



الجمهورية العربية السورية

وزارة التعليم العالي والبحث العلمي

جامعة دمشق

كلية الهندسة الميكانيكية والكهربائية

قسم هندسة الإلكترونيات والاتصالات

الكشف الآلي عن الأجسام المظمورة اعتماداً على صور رادار اختراق سطح الأرض باستخدام الشبكات العصبونية الالتفافية

رسالة مقدّمة لنيل درجة الماجستير في هندسة الإلكترونيات التطبيقية

إعداد

م. هشام نصر

إشراف

أ. د. م. نديم شاهين

العام الدراسي

2023-2022

صفحة قرار لجنة الحكم وتوقيعات لجنة المناقشة Approval Page

تصريح خطي

أنا الموقع أدناه أصرّح بعلمي الكامل، وقبولي:

1. أن كل ما ينتج عن البحث والرسالة هو ملكية فكرية ومالية بالتشارك مع جامعة دمشق، وأنا ألتزم بأخذ موافقة الجامعة في حال رغبتني في نشر البحث أو الرسالة أو جزء منها نصّاً أو مضموناً خارج إطار الجامعة (من دُور نشر أو مكنتبات أو مواقع إلكترونية وغيرها من وسائل النشر).

2. أنه لا يوجد أي جزء من هذه الرسالة أُقتبس من أي عمل آخر أو أُنجز للحصول على شهادة أخرى في جامعة دمشق أو أية جامعة أو معهد تعليمي داخل الجمهورية العربية السورية أو خارجها.

الاسم والتوقيع

.

شكر وتقدير Acknowledgment

أَتَقَدَّم بالشكر والامتنان إلى الأستاذ الدكتور نديم شاهين المشرف العلمي على الرسالة، الذي كان قد اقترح عليّ فكرة البحث، فكان لي خير معين، ولم يتوان لحظة في إثراء البحث مقدماً لي كل العون والنصح، وسار معي خطوة بخطوة حتى خرج هذا البحث إلى النور.

كما أَتَقَدَّم بالشكر الجزيل والعرفان إلى قسم هندسة الإلكترونيات والاتصالات، بكادره التدريسي والفني، وأخص بالشكر الدكتور نضال زيدان رئيس القسم لما قدّمه لي من العون والتيسير في إنجازي لهذا البحث بأقصر وقت ممكن.

كما أَتَقَدَّم بالشكر والعرفان إلى كل من: الدكتور طلال حمّود (قسم هندسة الإلكترونيات والاتصالات)؛ الذي كان لي خير معين في الإجابة عن تساؤلاتي في مجال التعلّم العميق؛ المتعلّق بموضوع بحثي، والأستاذ الدكتور فخري بوش (كلية الآداب - قسم اللغة العربية)؛ الذي دقّق رسالة البحث لغوياً وإملائياً ونحوياً، والدكتور محمد خالد شاهين (قسم هندسة الإلكترونيات والاتصالات) لتدقيقه رسالة البحث، وإعطائها الشكل التنظيمي النهائي الأمثل. كما أَتَقَدَّم بالشكر لزوجتي التي تحمّلتني طوال فترة دراسة الماجستير، وأشكرها لما قدّمته لي من دعم معنوي طوال فترة دراستي في سبيل نيل درجة الماجستير.

كما أتوجّه بخالص الشكر لعائلتي وأصدقائي، ولكل من مدّ لي يد العون والمساعدة على إنجاز هذا البحث.

فهرس المحتويات Table of Contents

رقم الصفحة	العنوان
I	صفحة قرار لجنة الحكم وتوقيعات لجنة المناقشة Approval Page
II	تصريح خطي
III	شكر وتقدير Acknowledgment
IV	فهرس المحتويات Table of Contents
IX	فهرس الأشكال التوضيحية
XI	فهرس الجداول
XII	قائمة المصطلحات والاختصارات
XIII	المستخلص
XIV	المستخلص بالإنكليزية Abstract
1	الفصل الأول: الإطار العام للبحث Research General Framework
2	1.1 المقدمة
3	2.1 بعض الدراسات السابقة
8	3.1 مشكلة البحث
9	4.1 هدف البحث
9	5.1 أهمية البحث
9	6.1 مسوغات البحث
10	7.1 محددات البحث
10	8.1 حدود البحث
10	9.1 منهج البحث وأدواته
11	10.1 بنية الرسالة
13	الفصل الثاني: مبدأ عمل تقانة GPR في كشف الأجسام المظمورة The Principle of GPR Technique in Buried Objects Detection
14	1.2 تمهيد
14	2.2 مبدأ عمل تقانة GPR

رقم الصفحة	العنوان
15	1.2.2 المسح المطالي (Amplitude Scan (A-Scan)
16	2.2.2 المسح النصوعي (Brightness-Scan (B-Scan)
17	3.2.2 المسح المقطعي العرضي (Cross sectional-Scan (C-Scan)
18	3.2 النموذج الرياضي لبصمة الهدف المطمور المنعكسة في الصورة من النوع B-Scan
20	4.2 محتويات الصور GPR B-Scan
21	5.2 المكونات غير المرغوبة في صور GPR B-Scan
21	1.5.2 الموجة المباشرة Direct wave
21	2.5.2 الكشرات Clutters
22	3.5.2 الضجيج Noise
22	6.2 العوامل المؤثرة في وضوح بصمة القطع الزائد الناتجة في صور GPR B-Scan
22	1.6.2 تأثير التربة المحيطة بالأنابيب المطمورة
22	1.1.6.2 السماحية الكهربائية النسبية Dielectric Permittivity
23	2.1.6.2 الناقلية الكهربائية النوعية Electrical conductivity
23	3.1.6.2 النفوذية المغناطيسية Magnetic Permeability
24	2.6.2 انتشار الأمواج الكهرومغناطيسية EMs في الوسط تحت سطح الأرض
24	1.2.6.2 الانعكاس والانكسار Refraction & Reflection
25	2.2.6.2 التخماد Attenuation
26	3.2.6.2 الانتثار والامتصاص Scattering & Absorption
27	3.6.2 نوع مادة الجسم المطمور، وشكله
27	4.6.2 المواصفات الفنية لجهاز GPR
29	الفصل الثالث: الشبكات العصبونية العميقة وتدريبها
30	1.3 تمهيد
30	2.3 النموذج الرياضي للعصبون Neuron model
31	3.3 الشبكات العصبونية الصناعية (ANNs) Artificial Neural Networks
32	4.3 توابع التنشيط Activation Functions
33	2.4.3 تابع التنشيط ReLU

رقم الصفحة	العنوان
34	3.4.3 تابع التنشيط Softmax
35	5.3 الترميز الساخن الواحد One-hot-encoding
36	6.3 الشبكات العصبونية الالتفافية (CNNs) Convolutional Neural Network
36	1.6.3 عامل الالتفاف ثنائي الأبعاد Convolution 2D
38	2.6.3 معمارية الشبكة العصبونية الالتفافية CNN
38	1.2.6.3 قسم استخراج الميزات Features extraction
38	2.2.6.3 قسم التصنيف Classification
39	3.6.3 أنواع الطبقات في قسم استخراج الميزات
39	1.3.6.3 طبقة الالتفاف Convolution
40	2.3.6.3 طبقة التجميع (الدمج) Pooling
41	3.3.6.3 طبقة التسطيح Flatten layer
41	7.3 التصنيف Classification
42	8.3 تدريب الشبكات العصبونية الصناعية ANNs
44	9.3 تدريب نماذج التعلم العميق
44	1.9.3 مجموعة البيانات Dataset
44	2.9.3 المتوسطات الفائقة Hyper parameters
45	1.2.9.3 الحقبات Epochs
45	2.2.9.3 حجم الدفعة Batch
45	3.2.9.3 معدل التعلم Learning Rate
47	3.9.3 توابع الخطأ Lose Functions المستعملة في نماذج التصنيف
47	1.3.9.3 تابع خطأ الأنتروبيا المتقاطعة Cross-Entropy Loss
48	2.3.9.3 تابع الخطأ Binary Cross Entropy
48	4.9.3 خوارزميات أمثلة التعلم العميق Optimization Algorithms
48	1.4.9.3 خوارزمية الانحدار المتدرج الدفعي Batch Gradient Decent (BGD)
49	2.4.9.3 خوارزمية الانحدار المتدرج العشوائي Stochastic Gradient Decent (SGD)
49	3.4.9.3 خوارزمية انحدار الدفعات الصغيرة المتدرجة Mini-Batch Gradient Decent (M-BGD)
49	4.4.9.3 خوارزمية الانحدار المتدرج مع الزخم Gradient Decent with Momentum

رقم الصفحة	العنوان
50	5.4.9.3 خوارزمية الخطوة التكييفية (Adam) Adaptive moment Estimation
51	10.3 التعميم Generalization
53	11.3 طرائق التنظيم Regularization للشبكات العميقة
52	1.11.3 إضافة الضجيج إلى مداخل النموذج
52	2.11.3 تقانة الحذف العشوائي (التسرب) Dropout
54	3.11.3 التسوية الدفعية Batch normalization
55	الفصل الرابع: منهجية البحث، وإجراءاته Research Methodology and Procedures
56	1.4 تمهيد
56	2.4 مصادر مجموعة البيانات المستعملة في البحث
56	1.2.4 برنامج المحاكاة gprMax
58	2.2.4 قاعدة البيانات TU1208 Open database
62	3.4 محاكاة عملية كشف الأنابيب المطمورة في التربة باستعمال جهاز GPR
63	1.3.4 تصوّرات المحاكاة التي نُقّدت في البحث
66	4.4 مجموعات البيانات المستعملة في البحث
66	1.4.4 مجموعة بيانات التدريب Training Dataset
67	2.4.4 مجموعة بيانات الاختبار Testing Dataset
67	5.4 معمارية نموذج التصنيف المقترح المبني على الشبكة العصبونية الالتفافية CNN
69	1.5.4 قسم استخراج الميزات
69	2.5.4 المصنّف
69	3.5.4 المعالجة الأولية Preprocessing لصور الدخل
70	6.4 تدريب نموذج التصنيف المقترح
71	1.6.4 الموسطات الفائقة للنموذج المقترح في هذا البحث
71	2.6.4 تقانات التنظيم التي استُعملت في أثناء التدريب
71	7.4 الأدوات البرمجية والعنصرية التي استُعملت في البحث
72	8.4 مقاييس الأداء لنماذج التصنيف Metrics in classification
73	1.8.4 الدقة Precision (Pre)
74	2.8.4 الاستدعاء Recall (Rec)

رقم الصفحة	العنوان
74	3.8.4 Specificity (Spe) الخصوصية
74	4.8.4 Accuracy (Acc) الضبط
74	5.8.4 F1-Score مؤشر التقييم
75	6.8.4 Receiver Operating Characteristic (ROC) منحني خصائص التشغيل
76	9.4 Results and Discussion النتائج والمناقشة
76	1.9.4 تقويم أداء نموذج التصنيف المقترح المبني على الشبكة العصبونية الالتفافية مع استعمال خوارزمية الأمثلة SGD مع الزخم
76	1.1.9.4 نتائج التدريب؛ مع استعمال خوارزمية الأمثلة SGD مع الزخم
78	2.1.9.4 نتائج الاختبار؛ باستعمال خوارزمية الأمثلة SGD مع الزخم على مجموعة بيانات الاختبار
80	2.9.4 تقويم أداء نموذج التصنيف المقترح؛ مع استعمال خوارزمية الأمثلة Adam
80	1.2.9.4 نتائج التدريب؛ مع استعمال خوارزمية الأمثلة Adam
82	2.2.9.4 نتائج الاختبار؛ مع استعمال خوارزمية الأمثلة Adam على مجموعة بيانات الاختبار
86	10.4 تحليل النتائج والمناقشة
88	11.4 Conclusions الاستنتاجات
89	12.4 خاتمة البحث
90	الآفاق المستقبلية
91	المراجع References

فهرس الأشكال التوضيحية

رقم الصفحة	الشكل
14	الشكل (1-2): مكونات جهاز GPR
15	الشكل (2-2): تحصيل البيانات بواسطة GPR
16	الشكل (3-2): الإشارة الناتجة عن المسح من النوع A-Scan
17	الشكل (4-2): صورة بالمجال الرمادي ناتجة عن المسح من النوع B-Scan
18	الشكل (5-2): المسح من النوع C-Scan
19	الشكل (6-2): القطع الزائد الناتج عن الهدف المظمو في صور GPR B-Scan
21	الشكل (7-2): الإشارات المرسله والمستقبله بجهاز GPR
24	الشكل (8-2): الانعكاس والانكسار للأمواج الكهريسيية في وسط الانتشار تحت سطح الأرض
26	الشكل (9-2): خسائر التشتت للأمواج الكهريسيية عند مرورها في الأوساط غير المتجانسة
31	الشكل (1-3): النموذج الرياضي للعصبون.
32	الشكل (2-3): الشبكة العصبونية الصناعية ANN كاملة الاتصال FC
33	الشكل (3-3): تابع التنشيط ReLU، ومشتقه
34	الشكل (4-3): آلية عمل تابع التنشيط Softmax.
35	الشكل (5-3): مبدأ الترميز الواحد الساخن
37	الشكل (6-3): مبدأ عمل الالتفاف ثنائي الأبعاد
38	الشكل (7-3): معمارية الشبكة العصبونية الالتقافية
41	الشكل (8-3): مبدأ عمل طبقة التجميع
43	الشكل (9-3): مراحل التدريب في الشبكات ANNs
46	الشكل (10-3): طريقة تحديث x عند استعمال معدل تعلم صغير جداً.
46	الشكل (11-3): طريقة تحديث x عند استعمال معدل تعلم مرتفع بصورة مفرطة
52	الشكل (12-3): مفهوم الإفراط في التعليم والتعلم الناقص
53	الشكل (13-3): تقانة التسرب Dropout
57	الشكل (1-4): خلية Yee واحدة تظهر عليها مركبات الحقل الكهريائي E والمغنطاطيسي B

الشكل	رقم الصفحة
الشكل (4-2): شكل حفرة الاختبار المستعملة في قاعدة البيانات TU1208 وأبعادها، وما تحتويه من أهداف مطمورة	59
الشكل (4-3): صورة ناتجة عن مسح منطقة الطبقات المتعددة؛ باستعمال التردد 900 MHz	61
الشكل (4-4): صورة ناتجة عن خط المسح الثاني في منطقة Gneiss 14-20 باستعمال التردد 900 MHz	61
الشكل (4-5): صورة ناتجة عن خط المسح الثاني في منطقة الحجر الجيري باستعمال التردد 250 MHz	61
الشكل (4-6): توصيف للبيئة المحاكاة	62
الشكل (4-7): صورة GBR B-Scan محاكاة ناتجة عن أحد تصوّرات المحاكاة	65
الشكل (4-8): معمارية نموذج التصنيف المقترح في البحث (عمل الباحث)	68
الشكل (4-9): مصفوفة الارتباك Confusion matrix في المصنفات الثنائية	73
الشكل (4-10): منحنى خصائص التشغيل ROC	75
الشكل (4-11): منحنى الخسارة لمرحلة التدريب، والتحقق؛ باستعمال خوارزمية الأمثلة SGD مع الزخم	77
الشكل (4-12): منحنى الضبط لمرحلة التدريب، والتحقق؛ باستعمال خوارزمية الأمثلة SGD مع الزخم	77
الشكل (4-13): مصفوفة الارتباك الناتجة عن اختبار نموذج التصنيف (باستعمال خوارزمية الأمثلة SGD مع الزخم) على مجموعة بيانات الاختبار	79
الشكل (4-14): منحنى خصائص التشغيل ROC لنموذج التصنيف (باستعمال خوارزمية الأمثلة SGD مع الزخم) عند اختباره على مجموعة بيانات الاختبار	79
الشكل (4-15): منحنى الخسارة لمرحلة التدريب، والتحقق؛ باستعمال خوارزمية الأمثلة Adam	81
الشكل (4-16): منحنى الضبط لمرحلة التدريب، والتحقق؛ باستعمال خوارزمية الأمثلة Adam	81
الشكل (4-17): مصفوفة الارتباك الناتجة عن اختبار النموذج؛ باستخدام خوارزمية الأمثلة Adam على مجموعة بيانات الاختبار	83
الشكل (4-18): منحنى خصائص التشغيل ROC للنموذج؛ باستخدام خوارزمية الأمثلة Adam عند اختباره على مجموعة بيانات الاختبار	84
الشكل (4-19): نتيجة الإخراج لنموذج التصنيف المُعتمد، على عيّنة عشوائية من مجموعة بيانات الاختبار	85

