

الكشف الآلي عن الأجسام المطحورة اعتماداً على صور رادار اختراق سطح الأرض باستخدام الشبكات العصبية الالتفافية

هشام زيد نصر^{1*} نديم يوسف شاهين²

¹. طالب ماجستير في قسم هندسة الإلكترونيات والاتصالات - كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق. hisham.nasser@damascusuniversity.edu.sy

². أستاذ دكتور في قسم هندسة الإلكترونيات والاتصالات - كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق. nchahin@scs-net.org

الملخص:

رادار اختراق سطح الأرض (GPR) هو أحد التقانات التي أثبتت كفاءتها في كشف الأجسام المطحورة وذلك باستخدام الأمواج الكهرومغناطيسية. تعاني هذه التقانة من مشكلة تتمثل في أن التعرف بشكل دقيق على الأجسام المطحورة من خلال صور GPR يظل مهمة صعبة تعتمد بشكل كبير على خبرة مستثمر جهاز GPR، وبالتالي قد تكون نتائج تفسير الصور غير موثوقة، كما وتحتاج لعمل شاق ووقت طويل للتقسيير. يهدف البحث إلى مساعدة مستثمر جهاز GPR في التغلب على هذه المشكلة، وذلك عن طريق بناء نموذج شبكة عصبية تلقائية (CNN) Convolutional Neural Network يقوم بالكشف الآلي عن بصمة القطع الزائد المنعكسة عن الهدف المطحور (أنبوب مطحور في التربة كحالة دراسية) في صور GPR من النوع B-Scan (مسح نصوبي- Brightness- Scan).

هناك تحدي يتمثل في تأمين مجموعة البيانات اللازمة لتدريب نماذج التعلم العميق في مجال تقانة GPR، وذلك بسبب ندرة بيانات GPR الحقيقية والمشروحة من قبل خبراء في هذا المجال، كما أن الحصول على صور GPR معلمة Labeled images غير متاح دوماً، لذا تم في هذا البحث إنشاء مجموعة بيانات Datasets مكونة من صور GPR B-Scan محاكاة باستخدام برنامج المحاكاة gprMax ومن صور GPR B-Scan حقيقية، استُخدمت في تدريب واختبار نموذج CNN. حقق النموذج المقترن دقة 100% على بيانات التحقق، ودقة 97.5% على بيانات الاختبار التي تمثل بيانات غير مرئية بالنسبة للنموذج، وهذا يمثل أداء عالي للنموذج المقترن، وبالتالي يمكن استخدام نموذج CNN المقترن كنظام داعم لعملية كشف الأجسام المطحورة من قبل مستثمرين ليس لديهم الخبرة الكافية في مجال تقانة GPR.

الكلمات المفتاحية: رادار اختراق سطح الأرض GPR، كشف الأجسام المطحورة، شبكة عصبية تلقائية CNN، بصمة القطع الزائد، صور GPR من النوع B-Scan

تاريخ الإيداع: 2023/3/7

تاريخ القبول: 2023/6/12



حقوق النشر: جامعة دمشق -
سورية، يحتفظ المؤلفون بحقوق
النشر بموجب CC BY-NC -

SA

Automatic Detection of Buried Objects Depending on Ground Penetrating Radar Images Using Convolutional Neural Networks

Hisham Zaid Nasser^{*1} Nadim Youssef Chahin²

^{*1}. Master student; Mechanical and Electrical Faculty - Electronics and Communications Engineering Department - Damascus university.
hisham.nasser@damascusuniversity.edu.sy

². Professor, doctor in Electronics and Communications Engineering Department - Mechanical and Electrical Faculty - Damascus university. nchahin@scs-net.org

Abstract:

Ground Penetrating Radar (GPR) is one of the technologies that has proven its efficiency in detecting buried objects by using electro-magnetic waves. However, this technology suffers from the problem that accurately identifying buried objects through GPR images remains a challenging task that heavily relies on the experience of the GPR device operator. So, the results of interpreting images may be unreliable, and require hard work and a long time for interpretation. The aim of this research is to help GPR device operator overcome this problem by building a Convolutional Neural Network (CNN) model that automatically detects the hyperbola signature reflected from the buried target (buried pipe in soil as case study) in GPR images from type of B-Scan (Brightness -Scan) .There is a challenge in providing the necessary dataset for deep learning models in the field of GPR technology, due to the scarcity of real GPR data discussed by experts in this field. Also, obtaining labeled GPR images is not always available. Therefore, in this research, two datasets consisted of simulated GPR B-Scan images using the gprMax simulation software, and real GPR B-Scan images were created, which were used to train and test the CNN model. The proposed model achieved accuracy = 100% on the validation dataset and accuracy = 97.5% on the test dataset, which represents invisible data to the model. This demonstrates the high performance of the proposed model, and thus the proposed CNN model can be used as a supporting system for detecting buried objects by GPR device operators who do not have sufficient experience in the field of GPR technology.

Keywords: Ground Penetrating Radar (GPR), Buried objects detection, Convolutional Neural Network (CNN), Hyperbola signature, GPR B-Scan images.

Received: 7/3/2023

Accepted: 12/6/2023



Copyright: Damascus University- Syria, The authors retain the copyright under a CC BY- NC-SA

GPR B-Scan image 29، هذه الصورة يتم إنشاؤها من قياسات

مبنية على انتشار الأمواج الكهرومغناطيسية في أوساط انتشار معقدة، حيث أن الأمواج الكهرومغناطيسية المنعكسة عن الأجسام المطمورة تشكل بصمة قطع زائد في صور GPR B-Scan (Zhou et al., 2021, 1-13)، فإن وضوح بصمة القطع الزائد في صور GPR مرتبط بشكل وثيق بجودة الأمواج الكهرومغناطيسية المستقبلة، وبالتالي فهو مرتبط بتعقيد البيئة الجيولوجية المتواجد فيها الجسم المطمور.

ومن هنا تبرز مشكلة صعوبة التعرف على الأجسام المطمورة من خلال صور GPR المحصلة، حيث يعتمد تقسيم صور GPR B-Scan المحصلة بشكل كبير على خبرة مستثمر جهاز GPR، وبالتالي قد تكون نتائج تقسيم الصور غير موثوقة. غالباً ما تكون المرافق الخدمية المطمورة تحت سطح الأرض على شكل أسطواني (أنابيب الماء وأنابيب الغاز والنفط والصرف الصحي والكابلات الكهربائية.. الخ)، لذلك سيتم في هذا البحث أتمتة كشف الأنابيب المطمورة في التربة (كحالة دراسة) من خلال الصور GPR B-Scan وذلك باستخدام نموذج شبكة عصبية التفافية Convolutional Neural Network (CNN).

2. الدراسات المرجعية Literature Review

قام الباحثون باستخدام منهجيات مختلفة بهدف الكشف الآلي عن القطع الزائد في صور GPR B-Scan الناتج عن انعكاسات الأمواج الكهرومغناطيسية عن الأجسام المطمورة في أوساط طمر مختلفة.

قام الباحث Onyszko وزميله باستخدام نموذجان مبنيان على المعالجة التقليدية للصورة (تحليل الموجة ومرشح غابور) من أجل كشف الأجسام المطمورة ذات الشكل الأسطواني في التربة باستخدام الصور GPR B-Scan، وقد اعتمدت الدراسة على

1 المقدمة :Introduction

يُعد رادار اختراق سطح الأرض 30 أحد أهم التقانات 31 (GPR) Ground Penetrating Radar أحد أهم التقانات 32 المس تخدمة في التقييم غير المدمّر 33 Non Destructive Evaluation (NDE)، وفي الكشف عن 34 الأجسام المطمورة في الأوساط المختلفة مثل التربة والخرسانة 35 والإسفلات والجليد والصخور 36 (Lombardi et al., 2022, 3033)، سواء كانت الأجسام 37 المطمورة مصنوعة من مواد معدنية، أو من مواد عازلة، وذلك 38 باستخدام الأمواج الكهرومغناطيسية. تم استخدام GPR على نطاق 39 واسع في مختلف المجالات ذكر منها:

في التطبيقات العسكرية: كشف الألغام الأرضية المطمورة 40 Land mines والقذائف غير المنفجرة 41 (Ebrahim et al., 2018, 90-98). في تطبيقات علم الآثار 42 كشف الكنوز المطمورة والمقابر الأثرية 43 (Al-Khalidy et al., 2023, 64-75). في تطبيقات الهندسة 44 المدنية: كشف حديد التسليح Rebar ضمن الخرسانة وكشف 45 أنابيب المرافق الخدمية المطمورة Buried utility pipes مثل 46 شبكات المياه والصرف الصحي، وتقدير حالتها 47 (Lai et al., 2018, 58-78). في التطبيقات الجنائية: كشف 48 الجثث المطمورة في التربة (Kelly et al., 2021, 110882) 49 في التطبيقات الجيولوجية: كشف التجاويف تحت سطح الأرض 50 (Alsharabi et al., 2019, 177-187) 51.

