

FONDATION D'ENTREPRISE

**FE R EC**

ADOU CIR

Aide au Diagnostic d'OUvrages par Couplage d'Images et Radar

Cerema et Université Gustave Eiffel



Lauréat de l'appel à projets 2019

« Intelligence artificielle (IA) appliquée aux infrastructures en service »

Novembre 2021

## Partenaires

- Cerema, Equipe ENDSUM (Evaluation Non Destructive des Structures et de Matériaux)  
Philippe FOUCHER, ENDSUM Strasbourg, responsable du projet ADOUCIR  
Cyrille FAUCHARD, ENDSUM Rouen
- Université Gustave Eiffel, Laboratoire GeoEND (Géophysique et Evaluation Non Destructive)  
Xavier DEROBERT, GeoEND Nantes

## Sommaire

<b>1</b>	<b>Résumé .....</b>	<b>4</b>
<b>2</b>	<b>Contexte et objectifs du projet.....</b>	<b>5</b>
<b>3</b>	<b>Description des travaux menés.....</b>	<b>7</b>
3.1	Description des types de données .....	7
3.2	Bases de données .....	11
3.3	Méthodes de reconnaissance de formes.....	7
<b>4</b>	<b>Utilisation de l'aide de la Ferec dans le projet .....</b>	<b>15</b>
<b>5</b>	<b>Résultats acquis.....</b>	<b>16</b>
5.1	Classification .....	16
5.2	Segmentation d'instances.....	16
<b>6</b>	<b>Impact.....</b>	<b>20</b>
6.1	Apports et retombées pour la collectivité .....	20
6.2	Mise en évidence du caractère collaboratif et d'intérêt général .....	20
6.3	Publications et autres éléments de communication auxquels le projet et ses résultats ont donné lieu.....	21
<b>7</b>	<b>Perspectives ouvertes par le projet notamment en matière de recherche collaborative.....</b>	<b>22</b>
	<b>References .....</b>	<b>23</b>

## 1 Résumé

Le projet ADOUCIR (Aide au Diagnostic d'Ouvrages par Couplage d'Images et Radar) vise à mettre au point et évaluer des méthodes d'apprentissage profond (*deep learning*) pour classer des images de pont en béton en catégories « avec fissures » ou « saines ». L'originalité de cette approche est la combinaison d'images visibles acquises à la surface des parois et d'images de la structure interne du matériau collectées au moyen de capteurs GPR (*Ground Penetrating Radar*). En établissant le lien entre surface et état interne du matériau, l'objectif est également d'identifier les causes possibles d'apparition des fissures. Une campagne expérimentale a permis l'acquisition d'un jeu de couples de données sur deux structures en béton. Les résultats ont montré que les performances en classification étaient meilleures en utilisant les modalités plutôt qu'une seule. Dans un second temps, en s'appuyant toujours sur des algorithmes de segmentation par apprentissage profond, il a été possible de détecter, dans les images GPR, plus de 88% des hyperboles caractérisant la présence d'armatures. Cette extraction est une première étape pour comprendre l'apparition de fissures en analysant les propriétés physiques.

## 2 Contexte et objectifs du projet

L'auscultation périodique des ouvrages d'art est essentielle pour garantir leur bon état et assurer leur fonctionnement. L'inspection consiste, entre autres, à déceler et identifier les désordres, suivre leur évolution et analyser leurs causes. Parmi les désordres à recenser, on s'intéresse en particulier aux fissures sur ouvrages en béton. Les fissures sont des désordres fréquents, d'ouverture, de longueur, d'orientation et de densité très variées. Elles peuvent présenter aucun critère de gravité ou au contraire être annonciatrices de pathologies très variées. Les raisons d'apparition de ces fissures sont multiples et il est important d'en comprendre leurs origines pour affiner le diagnostic et mettre en place des actions de suivi et/ou de traitement. Ainsi, les fissures d'origine mécanique souvent liées à un fonctionnement normal de l'ouvrage, peuvent aussi mettre en évidence une insuffisance de ferrailage ou un problème de corrosion des armatures. Les conditions de prise non respectées et/ou une qualité du béton inadaptée peuvent aussi conduire à l'apparition de ce type de fissures. Les fissures peuvent également être dues à des réactions physico-chimique dans le matériau et entraîner gonflement et fissuration de celui-ci. Enfin le retrait du béton, lorsqu'il n'est pas bien maîtrisé, peut entraîner ce phénomène de fissurations. D'une manière générale, pour expliquer l'origine des fissures, il est nécessaire de caractériser l'état du matériau en lui-même ou des éléments constitutifs de la structure tels que les armatures métalliques.

Les techniques d'imagerie sont régulièrement employées pour fournir des données aux spécialistes afin de les aider dans leur tâche d'inspection. Selon les capteurs utilisés, on peut visualiser la surface de l'ouvrage avec des images dans le domaine visible ou infra-rouge. L'utilisation de caméras 3D permet d'extraire les variations de profondeur à la surface de la structure. Grâce aux capteurs GPR (*Ground Penetrating Radar*), il est également possible de visualiser la sub-surface du matériau et avoir un aperçu de son état interne. Si les outils d'acquisition de données sur ouvrages sont désormais assez répandus, leur analyse automatique commence seulement à être déployée de manière opérationnelle. Parmi ces méthodes automatiques, citons les algorithmes de reconnaissance de formes, branche de l'intelligence artificielle, qui permettent de détecter des éléments d'intérêt sur des images. Historiquement, de nombreuses approches de reconnaissance de forme se sont focalisées sur la détection automatique de désordres visibles sur des images de la surface du matériau (voir [1]). Ces mêmes approches de reconnaissance de forme peuvent être également mises en œuvre pour analyser les images GPR et identifier des éléments d'intérêt telles que des armatures ou des cavités (voir [2] pour un état de l'art). Dans ce domaine d'applications, on note cependant qu'aucune approche d'intelligence artificielle, à notre connaissance, propose un couplage de modalités alliant imagerie de surface et de sub-surface dans un algorithme de reconnaissance de formes.

L'objectif général du projet ADOUCIR (Aide au Diagnostic d'Ouvrages par Couplage d'Images et Radar) est de montrer la faisabilité et l'intérêt des méthodes d'intelligence artificielle combinant données images visibles de surface et GPR pour l'inspection des ouvrages. Cette problématique revêt un caractère innovant et répond à un besoin fort pour les inspecteurs. Dans cette optique, on s'intéresse en particulier à la classification d'images de parois d'ouvrages selon qu'elles contiennent des fissures ou non, comme on peut l'observer sur la Figure 1. On souhaite ainsi mettre en évidence l'apport éventuel d'une fusion de modalités pour effectuer cette tâche de classification par rapport à une approche automatique où une seule modalité serait prise en compte. Répondre à ce premier défi doit permettre d'identifier les zones du pont présentant une pathologie.

Pour orienter l'analyse de causes possibles d'apparition de fissures, on veut également s'appuyer sur les algorithmes de reconnaissance pour extraire des propriétés physiques (densité de ferrailage, profondeur, humidité du béton) du matériau. Dans l'approche retenue, nous proposons de nous

appuyer sur la détection automatique au pixel près d'armatures à l'intérieur du matériau, comme illustré sur la Figure 2 et mesurer les propriétés à partir des armatures détectées.

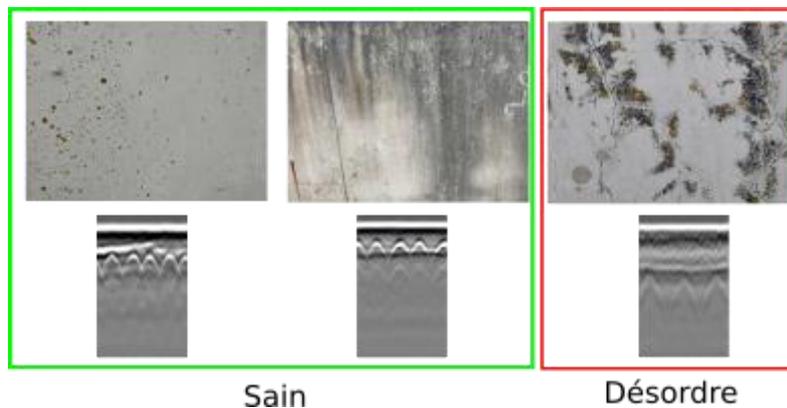


Figure 1 : Objectifs de classification automatique de parements de ponts en catégorie « saine » ou « désordres » en partant d'images visibles (en haut) et/ou d'images GPR (en bas) de la même zone.

