaque signal radar, ce qui présente l'avantage de figer ces pré-traitements. Une piste d'amélioration envisagée à ce stade est de permettre sous une interface d'avoir la main sur certains paramètres de ce pré-traitement afin de pouvoir par exemple renforcer le contraste sur certaines portions de l'image ou spécifier un niveau de bruit pour filtrer ce dernier.

3.2 Une interface d'annotation

3.2.1 Description de l'outil

L'outil proposé ici a vu le jour avec le projet Ferec Degre, et consiste en une interface graphique permettant de charger des fichiers radars, les représenter sous forme d'une image et de venir apposer des informations sur cette dernière. Un exemple est donné dans le figure 3.1.

Une fois l'annotation terminée, les informations sont enregistrées sous deux formats. Le premier est un format qui place les points sélectionnés en pixels et sauvegarde les images, et le deuxième qui sauvegarde les points du signal brut et pour lesquels les coordonnées sont exprimées en (x, t) (pour un B-scan).

La figure 3.1 montre la fenêtre du logiciel (qui est basé sur labelImg, ce dernier étant réservé aux images, qui a été adapté aux données radar). Les boîtes englobantes sont placées en deux clics puis modifiables en taille, et conjointement une description du phénomène détourné apparaît à droite de

l'image, qui servira à classer ce dernier.

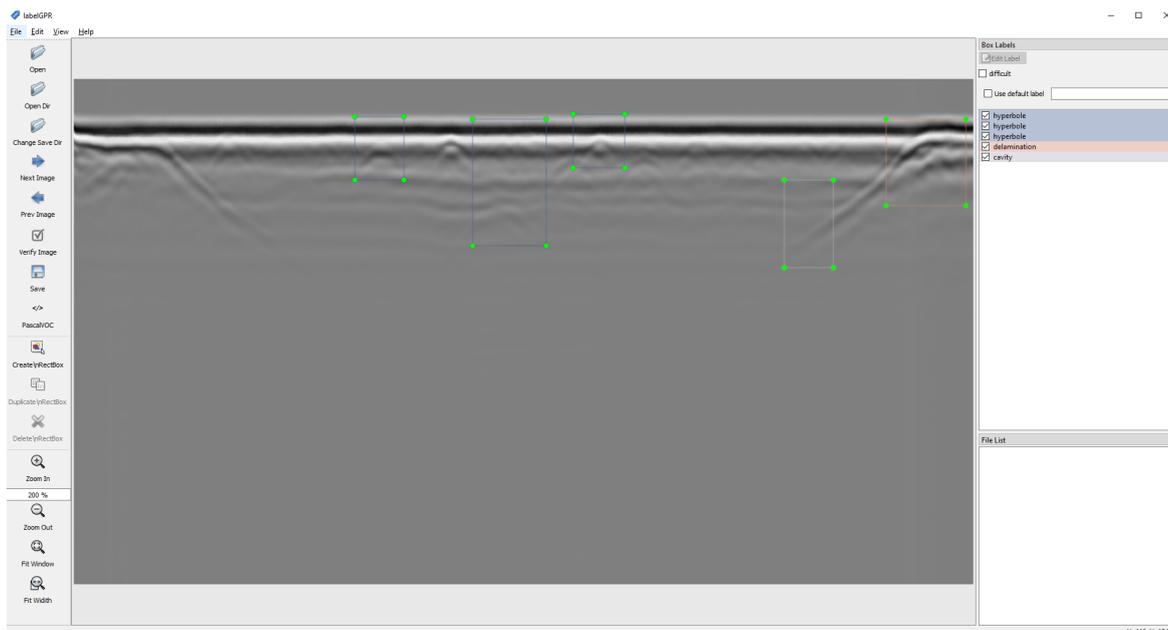


FIGURE 3.1 – Exemple d'annotation sous labelGPR.

3.2.2 Format des données radar pris en compte

Voici les formats de données qui peuvent être chargés avec labelGPR :

1. Fichiers .OUT
2. Fichiers .DZT
3. Fichiers .BSQ
4. Fichiers .DT1
5. Fichiers MALA (.rad .rd3 .rd7)

Les fichiers .ASC ne sont pas pris en compte pour l'instant.