عند استخدام جهاز GPR في كشف الأجسام المطمورة، يتم عرض نتيجة الكشف لمستثمر الجهاز على شكل صورة رقمية، وفي حال استخدام مسح من النوع B-Scan (مسح نصوبي) فإن الصورة الناتجة بهذا المسح تسمى Brightness-Scan 56 (Brightness-Scan) 57.

الكشف الآلي عن الأجسام المطمورة اعتماداً على صور رadar اختراق سطح الأرض.....

نصر، شاهين

57 بيانات حقيقة محصلة بجهاز GPR من نوع Leica SIR4000 DS2000 تحصيل البيانات جهاز GPR من النوع 87.01%.

58 باستخدام الترددin: 400MHz. حفقت الدراسة دقة كشف 88.01%.

59 قيم استدعاء 0.98 للطريقة الأولى و 0.86 للطريقة 89.

60 قام الباحث D. Sun وزملاؤه بالكشف الآلي عن القطوع الزائدة (Onyszko et al., 2021, 4892)

61 التي شكلتها جذور الأشجار في صور B-Scan GPR، وذلك استخدم الباحث J. Wang وزملاؤه باستخدام نموذج شبكات

62 عصبية عميقة (DNN) مبني على مرمز وفاك الترميز ، وذلك بهدف

63 كشف العيوب في حديد التسليح المتواجد داخل الخرسانة، واستخدمت الدراسة بيانات محاكاة في تدريب النموذج ثم تم

64 اختبار النموذج على بيانات حقيقة من قياسات ميدانية بجهاز

65 GPR. حفقت الدراسة دقة 85% وقيم استدعاء 67.

66 Precision = 0.852 وقيم احكام Recall= 0.854 وقيم مؤشر F1-Score= 0.853.

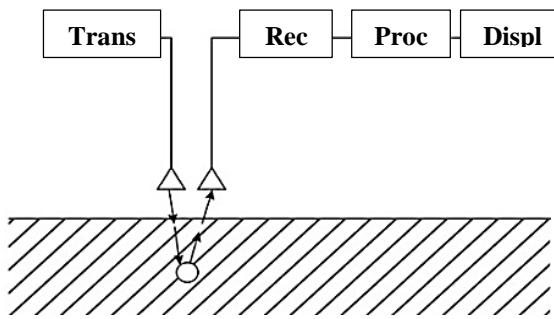
67 (J. Wang et al., 2021, 87207-87218)

68 قام الباحث Liu وزملاؤه بكشف التصدعات Cracks الداخلية في خرسانة الجسور بهدف التقييم الغير مدمر NDE للبنية التحتية لخطوط النقل، وذلك باستخدام نموذج Yolo v3-FDL (Four Scales-Detection Layer) كشف ذات أربعة مقاييس. استخدمت الدراسة صور GPR من النوع GPR B-Scan ومن النوع GPR C-Scan (مسح مقطعي عرضي Cross sectional- Scan)، وقد حفقت الدراسة قيمة مؤشر F1-Score = 88.1%. استخدمت الدراسة بيانات محاكاة، وبيانات حقيقة باستخدام جهاز GPR ذو نظام كشف ثلاثي الأبعاد (Liu et al., 2023a, 104698).

69 قام الباحث Liu وزملاؤه بالكشف الآلي عن التصدعات الداخلية في أسفل الطرق من صور GPR B-Scan، بهدف التقييم غير المدمر NDE للطرق تحديد فيما إذا كانت بحاجة للصيانة أم لا، وذلك باستخدام نموذج Mask R-CNN (Region-based Convolutional Neural Network) تحسينه في الدراسة، وحقق النموذج: Precision= 0.833 وحقق قيمة مؤشر F1- Score = 0.824. استخدمت الدراسة بيانات محاكاة وبيانات حقيقة باستخدام جهاز GPR من النوع

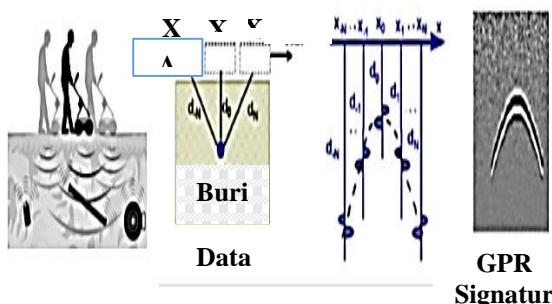
70 اقترح الباحث Su وزملاؤه نموذج تعلم عميق نوع 112 Key point-regression من End-to-End مبني على نموذج من أجل كشف موقع المرافق الخدمية المطمورة التي على شكل أنابيب (خرسانية ومعدنية) مثل أنابيب الماء والغاز والنفط والصرف الصحي وذلك من صور GPR B-Scan. استخدم في

Geo-Scope TM MKIV 117
 يتكون جهاز GPR من مرسل راديوسي، ومستقبل، ووحدة معالجة 148
 وإظهار لمعالجة البيانات المحصلة ثم عرضها على شاشة على 148
 شكل صور رقمية (Kanafiah et al., 2019, 012028) كما 149
 يوضح الشكل (1). 150



الشكل (1) مكونات جهاز GPR.

إنشاء عملية الكشف عن الهدف المطمور، يتم تمرير جهاز GPR فوق المنطقة المراد كشف الأهداف المطمورة فيها أما من قبل مستمر، أو باستخدام عربة متحركة كما هو موضح بالشكل (2) بحيث يتحرك كل من هوائي الإرسال والاستقبال لجهاز GPR سويةً مع بعضهما خلال عملية الكشف.



الشكل (2) تحصيل البيانات بواسطة جهاز GPR.

في كل موقع (X_i) لجهاز GPR على خط المسح Survey line، يتم إرسال أمواج كهرومغناطيسية عن طريق هوائي الإرسال لجهاز GPR باتجاه الأرض، تنتشر الأمواج كهرومغناطيسية في الوسط تحت سطح الأرض وتعاني من عدة ظواهر أهمها التخادم Attenuation، وعند وجود اختلاف في قيم السماحية

الكهرومغناطيسية النسبية (ϵ_r)

الكشف الآلي عن الأجهزة المطمورة اعتماداً على صور رادار اختراق سطح الأرض..... 118
 (0.3, 0.6, 0.9, 1.6, 2, 3) GHz 118
 (Liu et al., 2023b, 104689) 119
 خلاصة الدراسات السابقة: 120

اعتمدت الدراسات السابقة أساليب مختلفة بهدف الكشف الآلي 121
 عن القطع الزائد الناتج عن الأهداف المطمورة في صور 122
 GPR B-Scan 123
 عميق جاهزة تم استخدامها في الدراسة أما بشكل مباشر أو بعد 124
 إدخال تحسينات على هذه النماذج، ومن أجل الحصول على 125
 مجموعة البيانات Dataset اللازمة لتدريب نموذج الكشف، فإن 126
 بعض الدراسات استخدمت صور GPR محاكاة، وبعضها 127
 الآخر اعتمد (بالإضافة إلى صور المحاكاة) على صور 152 128

Dataset 129
 حقيقة، وبالتالي كان لكل دراسة مجموعة بيانات 130
 خاصة بها. لكن سلبية هذه الدراسات أنها أنشأت مجموعة 155 131
 البيانات (سواء بالمحاكاة أو بالقياسات الميدانية) باستخدام نوع 131
 معين لجهاز GPR وفي وسط طمر من نوع واحد وباستخدام 132
 عدد قليل من الترددات لجهاز GPR. تم في بحثنا بناء نموذج 158 133
 خاص بنا لكشف الأهداف المطمورة بالاعتماد على 155 134

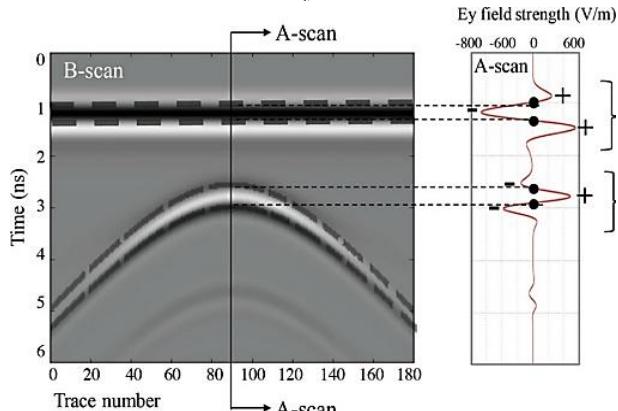
صور GPR B-Scan 135
 استناداً إلى الشبكات 136
 العصبية الالتفافية CNNs، يتم بعدم التعقيد وبعدم الاعتماد 136
 على نماذج التعلم العميق الجاهزة والمتوفرة على الانترنت، 137
 وكذلك تم إنشاء قاعدة بيانات خاصة بالدراسة تتسم بشمولية 138
 الحالة المدروسة (أنابيب مطمورة في التربة) من حيث تنوّع 139
 أنواع وعدد الأنابيب المدروسة، وتتوّع أنواع الأوساط المطمورة 140
 فيها الأنابيب، واستخدمنا ترددات عمل مختلفة لجهاز 141
 GPR ضمن المجال الترددية MHz [1000, 100] واعتمدنا 142