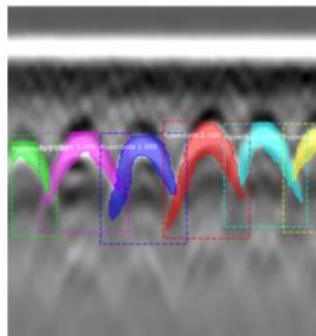


Figure 2 : Extraction automatique d'hyperboles (correspondant aux armatures) sur une image GPR par méthode de reconnaissance de forme. Les éléments colorés montrent que les hyperboles sont différenciées entre elles.

Le rapport est organisé de la façon suivante. La section 3 sera dédié à la description des travaux menés avec la présentation d'abord des méthodes d'apprentissage profond mises en œuvre dans ce projet puis des données utilisées et des moyens d'acquisition. Dans la section 4, la manière dont l'aide FEREC a été utilisée sera décrite. Les résultats du projet seront montrés et analysés dans la section 5. Enfin l'impact du projet sera discuté dans la section 6 avant d'ouvrir sur les perspectives (section 7).

### 3 Description des travaux menés

#### 3.1 Description des types de données

Dans ce projet, deux modalités d'images sont utilisées.

- Les images de la surface de la paroi de l'ouvrage sont enregistrées en couleurs dans le domaine visible à partir de caméras ou d'appareils photos standard. Pour visualiser les désordres avec suffisamment de détails, l'acquisition doit se faire selon un plan rapproché représentant une surface de l'ordre du m<sup>2</sup>.
- Les images de sub-surface de la paroi sont acquises avec des capteurs GPR. Un radar géophysique fonctionne de la manière suivante. Une onde électromagnétique est émise par une antenne vers l'intérieur du matériau. Une antenne réceptrice, placée sur ce même capteur, enregistre l'onde réfléchiée engendrée par des changements de milieu. Ce signal obtenu, appelé Ascans est représentée sous forme d'une variation d'amplitude en fonction du temps de parcours aller-retour de l'onde. En déplaçant le capteur à la surface du matériau de manière longitudinale, on obtient un ensemble de profils Ascans qui, agglomérés, forme une image Bscan dans laquelle l'abscisse représente la longueur de déplacement du capteur à la surface et l'ordonnée représente le temps de parcours de l'onde dans le matériau. L'ensemble de ce processus d'acquisition est décrit sur la Figure 3. Ces images Bscans seront utilisées dans la suite de ce projet. On observe sur ces données des hyperboles qui sont dues à la présence d'un obstacle (tube PVC dans la Figure 3, armatures métalliques dans la Figure 1).

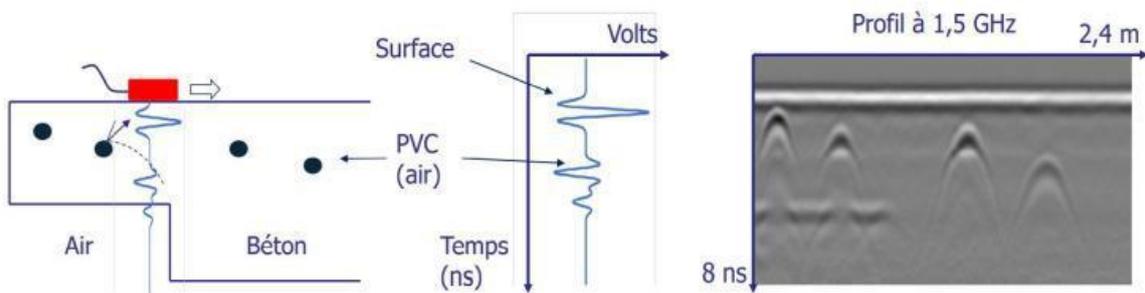


Figure 3 : Principe de fonctionnement d'un capteur GPR (de [3][4]) avec à gauche : le capteur (en rouge) se déplaçant sur une surface en béton ; au milieu, un profil Ascans acquis par le capteur GPR à une position donnée ; à droite, une image Bscan sur une longueur de déplacement de 2.4 mètres.

#### 3.2 Méthodes de reconnaissance de formes

##### 3.2.1 Présentation générale

D'une manière générale, associer automatiquement des données (images, portions d'images) à une classe au moyen d'une ou de fonction(s) mathématique(s) est un problème de reconnaissance de formes, pour lequel on distinguera trois tâches (Figure 4) : la classification de données, la détection d'objets et la segmentation. La classification consiste à assigner à l'image une catégorie sémantique. Par exemple on peut indiquer que la paroi est saine (classe 1) ou présente des fissures (classe 2). La détection consiste à indiquer la présence d'un ou plusieurs éléments d'intérêt dans l'image et à localiser ces éléments par exemple au moyen d'une boîte englobante. La segmentation consiste à délimiter un objet d'intérêt au pixel près. Quelle que soit la tâche à réaliser, une phase d'apprentissage doit, dans un premier temps, être effectuée de manière à optimiser la fonction mathématique, appelée fonction de classification, à partir d'un ensemble d'exemples. Une fois appris, l'algorithme peut être utilisé, en mode

classification, de manière à affecter automatiquement les classes à des données nouvelles, non utilisées pour l'apprentissage.

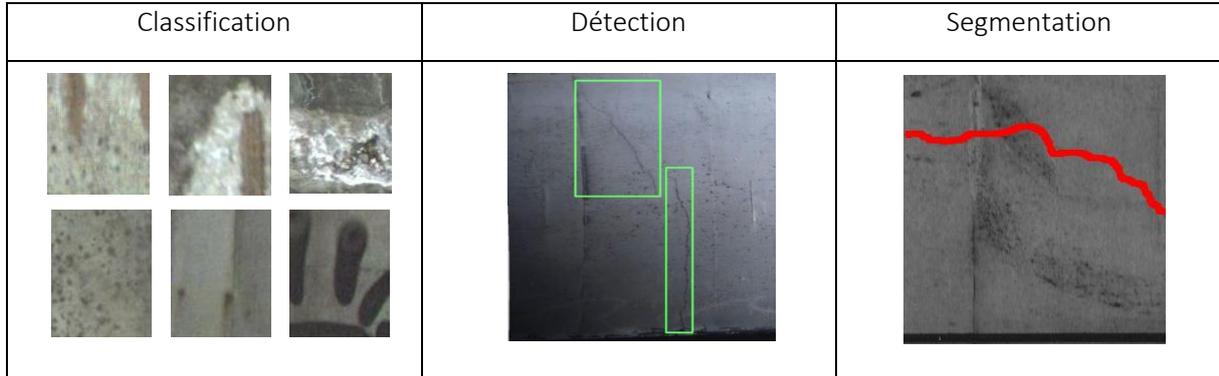


Figure 4 : Application de méthodes de reconnaissance de formes sur des images de parois d'ouvrages. Colonne de gauche : classification d'images en catégories : désordres (en haut) et saines (en bas) ; Colonne du milieu : détection de fissures ; Colonne de droite : segmentation d'images.

L'apprentissage est dit « supervisé », lorsque les exemples utilisés pour cette phase sont de classes connues et ont été préalablement annotés. Ces échantillons labellisés manuellement forment la vérité-terrain. A partir de ces exemples, l'objectif de l'apprentissage est de minimiser l'écart (selon un critère préalablement défini) existant entre la classe résultante de la fonction classifiante et la classe réelle indiquée par la vérité-terrain. Cette minimisation se fait de manière itérative en ajustant pas à pas les paramètres internes de la fonction de classification. L'apprentissage est terminé lorsque le critère n'évolue qu'à la marge ou que le nombre d'itérations fixé initialement est atteint. Avant d'être envoyées en entrée de la fonction de classification, les données sont représentées selon un vecteur de caractéristiques adaptées à l'algorithme. Ces caractéristiques sont soit générées selon des connaissances expertes et en fonction du problème à résoudre, soit directement apprises à partir de l'ensemble d'exemples pré-cité. Cette seconde possibilité correspond aux approches par apprentissage profond (*deep learning*) qui ont connu un essor considérable ces dernières années et donnent d'excellentes performances dans de nombreux domaines d'application. Ces méthodes d'apprentissage seront utilisées dans la suite de ce rapport.