Pour chacun des formats, il est nécessaire de pouvoir accéder aux paramètres de la mesure (fréquence de la source utilisée, espacement des mesures...) qui diffèrent évidemment d'un format à l'autre. Il arrive dans certains cas que ces renseignements figurent dans un fichier annexe aux mesures, mais la plupart du temps il existe un système d'en tête dans les fichiers qui recense ces informations.

3.2.3 Classes d'annotations actuelles

Actuellement seules des boîtes englobantes, *Bounding box* en anglais, peuvent être dessinées sur l'image. On peut soit sélectionner le phénomène localement, i.e. tracer une boîte uniquement autour de l'hyperbole par exemple ou bien plus globalement inclure la réflexion de surface pour accéder à la profondeur.

Dans la pratique, ce type d'annotation est-il vraiment suffisant ? En effet la forme du phénomène est importante, mais on ne peut pas relever l'épaisseur de la parabole par exemple, qui est importante vis-à-vis de la permittivité des matériaux rencontrés.

3.3 Évolutions envisagées

3.3.1 Détourage d'hyperboles

La première amélioration envisagée serait de développer un outil d'assistance pour l'opérateur qui détoure les formes automatiquement, en partant d'un point et le logiciel sélectionne les points les plus proches selon un critère. La méthode envisagée est le fastmarching [Sethian \(2021\)](#), qui permet de sélectionner un chemin automatiquement dans l'image, que l'on envisage de contraindre à un parcours le long d'une hyperbole. Cette solution graphique pourrait s'avérer très efficace pour annoter les signaux radar que nous cherchons à exploiter.

3.3.2 Méthodes automatiques

Un autre aspect très prometteur des techniques d'apprentissage est son côté incrémentiel. En effet, une fois un algorithme appris, il est possible de le ré-injecter dans le logiciel d'annotation et de ne plus annoter l'ensemble des données, mais simplement de corriger les annotations obtenues par l'algorithme. Ceci se traduit par une efficacité lors de la labellisation, mais contribue aussi à augmenter la taille et la qualité de la base d'apprentissage, 2 éléments essentiels pour arriver à ses fins lorsque l'on utilise ces méthodes.

4 Résultats expérimentaux

4.1 Détection

4.1.1 Base de données numériques

Les scénarios de détection proposés ont été validés numériquement sur des images GPR synthétiques (B-scans) générées à l'aide de gprMax (Warren et al. (2016)) en considérant pour la modélisation une dispersion homogène du milieu et aucun bruit. La configuration à couche unique est adoptée avec l'hypothèse selon laquelle les couches multiples peuvent être approchées comme une seule couche avec des valeurs paramétriques globales uniques. La source électromagnétique utilisée pour simuler l'antenne GPR est un dipôle hertzien alimenté par une forme d'onde de Ricker avec une fréquence centrale de $f_c = 1,5$ GHz. Les modèles générés aléatoirement se compose d'un ou plusieurs réseaux enterrés dans une seule couche. Trois types de réseaux enterrés ont été modélisés : en métal, en PVC avec de l'air à l'intérieur ou en PVC avec de l'eau à l'intérieur. La permittivité de la couche (ϵ_r) varie entre 6 et 9 aléatoirement. La profondeur de positionnement d'un réseau enterré varie entre 0,5 m et 1,5 m aléatoirement. Le diamètre du réseau enterré varie aléatoirement de 2 cm à 15 cm. La conductivité est fixée à $1 \times 10^{-5} \text{ S m}^{-1}$. La résolution spatiale entre les A-scans adjacents est de 2 cm. Ainsi, un total de 200 B-scans uniques composés de 600 A-scans avec un ou plusieurs réseaux enterrés ont été créés.

Un gain a été appliqué sur les B-scans générés pour augmenter la visibilité de l'hyperbole. Ensuite, un bruit blanc gaussien a été ajouté afin de produire un B-scan plus proche du scénario réaliste. De plus, les B-scans originaux de dimensions 600 x 4200, ont été redimensionnés en une image binaire de 600 x 600 pixels plus appropriée pour le modèle Faster-RCNN. Par conséquent, la résolution horizontale a été conservée comme le B-scan d'origine tandis que les informations temporelles ont été compressées lors du redimensionnement. Les bords de l'hyperbole étaient beaucoup plus nets et clairs après le pré-traitement et la binarisation.