على قاعدة البيانات TU1208 المؤلفة من صور B-Scan 143
 GPR 143
 حقيقة محصلة بثلاثة أنواع مختلفة من أجهزة GPR. 144
 Scan 164
 3. الأسس النظرية للبحث: 145
 1.3. تحصيل البيانات باستخدام GPR: 146

168 بين الجسم المطمور والوسط المحيط به، تتعكس الأمواج A-Scan فعالية من المسح 169 المطمورة تحت سطح الأرض 170 لجهاز GPR، فإذا كانت شدة الأمواج الكهرومغناطيسية الواردة أعلى 171 من عتبة حساسية المستقبل لجهاز GPR، يتم كشفها، حيث 172 يتم قياس مطال الإشارة المستقبلة كدالة في الزمن. تدعى هذه 173 الإشارة الناتجة: المسح المطالي 174 كما هو موضح في الشكل 175 (3). تقوم وحدة المعالجة لجهاز GPR بتسجيل قيمة 176 في الموضع الحالي لجهاز GPR على سطح الأرض. 200

في صور GPR B-Scan: يتم تمثيل A-Scans المسجلة في كل موضع لـ GPR على خط المسح بشدة سطوع للبكسلات في الموضع المقابل لها في الصورة B-Scan GPR، كما ويتم عرض زمن انتشار الأمواج الكهرومغناطيسية من وإلى جهاز GPR مقابل موضع جهاز GPR على سطح الأرض، ويتم تمثيل تغير صفة الإشارة المستقبلة عن الإشارة المرسلة بتدرج رمادي (صورة بال المجال الرمادي Gray Scale) أو بتدرج الألوان (صورة ملونة RGB). يبين الشكل (4) مثال لصورة محاكاة

GPR B-Scan بالمجال الرمادي.

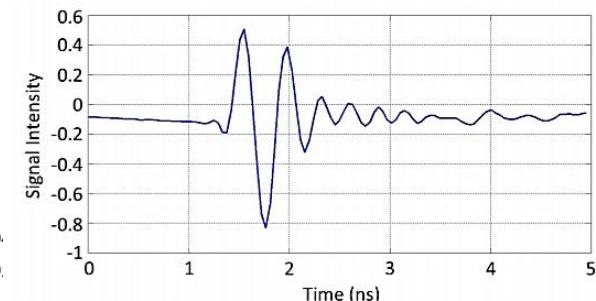


الشكل (4) صورة محاكاة GPR B-Scan بالمجال الرمادي.

إن أزمنة وصول الأمواج الكهرومغناطيسية المنعكسة عن الجسم المطمور تشكل في صور GPR B-Scan قطع زائد Hyperbola، وبالتالي فإن كشف الجسم المطمور يمكن النظر إليه على أنه كشف بصمة القطع الزائد GPR B-Scan في صور Hyperbola signature المحصلة.

2.3 محتويات الصور :GPR B-Scan

كما هو موضح في الشكلان (4,5) فإن الصورة GPR B-Scan تحتوي على:



الشكل (3) المسح المطالي .A-Scan

وهكذا خلال حركة جهاز GPR فوق الهدف المطمور وعلى خط مستقيم وبخطوات مسح متباينة، يتم في كل موضع جديد لـ GPR الحصول على مسح A-Scan جديد. تقوم وحدة المعالجة لجهاز GPR بدمج مجموعة عمليات المسح A-Scans على صورة رقمية ثنائية البعد تدعى GPR B-Scan image، تتمثل هذه الصورة مقطع رأسياً للأرض التي يتم مسحها على طول خط المسح لـ GPR وتعد وسيلة أكثر 214

215 1.2.3 بصمة القطع الزائد Dielectric Permittivity signature: الناتجة ϵ_{r1} 216 عن انعكاسات الأمواج الكهرومغناطيسية عن الهدف المطمور ϵ_{r2} 216 لوسط الانتشار تحت سطح الأرض.

217 1-13 (Zhou et al., 2021, 2017) 217 بصمة القطع الزائد ϵ_{r2} 218 في الصورة يتأثر بشكل أساسى بالعوامل التالية: 218 للجسم المطمور.

219 1.1.2.3 وسط الانتشار تحت سطح الأرض وتردد العمل ω 219 المستخدم لجهاز GPR: تخدامد الأمواج الكهرومغناطيسية عن 220 المطمور الغير معدني والوسط المحيط به حتى تكون بصمة 221 انشارها في الوسط تحت سطح حيث أن معامل تخدامد الأمواج ω 221 الكهرومغناطيسية عند انشارها في الوسط تحت سطح الأرض يعطى 222

223 2.2.3 الموجة المباشرة Direct wave: وتألف من الاشارة 223 المتسربة مباشرةً من المرسل إلى المستقبل عبر الهواء وتدعى 224 بالاقتران المباشر Direct coupling، ومن الاشارة المنعكسة 225 عند اصطدامها بسطح الأرض الذي يفصل بين الهواء ووسط 225

226 3.2.3 الكشرات Clutters: الناتجة عن انتشار الأمواج 226 الكهرومغناطيسية في البيئات الجيولوجية المعقدة (عندما يكون وسط 227 الانتشار يحتوى على طبقات مختلفة في السماحية الكهرومغناطيسية 227

228 تمتاز الموجة المباشرة بميزة المطال الكبير، وبحذفها تصبح 228 بصمة القطع الزائد للهدف في الصورة GPR B-Scan أكثر 229

229 وضوحاً (Chantase et al., 2018, 210-227). 229

230 3.2.3 الكشرات Clutters: الناتجة عن انتشار الأمواج 230 الكهرومغناطيسية في البيئات الجيولوجية المعقدة (عندما يكون وسط 231

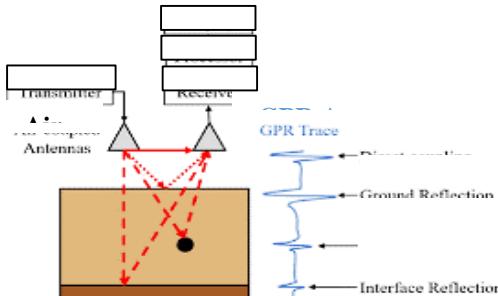
232 الانتشار يحتوى على طبقات مختلفة في السماحية الكهرومغناطيسية 232

233 فإنه يسبب انعكاسات متعددة للأمواج الكهرومغناطيسية عن 233

234 الأسطح الفاصلة بين هذه الطبقات (Interface reflection). 234

235 يظهر الـ Clutters على شكل قطع خطية في الصور المحصلة 235

236 (Oliveira et al., 2021, 2005)



الشكل (5) الإشارات المرسلة والمستقبلة بجهاز GPR.

$$253 \quad \alpha = \sqrt{\frac{\omega \mu \sigma}{2}}; \quad \omega = 2\pi f \quad 254 \quad (1) \quad 255$$

256 f: تردد العمل المستخدم لجهاز GPR. 256

257 μ : النفوذية المغناطيسية Magnetic Permeability 257 لوسط

258 258 σ : الموصليّة الكهرومغناطيسية Electrical conductivity 258 لوسط

259 259 الانشار تحت سطح الأرض. 259

260 260 نلاحظ من العلاقة (1) أنه بزيادة الموصليّة الكهرومغناطيسية والنفاذية 260

261 261 المغناطيسية لوسط الانتشار وبزيادة تردد العمل المستخدم 261

262 262 لجهاز GPR يزداد تخدامد الأمواج الكهرومغناطيسية عند انشارها في 262

263 263 وسط الانتشار تحت سطح الأرض، وبالتالي يقل وضوح بصمة 263

264 264 القطع الزائد في الصورة GPR B-Scan. 264

265 2.1.2.3 نوع مادة الهدف المطمور: من المعلوم أن انعكاس 265 الأمواج الكهرومغناطيسية عن المعادن يكون كبيراً، وعليه ستكون 266

266 بصمة القطع الزائد (الناتجة عن الأهداف المعدنية المطمورة) 266

267 267 في الصورة المحصلة أكثر وضوحاً، أما في حالة الأجسام 267 العازلة فإن انعكاس الأمواج الكهرومغناطيسية عنها يعتمد على الفرق 268 في السماحية الكهرومغناطيسية ϵ_r بينها وبين الوسط المحيط 268

269 269 بها. وفقاً Snell فإن معامل الانعكاس R على السطح الفاصل 269

270 270 بين مادتين مختلفتين بالسماحية الكهرومغناطيسية يعطى 270

271 271 : (H. Wang et al., 2022, 018503) (2) 271

$$272 \quad R = \frac{\sqrt{\epsilon_{r1}} - \sqrt{\epsilon_{r2}}}{\sqrt{\epsilon_{r1}} + \sqrt{\epsilon_{r2}}} \quad 273 \quad (2) \quad 274$$

4. مواد البحث وطرائقه: 271

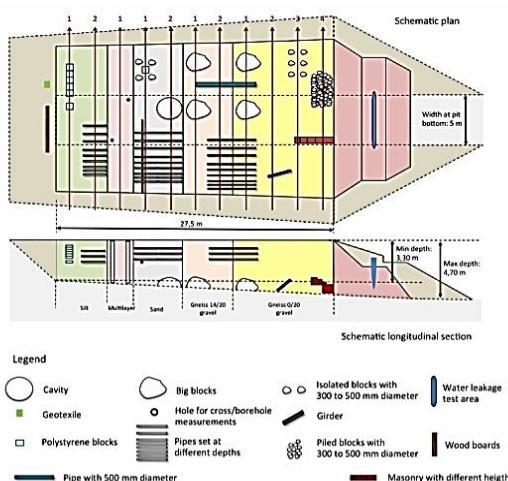
301 تحديد الأبعاد الهندسية Geometric لنموذج المحاكاة

272 المدرسو، وكذلك عند تحديد الدقة المكانية
 273 resolution، وذلك استناداً إلى نوع مادة وسط الانتشار
 274 المدروسة، وأبعاد الهدف المطمور، والشكل الموجي
 275 الموجي (Wave form) للنقطة المرسلة من جهاز GPR وإلا فلن
 276 يعمل البرنامج بالشكل المطلوب أثناء المحاكاة.