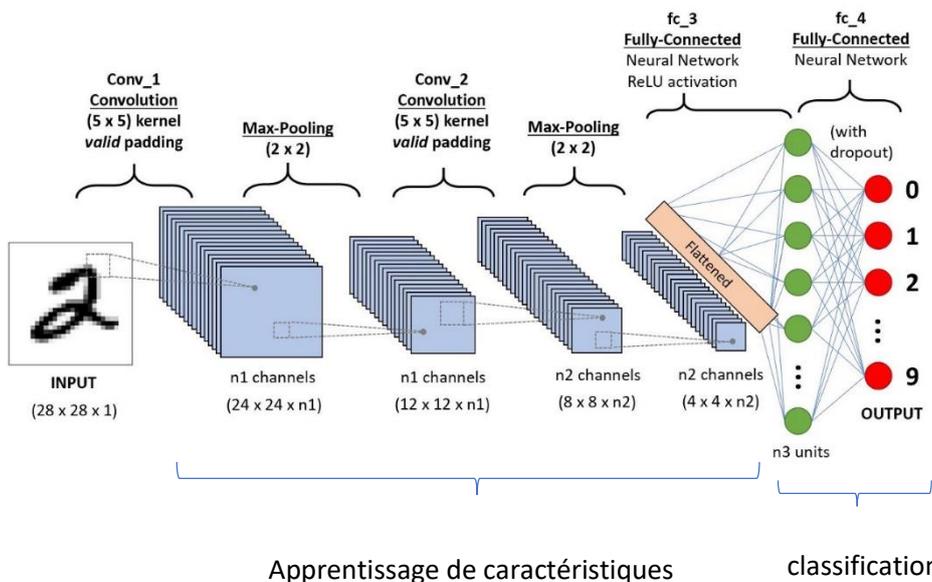


Figure 5 : schéma général d'une architecture d'apprentissage profond dédiée à la classification de chiffres manuscrits.

La structure générale d'une architecture d'apprentissage profond est illustrée sur la Figure 5 dans laquelle l'image est entrée directement dans un algorithme. Celui-ci est constitué de deux parties. La première, composée d'un ensemble d'opérateurs mathématiques : filtres de convolution, redimensionnement de l'image (*pooling*) entre autres, permet d'extraire les caractéristiques utilisées par la suite. La deuxième partie est dédiée à la tâche à accomplir, dans ce cas-ci, il s'agit d'une classification de chiffres manuscrits dans une des 10 catégories de chiffres possibles. L'efficacité de ces techniques va dépendre du nombre et de la représentativité des échantillons pour l'apprentissage, des éléments que l'on souhaite reconnaître et de la complexité des images.

La taille de la base d'apprentissage est un critère important pour obtenir de bonnes performances de classification et les méthodes d'apprentissage profond sont particulièrement gourmandes en nombre d'échantillons pour apprendre. Collecter des données représentatives n'est pas une tâche aisée, d'autant plus lorsque les éléments à classer sont par nature rares. De plus, annoter celles-ci, surtout au pixel près dans le cas de la segmentation, prend parfois beaucoup de temps. Des techniques d'augmentation artificielle de données, à partir de transformations géométriques et/ou photométriques des données réelles sont en général mises en œuvre pour l'apprentissage.

Lorsque l'apprentissage est terminé, l'algorithme est testé sur une base de données non utilisée pour l'apprentissage. Cette étape permet de mesurer les performances de l'algorithme sur des images nouvelles et d'évaluer ainsi sa capacité de généralisation.

### 3.2.2 Architecture de classification avec données multi-modales

Dans ce projet, nous voulons évaluer la faisabilité et l'intérêt d'une approche d'intelligence artificielle, axée sur la classification d'images et combinant images visibles et radar. Pour réaliser cela, nous nous appuyons sur le type d'architecture de classification présentée à la Figure 5 à la différence que l'apprentissage des caractéristiques est réalisée pour chaque modalité (image visible ou radar) parallèlement selon deux branches, comme le montre la Figure 6. Les caractéristiques extraites de chaque type d'images sont fusionnées (concaténation) de manière à former un vecteur de caractéristiques unique, présenté à l'algorithme de classification.

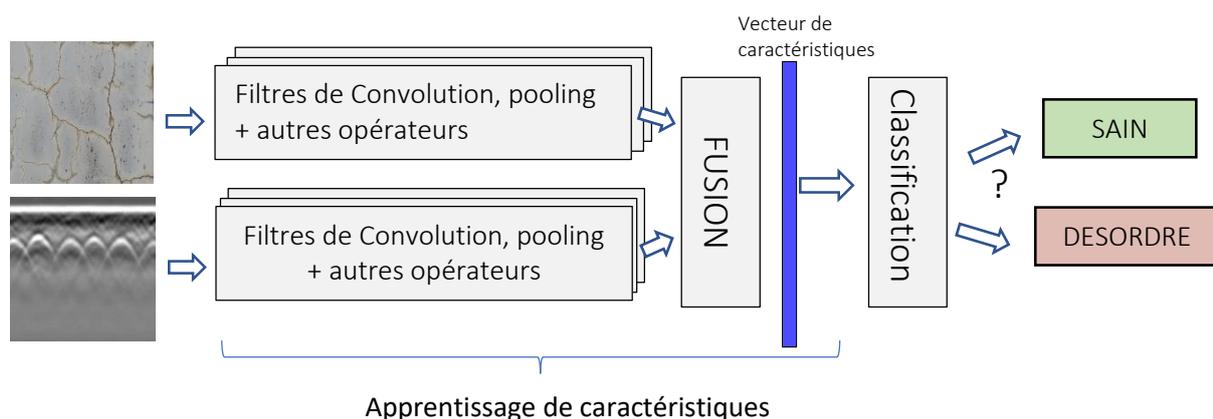


Figure 6 : architecture en apprentissage profond pour la classification de données multi-modales

Cet algorithme est détaillé dans [4]. Notons que dans l'approche que nous avons retenue l'algorithme de classification choisi est un perceptron multicouches

### 3.2.3 Segmentation d'hyperboles

La segmentation, telle qu'elle est définie dans la section 3.2.1, permet de donner automatiquement un label à chaque pixel de l'image. Dans le cas des images GPR, il s'agit de segmenter les hyperboles qui correspondent aux armatures du béton. Deux approches de segmentation sont possibles (Figure 7) :

- La segmentation sémantique est la méthode basique. Tous les pixels appartenant aux hyperboles doivent être identifiés mais il n'y a pas de distinction entre les hyperboles (Figure 7-milieu). Lorsque les éléments segmentés sont disjoints, cela ne pose pas de difficulté puisqu'on peut isoler aisément chaque composante connexe. En revanche, lorsqu'on observe une connexité entre hyperboles, il est plus complexe de distinguer les éléments connexes.
- La segmentation d'instances permet de répondre à cette difficulté en proposant une segmentation de chaque occurrence de l'hyperbole (voir Figure 7-droite). Cette deuxième approche de segmentation est mise en œuvre dans ce projet.

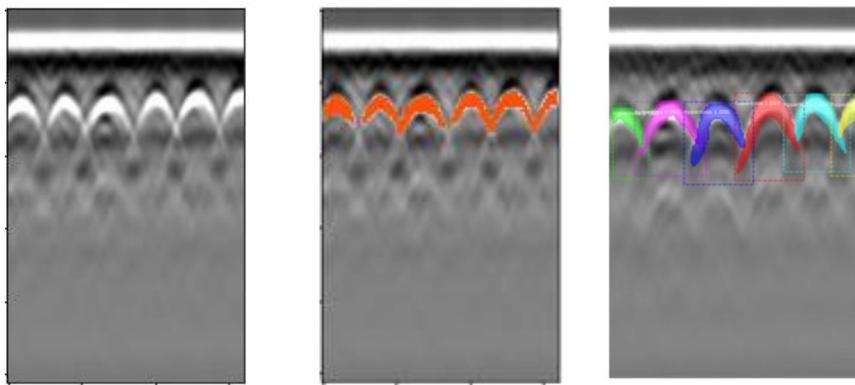


Figure 7: à gauche Image Bscan d'une structure en béton ; au milieu segmentation sémantique des hyperboles de l'image (pixels en rouge) ; segmentation d'instances des hyperboles de l'image (pixels colorés)

L'algorithme Mask R-CNN [5] est une architecture d'apprentissage profond dédiée à la segmentation d'instances. Le principe de cet algorithme se calque, dans la première partie, sur les architectures de détection d'objets, dits Réseaux à Proposition de Régions (RPN<sup>1</sup>) dont le but est d'abord de trouver et localiser (sous forme d'une boîte englobante) des éléments dans l'image, puis d'identifier la classe de l'objet. Dans ces familles d'algorithmes RPN, on extrait dans un premier temps les caractéristiques en utilisant un ensemble de filtres de convolution et d'opérateurs de *pooling* de la même manière que ce qui est présenté à la Figure 5. Les propositions de régions sont des boîtes rectangulaires de taille et de rapport longueur/largeur variables (9 configurations en tout). Celles-ci sont appliquées de manière glissante à chaque pixel de la carte de caractéristiques ce qui permet de calculer la probabilité que cette région soit une région d'intérêt. On ne retient que les régions dont la probabilité de contenir, dans notre cas une hyperbole, est supérieure à un seuil. Notons qu'une phase d'ajustement des coordonnées de la proposition de région est également prévue dans l'algorithme de manière à obtenir une boîte englobante qui détoure au plus près l'objet d'intérêt. Grâce à cette approche, on peut ainsi extraire la boîte englobante entourant l'objet d'intérêt. Cela se matérialise dans la Figure 7-droite par des rectangles colorés avec la bordure en pointillés. L'architecture Mask-R-CNN ajoute une étape supplémentaire puisque pour chaque boîte englobante détectée, elle calcule le masque de l'objet d'intérêt au pixel près, ce qui permet d'aboutir à la segmentation d'instances.