Les B-scan prétraitées ont été séparées au hasard en trois groupes de 60, 25 et 100 B-scans respectivement pour l'apprentissage, la validation et les tests. Deux ensembles distincts d'annotations ont été réalisés selon les deux scénarios. Enfin, deux modèles Faster RCNN ont été entraînés en conséquence à l'aide de TensorFlow dans Google Colab. Le nombre d'itérations a été maintenu à 40 000 pour être suffisant pour la convergence de la fonction de perte d'apprentissage (L).

Le tableau montre 4.1 les résultats sur la base de test de 100 images contenant 272 hyperboles. Ils ont été obtenus à partir de la prédiction des deux modèles Faster-RCNN construits à l'aide de deux stratégies d'annotation et de l'architecture convolutive RESNET-50 avec un seuil d'IoU de 0,6.

	Vrai Positifs	Faux Négatifs	Faux Positifs	Précision	Rappel
Scénario 1	270	2	8	97,1 %	99,2 %
Scénario 2	262	10	3	98,1 %	95,8 %

TABLE 4.1 – Précision et rappel selon les différents scénarios sur des données modélisées.

Les figures 4.1 et 4.2 sont de bons exemples qui démontrent les avantages et les inconvénients des deux modèles. La vérité terrain pour ces deux exemples comporte trois réseaux enterrés. Dans la figure 4.1, le modèle détecte les trois réseaux enterrés avec un faux positif supplémentaire car il classe à tort la réflexion multiple d'un tuyau. La figure 4.2 fournit un faux négatif où il ne parvient pas à détecter le troisième réseau enterré. Cependant, le deuxième scénario valide son objectif ultime en éliminant les faux positifs causés dans le premier scénario.

Avec le scénario 1, 270 hyperboles sur un total de 272 ont été détectées. 8 fausses détections dues à des

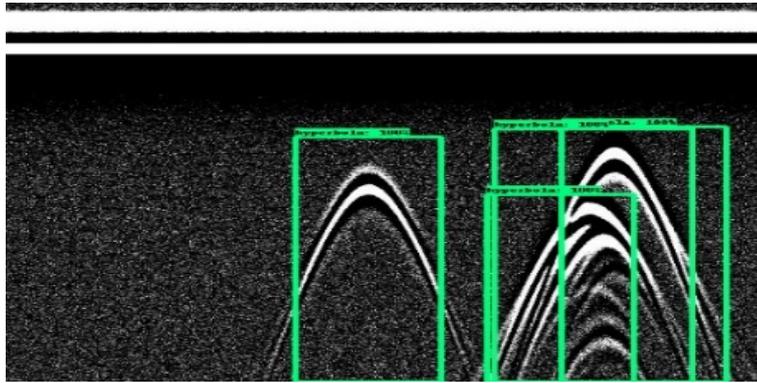


FIGURE 4.1 – Exemple de faux positif.

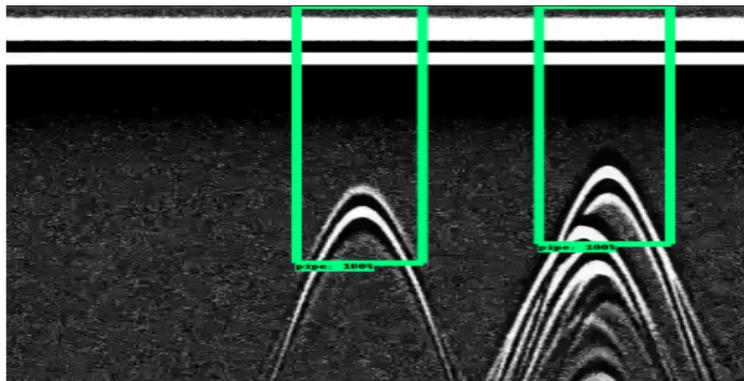


FIGURE 4.2 – Exemple de faux négatif.

multiples réflexions ont été relevées. Le scénario 2 dont l'objectif est d'éviter les fausses détections, n'a effectué que 3 fausses détections. 262 hyperboles sur un total de 272 ont été détectées. Comme observé dans le tableau 4.1, la précision globale et le rappel ont été estimés. Il a été observé que la précision du modèle Faster-RCNN est meilleure dans le scénario 2 tandis que le rappel est meilleur dans le scénario 1.