277 2.4 قاعدة البيانات TU1208:

278 GPR Radargrams في هذه القاعدة تم تسجيل بيانات خام
 279 (مسوحات من نوع B-Scan) في موقع الاختبار الجيوفизيائي
 280 Nantes في فرنسا، هذا الموقع عبارة عن حفرة اختبارية
 281 تحتوي عدد من الأهداف المختلفة الاشكال والممواد، وهي
 282 مطمورة في أوساط طمر مختلفة. الموقع المذكور بعد عن
 283 مصادر الضجيج مثل التركيبات الكهربائية والأشجار، وقد تم
 284 تصميمه لتوفير حقل تجاري لتقنية GPR في بيئة متحكم بها
 285 منذ التصميم، وذلك بهدف مشاركة المجتمع العلمي في
 286 مجموعة مختارة من استجابات GPR الموثوقة والمثيرة للاهتمام
 287 (.Derobert et al. , 2018, 530)

288 يبين الشكل (6) شكل وأبعاد حفرة الاختبار المذكورة والأهداف
 289 المطمورة المستخدمة فيها.



الشكل (6) شكل وأبعاد حفرة الاختبار والأهداف المطمورة المستخدمة في
 قاعدة البيانات TU1208.

302 من المعروف أن دقة النتائج لنموذج التعلم العميق تعتمد إلى
 303 حد كبير على حجم وموثوقية مجموعة البيانات المستخدمة في
 304 تدريب النموذج. نظراً لصعوبة توفر جهاز GPR لإجراء
 305 قياسات ميدانية حقيقة بواسطته، فقد قمنا بإنشاء مجموعة
 306 بيانات خاصة بالبحث بالاعتماد على صور GPR B-Scan

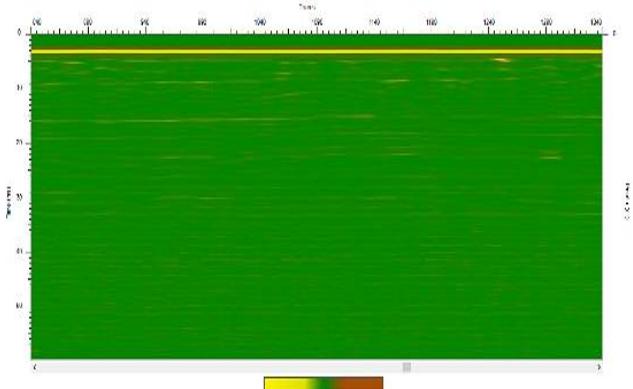
307 محاكاة باستخدام برنامج المحاكاة gprMax، وعلى صور GPR B-Scan
 308 حقيقة تم استخراجها من قاعدة البيانات TU1208
 309 وعلى صور GPR B-Scan حقيقة (سواء ملونة أو بالمجال
 310 الرمادي) مما هو متاح على موقع الانترنت.

1.4 برنامج المحاكاة: 281

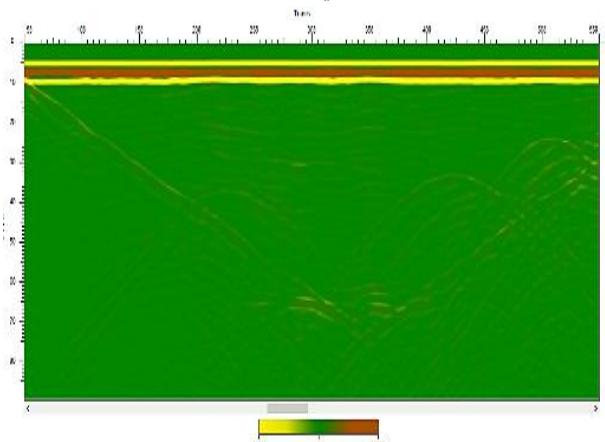
311 يعتبر برنامج gprMax أحد أهم برامج المحاكاة المستخدمة من
 312 قبل الباحثين للحصول على صور محاكاة لجهاز GPR من
 313 أجل معالجة مشكلة ندرة بيانات GPR المنشورة من قبل
 314 الخبراء في مجال تقانة GPR. وهو برنامج مفتوح
 315 المصدر (Warren et al., 2016, 163-170) يحاكي انتشار
 316 الأمواج الكهرومغناطيسية في أوساط الانتشار تحت سطح الأرض،
 317 ويحل معادلات ماكسويل في الأبعاد الثلاثة 3D باستخدام
 318 طريقة التكامل المحدود بال المجال الزمني 319

290 .Finite Difference Time Domain (FDTD)

291 تم تصميم البرنامج لنموذج جهاز GPR، ونمذجة التربة والماء.
 292 تم كتابة البرنامج بلغة Python 3x مع كتابة الأجزاء المهمة
 293 للأداء بلغة Cython بهدف تحسين الكفاءة والسرعة وسهولة
 294 الاستخدام للبرنامج، وهو يتضمن محلل Solver قائم على وحدة
 295 المعالجة المركزية (CPU) (Central Processing Unit (CPU))
 296 Graphics قائم على وحدة معالجة الرسومات
 297 Processing Unit (GPU) (GPU). برنامج gprMax يحتاج لملف
 298 إدخال Input file يحتوي على معلومات عن جهاز GPR
 299 المراد نمذجته وعن المواد المراد محاكتها، وكذلك يحتوي أوامر
 300 خاصة ببرنامج gprMax. يجب تحقيق شروط معينة عن



الشكل (7) صورة GPR B-Scan حقيقية من قاعدة البيانات TU1208 لا تحتوي على أهداف مطحورة.



الشكل (8) صورة GPR B-Scan حقيقية من قاعدة البيانات TU1208 تحتوي على أنابيب مطمورة.

3.4 محاكاة عملية كشف الأنابيب المطحورة في التربة

• G

قمنا بمحاكاة عملية كشف أنابيب بلاستيكية ومعدنية (أنبوب مفرد، أنبوبان، ثلاثة أنابيب) مطحورة في تربة من أربعة أنواع مختلفة، الأنابيب على عمق 2m في التربة، وطول خط المسح الذي سيتحرك عليه جهاز GPR هو 10m، وذلك باستخدام برنامج المحاكاة gprMax v3.1.6 . يبين الشكل (9) توصيف للبيئة التي تمت محاكماتها. تتكون البيئة التي قمنا بمحاكماتها في حثنا من:

القسم الأرضي (Ground): في هذا القسم تتم محاكاة التربية، والأناس المطمومة في التربية. هذا القسم على شكل مستطيل.

الكشف الآلي عن الأجسام المطحورة اعتماداً على صور رadar اختراق طول الحفرة الاختبارية 27.5m وهي ذات جوانب منحدرة، عرضها في القاع 5m وعرضها في الأعلى $(19 \div 24.6)$ m، وعمق الحفرة $(4.7 \div 3.3)$ m، تم تقسيم الحفرة الاختبارية إلى 5 مناطق مملوقة بمواد مختلفة:

(طمي Silt، حجر جيري رسوبى Limestone تم طحنه على 327
شكل حبيبات رملية، صخور رسوبية Gneiss تم سحقها على 328
شكل حبيبات رملية). المناطق المذكورة تضم العديد من 329
الأهداف الشائعة الوجود في البيئات الواقعية: أنابيب، كابلات 330
356 كهربائية، حجارة، تجاويف، حجارة بناء، وكتل صخرية، 331
357 باستثناء منطقة من المناطق الخمسة، حيث أنها لا تحتوي على 332
أي أهداف مطمورة (منطقة الـ Multilayers) وذلك بهدف 333
الحصول على صور تحوي فقط كشرات Clutters أي صور 334
تحوي فقط خلفية معقدة. 335

336 بالمجمل يوجد 11 خط مسح لـ GPR بطول 19m وبعرض
337 2.5m، وقد تم تسجيل 67 ملف Radargram (مسوحات من
338 (.DT, .dzt, .rd3) وهي ملفات ذات اللواحق (B-Scan نوع
339 وتحتاج إلى برامج خاصة لاستخراج الصور منها.