فهرس الجداول

رقم الصفحة	الجدول
23	الجدول (1-2): قيم سرعة انتشار EMs في بعض المواد الجيولوجية المعروفة
25	الجدول (2-2): قيم معامل الانعكاس على السطح الفاصل بين مادتين مختلفتين
64	الجدول (1-4): الخصائص الكهربية للتربة، ولألأنايب المحاكاة في تصورات المحاكاة
71	الجدول (2-4): الموسطات الفائقة للنموذج المقترح
76	الجدول (3-4): قواعد تفسير قيمة AUC
80	الجدول (4-4): نتائج الاختبار؛ مع استعمال خوارزمية الأمثلة SGD مع الزخم
84	الجدول (5-4): نتائج الاختبار؛ مع استعمال خوارزمية الأمثلة Adam
87	الجدول (4-6): مقارنة نموذج التصنيف المقترح مع الدراسات السابقة

قائمة المصطلحات والاختصارات

المصطلح باللغة العربية	الاختصار	مقابله باللغة الإنكليزية
الخطوة التكييفية	Adam	Adaptive Moment
الشبكات العصبونية الصناعية	ANNs	Artificial Neural Networks
المسح المطالي	A-Scan	Amplitude-Scan
المسح النصوعي	B-Scan	Brightness-Scan
شبكة عصبونية ثقافية	CNN	Convolutional Neural Network
المسح المقطعي العرضي	C-Scan	Cross sectional- Scan
التعلم العميق	DL	Deep Learning
شبكات عصبونية عميقة	DNNs	Deep Neural Networks
أمواج كهرومغناطيسية	EMs	Electro-Magnetic waves
الشبكة ذات الاتصال الكامل	FCN	Fully Connected Network
التكامل المحدود بالمجال الزمني	FDTD	Finite Differences -Time Domain
الشبكات التوليدية التنافسية	GANs	Generative Adversarial Nets
رادار اختراق سطح الأرض	GPR	Ground Penetrating Radar
تقويم لا إتلافي	NDE	Non-Destructive Evaluation
الوحدة الخطية المصححة	ReLu	Rectified Linear unit
صور ملونة من النوع: أحمر-أخضر-أزرق	RGB Images	Red-Green-Blue (Colorful Images)
الانحدار المتدرج العشوائي	SGD	Stochastic Gradient Descent

المستخلص

خلفية البحث: يُعد كشف الأجسام المغمورة تحت سطح الأرض من المشاكل المثيرة للاهتمام، إحدى التقانات التي أثبتت كفاءتها في أداء هذه المهمة هي رادار اختراق سطح الأرض (GPR) Ground Penetrating Radar وذلك باستعمال الأمواج الكهرومغناطيسية. عند استعمال هذه التقنية يبرز تحدي يتمثل في صعوبة تفسير الصور المحصلة؛ إذ غالباً ما تحتاج إلى مستثمر ذي خبرة في مجال تقنية GPR لتفسير محتويات هذه الصور.

هدف البحث: أتمتة عملية كشف وجود الأجسام المغمورة من الصور ¹GPR B-Scan، وذلك باستعمال الشبكة العصبونية الالتفافية (Convolutional Neural Network (CNN).

المواد والطرائق: أنشئ في هذا البحث نموذج شبكة عصبونية الالتفافية CNN؛ للكشف الآلي عن الأهداف المغمورة؛ بالاعتماد على صور GPR B-Scan، كما وأنشئت مجموعتا بيانات Datasets:

- الأولى: تضم صور GPR B-Scan محاكاة؛ باستعمال برنامج المحاكاة gprMax، وقد استُعملت في تدريب النموذج.
- الثانية: تضم صور GPR B-Scan حقيقية؛ مأخوذة من قاعدة البيانات مفتوحة المصدر TU1208 ومن مواقع إنترنت مختلفة، وقد استُعملت في اختبار أداء النموذج.

النتائج العملية: حقق النموذج المقترح ضبط على بيانات التحقق 100%، وعلى بيانات الاختبار 97.7%.

الاستنتاجات من وجهة نظر الباحث: يمكن استعمال النموذج المقترح كنظام داعم لعملية كشف الأهداف المغمورة تحت سطح الأرض؛ وذلك من قبل مستثمرين ليس لديهم الخبرة الكافية في مجال تقنية GPR.

الكلمات المفتاحية:

كشف الأجسام المغمورة تحت سطح الأرض، رادار اختراق سطح الأرض GPR، صور GPR B-Scan، شبكة عصبونية الالتفافية CNN.

¹GPR B-Scan: الصور المحصلة بجهاز GPR من النوع Brightness-Scan (المسح النصوعي).

Abstract

Research Background: The detection of underground objects considers One of interesting problems, one of technologies that has proven effective in performing of this task is Ground Penetrating Radar (GPR), using electro-magnetic waves. When using this technology, a challenge appears in difficulty of interpreting the images collected, which often requires an experienced GPR technology expert to interpret the contents of these images.

Research Aim: Is to automate the process of detecting the presence of buried objects from GPR B-Scan images¹ using Convolutional Neural Network (CNN).

Material and Methods: In this research, a Convolutional Neural Network (CNN) model was created to automatically detect buried objects based on GPR B-Scan images, and two datasets were created:

- The first: includes simulated GPR B-Scan Images, using gprMax simulation software. this dataset was used to train the model.
- The second: includes real GPR B-Scan Images, using TU1208 database, and various internet sources. this dataset was used to test the performance of the model.

Practical Results: The proposed CNN model achieved:

an accuracy of 100% on the validation dataset and 97.7% on the testing dataset.

Conclusions from Researcher point of View: The proposed model can be used as a supporting system for the process of detecting buried objects underground by operators who do not have sufficient experience in GPR technology.

Keywords:

Buried Objects Detection, Ground Penetrating Radar (GPR), GPR B-Scan Images, Convolutional Neural Network (CNN).

¹GPR B-Scan images: the images collected using GPR device which their type are Brightness-scan.

الفصل الأول

الإطار العام للبحث

Research General Framework

1.1 المقدمة:

يُعدُّ رادار اختراق سطح الأرض (GPR) Ground Penetrating Radar أحد أهم التقانات المستعملة في التقويم اللا إتلافي (Non-Destructive-Evaluation (NDE، وفي الكشف عن الأهداف المغمورة في الأوساط المختلفة، مثل: التربة، والخرسانة، والأسفلت، والجليد، والصخور [1]، وفي إجراء قياس المتوسطات الجيولوجية Geometric parameters للأهداف المغمورة. (وتتمثل في تقدير عمق الهدف المغمور وأبعاده)، سواء كانت الأهداف المغمورة مصنوعة من مواد معدنية، أو من مواد عازلة؛ وذلك باستعمال الأمواج الكهرومغناطيسية

.Electro-Magnetic waves (EMs)

استعمل رادار اختراق سطح الأرض GPR على نطاق واسع في المجالات المختلفة، ومنها:

- في التطبيقات العسكرية: كشف الألغام الأرضية المغمورة Land mines والقذائف غير المنفجرة [2].
 - في تطبيقات علم الآثار: كشف الكنوز المغمورة والمقابر الأثرية [3].
 - في تطبيقات الهندسة المدنية: كشف حديد التسليح Rebar؛ ضمن الخرسانة، وكشف أنابيب المرافق الخدمية المغمورة Buried utility pipes، مثل شبكات المياه، والصرف الصحي، وتقويم حالتها [4].
 - في التطبيقات الجنائية: كشف الجثث المغمورة في التربة [5].
 - في التطبيقات الجيولوجية: كشف التجاويف والكهوف تحت سطح الأرض، ودراسة بنية الطبقات تحت سطح الأرض وسماكتها [6].
- غالباً ما تكون المرافق الخدمية المغمورة تحت سطح الأرض على شكل أسطواني (أنابيب الماء وأنابيب الغاز والنفط والصرف الصحي والكابلات الكهربائية.. الخ)، لذلك سيُرَكِّز في هذا البحث على كشف الأهداف المغمورة في التربة والتي على شكل أنابيب (شكل أسطواني).

كمقارنة مع الصور الرقمية التقليدية، فإن الصور الرقمية الناتجة عن رادار اختراق سطح الأرض GPR تُنشأ من قياسات مبنية على انتشار الأمواج الكهرومغناطيسية EMs، وذلك في أوساط انتشار معقدة؛ ومن ثم فإن ميزات صور رادار اختراق سطح الأرض GPR مرتبطة بصورة وثيقة بالأمواج الكهرومغناطيسية EMs المستقبلية، وجودتها.

2.1 بعض الدراسات السابقة:

استعمل الباحثون في عددٍ من الدراسات منهجيات مختلفة؛ بهدف الكشف الآلي عن القطع الزائد في صور رادار اختراق سطح الأرض GPR والذي يدل على وجود الأجسام المظلمة.

استعمل الباحثان (Onyszko & Skibniewska (2021) نموذجين مبنيين على المعالجة التقليدية للصورة (تحليل الموجة ومرشح غابور)؛ من أجل كشف الأجسام المظلمة ذات الشكل الأسطواني في التربة؛ باستعمال الصور GPR B-Scan، وقد اعتمدت الدراسة على بيانات حقيقية محصلة بجهاز رادار اختراق سطح الأرض GPR من نوع DS2000 Leica؛ باستعمال الترددين: 250 MHz, 700 MHz. حققت الدراسة قيمة استدعاء $Recall = 0.98$ للطريقة الأولى، و 0.86 للطريقة الثانية [7].

استعمل الباحث Wang et al (2021) وزملاؤه نموذج شبكات عصبونية عميقة Deep Neural Network (DNN) مبنياً على مرمرز، وفاك الترميز Encoder-Decoder، وذلك بهدف كشف العيوب في حديد التسليح المتواجد داخل الخرسانة، واستعملت الدراسة بيانات محاكاة في تدريب النموذج ثم تم اختبار النموذج على بيانات حقيقية من قياسات ميدانية بجهاز رادار اختراق سطح الأرض GPR. حققت الدراسة قيمة ضبط $Accuracy = 85\%$ ، وقيمة استدعاء $Recall = 0.854$ ، وقيمة دقة $Precision = 0.852$ ، وقيمة مؤشر $F1-Scor = 0.853$ [8].

قدّم الباحث Feng et al (2021) وزملاؤه إطار عمل DNN-based Migration؛ بهدف كشف

الأنابيب المغمورة تحت سطح الأرض، واستطاعت الدراسة إلى جانب كشف بصمة القطع الزائد في صور GPR B-Scan، تفسير ميزات هذه البصمة؛ وذلك بهدف إعادة بناء الصور للأنابيب المغمورة، وقد حققت الدراسة ضبط Accuracy قدره 95.7% [9].

استعمل الباحث Wang et al (2022) وزملاؤه شبكة دمج ميزات متعددة الطبقات Multilayer Feature Fusion Network؛ مبنية على الشبكات العصبونية الالتفافية (CNNs)، وذلك بهدف الكشف الآلي عن الأجسام المغمورة في التربة التي على شكل تجاويف مملوءة بالهواء وتجاويف مملوءة بالماء. تم تدريب النموذج واختباره على مجموعة بيانات أنشئت في الدراسة باستعمال برنامج المحاكاة gprMax، وباستعمال حلقة تكبير بيانات مبنية على الشبكات التوليدية التنافسية (Generative Adversarial Nets (GANs)، كما واستُعملت قياسات ميدانية بجهاز رادار اختراق سطح الأرض GPR. حققت الدراسة F1-scor = 93.23% [10].

اقترح الباحث Su et al (2023) وزملاؤه نموذج تعلم عميق نوع End-to-End مبني على نموذج Key point-regression؛ من أجل كشف مواقع المرافق الخدمية المغمورة التي على شكل أنابيب (خرسانية ومعدنية)، مثل: انابيب الماء، والغاز، والنفط، والصرف الصحي، وذلك من صور GPR B-Scan. استُعمل في تحصيل البيانات جهاز رادار اختراق سطح الأرض GPR من النوع GSSI SIR4000 وبتردد 400MHz. حققت الدراسة ضبط Accuracy بقيمة 97.01% [11].

كشف الباحث Sun et al (2023) وزملاؤه آلياً عن القطوع الزائدة التي شكلتها جذور الأشجار في صور GPR B-Scan؛ وذلك باستعمال نموذج YOLO V5s. اعتمدت الدراسة على بيانات محاكاة، وبيانات حقيقية. في المحاكاة استُعملت ترددات العمل التالية لجهاز رادار اختراق سطح الأرض GPR:

500, 750, 1000) MHz، ثم حُدّد أفضل تَرَدّد يناسب الحالة المدروسة وهو 1 GHz، ثم استُعمل جهاز رادار

اختراق سطح الأرض GPR نوع EKKO PRO GPR عند التردد 1GHz في تحصيل البيانات الميدانية.

حققت الدراسة : ضبط $Accuracy = 96.7\%$ ، وقيمة استدعاء $Recall = 86.6\%$ ، وقيمة مؤشر $F1-Score = 88.1\%$ [12].

كشف الباحث (Liu et al (2023) وزملاؤه التصدّعات Cracks الداخلية في خرسانة الجسور؛ بهدف التقويم اللا إتلافي NDE للبنية التحتية لخطوط المواصلات؛ وذلك باستعمال نموذج YOLO v3-FDL بطبقات كشف ذات أربعة مقاييس (Four Scales-Detection Layer). استعملت الدراسة صور GPR B-Scan، وصور¹ GPR C-Scan، وقد حققت الدراسة قيمة مؤشر $F1-Score = 88.1\%$. استعملت الدراسة بيانات محاكاة، وبيانات حقيقية باستعمال جهاز رادار اختراق سطح الأرض GPR ذي نظام كشف ثلاثي الأبعاد 3D [13].

كشف الباحث (Liu et al (2023) وزملاؤه آلياً عن التصدّعات الداخلية في أسفلت الطرقات من صور GPR B-Scan؛ بهدف التقويم اللا إتلافي NDE للطرقات؛ لتحديد فيما إذا كانت بحاجة للصيانة أم لا؛ وذلك باستعمال نموذج Mask R-CNN (Mask Region-based Convolutional Neural Network) حُسن في الدراسة، وحقق النموذج: دقة $Precision = 0.833$ كما حقق قيمة مؤشر $F1-Score = 0.824$. استعملت الدراسة بيانات محاكاة وبيانات حقيقية؛ باستعمال جهاز رادار اختراق سطح الأرض GPR من النوع Geo-Scope TM MKIV؛ إذ استُعملت الترددات الآتية: (0.3, 0.6, 0.9, 1.6, 2, 3) GHz [14].