A partir des hyperboles détectées au pixel près, plusieurs indicateurs physiques peuvent être envisagés :

<sup>1</sup> Region Proposal Network

- **La densité d'armatures.** L'insuffisance en ferrailage peut être une des causes mécaniques à l'origine de l'apparition des fissures. En segmentant chaque instance d'hyperboles dans l'image radar, on peut mesurer l'écartement en pixels entre deux armatures au niveau du sommet de leurs hyperboles. Connaissant la résolution de l'image et la longueur (en m) de déplacement du capteur à la surface lors de la mesure, on peut en déduire l'écartement (en m) entre armatures.
- La **profondeur des armatures** peut également être calculée. Pour cela, il faut définir le niveau de la surface et convertir le temps donné par la hauteur de l'image en profondeur. Cette valeur est dépendante des paramètres du capteur. Cet indicateur n'a pour le moment pas été mesuré dans le projet.
- La **teneur en eau du béton** est une information qui intéresse fortement les inspecteurs. Au niveau de l'image Radar, une forte teneur en eau peut se traduire par une atténuation du signal mais ce n'est pas le seul paramètre en jeu. En observant les hyperboles, on peut visualiser les différences d'amplitude d'une image Bscan (voir Figure 8) avec une atténuation faible sur l'image de gauche (amplitude du signal des hyperboles élevée) et au contraire une atténuation forte sur l'image de droite. Il n'y a cependant pas de liens simples entre une atténuation et teneur en eau. D'autres critères doivent être prises en compte, profondeur de l'armature, composition chimique du matériau et notamment la teneur en chlorure. Dans ce projet, nous avons proposé une mesure de contraste (voir [4]) mais nous n'avons pas exploré la manière de faire automatiquement le lien avec la teneur en eau. Nous ne présenterons donc pas de résultat sur ce point précis.

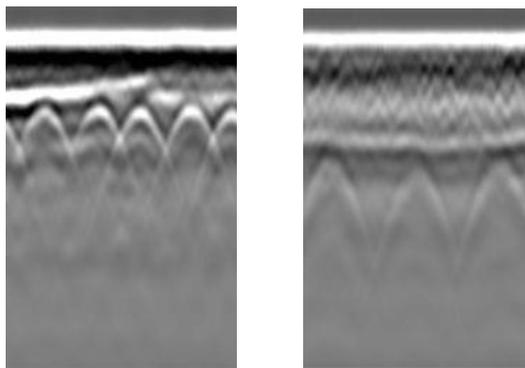


Figure 8 : observations des différences d'amplitude des hyperboles sur les images Bscans gauche et droite.

### 3.3 Bases de données

Pour apprendre et évaluer les différents modèles (classification ou segmentation d'instances) et leurs évaluations, nous devons disposer de bases constituées d'images visibles et radar.

#### 3.3.1 Bases existantes

Il existe des bases d'images de parois de ponts en béton mises à disposition par la communauté internationale à des fins de recherche mais aucune d'entre-elles n'associe images visibles de la surface et images GPR de la structure interne. La base CODEBRIM [6], en particulier, est constituée de plus de 4000 images de la surface de parois de ponts, prises à différentes échelles, avec fissures. Nous n'avons trouvé qu'une seule base d'images GPR sur des structures en béton [7] contenant plus de 8000 radargrammes. Notons que chaque image Bscan de la base ne contient qu'une unique hyperbole, ce qui reste assez éloigné de nos besoins. Dans le projet ADOUCIR, ces deux bases ont permis de réaliser les tests d'implémentation des méthodes utilisées. Cependant, elles ne sont pas du tout utilisées ni pour

l'apprentissage en lui-même des différents modèles ni pour l'évaluation des performances sur une base de tests dédié.

### 3.3.2 Images simulées

La simulation de données est une seconde possibilité pour générer des bases d'images. A notre connaissance, il n'existe pas d'outils informatiques permettant de simuler à la fois des images de surface et des images de sub-surface. Nous pouvons cependant utiliser GprMax, logiciel open source, conçu entre autres pour modéliser des profils radar géophysiques et des images Bscans correspondantes. L'avantage d'une construction de la base de données par simulation est la maîtrise totale des paramètres du modèle de structure. Parmi ces paramètres, on peut modéliser la présence d'armatures avec un écartement, une profondeur pré-établie, modéliser un béton selon la taille et la densité de granulats, faire varier la teneur en eau, introduire des désordres... L'inconvénient des méthodes simulées est qu'il s'agit de modèles simplifiés qui ne reflètent pas totalement la réalité. On considère ainsi par exemple que les milieux sont homogènes et qu'il n'y a aucun bruit de mesures, ce qui reste éloigné des structures et des conditions d'acquisition sur ouvrages. Les détails techniques sur la simulation d'images GPR au moyen du logiciel GPRmax sont donnés dans [8],[9].

Tableau 1 : Paramètres des différentes modélisations.  $\epsilon_r$  indique la permittivité du milieu, critère dépendant de la teneur en eau.

Fréquence (Ghz)	$\epsilon_r$ ( $F/m$ )	Espacement entre armatures (cm)	Profondeur des armatures (cm)
2.6	5	15	3
			7
		30	3
			7
	12	15	3
			7
		30	3
			7
1.5	5	15	3
			7
		30	3
			7
	12	15	3
			7
		30	3
			7

Pour répondre à l'objectif de classification d'images en deux catégories, les images simulées ne peuvent être considérées puisqu'il n'y a aucune image visible associée. En revanche, nous avons introduit les données simulées dans les modèles d'apprentissage dédiés à la segmentation d'instances d'hyperboles. Les différents paramètres utilisés pour la modélisations d'images GPR sont recensés dans le Tableau 1. Notons que nous avons introduit des petites variations autour de la valeur indiquée de chaque paramètre permettant de créer plusieurs occurrences possibles pour une configuration indiquée. Au total, 55 images simulées sont incluses dans la base d'apprentissage pour la segmentation d'instances.

### 3.3.3 Campagnes d'acquisition

Pour construire une base de couples d'images visibles et radar sur des ouvrages en béton, nous avons mené deux campagnes expérimentales d'acquisition en juillet 2021. Deux structures en béton ont été identifiées :

- La première série d'acquisitions a été effectuée sur deux poutres en béton renforcé par des armatures métalliques et utilisées pour des essais à l'université Gustave Eiffel, site de Nantes. L'une des deux poutres présente de fortes dégradations et notamment de la fissuration. L'autre est considérée comme saine.
- La deuxième série d'acquisitions a eu lieu sur les piliers d'un pont en service à Nantes. Cet ouvrage, datant d'une trentaine d'années, présente quelques dégradations sur certains piliers, dues la plupart du temps au vieillissement et, selon l'orientation des faces des piles, à l'ensoleillement et aux intempéries.

Le capteur GPR utilisé pour les expérimentations est un radar portable GSII (voir Figure 9) dont la fréquence d'acquisition est fixée à 2.6 Ghz. Cette fréquence est la même que celle choisie pour la moitié des modèles GPR simulés (voir section 3.3.2).



Figure 9 : radar portable utilisé pour l'acquisition des données GPR sur les poutres et le pont.