358	تم استخدام الأنواع التالية من الأنابيب المطمورة:	340
359	أنابيب فلاذية steel فارغة، وأنابيب Poly Vinyl Chloride	341
360	مملوقة بالماء، وأنابيب PVC فارغة وذلك بأقطار (PVC)	342
361	12.5 cm، بالإضافة إلى وجود أنبوب خرساني واحد فارع	343
362	وبقطر 0.5 m. تم استخدام ثلاثة أنواع من أجهزة GPR وهي:	344
363	- GSST (Nashua, NH, USA).	345
364	- MALA Geoscince (Mala, sweden).	346
	- JDS (Pisa, Italy).	347

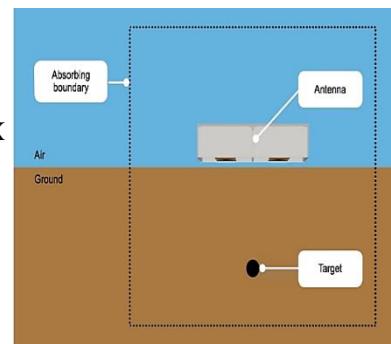
365	هذه الأجهزة تعمل في المجال الترددي MHz (900 ÷ 200)	348
366	في بحثنا استخرجنا من قاعدة البيانات TU1208 الصور	349
367	الناتجة عن أهداف مطمورة التي على شكل أنابيب والمسموحة	350
368	بأنواع أجهزة GPR مختلفة وذلك باستخدام البرنامج GPRSoft	351
369	Viewer ver1.4.2 . يبين الشكلان (7,8) مثالين من صور	352
370	GPR حقيقة مستخرجة من قاعدة البيانات	353
371	TU1208	354

نصر، شاهین

الكشف الآلي عن الأجسام المطحورة اعتماداً على صور رadar احتراق سطح الأرض.....

372	يحاكي تربة بعمق أعظمي 4m على طول المحور Y وبعرض 350 سيناريو محاكاة باستخدام gprMax
373	على طول المحور X وبسماكة قيمتها 2mm وفقاً 10m، كل سيناريو محاكاة ينتج عنه صورة GPR B-Scan
374	واحدة. في سيناريوهات المحاكاة المذكورة، تم محاكاة نوعين من المحور Z قدرها خلية yee واحدة. ¹
375	القسم الهوائي (Air): في هذا القسم يتم محاكاة جهاز GPR
376	الأنباب المطمورة (بلاستيكية ومعدنية)، وتم اختيار ثلاثة قيم ل قطرها: 10 cm, 25 cm, 50 cm، وتم اختيار ثلاثة قيم ل عدد الأنابيب المطمورة: 1، 2، 3، وتم اختيار أربعة أنواع من التربة المطمورة. هذا القسم على شكل مستطيل، يحاكي المنطقة فوق سطح التربة المدرستة، وهو بارتفاع 1m (على طول المحور X) وفقاً 400
377	المحيطة بالأنباب، وتم اختيار أعمق طمر عشوائية لأنابيب وذلك ضمن المجال [0.25, 2]m وفقاً 400
378	Y) وبعرض 10m (على طول المحور X) وبسماكة وفقاً 400
379	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
380	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
381	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
382	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
383	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
384	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
385	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
386	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
387	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
388	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
389	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
390	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
391	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
392	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
393	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
394	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
395	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
396	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
397	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
398	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
399	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
400	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
401	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
402	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
403	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
404	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
405	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
406	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
407	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
408	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400
409	لأنابيب ضمن القسم الأرضي من البيئة المحاكاة وفق المحور Z قدرها خلية yee واحدة وفقاً 400

الجدول (1) الخصائص الكهرومغناطيسية للترابة وللأنابيب التي تم محاكتها في سيناريوهات المحاكاة المنفذة في البحث.



الشكل (9) توصيف للبيئة التي تمت محاكاتها.

أنواع الأنابيب المحاكاة	أنواع التربة المحاكاة
أنابيب بلاستيكية: $\epsilon_r=2, \sigma=0.01 \text{ mS}, \mu=1$:Dray sand $\epsilon_r=3, \sigma=0.001 \text{ S/m}, \mu=1$
أنابيب معدنية (gprMax) (مضمنة ضمن)	:Dray clay soil $\epsilon_r=10, \sigma=0.01 \text{ S/m}, \mu=1$
	:Wet sand $\epsilon_r=20, \sigma=0.1 \text{ S/m}, \mu=1$
	:half_space (gprMax) (مضمنة ضمن) $\epsilon_r=6, \sigma=0 \text{ S/m}, \mu=1$

يبين الشكل (10) ملف الإدخال لبرنامج المحاكاة gprMax (تم كتابته بواسطة البرنامج Visual Studio Code على شكل ملف للاضافة (.in)). وذلك في أحد سيناريوهات المحاكاة.

في السيناريو الموضح بالشكل (10) تم محاكاة عملية مسح التربة بجهاز GPR، حيث يتحرك على خط مسح Survey

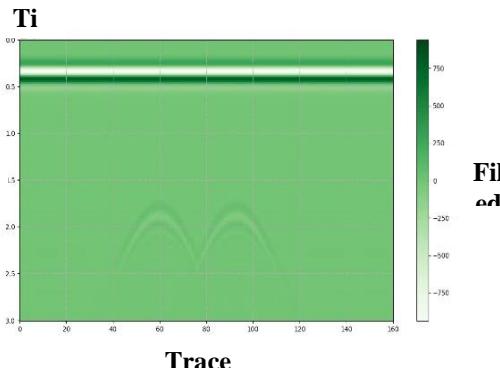
تم محاكاة جهاز GPR بالمعلمات التالية كحالة دراسية:	385
الهوائي من النوع Dipole hertzian مستقطب وفق المحور Z،	386
إشارة الارسال ذات شكل موجي Waveform من النوع	387
إشارة الارسال ذات شكل موجي Waveform من النوع	387
وترددات العمل للجهاز ضمن المجال [100, 1000] Ricker،	388
وهوائي الإرسال يرتفع عن سطح الأرض 5cm وفق	389
المحور Y، وهوائي الاستقبال يبعد عن هوائي الارسال بمسافة	390
أفقية وفق المحور X قدرها 3cm، وخلال عملية المسح فإن	391
كلا الهوائيان يتحركان معاً وبوقت واحد في كل خطوة تحصيل	392
معلومات على طول المحور X حيث أن قيمة خطوة الحركة	393
على طول خط المسح هي 5cm	394

¹ في برنامج gprMax يتم تقسيم شبكة FDTD التي تنتشر فيها الأمواج⁴¹ في السيناريو الموضح بالشكل (10) تم محاكاة عملية مسح الكهربائية لبناء المعايير إلى خلايا تعبر عن الدقة المكانية لعملية⁴² التربة بجهاز GPR، حيث يتحرك على خط مسح Survey المعايير وتدعى الخلية الواحدة بخلية yee.

نصر، شاهين

الكشف الآلي عن الأجسام المطمورة اعتماداً على صور رadar اختراق سطح الأرض.....

417 وفق المحور X بطول 10m وبخطوة مسح 5cm. تم 444 الصورة GPR B-Scan الناتجة عن سيناريو المعاكاة المشروع
418 اختيار قيمة الدقة المكانية mm 2 ونافذة الزمن 4560nsec 445 سابقاً موضحة بالشكل (11).



الشكل (11) صورة GPR B-Scan ناتجة عن أحد سيناريوهات

المحاكاة المنفذة في البحث.

تم في بحثا تففيذ 200 سيناريو معاكاة بوجود الأنابيب المطمورة في القسم الأرضي، و تم في النهاية الحصول على 455 200 صورة GPR B-Scan معاكاة ملونة RGB تحتوي على 456 قطوع زائدة ناتجة عن وجود الأنابيب المطمورة في 457 البيئة 458 المعاكاة. 459

وتم تففيذ 150 سيناريو معاكاة السابقة على نفس البيئة 460 المعاكاة ولكن من دون وجود أنابيب مطمورة في القسم 461 الأرضي، فحصلنا على 150 صورة معاكاة GPR B-Scan 462 ملونة لا تحتوي على قطوع زائدة (صور تحتوي فقط خلفية 463 بسيطة).

4.4 مجموعة البيانات المستخدمة في البحث:

1.4.4 مجموعة بيانات التدريب :Training Dataset

قمنا يدوياً بتجميع صور GPR B-Scan الناتجة عن 464 سيناريوهات المعاكاة والتي تحتوي على قطوع زائدة ناتجة عن 465 وجود أنابيب مطمورة في البيئة المعاكاة (وعددتها 200 صورة) 466 في فئة تحت اسم: يوجد كشف أهداف Target detection وتم 467 تعليمها بـ 0.