هناك عديد من الدراسات التي ناقشت ندرة توفر بيانات التدريب اللازمة لنماذج التعلم العميق في مجال تقانة رادار اختراق سطح الأرض GPR، وبَيّنَت أن بيانات التدريب المستعملة عادةً ما تكون مكوّنة من مجموعة محدودة نسبياً من البيانات الحقيقية المحصّلة بأجهزة رادار اختراق سطح الأرض GPR. لقد أكدت هذه الأبحاث إمكانية استعمال الصور المحاكاة كبيانات تدريبية، ومع ذلك لا تزال الحاجة موجودة لتنوّع البيانات التدريبية اللازمة؛

¹ GPR C-Scan: الصور المحصلة بجهاز GPR من النوع Cross sectional- Scan (مسح مقطعي عرضي).

للحصول على نماذج قوية في الكشف عن الأهداف المظمورة؛ باستعمال صور رادار اختراق سطح الأرض GPR.

اعتمد الباحث (Pham et al (2018) وزملاؤه على نموذج Faster R-CNN، للكشف عن بصمة القطع

الزائد في صور GPR B-Scans، واستعمل برنامج المحاكاة gprMax لإنشاء صور GPR محاكاة بتكوينات مختلفة للأهداف المظمورة؛ بهدف حل مشكلة قلة توفر مجموعات البيانات الحقيقية [15].

استعمل الباحث (Yue et al (2021) وزملاؤه نموذج Least Square GAN (LSGAN) لتوليد صور

GPR، بهدف معالجة ندرة بيانات رادار اختراق سطح الأرض GPR المعلّمة، وارتفاع تكاليف الحصول عليها، وللمقارنة استُعمل نموذج YOLO4 حيث تُرَب في المرة الأولى على كشف حديد التسليح من صور GPR؛ باستعمال 500 صورة GPR B-Scan حقيقية لخرسانة مباني سكنية تحتوي على حديد تسليح، ثم أُعيد التدريب على الصور التي ولدت من نموذج LSGAN، وبالمقارنة فقد تحسنت قيمة الدقة (Precision (Pre؛ بمقدار 10%. بالمجمل حققت الدراسة $Pre = 95.9\%$ [16].

استعمل الباحث (Zhang et al (2021) وزملاؤه شبكات GANs من أجل توليد بيانات اصطناعية لرادار

اختراق سطح الأرض GPR لاستعمالها كمجموعات تدريب بهدف؛ معالجة مشكلة ندرة توفر هذه البيانات، ولاستعمال هذه البيانات في تدريب نموذج تعلم عميق للكشف الآلي عن الأجسام المظمورة بتشكيلات متنوعة. حقق النموذج متوسط دقة mean Average Precision قدره $mAP = 0.97$ [17].

مما سبق ذكره، فقد اعتمدت الدراسات السابقة أساليب مختلفة؛ بهدف الكشف الآلي عن القطع الزائد الناتج عن الأهداف المظمورة في صور GPR B-Scans، كما اعتمدت على نماذج تعلم عميق جاهزة استُعملت في الدراسة إمّا بصورة مباشرة أو بعد إدخال تحسينات على هذه النماذج، ومن أجل الحصول على مجموعة البيانات Dataset اللازمة لتدريب نموذج الكشف، فإن بعض الدراسات استعملت صور GPR محاكاة، وبعضها الآخر اعتمد على صور حقيقية؛ فضلاً عن صور المحاكاة؛ ومن ثمّ كان لكل دراسة مجموعة بيانات Dataset خاصة بها. لكن

سلبية هذه الدراسات أنها أنشأت مجموعة البيانات (سواء بالمحاكاة أو بالقياسات الميدانية)؛ باستعمال نوع معين لجهاز GPR، وفي وسط طمر من نوع واحد؛ وباستعمال عدد قليل من الترددات لجهاز رادار اختراق سطح الأرض GPR. أكدت الدراسات السابقة أن هناك نقصاً في مجموعة البيانات اللازمة لتدريب نماذج التعلم العميق؛ بسبب ندرة توفر البيانات الحقيقية المحصلة برادار اختراق سطح الأرض GPR التي شرحها خبراء في هذا المجال (Annotated data)، كما أن الحصول على صور معلّمة Labeled GPR images غير متاح دوماً.

بُني في هذا البحث نموذجٌ لكشف الأهداف المطمورة؛ بالاعتماد على صور GPR B-Scan استناداً إلى الشبكات العصبونية الالتفافية CNNs، يتّسم بعدم التعقيد، وبعدم الاعتماد على نماذج التعلم العميق الجاهزة والمتوفرة على الإنترنت، وكذلك أنشئ قاعدتا بيانات خاصة بالبحث: واحدة لتدريب نموذج الشبكة العصبونية الالتفافية CNN والثانية لاختباره. تتسم قواعد البيانات هذه بشمولية الحالة المدروسة (أنابيب مطمورة في التربة) من حيث تتوّع أنواع الأنابيب المدروسة، وأقطارها، وعددها، وتتوّع الأوساط المطمورة فيها الأنابيب. ففي أثناء محاكاة عملية كشف الأجسام المطمورة بجهاز رادار اختراق سطح الأرض GPR (وذلك باستعمال برنامج gprMax)، استُعملت ترددات عمل مختلفة لجهاز رادار اختراق سطح الأرض GPR ضمن المجال الترددي [100, 1000] MHz، ومن أجل الصور GPR B-Scan الحقيقية، اعتمد على الصور المتوفرة في قاعدة البيانات TU1208 والمحصلة بثلاثة أنواع مختلفة من أجهزة رادار اختراق سطح الأرض GPR عند ترددات عمل مختلفة لهذه الأجهزة ضمن المجال [200, 900] MHz وبأوساط طمر مختلفة، سواء كانت الصور B-Scan ملونة RGB Scale أو بالمجال الرمادي Gray Scale.

3.1 مشكلة البحث:

التعرّف بصورة دقيقة على الأهداف المظمورة من خلال صور رادار اختراق سطح الأرض GPR يظل مهمة صعبة تعتمد بصورة كبيرة على خبرة العامل البشري؛ ومن ثمّ قد تكون النتائج غير موثوقة، كما تحتاج لعمل شاق ووقت طويل للتفسير. وهذا يحذّر من اتخاذ القرار السريع في ضرورة الصيانة، وإعادة التأهيل عندما يستعمل رادار اختراق سطح الأرض GPR في التقويم اللا إتلافي وكمثال: التقويم اللا إتلافي لخرسانة الجسور، والمباني السكنية، والرصيف الأسفلتي للطرق.

إن بصمة القطع الزائد في صورة رادار اختراق سطح الأرض GPR المنعكسة عن الهدف المظمور قد تكون غير واضحة؛ وذلك بسبب:

- الضجيج Noise في الصور المحصّلة، والنتائج عن جهاز رادار اختراق سطح الأرض GPR، والبيئة المحيطة بمنطقة العمل.
- الكشّرات Clutters في الصور المحصّلة، والنتائج عن عدم تجانس التربة أو وجود طبقات عدّة تحت سطح الأرض ذات سماحية كهربائية نسبية مختلفة فيما بينها.
- قد يكون التباين في السماحية الكهربائية النسبية بين الهدف المظمور (غير المعدني) والوسط المحيط به صغيراً أو قد يكون الهدف المظمور صغير الأبعاد؛ مما يجعل الأمواج الكهرومغناطيسية EMS المنعكسة عنه ضعيفة.
- قد يكون معامل تخامد الأمواج الكهرومغناطيسية EMS في أثناء انتشارها في الوسط المحيط بالأجسام المظمورة كبيراً؛ مما يجعل الأمواج الكهرومغناطيسية EMS المنعكسة عن الهدف المظمور ضعيفة.

4.1 هدف البحث:

يهدف البحث إلى مساعدة مستثمر الجهاز في التغلب على صعوبة كشف الأهداف المغمورة في صور رادار اختراق سطح الأرض GPR، وذلك عن طريق الكشف الآلي عن بصمة القطع الزائد المنعكس عن الهدف المغمور (أنابيب مغمورة في التربة كحالة دراسية) في صورة GPR B-Scan باستعمال الشبكات العصبونية الالتفافية CNNs.

5.1 أهمية البحث:

في السنوات الأخيرة اكتسبت تقانة رادار اختراق سطح الأرض GPR شهرة واسعة كتقانة لإتلافية NDE في الكشف عن الأهداف المغمورة. إذا تم التعرف آلياً إلى بصمة القطع الزائد للأهداف المغمورة في الصور المحصلة فإن هذا سيسهل على مستثمر جهاز رادار اختراق سطح الأرض GPR فهم نتيجة بياناته؛ ومن ثم يقلل من الاعتماد على الخبرة البشرية في تفسير بيانات رادار اختراق سطح الأرض GPR؛ مما سيؤدي إلى تقليل التكلفة المالية والزمن اللازم لتفسير بيانات رادار اختراق سطح الأرض GPR؛ ومن ثم تحسين مجالات استعمال هذه التقانة.

6.1 مسوغات البحث:

تفسير محتوى الصور المحصلة باستعمال جهاز رادار اختراق سطح الأرض GPR؛ بهدف كشف الأجسام المغمورة، يظل مهمة صعبة تعتمد بشكل كبير على خبرة العامل البشري، وطالما أن هذه النتائج تعتمد على الإنسان؛ فيمكن أن تكون غير موثوقة، وعرضة للأخطاء في الكثير من الأحيان، كما وتحتاج لعمل شاق ووقت طويل للتفسير، الأمر الذي يتطلب البحث عن طريقة أكثر موثوقية، وأقل تكلفة واستهلاكاً للوقت؛ للكشف وبشكل آلي عن الأجسام المغمورة في الصور المحصلة باستعمال جهاز رادار اختراق سطح الأرض GPR.

7.1 محددات البحث:

أبرز التحديات التي تواجه تصنيف صور رادار اختراق سطح الأرض GPR؛ بهدف كشف وجود أهداف مطمورة فيها أو عدم وجودها هو ندرة البيانات المتوفرة والتي شرحها الخبراء في هذا المجال، والصعوبة في الحصول على ما هو متوفر.

8.1 حدود البحث:

- **الحد المكاني:** أُجريت الدراسة في قسم هندسة الإلكترونيات والاتصالات - كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق.

- **الحد التقني:** جرى تنفيذ تصوّرات محاكاة عملية كشف الأجسام المطمورة باستعمال جهاز رادار اختراق سطح الأرض GPR، وبناء وتدريب نموذج الشبكة العصبونية الالتقافية CNN المقترح؛ باستعمال حاسوب بالموصفات الآتية: Intel(R) Core (TM) i3-5005U CPU@2.00 GHZ ,RAM 4 GByte

- **الحد العلمي:** جرى اتباع المنهج التحليلي / التجريبي.

- **الحد الزمني:** استغرق تنفيذ البحث مدة عام وشهر اعتباراً من تاريخ صدور قرار رئاسة جامعة دمشق بالموافقة على تسجيل موضوع البحث: رقم /2010/، تاريخ 2022-05-29.

9.1 منهج البحث وأدواته:

استُخدم المنهج التحليلي/ التجريبي؛ بوصفه أكثر المناهج استعمالاً، وأكثرها مناسبة لموضوع البحث، واعتمد في جمع البيانات على الأدوات الآتية:

- مصادر البيانات الأولية هي صور GPR B-Scan الحقيقية باستعمال مواقع الإنترنت، وقاعدة البيانات TU1208، وصور GPR B-Scan المحاكاة التي تم محاكاتها باستعمال برنامج المحاكاة gprMax
- مصادر البيانات الثانوية كالكتب والأبحاث المنشورة في مجال البحث.
- البرامج الحاسوبية اللازمة لإجراء عملية محاكاة كشف الأهداف المظمورة بجهاز رادار اختراق سطح الأرض GPR، والبرامج الحاسوبية اللازمة لبناء النموذج المقترح.

10.1 بنية الرسالة:

قُسم البحث إلى أربعة فصول متنوعة، فقد أُشير في الفصل الأول إلى الإطار العام المتضمن: المقدمة، والإشكالية البحثية، والفرضيات، والهدف، والأهمية؛ ومحددات وحدود البحث، مع استعراض لأبرز الدراسات المرجعية السابقة ذات الصلة بالموضوع، كما أُشير إلى منهج البحث المتبع، والأدوات المستعملة.

يعرض الفصل الثاني مبدأ عمل رادار اختراق سطح الأرض GPR في الكشف عن الأهداف المظمورة في التربة، وأنواع الصور المحصلة؛ باستعمال جهاز رادار اختراق سطح الأرض GPR؛ إذ ركّز على الصور المحصلة من النوع B-Scan (المسح السطوعي) وما تحتويه من بصمة قطع زائد ناتجة عن انعكاس الأمواج الكهرومغناطيسية عن الهدف المظمور، وما تحتويه من معيقات، وأهمها الكثرات Clutters، كما تم التحدّث عن العوامل التي تؤثر في وضوح بصمة القطع الزائد في صور GPR B-Scan.

يعرض الفصل الثالث مبدأ الشبكات العصبونية العميقة (DNNs) Deep Neural Networks؛ وذلك بدءاً من العصبون، ووظائف التنشيط شائعة الاستعمال؛ وصولاً إلى الشبكات العصبونية الالتفافية CNNs، ومعمارياتها، وآلية عملها، وآلية تدريب الشبكة العصبونية الصناعية (ANN) Artificial Neural Network، والموسطات الفائقة عند تدريب نماذج التعلم العميق، وتوابع الخطأ شائعة الاستعمال في نماذج التصنيف، كما وقُدّم

شرحاً مبسطاً لأهم خوارزميات الأمثلة المستعملة في الشبكات العصبونية العميقة، وتحديث عن مفهوم التعميم في التعلم العميق، وأهم طرائق التنظيم المتبعة للتقليل من مشكلة الإفراط في التعلم Overfitting.

ضمّ الفصل الرابع مراحل الدراسة التي أُنجزت لإنشاء وتدريب نموذج التصنيف المقترح؛ بدءاً من محاكاة عملية كشف الأنابيب المطمورة في التربة باستخدام جهاز GPR، ثم إنشاء مجموعة البيانات اللازمة لتدريب النموذج واختباره، إلى بناء نموذج التصنيف المقترح المبني على الشبكة العصبونية الالتفافية CNN، والموسطات الفائقة المستعملة في تدريب النموذج، والأدوات البرمجية والعتادية التي استُعملت في بناء نموذج التصنيف المقترح وتدريبه، كما ويستعرض مقاييس الأداء لنماذج التصنيف، والنتائج التي حُصلَ عليها من تدريب واختبار نموذج التصنيف المقترح؛ باستعمال نوعين من خوارزميات الأمثلة، وعلى مجموعة بيانات التدريب وبيانات الاختبار نفسها، واختيار الخوارزمية الأفضل بناءً على النتائج الأفضل، ومقارنة هذه النتائج بالمصنّعات التي اعتمدتها الدراسات السابقة، كما استعرض هذا الفصل الاستنتاجات، وخاتمة البحث، وأبرز التوصيات، والمقترحات.

الفصل الثاني

مبدأ عمل تقانة GPR في كشف

الأجسام المظمورة

**The Principle of GPR Technique
in Buried Objects Detection**


1.2 تمهيد:

تعتمد تقانة GPR بصورة أساسية على الاختلاف في السماحية الكهربائية النسبية Dielectric Permittivity بين مكونات وسط الانتشار تحت سطح الأرض، والهدف المظمور المطلوب كشفه.