Les images GPR se présentent selon une vue orthogonale à la surface, comme on peut le voir sur la Figure 10. Le protocole d'acquisition est le même pour les deux structures. On matérialise (à la craie) la zone d'acquisition par un carré de  $80 \times 80 \text{ cm}$ . Sur cette zone, deux images visibles à haute résolution (en général  $3000 \times 4000$  pixels) sont acquises, la première face à la paroi (Figure 11, en haut à gauche) et la seconde en visée oblique (voir Figure 11, en bas à droite). Notons que les dimensions ne sont pas tout à fait équivalentes selon les campagnes car obtenues avec des smartphones différents. Cela n'a pas d'importance car les images sont « découpées » au plus près de la zone d'intérêt avant d'être traitées par l'algorithme (voir section 5.1).

Sur cette même zone, on effectue le relevé de deux profils GPR localisés au milieu de chaque côté du carré définissant la zone (voir les flèches bleues sur la Figure 11, en haut à gauche) avec un relevé dans le sens horizontal de la surface (Figure 11, en haut à droite) et l'autre dans le sens vertical (Figure 11, en bas à gauche)... Notons que les mesures Radar sont effectuées au pas de 1 acquisition tous les 50 cm, c'est-à-dire une émission-réception d'un signal par 0.5 m. Pour une longueur de 80 cm, nous avons 160 acquisitions. Le résultat est une image GPR (horizontal ou vertical) de 160 pixels de large. La hauteur de l'image est de 256 pixels.

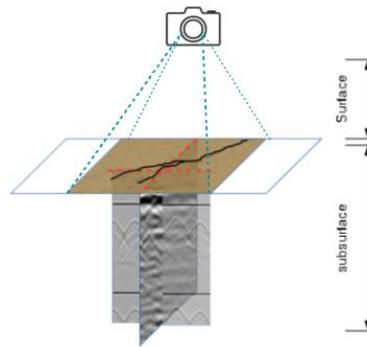


Figure 10 Schéma d'acquisition des données images et GPR

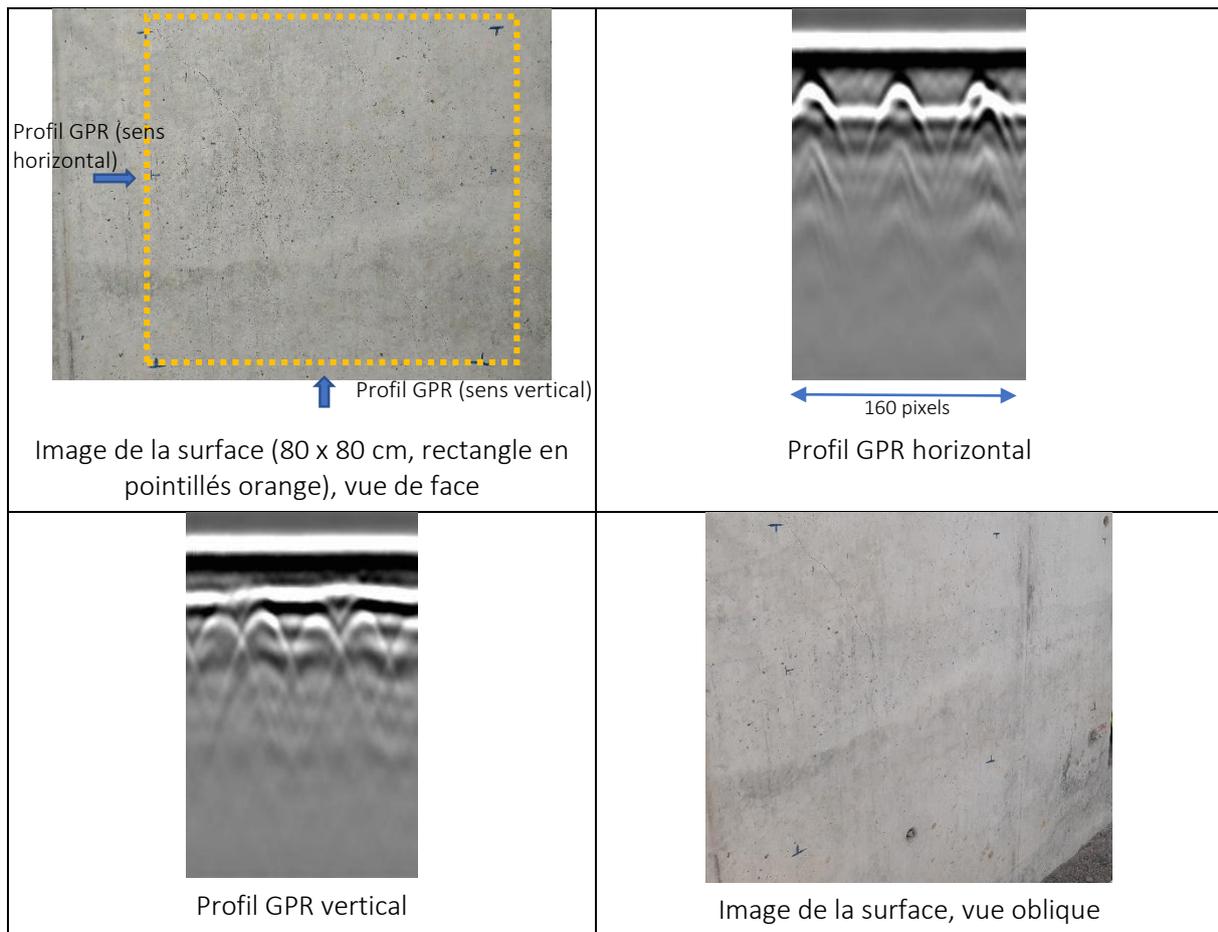


Figure 11 : Exemples des 2 images visibles et 2 images GPR acquises sur la même zone de 80 x 80 cm

A chaque zone de l'ouvrage, on associe donc 4 images. Avec l'aide d'un spécialiste des ouvrages d'art du Cerema, nous avons visuellement classé ces zones en deux catégories : zone saine ou zone avec fissure. Les 4 images de la même zone ont obligatoirement le même label. Au total, 88 zones ont été identifiées permettant d'acquérir 176 images visibles (vues de face ou oblique) et 176 images GPR (profils horizontal ou vertical). 33 zones sont considérées comme saines et 55 comme présentant un désordre. En entrée de l'architecture, nous présentons un couple constitué d'une image visible et d'une image GPR. Il est possible de croiser les couples au sein d'une même zone, par exemple l'image visible de face avec l'image GPR horizontale ou l'image visible de face avec l'image GPR verticale. Ainsi, nous avons à disposition 352 couples d'images visibles et GPR réelles pour effectuer l'apprentissage et les tests de classification.

#### 4 Utilisation de l'aide de la Ferec dans le projet

L'aide allouée par la fondation FEREC pour le projet ADOUCIR a été utilisée pour trois actions :

- la gratification des stagiaires qui ont participé au projet (voir Tableau 2).
- L'achat de deux stations de calcul DELL avec 2 cartes graphiques Nvidia GeForce RT 2080 TI. Ces machines sont nécessaires pour effectuer les apprentissages et les tests en intelligence artificielle par station. Elles permettent également d'accélérer les calculs de simulation avec le logiciel GPR. Elles ont été livrées au Cerema fin mai 2021.
- Les frais de mission (déplacements Strasbourg-Nantes et Rouen-Nantes) pour la campagne d'acquisition de données

Le récapitulatif de ces frais est donné dans le Tableau 3.

Tableau 2 : Tableau récapitulatif des stagiaires pour le projet ADOUCIR

Stagiaire (Master 2)	Durée	Sujet de stage	Lieu
Amine Mansouri (Université de Bourgogne)	6 mois	ADOUCIR : Développement et évaluation méthodes de reconnaissances de formes. (voir rapport [4]).	Cerema ENDSUM Strasbourg
Camille Lanéelle (Sciences Sorbonne Université)	5 mois	ADOUCIR : Développement et évaluation méthodes de reconnaissances de formes. (voir rapport[8]).	Cerema ENDSUM Rouen
Nasr Chami (Insa Rennes)*	4 mois	ADOUCIR : Construction d'une base de données d'images et radar pour l'aide à l'inspection d'ouvrages d'art par méthodes d'apprentissage supervisé (voir rapport [9]).	Université Gustave Eiffel, laboratoire GeoEnd, Nantes

\* Pour des raisons administratives, le stage de Nasr Chami n'a pas été comptabilisé dans ce projet bien que son sujet soit partie prenante du projet

Tableau 3 : récapitulatif des coûts du projet ADOUCIR

Objets	Quantité	Prix unitaire (€)	Prix (€)
Stagiaires	11 mois	580 € / mois	6380
Stations de calcul	2	5500 €	11000
Frais de mission			800
<b>TOTAL</b>			<b>18180</b>

Une publication en revue *open access*, par exemple *remote sensing* édité par MDPI, est envisageable. Ces publications suivent le processus classique de *reviews* par les pairs de la soumission. En cas d'acceptation, le modèle économique impose un coût de parution à la charge des auteurs compris entre 1500 et 2000 euros en général.