Le scénario 2 valide son objectif en éliminant les faux positifs relevés dans le scénario 1. En fait, les faux négatifs du scénario 2 peuvent être négligés, car l'objectif et l'hypothèse de cette étude est de considérer comme cible unique une ou plusieurs canalisations à un endroit dense.

4.1.2 Base de données réelles

Les scénarios proposés ont été validés sur des données GPR de terrain acquises à l'Université Gustave Eiffel de Nantes (Fig. 4.3).

Deux GPR à impulsion de 400 MHz (modèle GSSI SIR-4000) ont été déployés pour effectuer un levé GPR. Des profils parallèles à la route espacés de 0,5 m d'une distance approximative de 30 m chacun (profils bleus), ainsi que des profils perpendiculaires à la route espacés de 1 m d'intervalle de 20 m ont été acquis (profils jaunes). Pour garantir l'exclusivité de la base de données de test, des données pour l'apprentissage ont été collectés dans d'autres zones du campus.

Les deux GPR avaient la même configuration avec :

- 70 A-scans/m ;
- 1024 échantillons de temps par A-scan pour une fenêtre temporelle de 35 ns

Bien que les B-scans acquis sont de longueurs différentes, l'ensemble des B-scans a été subdivisé en image de 5 m de long. Enfin, sur chaque B-scan de 5 m, un gain logarithmique, un décalage de l'offset et le redimensionnement à 600 par 600 pixels requis pour Faster-RCNN ont été appliqués. Environ 84

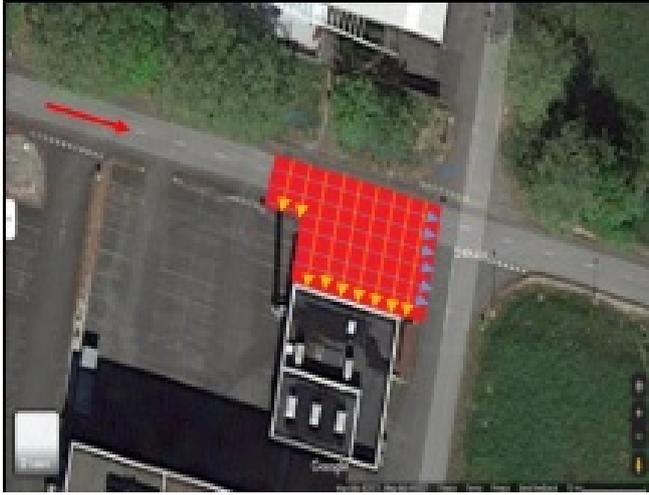


FIGURE 4.3 – Site d’essai à l’université Gustave Eiffel à Nantes, avec des profils mis en évidence.

B-scans comprenant 116 hyperboles ont été regroupés en 67 B-scans pour l’entraînement et 17 B-scans pour l’ensemble de données de validation. Alors que la zone de test avait 99 B-scans avec 149 hyperboles.

	Vrai Positifs	Faux Négatifs	Faux Positifs	Précision	Rappel
Scénario 1	140	11	19	88 %	92,7 %
Scénario 2	131	20	12	91,6 %	86,7 %

TABLE 4.2 – Précision et rappel selon les différents scénario sur des données réelles.

Les résultats obtenus dans le cadre des deux scénarios sont présentés dans le tableau 4.2. Les résultats indiquent que la précision du modèle est plus élevée avec le scénario 2, tandis que le rappel est meilleur dans le cas du scénario 1. Dans les deux cas la précision et le rappel sont supérieurs à 85 %. Ces résultats sont en accord avec ceux observés sur la base de données numériques. Alors que certaines fausses alarmes sont observées dans le cas du scénario 1, elles sont évitées dans le scénario 2. Bien que le nombre de vrais positifs soit plus élevé, il y a eu peu de cas où les fausses alarmes ont été détectées dans les deux approches. De plus, le scénario 2 ne détecte pas un réseau enterré ce qui augmente le taux de faux négatifs et le risque de détérioration du réseau.