سيُشرح في هذا الفصل مبدأ عمل تقانة GPR في الكشف عن الأهداف المظمورة في التربة، وأنواع الصور المحصلة من جهاز GPR، والعوامل المؤثرة في وضوح بصمة القطع الزائد المنعكس عن الهدف المظمور في الصور المحصلة بجهاز GPR.

2.2 مبدأ عمل تقانة GPR:

يتكون جهاز GPR من مرسل راديوي، ومستقبل، ووحدة معالجة وإظهار؛ لمعالجة البيانات المحصلة، وعرضها على شكل صور رقمية، كما يوضح الشكل (2-1)[18].




الشكل (2-1): مكونات جهاز GPR [18].

في أثناء عملية الكشف عن الهدف المظمور، يُمرّر جهاز GPR فوق المنطقة المراد كشف الأهداف المظمورة فيها إما من قبل عامل خبير باستعمال الجهاز، أو باستعمال عربة متحركة، كما هو موضح بالشكل (2-2).

1.2.2 المسح المطالي (A-Scan):


في كل موقع لجهاز GPR على خط المسح تُرسل أمواج كهريطيسية EMS عن طريق هوائي الإرسال المناسب للمجال الترددي المستعمل باتجاه الأرض، تنتشر EMS في الوسط تحت سطح الأرض، وتعاني من ظواهر عدة تضعف الأمواج الكهريطيسية EMS، أهمها: التخماد Attenuation، والامتصاص Absorption، والانتثار scattering.



الشكل (2-2): تحصيل البيانات بواسطة GPR [18].

عند وجود اختلاف في السماحية الكهربية النسبية ϵ_r بين الهدف المظموّر والوسط المحيط به، تنعكس EMS باتجاه هوائي الاستقبال لجهاز GPR، فإذا كانت شدة EMS الواردة أعلى من عتبة حساسية المستقبل، تُكشف، ويُقاس مطال الإشارة المستقبلة كدالة في الزمن (كلما زادت حساسية المستقبل، وكذلك استطاعة المرسل، سيزداد عمق الاختراق الأعظمي الذي يمكن تحقيقه بجهاز GPR). تدعى هذه الإشارة الناتجة: المسح المطالي A-Scan، كما هو موضّح في الشكل (2-3). تُسجّل وحدة المعالجة لجهاز GPR قيمة A-Scan المستقبلية في الموضع الحالي لجهاز GPR على سطح الأرض.

بنية المسح A-Scan تتأثر بقوة بالوسط الذي تنتشر فيه EMs، فإذا كان هذا الوسط يحتوي مناطق ذات خصائص كهربية متفاوتة فيما بينها فإن المسح A-Scan سيحتوي على انعكاسات EMs معقدة (تسمى بالكشترات Clutters) [19] فضلاً عن انعكاسات EMs عن الهدف المظمو.



الشكل (2-3): الإشارة الناتجة عن المسح من النوع A-Scan [22].


2.2.2 المسح النصوعي (Brightness-Scan (B-Scan):

عندما يتحرك جهاز GPR فوق الهدف المظمو وعلى خط مستقيم (والذي يدعى بخط المسح) وبخطوات مسح متتالية، يتم في كل موضع جديد لـ GPR الحصول على مسح A-Scan جديد، ثم تدمج وحدة المعالجة لجهاز GPR مجموعة عمليات المسح A-Scans؛ للحصول على صورة رقمية ثنائية البعد، تدعى الصورة المحصلة من هذا المسح GPR B-Scan image. تمثل هذه الصورة مقطعاً رأسياً للأرض التي تُمسح على طول خط المسح لـ GPR وتعدّ وسيلة أكثر فاعلية من المسح A-Scan في توصيف البيانات للأهداف المظمو في الأرض [20].

في صور GPR B-Scan تُمثل المسوحات A-Scan المسجلة في كل موضع لـ GPR على خط المسح بشدة سطوع لعناصر الصورة (بحيث يكون السطوع في الصورة متناسباً مع مطال A-Scan المستقبلية) في الموضع المقابل لها في الصورة الرقمية المحصلة، كما يُعرض زمن انتشار الأمواج الكهربية EMs من جهاز GPR

وإليه؛ مقابل موضع جهاز GPR على سطح الأرض، ويُمثَّل تغيُّرُ صفحة الإشارة المستقبلية عن المرسل بتدرج سطوح أما بالمجال الرمادي (Gray scale) أو بالمجال الملون (صور ملونة RGB):

في الصورة GPR B-Scan ذات المجال الرمادي، يتم تمثيل تغيُّر صفحة الإشارة المستقبلية كما يلي: يُمثَّل المطال الأعظمي الموجب للإشارة المستقبلية في الصورة المحصلة باللون الأبيض، والمطال الأعظمي السالب للإشارة المستقبلية باللون الأسود، ومن ثم فإن القيم للإشارة المستقبلية التي تقع بين القيم الأعظمية المذكورة، يُعبَّر عنها بتدرج الرمادي كما هو موضح في الشكل (4-2). بنفس الأسلوب يتم تمثيل تغيُّر صفحة الإشارة المستقبلية بتدرج الألوان في الصورة GPR B-Scan الملونة. يستند تفسير بيانات GPR في أغلب الدراسات إلى معلومات المسح من النوع B-Scan، وهذا ما سيعتمد في هذا البحث. يبين الشكل (4-2) مثلاً لصورة محاكاة من النوع B-Scan.




الشكل (4-2): صورة بالمجال الرمادي ناتجة عن المسح من النوع B-Scan [20].

3.2.2 المسح المقطعي العرضي (Cross sectional-Scan (C-Scan):

ويتم كالآتي: بداية يرسم العاملون على جهاز GPR شبكة المسح على سطح الأرض المراد سبرها، بحيث تكون الأبعاد بين خطوط المسح مساوية لأبعاد الهوائي المستخدم لجهاز GPR، والذي بدوره تتعلق أبعاده مع التردد الذي


سيتم استخدامه في جهاز GPR. ويُمرّر جهاز GPR على خطوط المسح؛ وفق الشبكة المرسومة ذهاباً وإياباً، وبغاية من قبل المستثمر، وبعد أن يُحصل على مجموعة البيانات B-Scans في شبكة الخطوط المستقيمة التي تغطي كامل المنطقة المطلوب سبرها، تُدمج جميع البيانات المحصلة بواسطة معالج جهاز GPR. عند كل مستوي زمن (يمثل عمق طمر محدد) يُحصل على صورة تدعى GPR C-Scan image، كما يوضح الشكل (2-5).



الشكل (2-5): المسح من النوع C-Scan [21].

3.2 النموذج الرياضي لبصمة الهدف المظموّر المنعكسة في الصورة من النوع B-Scan:

بفرض هدف مظموّر موجود في تربة متجانسة (وسط انتشار تحت سطح الأرض غير معقّد)، فإنه في أثناء المسح B-Scan يتحرك هوائي GPR في اتجاه واحد على سطح الأرض المطلوب مسحها وعلى خط مستقيم، في أثناء حركة GPR سيختلف طول مسار رحلة EMs من GPR إلى الهدف المظموّر (يشار إلى هذا المسار عند كل موضع x_i لجهاز GPR على سطح الأرض بـ z_i) بطريقة منتظمة. الشكل الرياضي في الصورة والنتائج عن انعكاسات EMs عن الهدف المظموّر هو قطع زائد [22] معادلته تربط الموقع المكاني رقم i لهوائي GPR (x_i)، مع زمن سفر EMs رقم i (t_i)، كما هو موضّح في الشكل (2-6).



الشكل (6-2): القطع الزائد الناتج عن الهدف المظمو في صور GPR B-Scan.

من الشكل (6-2) نستطيع كتابة العلاقة الآتية:

$$z_i^2 = z_o^2 + x_i^2 \quad (1-2)$$

إذ إن: $z_o = v \frac{t_o}{2}$, $z_i = v \frac{t_i}{2}$ ؛ وبالتعويض في العلاقة (1-2) نحصل على العلاقة التالية:

$$t_i = \left(\frac{4x_i^2}{v^2} + t_o^2 \right)^{1/2} \quad (2-2)$$

إذ إن:

v : سرعة EMs في الوسط المدروس (التربة المدروسة) بحيث: $v = \frac{c}{\sqrt{\epsilon_r}}$.

c : سرعة الضوء في الخلاء $3 \cdot 10^8$ m/sec.

ϵ_r : السماحية الكهربائية النسبية لوسط الانتشار (التربة).

(x_0, t_0) : تمثل إحداثيات قمة القطع الزائد؛ وبالتالي فهو يمثل عمق الهدف المظمو، وموضعه.

z_0 هو أقصر مسار سفر لـ EMS والذي يوافق الموضع x_0 لجهاز GPR على سطح الأرض؛ وبالتالي فهو يمثل تقدير العمق للكائن المظمو.

إنَّ المعادلة (1-2) هي معادلة قطع زائد Hyperbola؛ ومن ثَمَّ فإنه في المسح B-Scan عندما يتحرك GPR فوق الهدف المظمو على خط مستقيم وبخطوات متناسقة، فإن اختلاف أزمنة وصول الموجة المنعكسة عن الهدف المظمو يشكل قطعاً زائداً في صور GPR؛ ومن ثَمَّ فإن كشف الهدف المظمو يمكن النظر إليه على أنه كشف بصمة القطع الزائد المنعكسة عنه في صور B-Scan GPR المحصلة.

4.2 محتويات الصور GPR B-Scan:


تحتوي صور GPR B-Scan عادة على بصمة القطع الزائد GPR Hyperbola الناتج عن انعكاسات الأمواج الكهرومغناطيسية EMS عن الهدف المظمو، وعلى الموجة المباشرة Direct wave، وعلى ضجيج الخلفية Background noise. وحسب البيئة الجيولوجية المدروسة يُمَيَّز نوعان من خلفيات الصورة المحصلة:

- **خلفية بسيطة Simple Background:** تنتج عن مشاهد جيولوجية بسيطة. مثالها هدف واحد موجود في تربة متجانسة (بتوزيع موحد).

- **خلفية معقدة Complex Background:** تنتج عن مشاهد جيولوجية معقدة. مثالها هدف واحد موجود في وسط انتشار مكون من طبقات مختلفة بالسماحية الكهربائية النسبية، أو وجود أكثر من هدف مظمو وبمسافات متقاربة؛ وهذا يسبب التداخل بين EMS المنعكسة عن الأهداف المظمو، أو أن تكون التربة غير متجانسة.

5.2 المكونات غير المرغوبة في صور GPR B-Scan:

يبين الشكل (7-2) أنواع الاشارات المختلفة المستقبلية بهوائي الاستقبال لجهاز GPR .



الشكل (7-2): الإشارات المرسلية والمستقبلية بجهاز GPR [21].

1.5.2 الموجة المباشرة Direct wave:

الناتجة عن تسرب الأمواج الكهرومغناطيسية EMS مباشرةً من المرسل للمستقبل عبر الهواء (Direct coupling)،

وكذلك عن انعكاس EMS عند اصطدامها بسطح الأرض الذي يفصل بين الهواء ووسط الانتشار (Ground

Reflection). تظهر الموجة المباشرة على شكل خطوط مستقيمة في الأسطر الأولى من الصورة GPR B-

Scan، تمتاز الموجة المباشرة بميزة المطال الكبير، وبحذفها تصبح معلومات القطع الزائد للهدف في الصورة أكثر

وضوحاً لأنها تكون طاغية عليه.

2.5.2 الكَشَرَات Clutters:

الناتجة عن انتشار EMS في البيئات الجيولوجية المعقدة، فعندما يحتوي وسط الانتشار على طبقات عدّة مختلفة

.

في السماحية الكهربائية النسبية، ستحدث انعكاسات متعددة لـ EMS عن الأسطح الفاصلة بين هذه الطبقات (Interface reflection). يظهر ال Clutters على شكل قطع خطية في كامل مساحة الصورة GPR B-Scan المحصلة [19].

3.5.2 الضجيج Noise:

وأهمه ضجيج المستقبل في GPR، والضجيج الناتج عن البيئة المحيطة، وعادة ما يكون على شكل ضجيج غاوسي.

6.2 العوامل المؤثرة في وضوح بصمة القطع الزائد الناتجة في صور GPR B-Scan:

1.6.2 تأثير التربة المحيطة بالأنايب المظمورة:

من ناحية انتشار EMS، فإن وسط الانتشار تحت سطح الأرض له الخصائص الكهرطيسية الآتية:

1.1.6.2 السماحية الكهربائية النسبية Dielectric Permittivity:

و يرمز لها ϵ_r ، وهي تشير إلى قابلية وسط الانتشار للسماح للحقل الكهربائي E بالنفوذ خلاله، ولها تأثير في سرعة EMS. ففي وسط انتشار ذي سماحية كهربائية نسبية ϵ_r تكون سرعة انتشار EMS فيه [21]:

$$v \simeq \frac{c}{\sqrt{\epsilon_r}}; c = 3 * 10^8 \text{ m/sec} \quad (3-2)$$

إن قيم ϵ_r تتراوح من 1 للهواء إلى 82 للماء؛ ومن ثم فإن سرعة EMS في الهواء $v = 0.3 \text{ m/nsec}$ ، وفي المواد الجيولوجية الأرضية في المجال $(0.05-0.15) \text{ m/nsec}$.

2.1.6.2 الناقلية الكهربائية النوعية Electrical conductivity:

ويرمز لها σ ، وتشير إلى قدرة وسط الانتشار على نقل الشحنات المتحركة من مكان لآخر، ولها تأثير في تخامد

الموجة في وسط الانتشار. تزداد σ للمادة بوجود الماء والأملاح فيها، وبوجود المواد ذات الموصلية الكهربائية

العالية. يبين الجدول (1-2) قيم السماحية الكهربائية النسبية والناقلية الكهربائية النوعية لبعض المواد الجيولوجية

المعروفة، وسرعة انتشار EMS في هذه الأوساط [22].

الجدول (1-2): قيم سرعة انتشار الأمواج الكهرومغناطيسية EMS في بعض المواد الجيولوجية المعروفة [22]:

المادة	سرعة EMS (m/nsec)	الناقلية الكهربائية النوعية (mS/m)	السماحية الكهربائية النسبية
الهواء	0.3	10^{-7}	1
ماء عذب	0.033	0.1-30	81
رمل جاف	0.122-0.173	0.0001-1	3-6
الاسمنت	0.134	-	5
الحصى	0.122	-	6
الخرسانة	0.067-0.15	-	4-20
البلاستيك	0.165	0.00134	3.3
الحديد	0	10^3-10^7	300

3.1.6.2 النفوذية المغناطيسية Magnetic Permeability:

ويرمز لها μ ، وهي تشير إلى قابلية وسط الانتشار لاكتساب المغنطة، ولها تأثير في تخامد الموجة في وسط

الانتشار. تزداد μ بوجود الصخور المغناطيسية والمواد المعدنية. عادة ما تُعدُّ مساوية 1 لأغلب المواد الجيولوجية،

وعليه يمكن عدُّ μ لا تؤثر في إشارات الـ GPR شرط أن المنطقة المدروسة لا تحتوي على مواد مغناطيسية.

2.6.2 انتشار الأمواج الكهرومغناطيسية EMs في الوسط تحت سطح الأرض:


تحدث ظواهر كهرومغناطيسية - فيزيائية مختلفة عند انتشار EMs في وسط الانتشار تحت سطح الأرض المكوّن من مواد مختلفة في الخصائص الكهرومغناطيسية، وتؤثر هذه الظواهر في عملية الكشف عن الأهداف المغمورة؛ باستعمال GPR، سنذكر أهم هذه الظواهر.