## 5 Résultats acquis

L'ensemble des implémentations ont été réalisées avec le langage de développement Python et les bibliothèques informatique dynamiques tensorflow et keras<sup>2</sup>.

### 5.1 Classification en catégories « saines » ou « avec fissures »

Les techniques de *deep learning* nécessitent en général une base composée de plusieurs milliers d'images pour apprendre, ce qui est loin d'être le cas dans notre situation puisque nous avons uniquement 176 images visibles et GPR. Néanmoins, comme il est désormais d'usage avec les réseaux convolutionnels, il est possible de réaliser l'apprentissage à partir de modèles pré-appris sur des bases génériques. Ce processus permet de partir d'un état initial des paramètres internes du modèle moins aléatoire. L'apprentissage est complété et finalisé en utilisant les données propres à l'application mais en moins grand nombre. La limite de cette approche est que nous devons utiliser une architecture déjà existante. Nous avons opté pour cette solution de pré-apprentissage et nous avons choisi l'architecture Inception-v3 [10] qui comprend plus de deux cent suites d'opérateurs (filtres convolutionnels, pooling et autres fonctions).

Dans cette architecture, les images en entrée sont de taille 512 x 512 pixels. Nous devons donc redimensionner les images à la taille définie. Pour les images radar, initialement de taille 160 x 256 pixels, le redimensionnement est tel quel sans conversion des proportions. Les images visibles sont de taille initiale 3000 X 4000 pixels pour la plupart d'entre elles. Pour éviter un sous-échantillonnage trop important, nous avons préféré extraire la partie centrale et redimensionner celle-ci à la taille voulue comme montré sur la Figure 12.

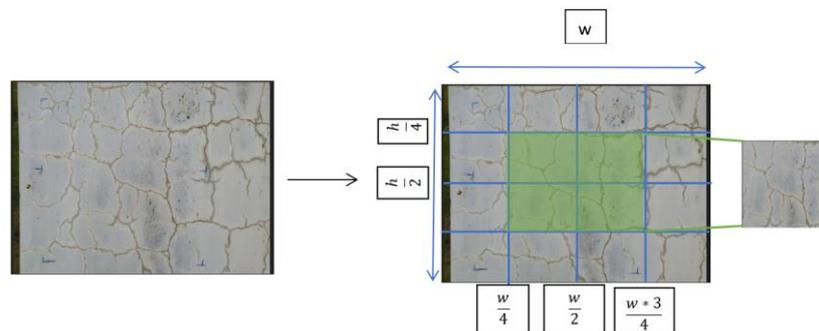


Figure 12 : Sélection de la partie centrale (en vert) de l'image visible et redimensionnement en 512 x 512 pixels de celle-ci.

Nous avons divisé la base de 352 couples d'images (visibles et GPR) en deux sous-bases. La première, constituée de 302 couples, est dédiée à l'apprentissage. Notons que dans cette base, il y a plus de zones avec fissures que de zones saines. Les 50 couples restants seront utilisés pour le test final. Notons que dans la base de test, 25 couples appartiennent à la classe « saine » et 25 sont dans la classe « avec fissures ». Pour la phase d'apprentissage d'un réseau de neurones, une « époque » correspond à une itération du jeu complet de données dans l'architecture. Dans cette application, nous avons fait un apprentissage avec 100 époques. Le dernier modèle est retenu pour réaliser les tests. A chaque itération, des techniques dites d'augmentation de données sont appliquées de manière à accroître la variabilité des images en apprentissage. Ces méthodes consistent à appliquer des filtres géométriques (effet miroir, rotation, zoom) ou photométriques (variations d'intensité) sur les données. Ces variations doivent bien entendu rester crédibles par rapport à la réalité. L'effet de rotation sur les hyperboles par exemple doit être limité de manière à ce que les hyperboles restent globalement orientées verticalement.

<sup>2</sup> <https://www.tensorflow.org/learn?hl=fr>

Pour analyser l'intérêt de la combinaison images visibles et GPR pour la classification, nous avons également réalisé deux autres apprentissages avec une seule modalité d'images, soit les images visibles, soit les images GPR. La base de test est constituée des 50 mêmes zones que précédemment.

Les résultats sont montrés sur le Tableau 4. On observe que, sur la base de test, les performances en classification sont meilleures avec un couplage d'images radar et visibles (47 bonnes détections sur les 50 images), comparées à la classification basée sur une seule modalité : 25 bonnes détections avec les images radar seules et 38 avec les images visibles seules. Il faut noter que, pour le modèle avec fusion de données, les 3 erreurs de classification sont toujours dans le même sens, à savoir que des images considérées comme saines dans la vérité-terrain ont été classées à tort dans la catégorie fissures. Le fait que l'apprentissage contienne plus d'images avec fissures que d'images saines pourrait être une explication à ce constat, mais cela doit être confirmée sur une base plus large. Pour le modèle utilisant des images visibles seules, on note que parmi les 12 mauvaises classifications, 7 images ont été identifiées à tort dans la catégorie fissures et 5 classées à tort dans la catégorie saine. Enfin, pour les images radar, les résultats sont au niveau du « hasard » avec 50% de bonnes classifications. Il apparaît que le modèle n'arrive pas à se déterminer uniquement à partir de cette modalité.

Cette première étude semble avoir montré l'intérêt d'une approche bimodale pour améliorer la classification. Il faut bien entendu rester prudent sur ces conclusions car la base de données reste relativement limitée en nombre et sans doute en représentativité des situations mais ces performances restent encourageantes et nous incitent à continuer dans cette voie.

Tableau 4 : résultats de classification en catégories saines ou fissures

	Mono-input (pas de fusion)		Dual-input (fusion)
	images GPR	Images visibles	Images GPR + visibles
Taux de bonnes détections	25/50	38/50	47/50

## 5.2 Extraction d'armatures

Pour réaliser la segmentation d'instances d'hyperboles, rappelons que l'architecture de réseau de neurones mask-R-CNN [5] a été choisie (voir section 3.2.3). Nous avons 176 images GPR à disposition auxquelles nous pouvons ajouter 55 images GPR simulées, soit 231 images au total. Parmi ces données 194 images Bscans sont sélectionnées aléatoirement pour l'apprentissage, et les 37 restantes constitueront la base de test. Contrairement à l'expérimentation en classification (Section 5.1), les images n'ont pas besoin d'être redimensionnées.

Nous avons fait le choix de repartir partiellement d'un modèle pré-appris. En effet, ce pré-apprentissage concerne uniquement la première partie du réseau mask-r-cnn pour l'obtention de la carte de caractéristiques. A partir de cet état pré-appris, les 231 images sont appliquées au réseau pour générer le modèle final au bout de 500 époques.

Les 37 images GPR de la base de test contiennent en tout 159 hyperboles (nombre d'hyperboles de la vérité-terrain). Nous définissons les critères d'évaluation suivants :

- VP (Vrais Positifs) le nombre d'hyperboles correctement détectées par l'algorithme parmi toutes celles à détecter
- FP (Faux Positifs) le nombre d'hyperboles détectées à tort par l'algorithme
- FN (Faux Négatifs) le nombre d'hyperboles de la vérité-terrain oubliées par l'algorithme

Pour analyser les performances, on considère qu'une hyperbole est détectée si au moins 50% des pixels considérées comme appartenant à l'hyperbole dans la vérité-terrain ont été segmentés comme

hyperboles. Pour les faux positifs, on considère le nombre de régions détectées en surplus. Les résultats sont donnés dans le Tableau 5. On remarque que 88.6% (141/159) des hyperboles ont été détectées. Les oublis sont principalement dus à des chevauchements importants dans les armatures, à des hyperboles situées en bordure d'images ou à une forte atténuation du signal. On observe également une seule fausse alarme, qui est en réalité une même hyperbole doublement détectée.