قمنا بإضافة 50 صورة GPR B-Scan حقيقة لا تحتوي على 468 أهداف مطمورة من قاعدة البيانات TU1208 إلى الصور 469

470 الكشف الآلي عن الأجسام المطمورة اعتماداً على صور رadar اختراق سطح الأرض.....
471 418 اختيار قيمة الدقة المكانية mm 2 ونافذة الزمن 4560nsec 445 سابقاً موضحة بالشكل (11).
472 419 الشكل الموجي لنبضة الإرسال لجهاز GPR من النوع 446 Ricker 447 وبتردد 400MHz، وتم معاكاة أنابيب معدنيان بقطر 448 30cm 449 للأنبوب الواحد، وعلى عمق 1m والأنبوبان مطموران في وسط 450 half_space 451 ذو الخصائص الكهرومغناطيسية التالية:
452 422 السماحية الكهربائية النسبية $\epsilon_r = 6$ ، الموصولة الكهربائية 453 $\sigma = 0$ 423، والنفاذية المغناطيسية $\mu_r = 1$ ، والفقد المغناطيسي 454 $.0 \text{ Ohms/m}$ 425

```
#title: B-scan from two metallic cylinders buried in a  
#domain: 10.000 5.000 0.02  
#dx_dy_dz: 0.02 0.02 0.02  
#time_window: 30e-9  
#material: 6 0 1 0 half_space  
#waveform: ricker 1 0.4e9 my_ricker  
#hertzian_dipole: z 0.240 4.050 0 my_ricker  
#rx: 0.270 4.050 0  
#src_steps: 0.05 0 0  
#rx_steps: 0.05 0 0
```

```
#box: 0 0 0 10.000 4.000 0.02 half_space  
#cylinder: 3.800 3.000 0 3.800 3.000 0.02 0.150 pec  
#cylinder: 5.800 3.000 0 5.800 3.000 0.02 0.150 pec
```

473 الشكل (10): ملف الإدخال لبرنامج gprMax في أحد 440 سيناريوهات المعاكاة. 441

474 في نهاية سيناريو المعاكاة السابق، تم الحصول على 442 160 Traces 443 (وتتمثل عدد المسوحات من النوع A-Scans) والتي 444 يتم دمجها للحصول على صورة واحدة GPR B-Scan 445 باستخدام الأمر التالي في موجه أوامر ويندوز Command 446 Prompt 447 :
475 python -m tools.outputfiles_merge 448 user_models/cylinder_Bscan_2D --remove-files 449

Conv2D GPR B-Scan 474
 Conv2D GPR B-Scan 474
 (المحاكاة التي لا تحتوي على قطع زائدة) 505 قسم استخراج الميزات: ويضم 6 طبقات التفافية 475
 (عدها 150 صورة) فأصبح مجموع الصور التي لا تحتوي 505 كل طبقة التفافية هو 475
 أنابيب مطمورة 200 صورة) وقمنا يدوياً بتجميع هذه الصور 505 (3*3)، أما عدد المرشحات فهو: 64 مرشح للطبقات الالتفافية 476
 في فئة تحت اسم: لا يوجد كشف أهداف 508 No Target 477 الأولى والثانية، و128 مرشح للطبقات الالتفافية الثالثة والرابعة، 477
 و256 مرشح للطبقات الالتفافية الخامسة والسادسة. 478
 على 400 صورة GPR B-Scan (200 صورة تحتوي 510 أنابيب 479
 مطمورة و200 صورة تحتوي فقط خلفية أما بسيطة أو معقدة) 511 لطبقات التجميع 480
 Maxpooling2D هو (2^2) ، وخطوة الالتفاف 512 481
2.4.4 مجموعة بيانات الاختبار :Test Dataset 481
 قمنا يدوياً بتجميع صور GPR B-Scan حقيقة (من قاعدة 513 482
 البيانات TU1208 ومن موقع انترنت مختلف) والتي تحتوي 514 483
 على قطع زائدة ناتجة عن وجود أنابيب مطمورة (وعددتها 515 484
 صورة) في فئة تحت اسم: يوجد كشف أهداف 516 485
 كاملة الاتصال Dense، بعدد عصbones 1024 عصbones 517 486
 للطبقة الأولى، و512 عصbones للطبقة الثانية، و64 عصbones 518 487
 (عدها 40) في فئة تحت اسم: لا يوجد كشف أهداف 519 488
 المستخدمة للطبقات الثلاث الأولى هي Relu، ولطبقة الأخيرة 520 489
 بالمجمل بيانات الاختبار تحتوي على 100 صورة 521 490
 GPR B-Scan حقيقة (60 صورة تحتوي أنابيب مطمورة و40 522 491
 صورة تحتوي فقط خلفية معقدة). 523 492
 .GPR B-Scan 524 493

5.4 بنية نموذج CNN المقترن: 493
 مهمة النموذج هي كشف وجود أو عدم وجود بصمة القطع 525 494
 الزائد الناتجة عن انعكاسات الأمواج الكهرومغناطيسية عن الأنابيب 526 495
 المطمورة في التربة داخل صور GPR B-Scan، وبالتالي تم 527 496
 تأطير المهمة إلى مشكلة تصنيف ثنائي. تم تفزيذ الشبكة 528 497
 العصبية باستخدام لغة البرمجة Python 3.9.12 مع استخدام 529 498
 المكتبات Tensorflow 2.10.0 وKeras 2.9.0 وذلك باستخدام 530 499
 منصة العمل Jupyter Notebook 500 500
 يتكون نموذجنا من قسم استخراج الميزات يليه مصنف مبني 501 501
 على الشبكات العصبية الصناعية Artificial Neural Networks (ANNs) 502 502
 (11) معمارية نموذج 503 503
 CNN المقترن. 504 504

نصر، شاهين

الكشف الآلي عن الأجسام المطمورة اعتماداً على صور رadar اخترق سطح الأرض.....

539 - توحيد أبعاد صور الدخل إلى $128*128$ بيكسل
540 .Image_size= (128,128,3)

541 - تحويل صور الدخل إلى مصفوفات Numpy ثم جعل قيم
542 هذه المصفوفة (والتي تمثل قيم بكسلات الصورة) بصيغة
543 الفاصلة العشرية Float32 ثم توحيد هذه القيمة في Rescaling في
544 المجال $[0,1]$ بقسمة هذه القيمة على 255.

545 6.4 تدريب نموذج CNN المقترن:

546 في هذا البحث تم استخدام التدريب الخاضع للإشراف. تم تقسيم
547 بيانات التدريب بنسبة: 80% للتدريب و 20% للتحقق، ونظرًا
548 لصغر حجم مجموعة بيانات التدريب المستخدمة فقد تم
549 استخدام تقنيات توسيع قاعدة البيانات Data-augmentation
550 التالية:

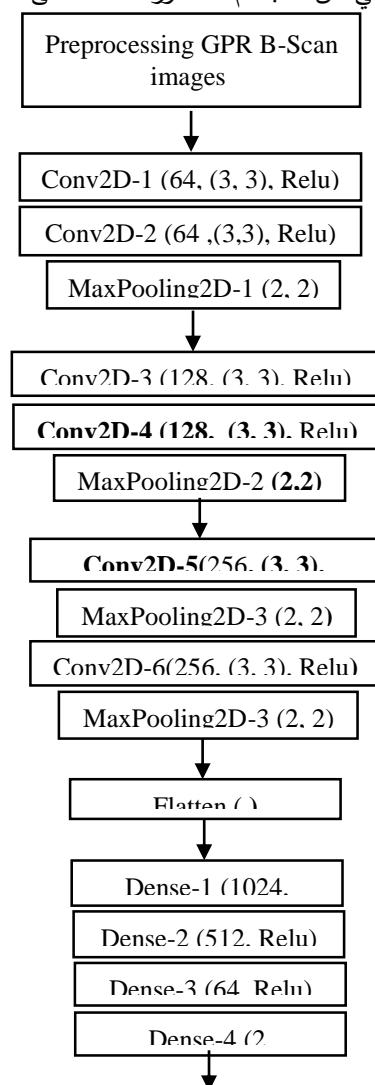
551 التغيير العشوائي لإضاءة الصور Random-Brightness
552 والتغيير العشوائي لتبابين الصور Random-Contrast. ولزيادة
553 متانة النموذج تم إدخال ضجيج غاوسي على الصور أثناء
554 التدريب بمتوسط 0 وبانحراف معياري 1 كما وتم استخدام
555 الخلط العشوائي للبيانات أثناء التدريب (Shuffle= True).

556 تم اختيار المعلمات الفائقة التالية الموضحة في الجدول (3)
557 أثناء عملية التدريب نموذج CNN.

558 الجدول (3) المعلمات الفائقة لنموذج CNN المقترن.

عدد حقب التدريب Max epochs	حجم دفعات البيانات Mini-Batch size	المحسن المستخدم Optimizer	وظيفة الخسارة Loss function	بارامترات القياس المراقبة Metrics	معدل التعلم Learning rate
100	16	Adam	Binary cross-entropy	Accuracy, Loss, Recall Precision, F1-Score	0.00001

559 بهدف زيادة مناعة النموذج ضد الإفراط في التعلم
560 Overfitting تم أثناء التدريب استخدام تقنيات التنظيم التالية:



530 الشكل (12) معمارية نموذج CNN المقترن في البحث.