1.2.6.2 الانعكاس والانكسار Refraction & Reflection:

يوضح الشكل (8-2) عملية انعكاس EMs وانكسارها عند ورودها على السطح الفاصل بين مادتين مختلفتين بالسماحية الكهربائية [23].

وفقا لـ Snell's law، فإن معامل الانعكاس R على السطح الفاصل بين المادتين المختلفتين بالسماحية الكهربائية النسبية، يعطى بالعلاقة (4-2) [10]:

$$R = \frac{\sqrt{\epsilon_{r1}} - \sqrt{\epsilon_{r2}}}{\sqrt{\epsilon_{r1}} + \sqrt{\epsilon_{r2}}} \quad (4 - 2)$$



الشكل (8-2): الانعكاس والانكسار للأمواج الكهرومغناطيسية في وسط الانتشار تحت سطح الأرض [23].

من العلاقة (2-4)، فإن شدة EMS المنعكسة تزداد كلما زاد الاختلاف بين السماحية الكهربائية النسبية

للمواد على طرفي الحدّ الفاصل بينها؛ ومن ثمّ يزداد معه وضوح القطع الزائد الناتج في الصورة المحصلة.

بين الجدول (2-2) بعض القيم لمعامل الانعكاس على السطح الفاصل بين مادتين مختلفتين بالسماحية الكهربائية

النسبية. حتى يكون القطع الزائد في الصورة المحصلة واضحاً يجب أن يكون هناك فرق بقيم السماحية الكهربائية

النسبية بين الهدف المطمور والوسط المحيط به.

الجدول (2-2): قيم معامل الانعكاس على السطح الفاصل بين مادتين مختلفتين [23]:

Material 1	ϵ_{r1}	Material 2	ϵ_{r2}	Reflectivity (R)
Air	1	Dry Soil	5	-38%
Dry Soil	5	Wet Soil	25	-38%
Dry Soil	5	Rock	6	-5%
Wet Soil	25	Rock	6	34%
Water	80	Rock	6	57%
Ice	3	Water	80	-67%
Permafrost	6	Wet Soil	25	-34%

2.2.6.2 التخامد Attenuation:

عندما تنتشر EMS في وسط الانتشار تحت سطح الأرض، فإنها تعاني من التخامد؛ مما ينعكس سلباً على

وضوح بصمة القطع الزائد الناتج في الصورة المحصلة.

معامل تخامد EMS عند انتشارها في الوسط تحت سطح الأرض يُعطى تقريباً بالعلاقة (2-5) [21]:

$$\alpha \simeq \sqrt{\frac{\omega \mu \sigma}{2}}; \quad \omega = 2\pi f \quad (5-2)$$

حيث أن:

f : تردد العمل المستعمل لجهاز GPR.


σ : الموصلية الكهربائية لوسط الانتشار.

μ : النفوذية المغناطيسية لوسط الانتشار.

كلما زاد معامل التخماد α ازداد تخامد الأمواج الكهرطيسية EMS عند انتشارها في الوسط تحت سطح الأرض؛ ومن ثمّ معامل التخماد يؤثر في وضوح بصمة القطع الزائد الناتج في الصورة GPR B-Scan وعلى عمق الكشف الأعظمي لجهاز GPR.

3.2.6.2 الانتثار والامتصاص Scattering & Absorption:

يؤدي عدم التجانس لمادة وسط الانتشار إلى تشتت الموجة الواردة، كما أن وجود جزيئات الماء في تكوين مادة وسط الانتشار يسبب امتصاص EMS ذات الترددات العالية، ووجود بعض المواد المغناطيسية يؤدي إلى امتصاص EMS وتحويلها إلى طاقة حرارية. يوضح الشكل (2-9) خسائر التشتت.



الشكل (2-9): خسائر التشتت للأمواج الكهرطيسية عند مرورها في الأوساط غير المتجانسة.

3.6.2 نوع مادة الجسم المظموّر وشكله:

من المعلوم أن انعكاس الأمواج الكهريطيسية عن المعادن يكون كبيراً، وعليه ستكون بصمة القطع الزائد في الصورة المحصلة واضحة. أما في حالة الأجسام العازلة؛ فإن انعكاس الأمواج الكهريطيسية عنها يعتمد على الفرق في السماحية الكهريائية النسبية بينها وبين الوسط المحيط بها. ومن ثم يجب أن يكون هناك تباين كهريائي كافٍ بين الجسم المظموّر غير المعدني والوسط المحيط به، كما أن الأجسام المظموّرة ذات الأسطح المستوية والمنتظمة تعكس الأمواج أكثر من الأجسام المظموّرة ذات الأسطح غير المستوية أو الأسطح المتعرجة.

4.6.2 المواصفات الفنية لجهاز GPR:

ما يخص المرسل: الاستطاعة المرسلة والتردد المستعمل: كلما زادت الاستطاعة المرسلة؛ كلما زاد عمق الاختراق الأعظمي الممكن تحقيقه بجهاز GPR، وبالتالي زاد وضوح بصمة القطع الزائد الناتجة في الصور .GPR B-Scan

وما يخص المستقبل: حساسية المستقبل وعملية الترشيح المستعملة: كلما زادت حساسية المستقبل؛ كلما زاد عمق الاختراق الأعظمي الممكن تحقيقه بجهاز GPR، وبالتالي زاد وضوح بصمة القطع الزائد الناتجة في الصور .GPR B-Scan

ما يخص الهوائيات: كفاية الهوائيات المستعملة للمرسل والمستقبل (ربح الهوائي): كلما قل عرض المخطط الاشعاعي للهوائي؛ كلما قلّ عرض منطقة الكشف، وزاد معه انحناء بصمة القطع الزائد الناتجة في الصور .GPR B-Scan

من أهم المواصفات الفنية المذكورة سابقاً هو تردد المسح المستعمل Scanning frequency الذي يُختار من خلال اثنين من المتطلبات المتناقضة:

.

- عمق السبر الأعظمي: وهو أكبر عمق يمكن أن تقطعه EMS في التربة، بحيث إذا وجد هدف مطمور على هذا العمق، انعكست عنه، ووصلت إلى المستقبل بمستوى استطاعة يكون قادراً على كشف EMS المستقبل وإظهارها في الصورة المحصلة النهائية على شكل قطع زائد يمكن تمييزه.
- الدقة في كشف الأهداف المطمورة: وهي أصغر مسافة بين هدفين مطمورين بحيث يستطيع جهاز GPR تمييزهما كهدفين منفصلين، وليس كهدف واحد.

يُميز نوعان من الدقة المطلوبة في الكشف [7]: الدقة العمودية ΔZ الموضحة في العلاقة (2-6) والدقة الأفقية $\Delta \alpha$ الموضحة في العلاقة (2-7)، في كلا نوعي الدقة يُلاحظ أنه تزداد الدقة كلما زاد تردد العمل المستعمل.

$$\Delta Z \simeq \frac{C}{4 * f \sqrt{\epsilon_r}} \quad (6 - 2)$$

$$\Delta \alpha \simeq \frac{d * c}{2 * f \sqrt{\epsilon_r}} \quad (7 - 2)$$

أما عمق السبر الأعظمي يقل كلما زاد التردد المستعمل؛ بسبب ازدياد معامل التخماد α مع زيادة التردد.

الفصل الثالث

الشبكات العصبونية العميقة وتدريبها

Deep Neural Networks (DNNs) and its Training

1.3 تمهيد:

بعد دراسات وأبحاث مطوّلة أثّرت باكتشاف طريقة عمل المخ البشري من حيث قابلية التعلم، والتذكر، والقدرة على تمييز الأشياء واتخاذ القرارات؛ تمّ محاكاة طريقة عمل المخ بطريقة رياضية برمجية، وذلك عن طريق ما يسمى بالشبكات العصبونية الصناعية التي تتكون من وحدات بناء أساسية تدعى بالعصبونات Neurons.


سيُشرح في هذا الفصل آلية عمل الشبكات العصبونية الصناعية Artificial Neural Networks (ANNs)، وشرح أهمّ توابع التنشيط المستعملة في الشبكات العصبونية العميقة Deep Neural Networks (DNNs)، وشرح لآلية عمل الشبكات العصبونية الالتفافية CNNs. وسيُحدّث عن آلية تدريب ANNs، والموسطات الفائقة اللازمة لتدريب نماذج التعلّم العميق، وأهمّ توابع الخطأ المستعملة في نماذج التصنيف، وأهمّ خوارزميات الأمثلة المستعملة، ومفهوم التعميم عند تدريب نماذج التعلم العميق، وطرائق التقليل من الإفراط في التعلم Overfitting.

2.3 النموذج الرياضي للعصبون Neuron model:

يتم محاكاة عصبون متعدد المداخل، وذي مخرج وحيد بالنموذج الرياضي المبين في الشكل (3-1). يتكون النموذج من وحدات الإدخال، ومن جامع، ومن الاتصالات بين وحدات الإدخال، والجامع، ومن تابع تنشيط Activation Function. يوجد لكل اتصال بين وحدات الإدخال والجامع معامل يدعى بالوزن Weight.

تُجمّع نتائج ضرب كل مدخل x_i بالوزن المقابل له w_i على الاتصال بين هذا المدخل والعصبون، ثم يُضاف الانحياز bias إلى الناتج السابق، ليصبح بدوره دخلاً لتابع التنشيط الذي يرجع بدوره الناتج النهائي للعصبون على المخرج y . إذا مُثّلت المداخل بمتجه (Vector) الدخل x والأوزان بمتجه الوزن w ، وبالنظر إلى أنّ الانحياز هو: b ، فإن الخرج النهائي للعصبون هو قيمة عددية y تُعطى بالعلاقة (3-1) [24].

$$y = f(\underline{w} * \underline{x} + b) \quad (1-3)$$



الشكل (1-3): النموذج الرياضي للعصبون [24].

3.3 الشبكات العصبونية الصناعية (ANNs): Artificial Neural Networks


وهي نموذج رياضي يحاكي كيفية عمل الخلايا العصبونية البيولوجية في دماغ الإنسان؛ ومن ثمّ يحاكي عملية التعلم عند الإنسان. تتكون الشبكة ANN من عصبونات عدّة، منظّمة في طبقات ومتصلة فيما بينها [24]، بحيث يتصل كل عصبون في الطبقة مع جميع العصبونات في الطبقة التالية؛ لذلك تسمى بالشبكات كاملة الاتصال Fully Connected (FC).

تتكوّن الشبكة ANN من طبقة إدخال، وطبقة إخراج، ويوجد بينهما طبقة مخفية واحدة أو أكثر، ومع زيادة عدد الطبقات المخفية يُحصل على شبكات أعمق، لديها القدرة على حلّ مشاكل أكثر تعقيداً.

تُعدّ هذه الشبكات أساس التعلم العميق، وبنيتها موضّحة في الشكل (2-3)، ويمكن إدخال أنواع مختلفة من البيانات للشبكة: نصوص، وصور، وفيديو، وصوت.

منذ العقد الأول من القرن الحادي والعشرين حُسّن أداء المعالجات CPUs بصورة ملموسة عن القرن الفائت، كما تم توفير كمية كبيرة من البيانات على شبكة الإنترنت؛ مما سمح بإمكانية زيادة عدد طبقات الشبكات

العصبونية الصناعية. أدى تعدد الطبقات في الشبكات العصبونية إلى مفهوم التعلم العميق، والخوارزميات في هذه الشبكات تعالج البيانات في طبقات متعددة (طبقات عميقة)؛ ولهذا فقد سميت هذه الشبكات بالشبكات العصبونية العميقة (Deep Neural Networks (DNNs).



الشكل (2-3): الشبكة العصبونية الصناعية ANN كاملة الاتصال FC [24].

4.3 توابع التنشيط Activation Functions:

تابع التنشيط يقرر ما إذا كان يجب تنشيط العصبون أم لا، ويهدف إلى إدخال اللاخطية في ناتج العصبون. يجب أن يكون لتابع التنشيط في الشبكات العصبونية خصائص معينة، وهي:

- أن يكون غير خطي Nonlinear.
- أن يكون قابلاً للاشتقاق Differentiable: تُدرَّب الشبكات العصبونية الصناعية؛ باستعمال خوارزمية الانحدار المتدرج (الاشتقائي) Gradient Decent؛ لذلك يجب اشتقاق تابع التنشيط؛ وفقاً للدخل وهذا مطلب أساسي لتشغيل تابع التنشيط.
- أن يكون ذا طبيعة محدودة Bounded، لمنع حدوث مشكلة انفجار قيمة الخرج Explode.

هناك عددٌ من أنواع توابع التنشيط المستعملة في الشبكات العصبونية الصناعية. سيُتحدَّث فقط عن توابع التنشيط التي استُعملت في هذا البحث عند بناء نموذج الشبكة العصبونية الالتفافية المقترح.

1.4.3 تابع التنشيط ReLU:

ويدعى بالوحدة الخطية المصححة Rectified Linear Unit، ففي الشبكات العصبونية متعددة الطبقات تظهر مشكلة تلاشي الانحدار بصورة أكبر كلما زاد عدد الطبقات في الشبكة، وتابع التنشيط ReLU يتغلب على هذه المشكلة، مما يسمح للشبكة بالتعلم بصورة أسرع، وبأداء أفضل. يعرف هذا التابع، كما في العلاقة (2-3) [25].


$$f(x) = \begin{cases} 0 & \text{for } x \leq b \\ x & \text{for } x > b \end{cases} \quad (2-3)$$

حيث b : هي العتبة (الانحياز) التي يتم مقارنة الدخل معها، وعادة ما تكون صفراً، وعليه يحتفظ تابع التنشيط ReLU بالعناصر الإيجابية فقط، ويتجاهل جميع العناصر السلبية.

يُحسب مشتق تابع التنشيط ReLU، كما في العلاقة (3-3):

$$f'(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ 1 & \text{for } x > 0 \end{cases} \quad (3-3)$$


عندما يكون الإدخال سلبياً، سيكون مشتق تابع التنشيط مساوياً: 0، وعندما يكون الإدخال إيجابياً يكون مشتق تابع التنشيط مساوياً: 1. يبين الشكل (3-3) تابع التنشيط ReLU ومشتقه.



الشكل (3-3): تابع التنشيط ReLU ومشتقه [25].

2.4.3 تابع التنشيط Softmax:

يُحوّل هذا التابع مخارج الشبكة العصبونية إلى توزيعات احتمالية منفصلة. يكون موضع هذا التابع في الشبكات العميقة بعد طبقة الخرج. في مسائل التصنيف تكون القيم الناتجة عن عصبونات طبقة الخرج على هيئة أرقام $\hat{y}_i$ تمثل الفئات المتوقعة، ويحوّلها تابع التنشيط Softmax إلى توزيعة من الاحتمالات، ويضع قيم هذه الاحتمالات في متجه $\underline{p}$ يُستعمل بدوره كمخرج في مسائل التصنيف، لإيجاد الاحتمالات المتوقعة للفئات المختلفة. يبين الشكل (4-3) مبدأ عمل تابع التنشيط Softmax. لضمان اللاسلبية في مخارج النموذج النهائية، يُستعمل تابع أُسي على كل مخرج، تُحوّل بعد ذلك هذه القيم الجديدة بقسمة كل منها إلى مجموعها، حتّى إذا جمعنا هذه القيم الجديدة نحصل على 1، وهكذا أصبح لدينا تعيين المداخل x_i إلى احتمالات p_i ، وليس إلى فئات متوقعة $\hat{y}_i$.



الشكل (4-3): آلية عمل تابع التنشيط Softmax [26].