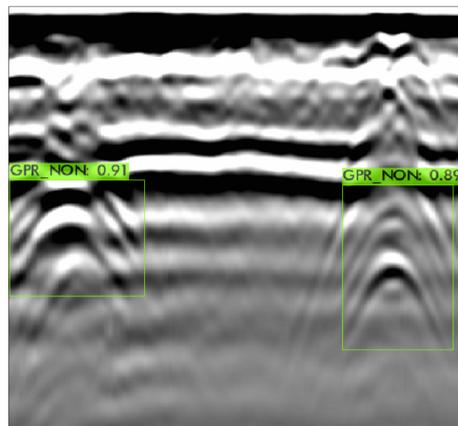


FIGURE 4.4 – B-scan réel avec le scénario d’annotation 1.

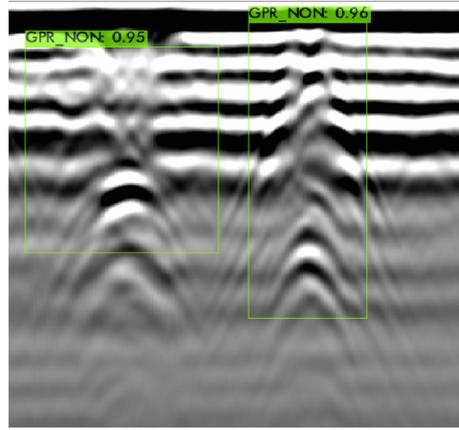


FIGURE 4.5 – B-scan réel avec le scénario d’annotation 2.

4.2 Estimation du rayon et de la profondeur du réseau enterré

Pour valider l’estimation du rayon et de la profondeur, une base de données réalisée à partir de gprMax Warren *et al.* (2016) avec comme hypothèse un milieu dispersif homogène simple est utilisé. La résolution d’échantillonnage dans le temps des B-scans réalisés est fixée à $\Delta t = 5,89 \times 10^{-12}$ s. Le domaine spatial de chaque modèle est défini par 1 m de longueur sur 1 m de profondeur. La résolution du maillage pour la simulation est $2,5 \times 10^{-3}$ m en longueur et en profondeur. Un dipôle hertzien alimenté par une forme d’onde de Ricker avec une fréquence centrale $f_c = 1,5$ GHz, à une hauteur de 5 mm de la surface est utilisé. Le modèle se compose d’un tuyau cylindrique métallique noyé dans une seule couche. La permittivité de la couche (ϵ_r) varie entre 6 et 16 avec des pas de 0,33. La profondeur de positionnement du tuyau cylindrique (d) varie entre 30 cm et 70 cm avec des pas incrémentiels de 10 cm. Les rayons du tuyau par contre sont de 1 cm, 2 cm, 3 cm, 5 cm, 7 cm, 10 cm avec 3 niveaux de conductivité (σ) différents à 1×10^{-5} S/m, 1×10^{-3} S/m et 1×10^{-1} S/m. La résolution spatiale entre les A-scans adjacents est de 2 cm. Ainsi, un total de 2610 B-scans uniques ont été créés avec chaque B-scan composé de 41 A-scans. L’extraction de caractéristiques est effectuée sur tous les B-scans. Les données sont ensuite divisées en trois ensembles : apprentissage, validation et test, représentant respectivement 70 %, 15 % et 15 % de la base de données. Le modèle proposé contient un réseau de neurones avec 6 caractéristiques d’entrée, 30 neurones cachés avec fonction d’activation sigmoïde, suivis d’une sortie de neurone unique contenant une fonction d’activation linéaire. Chaque modèle de réseau de neurones a pour sortie le rayon, la profondeur ou la vitesse.

Erreur (%)	rayon	Profondeur	Vitesse
Moyenne	2,49	0,2	0,16
P_{95}	9,68	0,5	0,42

TABLE 4.3 – Erreur moyenne et 95^e centile (P_{95}) pour l’estimation du rayon, de la profondeur et de la vitesse.