Tableau 5 : Résultats de la détection d'hyperboles

	Résultats
VP	141
FP	1
FN	18

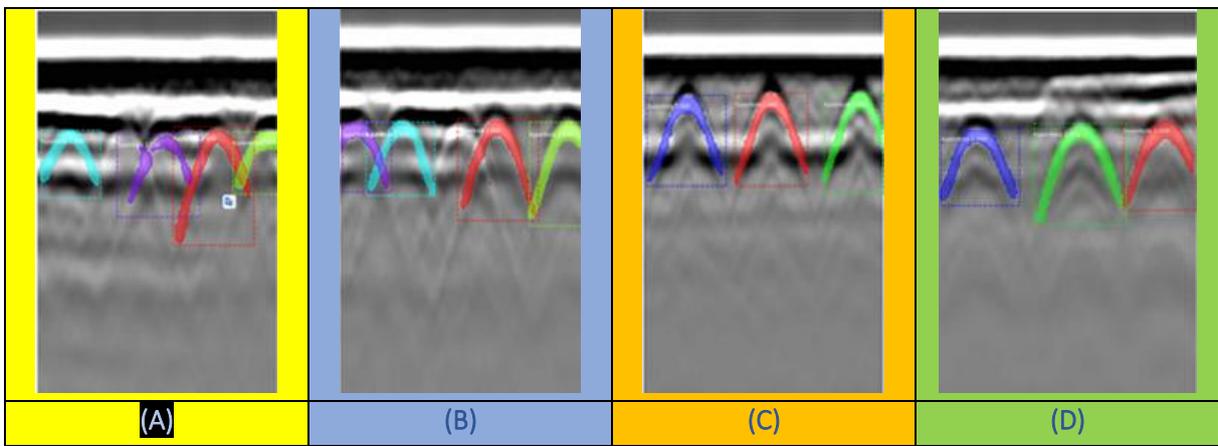


Figure 13: Exemples de détection d'hyperboles sur un pilier de pont. Les hyperboles en couleurs sont les instances détectées. Les images A, B et D sont des profils horizontaux et l'image C est un profil vertical. Le code couleur de chaque image renvoie à la localisation des données sur le plan de ferrailage de la Figure 14.

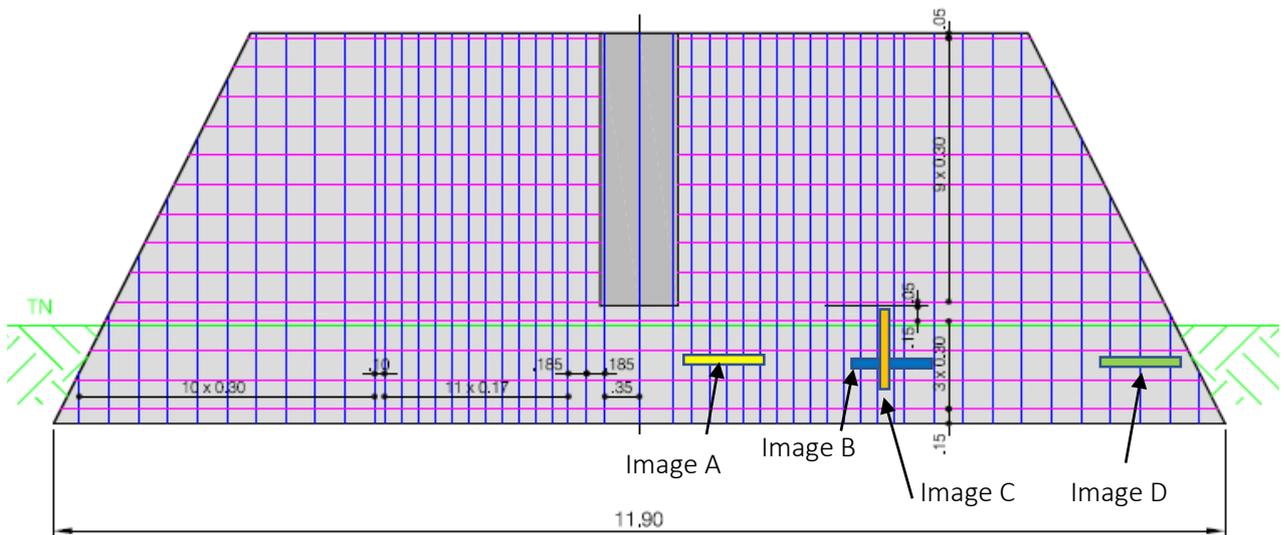


Figure 14 Plan de ferrailage de l'ouvrage étudié (Les rectangles colorés correspondent aux zones d'acquisition des images GPR montrées sur la Figure 13).

La Figure 13 illustre des exemples de détection sur un pilier de pont. On observe sur ces quatre images que l'écartement entre armatures est différent selon les zones. Celui-ci est plus petit sur les images A et B et plus important C et D. On observe également des différences sur la profondeur apparente des

armatures entre les profils verticaux (image C) et horizontaux (A, B et D). On a positionné de manière approximative ses 4 images GPR selon le plan de ferrailage donné par la Figure 14. Visuellement on observe que les hyperboles observées sur l'image GPR sont en cohérence avec le plan de ferrailage avec un maillage plus fin à gauche (au centre de la pile) qu'à droite. Le profil vertical (image C) donne également un écartement d'hyperboles pertinent par rapport au plan de ferrailage. A partir des résultats de segmentation, on a estimé l'écartement entre armatures sachant que le profil de 160 pixels mesure 80 cm. Pour cela, on mesure l'écart en pixels entre chaque sommet de l'hyperbole détectée et on convertit cette distance en cm. Dans le Tableau 6, les mesures d'écartement entre hyperboles détectées sont comparées à la réalité donnée par le plan de ferrailage (Figure 14). On voit que si les mesures ne sont pas très précises, elles restent cohérentes avec les données terrain. Les différences sont dues à de multiples facteurs : acquisition, segmentation...

Avec ce type d'images et leur traitement automatique, il est possible d'estimer (sans être dans la précision) les distances entre armatures. Cela peut être intéressant pour les nombreux ouvrages anciens qui ne sont pas totalement documentés sur cet aspect.

Tableau 6 : écartement en pixels et cm entre hyperboles des images A, B, C et D de la Figure 13 et comparaison avec le plan de ferrailage de la Figure 14.. Les valeurs entre parenthèses de la deuxième colonne correspondent à des écartements entre deux hyperboles dont l'une au moins est non détectée.

Image	Ecartement entre hyperboles considérées de gauche à droite.	Réalité (plan de ferrailage)
A	(36 pixels → 18 cm)	17 cm
	(32 pixels → 18 cm)	17 cm
	34 pixels → 17 cm	17 cm
	34 pixels → 17 cm	17 cm
B	30 pixels → 15 cm	17 cm
	(28 pixels → 14 cm)	17 cm ?
	(23 pixels → 11.5 cm)	?
	51 pixels → 25.5 cm	30 cm
C	56 pixels → 28 cm	30 cm
	59 pixels → 29.5 cm	30 cm
D	56 pixels → 28 cm	30 cm
	65 pixels → 32.5 cm	30 cm

## 6 Impact

### 6.1 Apports et retombées pour la collectivité

Dans ce projet, les possibilités offertes par l'intelligence artificielle utilisant des données multi-modales en lien avec les besoins métier pour l'inspection d'ouvrages ont été définies en concertation avec les spécialistes en ouvrages d'art du Cerema. D'une manière générale, ces derniers voient tout l'intérêt d'une aide technique automatisée pour permettre à l'expert de se focaliser sur des zones d'intérêt et/ou apporter une confirmation ou infirmation à l'expertise humaine. Outre son utilisation pour la classification de zones présentant des fissures, l'association d'images GPR et visibles présente également un intérêt pour analyser des zones de gonflement ou fissuration mécanique anormale. Dans ce cas, l'ajout de l'imagerie Infrarouge pourrait être un plus. Cette association de données permet également de mieux documenter les ponts, notamment les plus anciens dont les dossiers d'ouvrage ne sont pas toujours complets. Pour ces ouvrages peu documentés, la fusion d'images GPR et visibles peut s'avérer utile pour classer les structures en béton précontraint/ béton armé, lorsque la catégorie de pont n'apparaît pas clairement. L'apport de l'intelligence artificielle concerne également l'analyse des images GPR seules, notamment celles pour lesquelles la classification a identifié une zone avec désordres. La possibilité de détecter au pixel près les hyperboles peut ouvrir la voie à une explication sur les causes d'apparition des fissures.

Pour ces raisons, il nous semble que le développement d'outils d'intelligence artificielle dédiés à l'analyse des ouvrages en béton, représente donc un apport pour les professionnels. Les retombées de ces approches ne se limitent pas à au domaine des ouvrages d'art mais peuvent être étendues aux autres structures de génie civil en béton ou autres matériaux. L'apport des méthodes proposées sera d'autant meilleur que la mise au point des modèles d'intelligence artificielle sera réalisée en lien avec les problématiques du métier.