531 إن صور الدخل لنموذج CNN هي صور GPR B-Scan هي صور
532 (سواء ملونة أو بال المجال الرمادي)، وتشمل المعالجة الأولية
533 Preprocessing لصور الدخل مايلي:
534 - حذف الموجة المباشرة من صور الدخل، وذلك عن طريق
535 إزالة الصور الأولى القليلة من الصورة، والتي تحتوي على
536 الموجة المباشرة، وضبط السطوع والتباين لصور الدخل وذلك
537 بهدف زيادة مناعة النموذج ضد الإفراط في التعلم
538 Overfitting تم أثناء التدريب استخدام تقنيات التنظيم التالية:

538 بشكل يدوي باستخدام برنامج GPR Soft Viewer.

نصر، شاهين

الكشف الآلي عن الأجسام المطحورة اعتماداً على صور رadar اختراق سطح الأرض.....

561 التسوية الدفعية Normalization 561
562 باستخدام Batch ، وتقانة التسريع 562
563 Dropout بنسبة 20%، وتقانة توسيع قاعدة بيانات الاختبار. يتم عادة تقييم أداء نماذج التصنيف 563
564 من خلال مجموعة من المقاييس Metrics التي تعكس جودة 564
565 أداء النموذج (Onyszko et al., 2021, 4892) 565
566 بالنهاية كان لدينا نموذج CNN بعد معلمات كما يلي: 566
567 Total parameters: 18,491,394 567
568 Trainable parameters: 18,486,402 568
569 Non-Trainable parameters: 4,992 569
570 **5. النتائج والمناقشة :Discussion & Results** 570
571 توضح الأشكال (13،14) عملية fitting 571
572 Model للنموذج 572
573 المقترب أثناء عملية التدريب للنموذج. 573

$$\text{PRE} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (3)$$

574 (True Positive) TP : عدد القيم التنبؤية الإيجابية الصحيحة. 574

575 (False Positive) FP : عدد القيم التنبؤية الإيجابية الخاطئة. 575

576 الاستدعاء (Recall) Recall: ويمثل معدل الحالات الموجبة 576

577 الحقيقة (True Positive Rate (TPR)) ويزداد كمّا بالعلاقة (4). 577

$$\text{REC} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (4)$$

578 (False Negative) FN : عدد القيم التنبؤية السلبية الخاطئة. 578

579 (True Negative) TN : عدد القيم التنبؤية السلبية الصحيحة. 579

580 الدقة (Accuracy) ACC: ويمثل معدل عدد الحالات 580

581 المصنفة بصورة صحيحة وتقييم نسبة النتائج الحقيقة (السلبية 581

582 الحقيقة والموجبة الحقيقة) ضمن العدد الكلي من الحالات 582
583 الخاضعة لاختبار كما هو موضح بالعلاقة (5). 583

$$\text{ACC} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FN} + \text{TN} + \text{FP}} \quad (5)$$

584 مؤشر التقييم F1-Score: إن F تشير إلى دمج 584

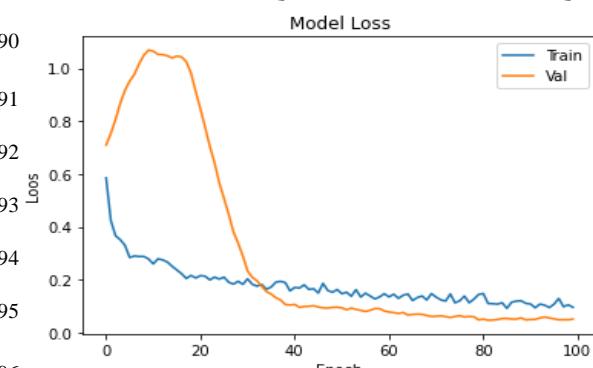
585 مقاييس التقييم PRE، REC والصيغة F1-Score تُعطى 585

586 بالعلاقة (6). 586

$$\text{F1 - Score} = 2 * \frac{\text{REC} * \text{PRE}}{\text{REC} + \text{PRE}} \quad (6)$$

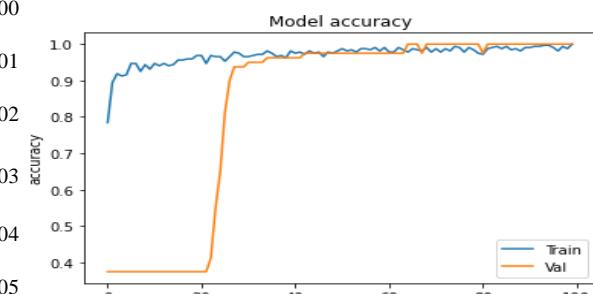
587 يبين الشكل (14) نتيجة الإخراج لنموذج CNN على عينة 587

588 عشوائية من مجموعة بيانات الاختبار. 588



589 الشكل (13) منحني الخسارة لمرحلة التدريب والتحقق. 589

590 كما هو متوقع تبدأ الخسارة بقيم عالية وتتحسن تدريجياً لتصل 590
591 أفضليات على بيانات التدريب إلى 0.0961 وعلى 591
592 بيانات التحقق إلى 0.0487. 592



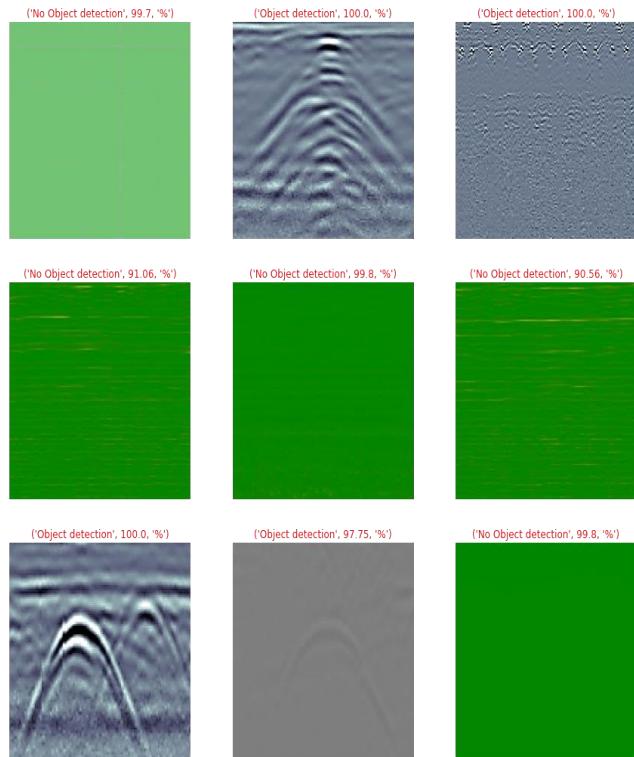
593 الشكل (14) منحني الدقة لمرحلة التدريب والتحقق. 593

594 تبدأ الدقة بقيم صغيرة وتزداد تدريجياً مع عملية التدريب لتصل 594
595 أفضليات على بيانات التدريب إلى 1.00 وعلى 595
596 بيانات التتحقق إلى 1.00. 596

597 بعد انتهاء عملية تدريب النموذج باستخدام بيانات التدريب التي 597
598 تم إنشاؤها في هذا البحث، قمنا بتقييم أداء هذا النموذج 598
599

610 قمنا بتقييم أداء النموذج CNN على بيانات الاختبار باستخدامه سلبيات كمبيوتر يوضّح الجدول (4).

611 مقاييس الأداء المذكورة وقمنا بمقارنتها مع دراسات مرجعية



الشكل (14) نتائج الإخراج للنموذج CNN على عينة عشوائية من مجموعة بيانات الاختبار.

الجدول (4) مقارنة نموذج CNN المقترن مع الدراسات السابقة

المرجع	الدقة ACC	الاستدعاء REC	الاحكام PRE	المؤشر F1-score	طريقة التصنيف (Method)
J. Wang et al (2021)	0.850	0.854	0.852	0.853	Encoder-decoder DNNs
H. Wang et al (2022)	0.9457	-	-	0.9323	Multilayer Feature Fusion Network based on CNNs
Su et al (2023)	0.9701	-	-	-	model end-to-end DL Key point- based on regression model
D. Sun et al (2023)	0.967	0.866	-	0.881	Yolo V5s
Liu et al (2023a)	-	-	-	0.881	Yolo V3- FDL Four scales-detection layer
Liu et al (2023b)	-	-	0.833	0.824	Improved Mask R-CNN
نموذج المقترح	0.975	0.97	0.976	0.973	CNN

GPR B-Scan حيث يكون بمثابة مساعد لمستمر جهاز GPR الذين لا يملكون الخبرة الكافية في تفسير بيانات GPR وبالتالي يقدم النموذج أدلة داعمة لكن دون استبدال الوكيل البشري الذي في النهاية سيكون صاحب القرار في التفسير النهائي للنتائج.

7. التوصيات:

أهم الصعوبات التي واجهتنا في بحثنا في تصنيف صور GPR B-Scan هي محدودية البيانات، حيث أن عدد الصور التي تم تدريب نموذج CNN المقترن عليها في البحث كان 400 صورة، وعدد الصور التي تم اختبار النموذج عليها كان 100 صورة، لذلك يوصى بزيادة عدد البيانات لتطوير البحث في المستقبل.

كما يوصى باستخدام جهاز GPR للقيام بالمسح الميداني لبيئة تحتوي أهداف مطمورة، بهدف الحصول على صور R حقيقة وواقعية، واستخدامها في تعزيز التأكيد من أداء نموذج CNN المقترن في هذا البحث.