Le tableau 4.3 compare les résultats de performance de l’erreur relative moyenne et de l’erreur relative maximale par rapport au 95^e centile (P_{95}) calculés en utilisant :

$$\text{erreur} = \left| \frac{L_{\text{estimé}} - L_{\text{référence}}}{L_{\text{référence}}} \right| \times 100$$

avec $L_{\text{estimé}}$ la valeur estimée et $L_{\text{référence}}$ la valeur de référence. Selon le tableau, le modèle montre une erreur de 0,2 %, 2,49 % et 0,16 % pour l’estimation de la profondeur, du rayon et de la vitesse, respectivement.

Le 95^e centile de l’estimation du rayon est relativement plus élevé par rapport à ceux de la profondeur et de la vitesse, indiquant ainsi une distribution d’erreurs plus large. Les estimations de la profondeur

et de la vitesse sont plus robuste que celle du rayon. Étant donné que l'information sur le rayon est très sensible à la variation de la forme de l'hyperbole, [Jaufer et al. \(2020a\)](#), l'erreur s'est avérée plus élevée. L'erreur est plus élevée dans les classes de rayon inférieures et elle diminue avec l'augmentation de la taille du rayon. De même, pour les classes de rayon inférieure, l'erreur est relativement plus grande pour une conductivité du matériau plus élevée (1×10^{-1} S/m) alors que cette tendance n'est pas observée dans les cas de rayon plus élevé.

5 Utilisation de l'aide de la FEREC dans le projet

L'aide de la fondation FEREC peut se décomposer de la manière suivante :

- Cerema 14 500 euros :
 - Gratification 2 stages de 6 mois ;
 - Conférence Near Surface Geoscience "2nd Conference on Geophysics for Infrastructure Planning, Monitoring and BIM", R. Jaufer, C. Heinkele, N. Loubat, D. Guilbert and A. Ihamouten, "Deep convolutional neural network for estimation of depth and radius from GPR raw signals", <https://doi.org/10.3997/2214-4609.202120222> ;
 - Conférence IWAGPR 2021, R. Jaufer, A. Ihamouten, D. Guilbert, S. Todkar, Tarun Yaram and X. Dérobert, "Deep learning based automatic hyperbola detection on GPR data for buried utility pipes mapping" ;
 - Déplacements ;
 - Fonctionnement ;
- Université Gustave Eiffel 7000 euros pour le coût de fonctionnement de Sense City, les déplacements et le fonctionnement
- ESEO 3000 euros pour le fonctionnement et les déplacements ;
- Logiroad 3000 euros pour le fonctionnement et les déplacements.

6 Impact

6.1 Apport et retombées pour la collectivités

Les résultats expérimentaux intéressent la profession dans le sens où ils devraient aider à localiser les réseaux enterrés et à estimer leur profondeur ainsi que le rayon des réseaux à partir d'une inspection radar sur une chaussée en service. De plus, il est prévu de mettre à disposition la base de données radar sur Internet, une fois les résultats valorisés par des publications et communications.

6.2 Publications et autres éléments de communication auxquels le projet et ses résultats ont donné lieu

Les principaux résultats de cette recherche ont été présentés lors de conférence internationale :

- Conférence Near Surface Geoscience « 2nd Conference on Geophysics for Infrastructure Planning, Monitoring and BIM », R. Jaufer, C. Heinkele, N. Loubat, D. Guilbert and A. Ihamouten, « Deep convolutional neural network for estimation of depth and radius from GPR rawsignals », <https://doi.org/10.3997/2214-4609.202120222> ;
- IWAGPR 2021, R. Jaufer, A. Ihamouten, D. Guilbert, S. Todkar, Tarun Yaramand X. Dérobert, « Deep learning based automatic hyperbola detection on GPR data forburied utility pipes mapping »

Les résultats ont aussi fait l'objet d'une publication :

- R. Jaufer, A. Ihamouten, Y. Goyat, T. Château, D. Guilbert, S. Todkar, X. Dérobert, Juillet - Août 2021, « CARTOGRAPHIE 3D DES RÉSEAUX ENTERRÉS UTILISATION DE MODÈLES DE TRAITEMENT DU SIGNAL DE DONNÉES RSF ET DE TECHNIQUES D'APPRENTISSAGE », Revue générale des routes et de l'aménagement, n°983, pp. 56-62

Il est envisagé de publier des résultats complémentaires dans des revues.