وهكذا يعطينا تابع التنشيط Softmax متجهاً $\underline{p}$ يمكن تفسير عناصره على أنها احتمالات مقدرة لكل

فئة، وبالنظر إلى قيمة الاحتمال الأكبر يمكن إرجاع الادخال إلى الفئة المقابلة لهذا الاحتمال.

عند استعمال هذا التابع يجب تحويل التسميات Labels في مجموعة بيانات التدريب إلى الترميز

الساخن الواحد One-hot-encoding.

يتم التعبير عن تابع التنشيط Softmax بالعلاقة الرياضية (4-3) [26].

$$p_i = \text{Softmax}(\hat{y}_i) = \frac{e^{\hat{y}_i}}{\sum_{i=1}^n e^{\hat{y}_i}} \quad (4-3)$$

n: عدد المخارج للشبكة العصبونية (عدد الأصناف الكلي).

$\hat{y}_i$: الفئات التي تنبأ بها نموذج التصنيف على طبقة الخرج، وذلك على هيئة أرقام.

i: رقم الفئة التي تنبأ بها نموذج التصنيف.


5.3 الترميز الساخن الواحد One-hot-encoding:

في الشبكات العصبونية العميقة DNNs، يُستعمل عادةً تابع التنشيط Softmax في طبقة الخرج، وإنّ استعمال

هذا التابع يستدعي تحويل التسميات في مجموعة بيانات التدريب إلى الترميز الساخن الواحد كما يأتي:

تحوّل التسميات Labels من الأرقام التي تمثل الصنف إلى متجه عدد عناصره مساوي لعدد الأصناف الموجودة

في بيانات التدريب، كما يوضّحه الشكل (5-3).



الشكل (5-3): مبدأ الترميز الواحد الساخن [24].

6.3 الشبكات العصبونية الالتفافية (CNNs) Convolutional Neural Network:

تُعدّ الشبكات العصبونية الالتفافية CNNs من أهم أنواع الشبكات العصبونية العميقة DNNs، وهي تشكل اللبنة الأساسية في بناء معظم نماذج التعلم العميق DL. في ANNs يتم توصيل جميع العقد (العصبونات) الخاصة بطبقة واحدة بجميع عقد الطبقة التالية، وكل اتصال له وزن والذي يجب أن توجده خوارزمية التعلم. يؤدي وجود طبقات مخفية متعددة إلى وجود عدد كبير جداً من الأوزان؛ مما يجعل عملية التعلم أكثر صعوبة، وتحتاج إلى المزيد من الوقت والموارد الحاسوبية (سرعة المعالجة والذاكرة المطلوبين).

حُلّت هذه المشكلة باستعمال CNNs، والتي هي فئة من الشبكات العصبونية أمامية التغذية تستعمل طبقات الالتفاف. يعتمد اسم هذه الشبكات على وظيفة رياضية تسمى الالتفاف؛ ومن ثمّ CNNs هي شبكات عصبونية تستعمل الالتفاف في طبقة واحدة على الأقل من طبقاتها؛ بدلاً من ضرب المصفوفات.

سيُدرس عمل الشبكة العصبونية الالتفافية CNNs من أجل دخل على شكل صور رقمية والذي ينطبق مع موضوع البحث.

1.6.3 عامل الالتفاف ثنائي الأبعاد Convolution 2D:

هو عملية تبدأ بمرشح (نواة) Krenel الذي هو عبارة عن مصفوفة صغيرة من الأوزان. ينزلق الـ Krenel على بيانات الدخل ثنائية الأبعاد (الصورة) وتُضرب عناصر Krenel بالعناصر المقابلة لها في جزء صورة الدخل الموجود عليها الـ Krenel حالياً، ثم تُجمع النتائج، وتوضع في العنصر الأول لمصفوفة تسمى خارطة الميزات Features map، كما هو موضّح في الشكل (3-6).


يكبر الـ Krenel هذه العملية في كل موقع له على صورة الدخل لنحصل من عملية التفاف الـ Krenel على كامل صورة الدخل على مصفوفة ثنائية البعد تسمى خارطة الميزات المقابلة لصورة الدخل.

.

تُحسب أبعاد مصفوفة خارطة الميزات كما يأتي [27]:

$$\text{الارتفاع} = (\text{ارتفاع الصورة المدخلة} - \text{ارتفاع الـ Krenel}) + 1.$$

$$\text{العرض} = (\text{عرض الصورة المدخلة} - \text{عرض الـ Krenel}) + 1.$$



الشكل (3-6): مبدأ عمل الالتفاف ثنائي الأبعاد [27].

إنَّ مرشح الالتفاف Krenel في أثناء التدريب يُعاد ضبط قيمه بعد كل Epoch. إذا كانت نتيجة الجداء

الداخلي للـ Krenel بجزء الصورة الممسوح كبير جداً هذا معناه أنه يوجد نسبة تطابق كبيرة بين المرشح وجزء


الصورة الممسوح، وعليه يمكن استعمال هذا الجداء لاختبار وجود أنماط معينة في الصورة، ولكن لا يمكن الاعتماد

على مرشحات معينة؛ لتحديد نمط في الصورة، لهذا تُطبَّق مرشحات عدّة على الصورة في الطبقة الالتفافية نفسها.

إن تدريب شبكة CNN يعني الحصول على قيم مصفوفات هذه المرشحات.

2.6.3 معمارية الشبكة العصبونية الالتفافية CNN:

يبين الشكل (7-3): معمارية الشبكة العصبونية الالتفافية [24].



الشكل (7-3): معمارية الشبكة العصبونية الالتفافية [24].

1.2.6.3 قسم استخراج الميزات Features extraction:

بالنظر إلى أنَّ الدخل صورة رقمية، فإن مهمة هذا القسم هو التعرف إلى الميزات المهمة في بكسلات صورة الدخل، وذلك عن طريق تنفيذ سلسلة من عمليات الالتفاف Convolution، والتجميع Pooling، بحيث تتعلم الطبقات الأقرب إلى الإدخال التعرف إلى الميزات البسيطة، مثل الحواف، وتدرج الألوان، بينما تتعلم الطبقات الأعمق التعرف إلى ميزات أكثر تعقيداً.

2.2.6.3 قسم التصنيف Classification:

عبارة عن شبكة متصلة بالكامل FC تعمل كمصنّف بعد خطوة استخراج الميزات، وهي تتوقع فئة الصورة بناءً على الميزات المستخرجة في الخطوات السابقة.

3.6.3 أنواع الطبقات في قسم استخراج الميزات:

1.3.6.3 طبقة الالتفاف Convolution:

تحتوي هذه الطبقة على مجموعة من المرشحات، يعرف المرشح باسم Krenel؛ إذ يُطبَّق كل مرشح على جميع مناطق الصورة المدخلة، وتتمثل المهمة الرئيسة لهذه الطبقة في تحديد الميزات الموجودة في المناطق المحلية لصورة الدخل، وينتج عن هذه الطبقة خارطة الميزات Features map.

إن لطبقة الالتفاف مجموعة محددة من المعاملات الفائقة، التي تحدد حجم الإخراج لخرائط الميزات، وتحدد عدد الاتصالات في الشبكة وهذه المعاملات هي:

- أبعاد مرشح الالتفاف Krenel: ويُعرّف الحقل الاستقبالي الذي سينزلق على جميع مواقع صورة الإدخال. زيادة هذا المعامل يسمح باستقبال المزيد من المعلومات المكانية من صورة الدخل، فنقل الدقة في الأداء للطبقة الالتفافية في استخراج الميزات لمصفوفات دخل الطبقة الالتفافية، كما يزيد في الوقت نفسه عدد معاملات الشبكة المطلوب تدريبها.

- عدد المرشحات الالتفافية: بزيادته يزداد عمق خرج طبقة الالتفاف (عدد خرائط الميزات الناتجة)، فتزداد الدقة في أداء الطبقة الالتفافية في استخراج الميزات لمصفوفات دخل الطبقة الالتفافية، كما ويزيد عدد أوزان الشبكة المطلوب تدريبها. إن كل مرشح التفاف سينتج خارطة ميزات منفصلة؛ ومن ثمّ نحصل على خرائط ميزات بعدد مساوٍ لعدد المرشحات.

- الخطوة Stride: إنّ الالتفاف عملية تراكمية تتم عن طريق الانزلاق للمرشح على صورة الإدخال، وتحدد الخطوة عدد وحدات البكسل التي ينتقل بها المرشح بين كل عمليتي انزلاق متتاليتين. وتنتج الخطوات الأكبر حجماً خرائط ميزات أصغر.

.

- الحشو Padding: بهدف منع فقدان المعلومات في الحواشي لصور الدخل؛ تُضاف مدخلات صفرية حول محيط الصورة، وعليه يُضاف إطار من البكسلات التي تحمل قيمة صفر تستعمل لعلاج المشكلتين الآتيتين:
- اضمحلال حجم الصورة تدريجياً عبر الطبقات الالتفاف المتعددة.
- البكسلات في أطراف الصورة لا تدخل في الحسابات إلا مرات قليلة.
- تابع التنشيط: عادة ما يُستعمل التابع ReLU كتابع تنشيط في الطبقات الالتفافية.


2.3.6.3 طبقة التجميع (الدمج) Pooling:

الوظيفة الأساسية لعملية التجميع هي خفض ناتج الطبقة الالتفافية على طول الأبعاد المكانية للارتفاع والعرض؛ مما يقلل من عدد المعاملات التي يجب أن تتعلمها الشبكة، فيقلل بالتالي من تأثير الإفراط في التعلم Over fitting. تتم عملية التجميع بعد عملية الالتفاف، والتجميع عبارة عن عملية اختزال لمجموعة من البكسلات المتجاورة في بكسل واحد. هذه المجموعة من البكسلات تسمى بمرشح التجميع Pooling Kernel، وعادة تُختار أبعاد مرشح التجميع 2×2 . طبقة التجميع تقيد في تقليل أبعاد خرائط الميزات؛ مما يقلل من قوة المعالجة المطلوبة لمعالجة مجموعة البيانات. التجميع له نوعان كما يوضحه الشكل (3-8) [24]:

- تجميع الحد الأقصى Max pooling: وهو النوع الأكثر استعمالاً وفيه تُختار القيمة العظمى فقط

ضمن مجال مرشح التجميع.

- تجميع المتوسط Average pooling: وفيه يُحسب متوسط القيم ضمن مجال مرشح التجميع.



الشكل (3-8): مبدأ عمل طبقة التجميع [24].

هناك معاملان فائقان لطبقة التجميع: أبعاد مرشح التجميع، وخطوة مرشح التجميع. الخيار شائع الاستعمال هو اختيار أبعاد مرشح التجميع 2×2 ، ويُنصح بعدم تكبير أبعاد مرشح التجميع كثيراً؛ لأن ذلك يسبب تجاهل كثير من المعلومات لطبقة الدخل، وتصبح عملية التجميع غير مفيدة. طبقات التجميع في الشبكة ليس لها وزن أو انحياز؛ لأنها فقط تستخرج القيم مثل الحد الأقصى.

3.3.6.3 طبقة التسطيح Flatten layer:

بعد انتهاء سلسلة الطبقات الالتفافية، وطبقات التجميع، وقبل إنشاء الطبقة كاملة الاتصال، يُصار إلى تحويل جميع خرائط الميزات إلى متجه واحد لأجل ربطه بالطبقة الكاملة الاتصال.

7.3 التصنيف Classification:

يُعدّ التصنيف في تعلم الآلة من قسم التعلّم الخاضع للإشراف، ويمكن تعريف التصنيف بأنه عملية تجميع الأشياء المتشابهة معاً؛ إذ يشترك جميع أعضاء المجموعة الواحدة أو الصنف الواحد الناتج عن التصنيف في خاصية محددة واحدة على الأقل لا يملكها أعضاء الأصناف الأخرى.

في التصنيف الخاضع للإشراف يتم بدايةً الحصول على ميزات Features؛ ممثلة لبيانات الدخل بصورة جيدة، وخلال عملية التدريب، يُغذى المصنّف ببيانات الدخل (الميزات Features)، وبالتسميات Labels المقابلة لها التي تمثل الفئات Classes، ويحاول المصنّف أن يتعلّم العلاقة الموجودة بين ميزات الدخل Features والتسميات المقابلة لها. يكون التصنيف بأحد الطريقتين:


- طريقة مباشرة: يُعطى في الخرج صنف الصورة المدخلة للنموذج بصورة مباشرة.
- طريقة غير مباشرة: يُعطى في الخرج مجموعة احتمالات للصور المدخلة للنموذج، والاحتمال الأكبر يمثل الصنف الذي تنتمي إليه الصورة فعلياً.

اقترح عددٌ من خوارزميات التصنيف التي تعتمد في عملها على الميزات التي تم حُصل عليها، ومن أبرز خوارزميات التصنيف:

خوارزمية آلة شعاع الدعم (Support Vector Machine (SVM، وخوارزمية أقرب الجيران K-nearest neighbors (KNN، والشبكات العصبونية الصناعية ANNs.

8.3 تدريب الشبكات العصبونية الصناعية ANNs:

يتكوّن التدريب في الشبكة العصبونية الصناعية المتعددة الطبقات من مرحلتين رئيسيتين: مرحلة الانتشار الأمامي Forward propagation، ومرحلة الانتشار الخلفي Backward propagation، كما يوضّحه الشكل (3-9).



الشكل (3-9): مراحل التدريب في الشبكات ANNs [24].

في أثناء عملية التدريب تكرر الشبكة هذه الخطوات، وتنفذها مرّات عدّة [24]:

- تُهيأ بدايةً معلمات التدريب (الأوزان والانحيازات) بقيم صغيرة بصورة عشوائية.
- مرحلة الانتشار الأمامي: تُولّد فيها المخارج؛ بناءً على القيم الحالية لمعاملات التدريب، وبيانات الدخل.
- مرحلة حساب الخطأ: يُحسب فيها الفرق بين المخارج الحالية (التي تنبأت بها الشبكة العصبونية) والمخارج المطلوبة (الأهداف)؛ وفق تابع الخطأ المختار.
- مرحلة الانتشار الخلفي: يُحسب فيها التدرّج (الانحدار) Gradient لتابع الخطأ عند معاملات التدريب الحالية للشبكة، لتنتشر الأخطاء التي حُصل عليها من طبقة الخرج إلى الطبقات السابقة في الشبكة، وباتجاه عكسي.

- مرحلة تحديث معلمات التدريب: تُحدّث خوارزمية الأمثلة معلمات التدريب بناءً على قيمة الخطأ الحالي بالاتجاه الذي يُقلّل فيه الخطأ في التكرار التالي.

9.3 تدريب نماذج التعلم العميق:

إن تدريب نموذج التعلم العميق DL Model يحتاج إلى المكونات الآتية:

مجموعة البيانات Dataset، المتوسطات الفائقة Hyper parameters، وتابع الخطأ Lose function، وخوارزمية الأمثلة Optimization algorithm.

1.9.3 مجموعة البيانات Dataset: في التعلم العميق، تشير البيانات Data إلى أجزاء مميزة من المعلومات

التي تُسَق، وتُخزَّن إلكترونياً؛ لتناسب غرض محدد، ويمكن أن تكون البيانات بأشكال عديدة؛ كالنصوص، والصور والصوت، والفيديو. مجموعة البيانات Dataset: هي مجموعة من البيانات Data لها الخصائص نفسها، وتُسمَّى كلُّ نقطة بيانات من مجموعة البيانات بـ مثال Example أو عينة Sample. غالباً ما تُمثَّل كلُّ نقطة بيانات بواسطة متَّجه مِيزة؛ إذ كل عنصر من عناصر هذا المتجه يمثل سمة من السمات المميزة لبيانات الدخل. في التعلم الخاضع للإشراف تتعلم الخوارزمية من مجموعة بيانات تسمى مجموعة بيانات التدريب، وهي عبارة عن مجموعة بيانات معلَّمة Labeled Dataset؛ إذ تكون مكوَّنة من أزواج: عينات، وأهداف (تسميات Labels) مقابلة لها. إنَّ كمية بيانات التدريب، وجودتها أمر بالغ الأهمية في دقَّة أداء نموذج التعلم العميق.