ويوصى بتطوير النموذج ليصبح مكون من مرحلة إضافية: مرحلة تحديد نوع مادة الجسم المطمور الذي تم كشفه. Clutters ويوصى باستخدام طرق فعالة في تقليل الضجيج في صور GPR B-Scan بهدف تحسين وضوح بصمة القطع الزائد فيها والذات عن الهدف المطمور.

التمويل: هذا البحث ممول من جامعة دمشق وفق رقم التمويل (501100020595).

Conclusions

1- الكشف الآلي للجسم المطمور من خلال صور GPR B-Scan قابل للتحقيق باستخدام الشبكات العصبية الالتفافية CNNs، حيث أنه تم في هذا البحث بناء نموذج تصنيف مبني على CNN، تم تدريبه على مجموعة بيانات تدريب تم إنشاؤها في هذا البحث بالمحاكاة باستخدام برنامج gprMax، ثم تم تقييمه على مجموعة بيانات الاختبار التي تمثل بيانات غير مرئية للنموذج، وهي عبارة عن مجموعة من صور GPR B-Scan حقيقة محصلة باستخدام عدة أجهزة GPR، تم الحصول عليها من قاعدة البيانات TU1208 ومن موقع انترنت مختلفة حسب ما هو متاح من هذه الصور.

2- نتائج التقييم أظهرت أن النموذج المقترن حقق على بيانات الاختبار: PRE=0.976, REC=0.97, ACC=0.975, F1-Score=0.973

3- نظراً لأنه في الواقع العملي الحقيقي عند كشف الأجسام المطمورة بجهاز GPR فإن البيئات الجيولوجية الحقيقة التي تحتوي الأجسام المطمورة قد تكون أكثر تعقيداً مما تم دراسته، وكذلك الأجسام المطمورة قد تكون بأشكال معقدة عن حالة الأنابيب التي تمت دراستها في هذا البحث كحالة دراسة، ونظراً لأن تقانات التعلم العميق الخاضعة للإشراف مقادرة بالبيانات Data-driven، فمن الصعب تطبيق الشبكة المدرية تدريب جيد، مباشرة على مجموعة بيانات جديدة مختلفة بشكل كبير عن بيانات التدريب، وبالتالي قد يسوء أداء النموذج المقترن في الدراسة على الكشوفات الميدانية الحقيقة في بيئات أكثر تعقيداً.

644 مما سبق مناقشته نستنتج أنه يمكن اعتماد نموذج CNN المقترن في الكشف الآلي عن الأنابيب المطمورة في صور

References:

- [1] Benedetto, A., Tosti, F., Ciampoli, L.B., & Damico, F. (2017). An overview of ground-penetrating-radar signal processing techniques for road inspections. *Signal processing*. 132, 201-209. 675
- [2] Chantases, N., Boonpoonga, A., Burintramart, S., Athikulwongse, K., & Akkaraekthalin, P. (2018). Automatic detection and classification of buried objects using ground-penetrating radar for counter-improvised explosive devices. *Radio Science*. 53(2): 210-227. 679
- [3] Dérobert, X., & Pajewski, L. (2018). TU1208 Open Database of Radargrams: The Dataset of the IFSTTAR Geophysical Test Site. *Remote sensing*. 10 (4), 530. <https://doi.org/10.3390/rs10040530>. 683
- [4] Ebrahim, S. M., Medhat, N.I., Mansour, K.K., & Gaber, A. (2018). Examination of soil effect upon GPR detectability of landmine with different orientations. *NRIAG Journal of Astronomy and Geophysics*. 7(1), 90–98. 686
- [5] Kanafiah, S., Ali, H., Firdaus, A.Z.A., Azalan, M.S.Z., Jusman, Y., Khairi, A.A., & others (2019). Metal shape classification of buried object using multilayer perception neural network in GPR data. *IOP Conference Series: Materials Science and Engineering*. 705 (1), 012028. <https://doi.org/10.1088/1757-899x/705/1/012028>. 690
- [6] Kelly, T., Angel, M.N., Oconov, D.E., Huff, C.C., Morris, L.E., & Wach, G.D. (2021). A novel approach to 3D modelling ground penetrating radar (GPR) data. A case study of cemetery and application for criminal investigation. *Forensic Science International*. 325, 110882. <https://doi.org/10.1016/j.forsciint.2021.110882>. 695
- [7] Al-Khalidy, A., Naser, H.A., & Al-Yasi, A.I. (2023). Detection of Buried Archeological Remains Using GPR technique at Kifel Town to the South of Hilla/Iraq. *Iraqi Journal of Science and Technology*. 12/3, 64-75. 700
- [8] Lai, W.W. L., Dérobert, X., & Annan, P. (2018). A review of ground penetrating radar application in civil engineering: a 30-year journey from locating and testing to imaging and diagnosis. *Ndt E International*. 96, 58–78. 704
- [9] Liu, Z., Gu, X., CH, J., Wang, D., Chen, Y., & Wang, L. (2023). Automatic recognition of pavement cracks from combined GPR B-Scan and GPR C-Scan images using multiscale feature fusion deep neural networks. *Automation in construction*. 146, 104698. <https://doi.org/10.1016/j.autcon.2022.104698>. 708
- [10] Liu, Z., Yeoh, J. KW., Gu, X., Dong, Q., Chen, Y., Wu, W. & others. (2023). Automatic pixel-level detection of vertical cracks in asphalt pavement based on GPR investigation and improved mask R-CNN. *Automation in construction*. 146, 104689. <https://doi.org/10.1016/j.autcon.2022.104689>. 712
- [11] Lombardi, F., Podd, F., & Solla, M. (2022). From its core to the niche: Insights from GPR applications. *Remote Sensing*. 14(13), 3033. 716
- [12] Oliveira, R.J., Caldeira, B., Teixido, T., & Borges, J.F. (2021). GPR Clutter Reflection Noise-Filtering through Singular Value Decomposition in the Dimensional Spectral Domain. *Remote sensing*. 13(10), 2005. <https://doi.org/10.3390/rs13102005>. 718

[13] Onyszko, K., & Skibniewska, A. (2021). A New Methodology for the Detection and Extraction of Hyperbolas in GPR Images. <i>Remote Sensing</i> . 13 (23), 4892. https://doi.org/10.3390/rs13234892 .	721
[14] Rasol, M., Perez-Gracia, V., Fermandes, F.M., Pais, J.C., Santos-Assuncao, S.S., & Roberts, J.S. (2022). Ground penetrating radar system: Principles. <i>Handbook of Cultural Heritage Analysis</i> . 705-738.	722
[15] Rossi, M. (2022). Ground penetrating radar. <i>Engineering Geophysics</i> . 87-94.	723
[16] Al-sharahi, G., Faize, A., Maftei, C., Bayjja, M., Louzazni, M., Driouach, A. & others. (2019). Analysis and modeling of GPR signals to detect cavities: case studies in Morocco. <i>Journal of Electromagnatic Engineering and Science</i> . 19(3), 177–187.	724
[17] Su, Y., Wang, J., Li, D., Wang, X., Hu, L., Yao, Y., & Kang, Y. (2023). End-to-end deep learning model for underground utilities localization using GPR. <i>Automation in construction</i> . 149, 104776. https://doi.org/10.1016/j.autcon.2023.104776 .	725
[18] Sun, D., Jiang, F., Wu, H., Liu, Sh., Luo, P., & Zhao, Z. (2023). Root Location and Root Diameter Estimation of Trees Based on Deep Learning and Ground Penetrating Radar. <i>Agronomy</i> . 13 (2), 344. https://doi.org/10.3390/agronomy13020344 .	726
[19] Sun, H.H., Cheng, W., & Fan, Z. (2022). Learning to Remove Clutter in Real-World GPR Images Using Hybrid Data. <i>IEEE Transactions on Geoscience and Remote Sensing</i> . 60, 1-14.	727
[20] Wang, H., Ouyang, S., Liu, Q., Liao, K., & Zhou, L. (2022). Buried target detection method for ground penetrating radar based on deep learning. <i>journal of Applied Remote Sensing</i> . 16 (1), 018503. http://doi.org/10.1117/1.JRS.16.018503	728
[21] Wang, J., Chen, K., Liu, H., Zhang, J., Kang, W., Li, S., & others. (2021). Deep Learning-based rebar clutters removal and defect echoes enhancement in GPR images. <i>IEEE Access</i> . 9, 87207-87218.	729
[22] Warren, C., Giannopoulos, A., & Giannakis, I. (2016). gprMax: Open source software to simulate electromagnetic wave propagation for Ground Penetrating Radar. <i>Computer Physics Communications</i> . 209, 163-170.	730
[23] Zhou, D., & Zhu, H. (2021). Application of Ground Penetrating Radar in Detecting Deeply Embedded Reinforcing Bars in Pile Foundation. <i>Advances in Civil Engineering</i> . 1-13.	731
	732
	733
	734
	735
	736
	737
	738
	739
	740
	741
	742
	743
	744
	745
	746
	747
	748
	749
	750
	751
	752
	753
	754
	755