7 Perspectives ouvertes par le projet

L'amélioration des algorithmes et outils développés devraient permettre prochainement d'être mieux intégrés pour une utilisation opérationnelle.

Bibliographie

- Al-Nuaimy, W., Huang, Y., Nakhkash, M., Fang, M. T. C., Nguyen, V. T., & Eriksen, A., 2000. Automatic detection of buried utilities and solid objects with GPR using neural networks and pattern recognition, *Journal of Applied Geophysics*, **43**(2), 157–165.
- Birkenfeld, S., 2010. Automatic detection of reflexion hyperbolas in gpr data with neural networks, in *2010 World Automation Congress*, pp. 1–6, Kobe, Japan, ISSN : 2154-4824.
- Borgioli, G., Capineri, L., Falorni, P., Matucci, S., & Windsor, C. G., 2008. The detection of buried pipes from time-of-flight radar data, *IEEE Transactions on Geoscience and Remote Sensing*, **46**(8), 2254–2266.
- Chandradeep, B., Indrajeet, K., Vijayakumar, Kamred, Kamred, S., & Abhishek, K., 2021. The state of the art of deep learning models in medical science and their challenges, *Multimedia Systems*, **27**.
- Delbo, S., Gamba, P., & Roccatò, D., 2000. A fuzzy shell clustering approach to recognize hyperbolic signatures in subsurface radar images, *IEEE Transactions on Geoscience and Remote Sensing*, **38**(3), 1447–1451.
- Feng, J., Yang, L., Wang, H., Song, Y., & Xiao, J., 2020. GPR-based Subsurface Object Detection and Reconstruction Using Random Motion and DepthNet, *arXiv :2008.08731 [eess]*.
- Giannakis, I., Giannopoulos, A., & Warren, C., 2021. A machine learning scheme for estimating the diameter of reinforcing bars using ground penetrating radar, *IEEE Geoscience and Remote Sensing Letters*, **18**(3), 461–465.
- Golovko, M., 2007. The Evaluation of Performances of Automatic Method for the Object Detection in GPR Images, in *2007 5th International Symposium on Image and Signal Processing and Analysis*, pp. 476–481, ISSN : 1845-5921.
- Guan, B., Ihamouten, A., Dérobert, X., Guilbert, D., Lambot, S., & Villain, G., 2017. Near-field full-waveform inversion of ground-penetrating radar data to monitor the water front in limestone, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **10**(10), 4328–4336.
- Harkat, H., Elfakir, Y., Bennani, S. D., Khaissidi, G., & Mrabti, M., 2016. Ground penetrating radar hyperbola detection using Scale-Invariant Feature Transform, in *2016 International Conference on Electrical and Information Technologies (ICEIT)*, pp. 392–397, IEEE, Tangiers, Morocco.
- Jaufer, R., Todkar, S. S., Ihamouten, A., Goyat, Y., Guilbert, D., Caucheteux, A., Baltazart, V., Heinkele, C., & Dérobert, X., 2020a. Ray-based method vs. svm for the inversion of embedded cylindrical pipe’s parameters from gpr data : Numerical comparative study, in *18th International Conference on Ground Penetrating Radar*, pp. 356–359.
- Jaufer, R., Todkar, S. S., Ihamouten, A., Goyat, Y., Guilbert, D., Caucheteux, A., Baltazart, V., Heinkele, C., & Dérobert, X., 2020b. Ray-based method vs. svm for the inversion of embedded cylindrical pipe’s parameters from gpr data : Numerical comparative study, in *18th International Conference on Ground Penetrating Radar, Golden, Colorado, 14–19 June 2020*, pp. 356–359, Society of Exploration Geophysicists.
- Ji, G., Gao, X., Zhang, H., & Gulliver, T. A., 2009. Subsurface object detection using UWB Ground Penetrating Radar, in *2009 IEEE Pacific Rim Conference on Communications, Computers and Signal Processing*, pp. 740–743, ISSN : 2154-5952.
- Lambot, S., Slob, E., van den Bosch, I., Stockbroeckx, B., & Vanclooster, M., 2004. Modeling of ground-penetrating radar for accurate characterization of subsurface electric properties, *IEEE Transactions on Geoscience and Remote Sensing*, **42**(11), 2555–2568.