2.9.3 المتوسطات الفائقة Hyper parameters:

وهي المتغيرات التي تسمح لنموذج التعلم العميق بالتدرَّب، وتتحكم قيمها في عملية تعلم النموذج [24].

1.2.9.3 Epochs: الحقبات


عدد الحقبات هو معلمة فائقة يجب تحديدها خلال التدريب. حقبة واحدة تعني أن كل عينة في مجموعة بيانات التدريب قد أتاحت لها فرصة لتحديث معاملات التدريب للنموذج. تتكون الحقبة من دفعة واحدة Batch من عينات الدخل أو أكثر. عندما يكون عدد الحقبات مرتفعاً جداً، قد تحدث مشكلة الإفراط في التعلّم Overfitting.

2.2.9.3 Batch: حجم الدفعة


حجم الدفعة هو معلمة فائقة تحدّد عدد عينات الدخل التي يُعامل معها قبل تحديث معاملات تدريب النموذج. يمكن تقسيم مجموعة بيانات التدريب إلى دفعة واحدة أو أكثر.

3.2.9.3 Learning Rate: معدل التعلّم

يشير معدل التعلّم إلى المقدار الذي تُحدّث من خلاله معاملات التدريب للنموذج في أثناء التدريب الذي يُعرف باسم حجم خطوة التحديث t_k ، وهو أحد المتوسطات الفائقة المهمة المستعملة في تدريب الشبكات العصبونية. في نماذج التعلّم العميق، يكون هدف خوارزمية الأمثلة هو تحديث معاملات تدريب النموذج؛ بما يضمن تصغير تابع الخطأ. بفرض أن تابع الخطأ الذي يجب تصغيره هو $f(x)$ ؛ إذ x هو واحد من معاملات التدريب المطلوب تحديثها، فإذا استُعمل معدل تعلّم صغير جداً، سيكون حجم خطوة التحديث t_k صغيراً جداً؛ ومن ثمّ عدد التكرارات المطلوبة سيكون كبيراً، وسيؤدي ذلك إلى تحديث x ببطء شديد؛ بهدف تقليل قيمة $f(x)$ ؛ ومن ثمّ يستغرق التدريب وقتاً طويلاً كما يوضّحه الشكل (3-10). وعلى العكس إذا استُعمل معدل تعلّم مرتفع بصورة مفرطة، سيكون حجم خطوة التحديث كبيراً جداً، ولا يمكن ضمان أن تحديث x سيكون قادراً على خفض قيمة $f(x)$ فقد يتجاوز الحل الأمثل ويتباعد تدريجياً؛ أي ينتهي الأمر إلى الارتداد حول الحد الأدنى؛ ومن ثمّ لا يتم الوصول إلى المستوى الأمثل، كما يوضّحه الشكل (3-11).



الشكل (3-10): طريقة تحديث x عند استعمال معدل تعلّم صغير جداً [24].



الشكل (3-11): طريقة تحديث x عند استعمال معدل تعلّم مرتفع بصورة مفرطة [24].

إن الحصول على معدل تعلّم صحيح تماماً يُعدُّ أمراً صعباً، فإذا اختير صغيراً جداً سيحرز تقدماً ضئيلاً، وإذا اختير

كبيراً جداً، فإن التدريب يتذبذب، وفي أسوأ الحالات يتباعد عن المطلوب تحقيقه. من المستحسن أن تتناقص قيمة

معدل التعلم في أثناء التدريب، وهذا يؤدي إلى تحسين الدقة، وتقليل الإفراط في التعلّم Overfitting.

3.9.3 توابع الخطأ Lose Functions المستعملة في نماذج التصنيف:

1.3.9.3 تابع خطأ الأنتروبيا المتقاطعة Cross-Entropy Loss:

يُعيّن نموذج المصنّف وباستعمال تابع التنشيط Softmax في خرج كل متجه دخل $\underline{x}$ إلى متجه $\underline{\hat{y}}$ يضم قيم الاحتمالات المتوقعة لنوع الصنف، بعدها تُحسّن دقة هذا التعيين باستعمال تابع خطأ الأنتروبيا المتقاطعة كما يأتي:

يُمثّل متجه التسميات Labels (الأهداف المطلوبة) باستعمال الترميز الواحد الساخن One-hot encoding بالمتجه $\underline{y}^h$ ، ويُقارن بعدها التقديرات الاحتمالية الناتجة في خرج النموذج (عناصر المتجه $\underline{\hat{y}}$)؛ مع التقديرات المطلوبة والمُمثّلة بصيغة الترميز الواحد الساخن (عناصر المتجه $\underline{y}^h$)؛ وفق تابع خطأ الأنتروبيا المتقاطعة، كما بالعلاقة (5-3) [28].

$$\text{Cross Entropy}(\underline{y}^h, \underline{\hat{y}}) = -\frac{1}{n} \sum_{j=1}^n y_j^h \log \hat{y}_j \quad (5-3)$$

n: عدد مخارج الشبكة العميقة (عدد الفئات الكلي المطلوب تصنيف المداخل إليها).

y_j^h : العنصر رقم j في المتجه $\underline{y}^h$ الذي يحتوي على الأهداف المطلوبة Labels بصيغة One-hot encoding.

$\hat{y}_j$: العنصر رقم j في المتجه $\underline{\hat{y}}$ الذي يحتوي على المخارج التي توقعها النموذج، والتي هي قيم خرج تابع التنشيط Softmax.

نظراً لأن $\underline{y}^h$ متجه واحد ساخن بطول n، فإن المجموع على j سيختفي لجميع الحدود؛ باستثناء حد واحد يمثل الخطأ الموافق لفئة معينة. هذا الخطأ محدود من الأسفل بالقيمة 0، وكون $\underline{\hat{y}}$ هو متجه احتمالي فلا يوجد قيمة

لعنصره أكبر من الواحد؛ ومن ثم فإن سالب اللوغاريتم لا يمكن أن يكون أصغر من الصفر؛ ومن ثم قيم تابع خطأ الأنتروبيا المتقاطعة ستكون موجبة دائماً.

2.3.9.3 تابع الخطأ Binary Cross Entropy:

في حال المصنفات الثنائية يكون عدد الفئات $n = 2$ ، وفيها يُستعمل تابع الخطأ Binary Cross Entropy، ويُعرّف كما في العلاقة (6-3) [28].

$$\text{Binary Cross Entropy}(\underline{y}^h, \underline{\hat{y}}) = -\frac{1}{2} \sum_{j=1}^2 (y_j^h \log y_j^{\hat{}} + (1 - y_j^h)(\log(1 - y_j^{\hat{}}))) \quad (6-3)$$

4.9.3 خوارزميات أمثلة التعلّم العميق Optimization Algorithms:

هي الأدوات التي تسمح بمواصلة تحديث معلمات تدريب النموذج (الأوزان والانحيازات)؛ بهدف تقليل قيمة تابع الخطأ، ويؤثر أداء خوارزمية الأمثلة بصورة مباشرة في كفاءة تدريب النموذج، ووقت التدريب.

المطلوب من خوارزمية الأمثلة موارد ذاكرة أقل، وجعل النموذج يتقارب بصورة أسرع عن طريق ضبط معاملات التدريب بالصورة المثلى لتسريع عملية التعلّم.

سيُعرض في هذه الفقرة بعض أنواع خوارزميات الأمثلة؛ وذلك بفرض أن تابع الخطأ المطلوب تصغيره هو $f(x_k)$ ؛ إذ x_k هي قيمة معامل التحديث x في التكرار رقم k ، والتدرج المقابل لها هو $\Delta f(x_k)$ ، وحجم خطوة التحديث في التكرار رقم k هو t_k .

1.4.9.3 خوارزمية الانحدار المتدرج الدفعي (BGD) Batch Gradient Decent:

في هذه الخوارزمية، تُمرّر مجموعة البيانات بأكملها قبل إجراء تحديث واحد لمعاملات التدريب، عملياً هذا يسبب تقارباً للنموذج بصورة بطيئة للغاية. تُحدّث هذه الخوارزمية معامل التدريب x بعد أن تُدخل كل عينات مجموعة

التدريب إلى النموذج؛ أي بعد مسح كل مجموعة التدريب، كما في المعادلة (7-3) [24].

$$x_{k+1} = x_k - t_k \Delta f(x_k)^{(1:n)} \quad (7-3)$$

2.4.9.3 خوارزمية الانحدار المتدرج العشوائي (SGD) :Stochastic Gradient Decent

في هذه الخوارزمية تُتخذ خطوات التحديث بناءً على ملاحظة واحدة في كل مرة؛ أي بعد إدخال كل عينة i . إن معالجة عينة واحدة في كل مرة تستغرق وقتاً أطول بكثير؛ مقارنةً بالدفعة الكاملة. تحسب خوارزمية SGD التدرج وتُحدّث المتوسطات لكل عينة تدريب، كما في العلاقة (8-3) [24].

$$x_{k+1} = x_k - t_k \Delta f(x_k)^{(i)} \quad (8-3)$$

3.4.9.3 خوارزمية انحدار الدفعات الصغيرة المتدرجة (M-BGD) :Mini-Batch Gradient Decent

في هذه الخوارزمية، وبدلاً من أخذ دفعة كاملة أو أخذ عينة واحدة فقط، تؤخذ دفعة صغيرة Mini-batch من العينات حجمها m عينة، وذلك بهدف تحسين الكفاءة الحسابية للنموذج، يعتمد اختيار حجم الدفعة الصغيرة m على عوامل عدّة، مثل: مقدار الذاكرة، وحجم مجموعة البيانات.

تدمج هذه الخوارزمية مزايا الخوارزميتين SGD و BGD ، وتُحدّث معاملات التدريب بعد الحصول على التدرج

لمجموعة صغيرة من العينات، كما في العلاقة (9-3) [24].

$$x_{k+1} = x_k - t_k \Delta f(x_k)^{(i:i+m)} \quad (9-3)$$

نظراً لأنه في كل تكرار تُستعمل دفعة من البيانات، بدلاً من أخذ مجموعة البيانات بأكملها، فإننا نحتاج إلى عدد أقل من التكرارات.

4.4.9.3 خوارزمية الانحدار المتدرج مع الزخم :Gradient Decent with Momentum

الزخم Momentum هو إحدى الآليات المستعملة لتحديد اتجاه التحديث، وتخمين التذبذبات في أثناء عملية التدريب، يتم ذلك عن طريق إضافة جزء من متجه التحديث لخطوة التحديث الماضية إلى متجه التحديث الحالي، كما هو

.

موضّح في العلاقتين (10-3) و(11-3) [24].

$$v_k = m v_{k-1} + t_k \Delta f(x_k) \quad (10 - 3)$$

$$x_{k+1} = x_k - v_k \quad (11 - 3)$$

m : هو قيمة الزخم Momentum إذ $m \in [0, 1]$ وهو يحدد عدد التكرارات التي دُمجت فيها التدرجات السابقة في التحديث الحالي. بصورة عامة تُضبط m على 0.5 حتى يستقر التعلّم الأولي ثم يُزاد إلى 0.9 أو أعلى.

5.4.9.3 خوارزمية الخطوة التكيفية (Adaptive moment (Adam):

في خوارزمية SGD تُحدّث كلُّ موسطات التدريب في الشبكة العميقة، باستعمال خطوة تحديث ثابتة t_k ، أما في

الطرائق التكيفية يُكَيّف حجم الخطوة لكل معامل تدريب على حدة. ففي الأجزاء الأولى من الشبكة العميقة توجد

طبقات التقافية، عدد قنواتها قليل، وبأبعاد كبيرة للقناة، وفي الأجزاء الأخيرة للشبكة العميقة تكون الطبقات ذات قنوات أكثر، ولكن بأبعاد أصغر، وعليه، فإن العمليات تكون مختلفة في مختلف أجزاء الشبكة؛ لذا حجم خطوة التحديث قد يكون مناسباً في الأجزاء الأولى، وغير مناسب للأجزاء الأخيرة.

موسطات التدريب في الأجزاء الأخيرة من الشبكة لها تأثير كبير في مخرجات الشبكة؛ لذا تحتاج إلى معدل خطوة صغير، أما موسطات التدريب في الأجزاء الأولى في الشبكة يكون تأثيرها صغيراً في مخرجات الشبكة لذا تحتاج إلى معدل خطوة أكبر.

Adam هي خوارزمية تحسب حجم الخطوة التكيفية لكل معامل تدريب، وتُستعمل كلاً من متوسط التدهور للتدرجات السابقة، وقيمها التربيعية. تتكون قاعدة تحديث Adam من الخطوات الآتية [29]:

- بعد أن يُحصَل على $\Delta f(x_k)$ (تدرج تابع الخطأ لمعامل التدريب x في التكرار رقم k) تُحدّث قيمة اللحظة

الزمنية الأولى والثانية في هذه الخطوة k ، كما في العلاقتين (12-3) و(13-3).

$$m_k = \beta_1 m_{k-1} + (1 - \beta_1) \Delta f(x_k) \quad (12 - 3)$$

$$v_k = \beta_2 v_{k-1} + (1 - \beta_2)(\Delta f(x_k))^2 \quad (13 - 3)$$

إذ β_1, β_2 : معدّل الانخفاض الأسّي لتقدير اللحظة الأولى والثانية تُحدّد يدوياً.

- تُصحّح قيمة اللحظة الزمنية الأولى والثانية، كما في العلاقة (14-3).

$$\hat{m}_k = \frac{m_k}{1 - \beta_1^k}, \hat{v}_k = \frac{v_k}{1 - \beta_2^k} \quad (14 - 3)$$

- يُحدّث معامل التدريب x ، كما في العلاقة (15-3).

$$x_{k+1} = x_k - \frac{1}{\sqrt{\hat{v}_k} + \varepsilon} t_k \hat{m}_k \quad (15 - 3)$$

ε : عدد صغير يُدخل يدوياً؛ بهدف تجنب القسمة على صفر. عادةً تكون قيمته 10^{-6} .

10.3 التعميم Generalization:

إن النهج في تدريب نماذج التعلّم العميق يتضمّن مرحلتين:

- **ملاءمة النموذج على بيانات التدريب Model fitting**: تمثّل هذه المرحلة الهدف الوسيط في تدريب نموذج


DL، أما الهدف الحقيقي هو اكتشاف الأنماط العامة للنموذج، والتي تقدم تنبؤات دقيقة حتى على عينات جديدة

غير مرئية بالنسبة للنموذج، ولكنها مشابهة للعينات التي تدرّب النموذج عليها.

- **تقدير خطأ التعميم**: يتم من خلال تقويم النموذج على بيانات الاختبار (أو بيانات التحقق)، ويطلق على الفرق

بين ملاءمة النموذج على بيانات التدريب وملاءمة النموذج على بيانات الاختبار بفجوة التعميم

Generalization gap، يبين الشكل (12-3) مفهوم الإفراط في التعلّم، والتعلّم الناقص.



الشكل (3-12): مفهوم الإفراط في التعلم، والتعلم الناقص [31].