### 6.2 Mise en évidence du caractère collaboratif et d'intérêt général

Les équipes ENDSUM du Cerema et GeoEND de l'université Gustave Eiffel ont travaillé en collaboration étroite sur le sujet. Les chercheurs du Cerema ont notamment apporté leurs expériences dans le domaine de l'intelligence artificielle et l'expertise en recherche sur les images GPR pour la simulation et les expérimentations ont été apportées conjointement par les deux partenaires. Le caractère collaboratif a été étendue aux experts métier, qui en nous présentant leurs connaissances, leur méthodologies d'inspection nous ont permis de cibler les besoins pour lesquelles l'intelligence artificielle pouvait apporter une réponse. Cette collaboration a également fortement aidé pour l'établissement de la base d'images annotées. Ce travail entre chercheurs et spécialistes métier va se poursuivre puisque de nouvelles campagnes d'acquisitions de données sont prévues en 2022 sur des ouvrages en béton. Nous gardons à l'esprit l'objectif de proposer des solutions innovantes basées sur l'intelligence artificielle qui répondent aux besoins des experts du domaine. Nous souhaitons également étendre les collaborations à des partenaires extérieurs selon un cadre à définir.

Ce genre d'approches est également applicable à d'autres désordres, d'autres infrastructures telles que les tunnels, routes, digues, barrages... Quelle que soit l'application, la démarche couplant des images de différentes origines peut être étendue à d'autres sources de données (infrarouge, lidar, sonar, potentiel électrique...) et donc d'autres applications et collaborations potentielles.

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

A la date du rendu du rapport, nous n'avons pas fait de communications ciblées dans des revues professionnelles ou académiques. Au même titre que les autres projets lauréats du FEREC 2020, la revue Travaux a cité le projet ADOUCIR dans son numéro 970 (Juillet/aout 2021, page 9). Nous nous sommes également appuyés sur les résultats de ce projet pour vulgariser la notion d'intelligence artificielle pour des applications en génie civil dans le cadre d'une animation proposée par le Cerema Strasbourg pour la fête de Science (6 octobre 2021<sup>3</sup>).

En terme de publications académiques, la valorisation de la base d'images annotée est envisagée sous forme de *Data Paper*. La mise à disposition de la base, complémentaire au *data paper*, peut intéresser à la fois la communauté scientifique du domaine de l'intelligence artificielle et celle du domaine de l'ouvrage. D'une manière générale, les chercheurs en intelligence artificielle sont demandeurs de ce genre de bases de données dont l'annotation représente un travail conséquent. Sur les résultats obtenus en intelligence artificielle, on travaille à la publication académique d'au moins un article dans une revue scientifique, par exemple ND T & E<sup>4</sup> ou MDPI remote sensing<sup>5</sup>.

---

<sup>3</sup> Article de presse, Dernières Nouvelles d'Alsace (DNA) du 7 octobre 2021, page 34

<sup>4</sup> <https://www.journals.elsevier.com/ndt-and-e-international>

<sup>5</sup> <https://www.mdpi.com/journal/remotesensing/about>

## 7 Conclusion et Perspectives ouvertes par le projet notamment en matière de recherche collaborative

Dans le projet ADOUCIR, le premier objectif était de montrer la faisabilité d'une approche de reconnaissance de formes combinant images de surface et images de sub-surface acquises par capteur Radar (GPR) pour la classification de parois de ponts en béton en catégories saines ou non. L'approche que nous avons retenue est basée sur des architectures par apprentissage profond. Pour répondre à ces objectifs, nous avons mené une campagne expérimentale d'acquisition de données sur deux structures réelles : des poutres en béton et un pont en service. Les images collectées ont été annotées pour constituer la base d'images pour l'apprentissage et l'évaluation. Les résultats obtenus sur des données réelles ont montré l'intérêt de la prise en compte de données multimodales par rapport à des données monomodales pour effectuer cette tâche. Cette première évaluation est très encourageante mais il est nécessaire de confirmer ces premiers résultats à partir d'une base d'images plus conséquente et offrant des situations plus variées. Nous avons approfondi l'analyse en proposant une segmentation automatique des instances d'hyperboles visibles sur les radargrammes en vue d'extraire des indicateurs physiques sur l'ouvrage. La faisabilité d'une telle segmentation a été évaluée sur des données réelles et les résultats sont également très prometteurs. Cependant l'analyse des performances doit être étendue sur une base d'images et de situations plus large et les méthodes pour caractériser des propriétés physiques en s'appuyant sur les outils d'intelligence artificielle doivent être approfondies.

A court-terme, deux nouvelles expérimentations sont prévues pour enrichir la base d'images. Au-delà de l'aspect base de données, les perspectives ouvertes par le projet ADOUCIR sont de deux ordres.

- La première voie de travail d'ordre méthodologique, doit être explorée en lien avec le laboratoire ICube de l'université de Strasbourg. Une thèse est envisagée à partir de l'automne 2022 dans laquelle trois problématiques seront étudiées. Le premier objectif est d'approfondir les stratégies de pré-traitement et de fusion de données en intelligence artificielle. La seconde problématique concerne la caractérisation physique du matériau à partir d'intelligence artificielle. L'idée de mesurer un indicateur de teneur en eau à partir de l'atténuation observée sur les hyperboles présente un réel intérêt et pourrait permettre d'estimer ou de catégoriser la qualité du béton. Enfin un dernier objectif est d'évaluer les capacités de généralisation du modèle sur des images de différents ponts non utilisés pour l'apprentissage et proposer, le cas échéant, des outils adaptés pour que les performances du modèle appris restent de bon niveau quel que soit l'ouvrage inspecté.
- Un deuxième axe de recherche et d'innovation concerne l'acquisition d'images par drone sur des zones difficilement accessibles d'un ouvrage. La mise au point de plateforme accueillant capteur GPR et le capteur visible sur un drone doit être envisagé. Une première problématique de l'enregistrement de données par drone est d'utiliser les techniques de localisation et de plan de vol pour maîtriser l'acquisition le long de parois verticales pour les deux capteurs. Un second enjeu sera de maîtriser la compatibilité électromagnétique du système embarqué, le rayonnement des antennes utilisées, la profondeur d'investigation attendue dans le béton, ainsi que la résolution spatiale associée. La maîtrise de ces paramètres est d'autant plus complexe à résoudre que les contraintes aérologiques doivent être prises en compte pour le vol de drone. Sur ce second axe de travail, des réflexions sont menées avec une entreprise spécialisée dans l'acquisition par drone en milieu complexe et des pistes de collaboration ont été avancées.

## Références

- [1] Christian Koch, Kristina Georgieva, Varun Kasireddy, Burcu Akinci, and Paul Fieguth. A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure. *Advanced Engineering Informatics*, 29(2):196–210, 2015.
- [2] Zheng Tong, Jie Gao, and Dongdong Yuan. Advances of deep learning applications in ground-penetrating radar : A survey. *Construction and Building Materials*, 258 :120371, 2020.
- [3] Xavier Dérobert, *Techniques radars appliquées au génie civil*, collection Etudes et Recherche des laboratoires des Ponts et Chaussées, numéro 9, 2003, 109 pages.
- [4] Amine Mansouri, Rapport de stage Master 2 Traitement des signaux et des images, Université de Bourgogne, Dijon, 2021.
- [5] Kaiming He, Georgia Gkioxari, Piotr Dollar and Ross Girshick, Mask R-CNN, *Proceedings of the IEEE international conference on computer vision*, 2017, pp. 2961-2969.
- [6] Martin Mundt, Sagnik Majumder, Sreenivas Murali, Panagiotis Panetsos and Visvanthan Ramesh, Meta-learning convolutional neural architectures for multi-target concrete defect classification with the concrete defect bridge image dataset, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019, pp. 11196—11205.
- [7] Pouria Asadi, Mayrai Gindi, Marco Alvarez and Alireza Asadi, A computer vision based rebar detection chain for automatic processing of concrete bridge deck GPR data, *Automation in Construction*, vol.112, 2020, p. 103106.
- [8] Camille Lanéelle, Rapport de stage Master 2 Mécanique des sols, des roches et des ouvrages dans leur environnement, Sciences Sorbonne Université, Paris, 2021
- [9] Nasr Chami, Rapport de stage Master 2 recherche Mécanique et Génie Civil, INSA de Rennes, 2021.
- [10] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jon Shlens and Zbigniew Wojna, Rethinking the inception architecture for computer vision, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 2818-2826.