- Li, Y., Zhao, Z., Luo, Y., & Qiu, Z., 2020. Real-Time Pattern-Recognition of GPR Images with YOLO v3 Implemented by Tensorflow, *Sensors*, **20**(22), 6476.
- Liu, F., 2007. *Modélisation et expérimentation radar impulsif et à sauts de fréquence pour l'auscultation de milieux stratifiés du génie civil*, Ph.D. thesis, Université de Nantes, Thèse de doctorat dirigée par Dérobert, Xavier et Laguerre, Laurent Électronique et génie électrique Nantes 2007.
- Liu, H., Lin, C., Cui, J., Fan, L., Xie, X., & Spencer, B. F., 2020. Detection and localization of rebar in concrete by deep learning using ground penetrating radar, *Automation in Construction*, **118**, 103279.
- Liu, T., Klotzsche, A., Pondkule, M., Vereecken, H., Su, Y., & van der Kruk, J., 2018. Radius estimation of subsurface cylindrical objects from ground-penetrating-radar data using full-waveform inversion, *GEOPHYSICS*, **83**(6), H43–H54.
- Liu, Y., Wang, M., & Cai, Q., 2010. The target detection for GPR images based on curve fitting, in *2010 3rd International Congress on Image and Signal Processing*, vol. 6, pp. 2876–2879.
- Mechbal, Zoubaida & Khamlichi, Abdellatif, 2018. Sensitivity of the inverse problem solution related to detection of rebars buried in concrete by using gpr scanning, *MATEC Web Conf.*, **191**, 00010.
- Pajewski, L., Benedetto, A., Derobert, X., Giannopoulos, A., Loizos, A., Manacorda, G., Marciniak, M., Plati, C., Schettini, G., & Trinks, I., 2013. Applications of ground penetrating radar in civil engineering — cost action tu1208, in *2013 7th International Workshop on Advanced Ground Penetrating Radar*, pp. 1–6.
- Pasoli, E., Melgani, F., Donelli, M., Attoui, R., & de Vos, M., 2008. Automatic Detection and Classification of Buried Objects in GPR Images Using Genetic Algorithms and Support Vector Machines, in *IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium*, vol. 2, pp. II-525–II-528, ISSN : 2153-7003.
- Sethian, J., 2021. A fast marching level set method for monotonically advancing front, *Proc. Natl. Acad. Sci.*, **93**(4), 1591–1595.
- Sezgin, M., Kurugollu, F., Tasdelen, I., & Ozturk, S., 2004. Real-time detection of buried objects by using GPR, in *Detection and Remediation Technologies for Mines and Minelike Targets IX*, vol. 5415, pp. 447–455, SPIE.
- Sham, J. F. & Lai, W. W., 2016. Development of a new algorithm for accurate estimation of gpr's wave propagation velocity by common-offset survey method, *NDT & E International*, **83**(C), 104–113.
- Spagnolini, U., 1997. Permittivity measurements of multilayered media with monostatic pulse radar, *IEEE Transactions on Geoscience and Remote Sensing*, **35**(2), 454–463.
- Terrasse, G., 2017. *Géodétection des Réseaux Enterrés par Imagerie Radar*, Ph.D. thesis, Télécom ParisTech Spécialité “Traitement du Signal et de l’Image”.
- Wang, J. & Su, Y., 2011. Underground object detection based on cross correlation and Hough transform, in *2011 MICROWAVES, RADAR AND REMOTE SENSING SYMPOSIUM*, pp. 363–366.
- Warren, C., Giannopoulos, A., & Giannakis, I., 2016. gprmax : Open source software to simulate electromagnetic wave propagation for ground penetrating radar, *Computer Physics Communications*, **209**, 163–170.
- Zou, Z., Shi, Z., Guo, Y., & Ye, J., 2019. Object detection in 20 years : A survey, *ArXiv*, **abs/1905.05055**.



**RÉPUBLIQUE
FRANÇAISE**

*Liberté
Égalité
Fraternité*



Cerema

CLIMAT & TERRITOIRES DE DEMAIN