مفهوم التعميم هو أن يكون خطأ التدريب قريباً من خطأ التعميم [30]. في التعميم يُعتمد عادةً على مجموعة التحقق من الصحة Validation Set، ويسمى الخطأ الناتج عن هذه البيانات بخطأ التحقق من الصحة Validation error.

عندما يُقارن بين خطأ التدريب Training error وخطأ التحقق من الصحة يتم تمييز الحالتين [31]:

- التعلم الناقص Underfitting: في هذه الحالة يكون كلٌّ من خطأ التدريب، وخطأ التحقق من الصحة كبير، ولكن هناك فجوة صغيرة بينهما. عندما يكون النموذج غير قادر على تقليل خطأ التدريب هذا يدل أن النموذج بسيط للغاية، وغير قادر على تحقيق المطلوب منه.
- الإفراط في التعلم Overfitting: عندما يكون خطأ التدريب أقل بكثير من خطأ التحقق من الصحة، ويُلاحظ نمو فجوة التعميم، ومن ثمَّ يكون أداء النموذج أفضل بكثير على بيانات التدريب؛ مقارنة مع أدائه على البيانات غير المرئية.

11.3 طرائق التنظيم Regularization للشبكات العميقة:


المطلوب من نموذج التعلم العميق أن يعمل بصورة جيدة مع البيانات غير المرئية Unseen data (والتي تكون مشابهة لبيانات التدريب)؛ وذلك بهدف تقليل الفجوة بين أداء التدريب وأداء الاختبار. تسمى الطرائق المستعملة؛ للتقليل من الإفراط في التعلم بطرائق التنظيم [32].

1.11.3 إضافة الضجيج إلى مداخل النموذج:

وذلك بهدف تحقيق النعومة Smoothness للنموذج، وعندها يصبح النموذج غير حساس للتغيرات الصغيرة في المداخل. مثلاً نتوقع عند إضافة بعض الضجيج العشوائي إلى وحدات البكسل في صورة الدخل، أنه لا يؤثر كثيراً في أداء النموذج.

2.11.3 تقانة الحذف العشوائي (التسرب) Dropout:

هي طريقة تنظيمية للشبكات العصبونية يتم فيها التخلي عن بعض العصبونات بصورة عشوائية في أثناء التدريب كما هو مبين في الشكل (3-13).



الشكل (3-13): تقانة التسرب Dropout [33].

ففي كل تكرار يُحذف جزء من العصبونات في كل طبقة بصورة عشوائية. في حين يُعطّل الـ Dropout في أثناء الاختبار [34]. بفرض يوجد شبكة ANN بطبقة مخفية واحدة تحوي 5 عصبونات كما في الشكل (3-13)، فعند تطبيق Dropout على الطبقة المخفية يُستبعد العصبون باحتمالية معينة، وتكون النتيجة شبكة تحتوي فقط على مجموعة فرعية من العصبونات الأصلية.

3.11.3 التسوية الدفعية Batch Normalization:

وهي من تقانات التعلّم الخاضع للإشراف، تؤدي إلى إعادة تعيين توزيع ناتج الطبقة السابقة في الشبكة العميقة لتُعالج بكفاية أكبر بواسطة الطبقة اللاحقة [34]. في أثناء تدريب الشبكات العميقة تتغير معاملات التدريب باستمرار، وقد يحدث تفاوت كبير بين قيم المداخل للطبقات التالية؛ أي زيادة كبيرة في الانحراف المعياري، يسمى هذا التأثير إزاحة المتغير الداخلي Internal covariant shift. من أجل التعامل مع التغير في التوزيع في أثناء التعلّم، قُدّمت التسوية الدفعية، وفيها تُجرى التسوية على بيانات الدخل لكل طبقة في الشبكة؛ ليكون لها متوسط حسابي بقيمة 0، وانحراف معياري بقيمة 1. تُنظّم طبقات التسوية في الشبكة العصبونية بين الطبقات الخطية والطبقات اللاخطية وكمثال: طبقة الالتفاف هي طبقة خطية تتبعها طبقة التسوية، ثم طبقة لاخطية ReLu. التعبير العام للتسوية، كما في العلاقة (3-16) [34].

$$y_i = \frac{a}{\sigma}(x_i - \mu) + b \quad (16 - 3)$$

حيث أن: x_i : العنصر رقم i في متجه الدخل x لطبقة التسوية، y_i : العنصر رقم i في متجه الخرج y لطبقة التسوية، μ : المتوسط الحسابي لقيم عناصر المتجه x ، σ : الانحراف المعياري لقيم عناصر المتجه x .

α : هو معامل تكبير قابل للتعلّم، b معامل انحياز قابل للتعلّم.

الفصل الرابع

منهجية البحث وإجراءاته

Research Methodology and Procedures

1.4 تمهيد:

يضم هذا الفصل المرحلة العملية التي أنجزت في هذا البحث؛ بدءاً من إنشاء مجموعة البيانات المستعملة في تدريب النموذج واختباره، إلى بناء النموذج المقترح، والتقانات التي استُعملت في توسيع قاعدة البيانات، والتقانات التي استُعملت للتغلب على مشكلة الإفراط في التعلّم $Overfitting$ ، كما ويتحدث عن المتوسطات الفائقة التي استُعملت في تدريب نموذج CNN المقترح، ومقاييس الأداء لنماذج التصنيف، والنتائج التي حُصل عليها من تدريب نموذج CNN المقترح واختباره باستعمال نوعين من خوارزميات الأمثلة، وعلى مجموعة بيانات الاختبار نفسها؛ فضلاً عن تقييم أداء النموذج المقترح عن طريق مقارنته مع دراسات سابقة.

2.4 مصادر مجموعة البيانات المستعملة في البحث:


أُنشئت في البحث مجموعة بيانات التدريب، بالاعتماد على الصور GPR B-Scan المحاكاة؛ باستعمال برنامج gprMax، وعلى الصور GPR B-Scan الحقيقية المأخوذة من قاعدة البيانات TU1208، أما مجموعة بيانات الاختبار فقد أُنشئت بالاعتماد على ما هو متاح على مواقع الإنترنت من صور GPR B-Scan حقيقية.

1.2.4 برنامج المحاكاة gprMax:

يُعدّ برنامج gprMax أحد أهم برامج المحاكاة التي يستعملها الباحثون للحصول على صور محاكاة لجهاز GPR من أجل معالجة مشكلة ندرة بيانات GPR التي شرحها الخبراء في مجال تقانة GPR.

gprMax هو برنامج مفتوح المصدر، يحاكي انتشار EMS في أوساط الانتشار تحت سطح الأرض، وهو مصمم لنمذجة Modeling جهاز GPR، ونمذجة التربة والمواد المظلمة في التربة [35]. كما هو معلوم يتم توصف جميع الظواهر الكهرومغناطيسية على مجال الـ Macroscopic بواسطة معادلات ماكسويل Maxwell. برنامج

gprMax يستعمل خوارزمية Yee¹ لحل معادلات ماكسويل في المجال ثلاثي الأبعاد 3D؛ باستعمال طريقة التكامل المحدود بالمجال الزمني (Finite Difference Time Domain (FDTD)؛ إذ قُسمت شبكة FDTD التي تنتشر فيها EMs في أثناء المحاكاة إلى خلايا تعبر عن الدقة المكانية لعملية المحاكاة، وتدعى الخلية الواحدة بخلية yee؛ ومن ثم فإن البنية الأساسية لشبكة FDTD هي خلية Yee الموضحة في الشكل (4-1).



الشكل (4-1): خلية Yee واحدة تظهر عليها مركبات الحقل الكهربائي E والمغناطيسي H [35].

يقوم البرنامج بالحل العددي Numerical solution لمعادلات ماكسويل بناءً على الدقة المكانية Δx , Δy , Δz (أبعاد خلية Yee). يختار مستثمر البرنامج الدقة المكانية بناءً على أعلى تردد في الطيف الترددي لنبضة الإرسال المستعملة في جهاز GPR المحاكى (أي بناءً على الشكل الموجي المستعمل waveform)، وبناءً على حجم الهدف المظموور المحاكى. كلما كانت الدقة المكانية أصغر، يصبح النموذج أقرب إلى التمثيل الحقيقي للمشكلة، لكن ذلك يكون محدوداً بإمكانات الحاسوب المستعمل (سرعة المعالجة، وسعة الذاكرة المتاحة). يقوم gprMax بالحل العددي لمعادلات ماكسويل في المجال الزمني بطريقة تكرارية، ففي كل تكرار Iteration

¹ خلية Yee: سميت على اسم الباحث Kane Yee الذي كان رائداً في طريقة FDTD.

تتقدم EMs في شبكة FDTD بمقدار خلية yee واحدة؛ إذ أن FDTD Solver يُحاكي انتشار الحقول الكهرومغناطيسية من أجل نافذة زمنية Time window معطاة (التي يختارها مستثمر البرنامج بما يكفي للسماح لـ EMs بالانتشار من هوائي مرسل GPR عبر المادة المحيطة بالهدف المظموّر، والعودة إلى هوائي مستقبل GPR، فقيمتها تتعلق بنوع مادة وسط الانتشار، وعمق الهدف المظموّر). يقوم gprMax بصورة أساسية بإجراء عمليات المحاكاة ثلاثية الأبعاد 3D باستعمال طريقة FDTD بالنمط (TEM) Transverse Electro-Magnetic: الحقل الكهرومغناطيسي المستعرض، ويمكن استعماله لإجراء عمليات المحاكاة 2D باستعمال النمط (TMz) Transverse Magnetic: الحقل المغناطيسي المستعرض في الاتجاه z، ويتم ذلك بجعل أحد الأبعاد نموذج المحاكاة Domain space في البيئة المحاكاة مساوياً خلية Yee واحدة في ذلك الاتجاه.

يحتاج برنامج gprMax لملف إدخال Input file يحتوي على معلومات عن جهاز GPR، وعن المواد المراد محاكاتها، وكذلك معلومات أخرى مثل (أبعاد البيئة المحاكاة، والدقة المكانية، والنافذة الزمنية، وطريقة حركة جهاز GPR على خط المسح). يجب تحقيق شروط معينة عند تحديد الأبعاد الهندسية Geometric لنموذج المحاكاة المدروس، وكذلك عند تحديد الدقة المكانية Spatial resolution، وذلك استناداً إلى نوع مادة وسط الانتشار المدروسة، وأبعاد الهدف المظموّر، والشكل الموجي (Waveform) للنبضة المرسلة من جهاز GPR، وإلا فلن يعمل البرنامج بالشكل المطلوب في أثناء المحاكاة، لهذا يُنصح بمراجعة الموقع الرسمي للبرنامج للتعرف بصورة دقيقة على هذه الشروط الواجب تحقيقها.

2.2.4 قاعدة البيانات TU1208 Open database:


سُجّلت فيها بيانات GPR Radar-grams (مسوحات من نوع B-Scan) في موقع الاختبار الجيوفيزيائي Nantes (France)، وهو تابع للمعهد الفرنسي للعلوم والتكنولوجيا:

Institut français des sciences et technologies des transports, de l'aménagement et des réseaux (IFSTTAR).

موقع الاختبار المذكور بعيد عن مصادر الضجيج، مثل التركيبات الكهربائية والأشجار، وقد صُمم لتوفير

حل تجريبي لتقانة GPR في بيئة متحكم بها منذ التصميم، وذلك بهدف مشاركة المجتمع العلمي في مجموعة مختارة من استجابات GPR الموثوقة والمثيرة للاهتمام [36].

يبين الشكل (2-4) شكل حفرة الاختبار المذكورة، وأبعادها، والأهداف المطمورة المستعملة فيها.



الشكل (2-4): شكل حفرة الاختبار وأبعادها، المستعملة في قاعدة البيانات TU1208، وما تحتويه من أهداف مطمورة [36].

طول الحفرة الاختبارية 27.5m وهي ذات جوانب منحدرة، عرضها في القاع 5m، وعرضها في الأعلى

يتراوح من 19 m إلى 24.6 m وعمق الحفرة يتراوح من 3.3 m إلى 4. m. قُسمت الحفرة الاختبارية إلى 5 مناطق

مملوءة بمواد طمر مختلفة (منطقة الطمي Silt region، و منطقة الطبقات المتعددة Multilayers، و منطقة الحجر الجيري Limestone، و منطقة Gneiss 14/20، و منطقة Gneiss 0/20)، وكل منطقة من المناطق المذكورة تضم عدداً من الأهداف شائعة الوجود في البيئات الواقعية: أنابيب، وكابلات كهربائية، وحجارة، وتجاويف هوائية، وحجارة بناء، وبلوكات صخرية؛ باستثناء منطقة الـ Multilayers؛ إذ إنها لا تحتوي على أي أهداف مطمورة؛ وذلك بهدف الحصول على صور تحوي فقط ضجيجاً وكشرات Clutter (أي الحصول على صور GPR تحتوي فقط على خلفية معقدة).

في قاعدة البيانات TU1208 يوجد 11 خطاً مسح لـ GPR، بطول 19m، ويعرض 2.5m، سُجِّلَ في هذه القاعدة 67 ملفاً Radargram (مسوحات من نوع B-Scan)، وهي ملفات ذات اللوحات (.rd3, .dzt, .DT)؛ وذلك باستعمال ثلاثة أنواع من أجهزة GPR نبضية مزودة بـ 14 هوائياً مختلفاً بحسب التردد المستعمل. هذه الأجهزة تعمل في المجال الترددي [200:1000] MHz، وأنواعها هي:


- GSST (Nashua, NH, USA).
- MALA Geoscience (Mala, sweden).
- IDS (Pisa, Italy).

تم في هذا البحث الاختيار - من قاعدة البيانات TU1208 - فقط للصور GPR B-Scan الخاصة بالأهداف المطمورة التي من نوع أنابيب والتي هي موضوع البحث؛ إذ استُعملت الأنواع الآتية من الأنابيب في قاعدة البيانات TU1208:


أنابيب فولاذية Steel فارغة، وأنابيب Poly Vinyl Chloride (PVC) مملوءة بالماء، وأنابيب PVC فارغة بأقطار 12.5 cm، وأنبوب خرساني واحد فارغ بقطر 0.5m.

تتبن الأشكال من الشكل (4-3) إلى الشكل (4-5) أمثلة عن الصور المأخوذة من قاعدة البيانات TU1208 [36].


.



الشكل (3-4): صورة ناتجة عن مسح منطقة Multilayers؛ باستعمال التردد 900MHz.




الشكل (4-4): صورة ناتجة عن خط المسح الثاني في منطقة Gneiss 14-20؛ باستعمال التردد 900MHz.



الشكل (5-4): صورة ناتجة عن خط المسح الثاني في منطقة Limestone؛ باستعمال التردد 250MHz.

3.4 محاكاة عملية كشف الأنابيب المظمورة في التربة؛ باستعمال جهاز GPR:

قمنا بمحاكاة عملية كشف أنابيب بلاستيكية ومعدنية (أنبوب مفرد، وأنبوبان، وثلاثة أنابيب) مضمورة في تربة من أربعة أنواع مختلفة، الأنابيب ذات أقطار مختلفة وعلى أعماق طمر مختلفة في التربة، وطول خط المسح الذي سيتحرك عليه جهاز GPR هو 10m؛ وذلك باستخدام برنامج المحاكاة gprMax v3.1.6؛ بهدف إنشاء صور GPR B-Scan محاكاة ملونة (RGB).



الشكل (4-6): توصيف للبيئة المحاكاة [35].

يوضح الشكل (4-6) توصيف للبيئة التي تم محاكاتها في بحثنا، وهي تتكون من قسمين:

- القسم الأرضي Ground: وهو على شكل مستطيل يحاكي تربة بعمق 4m (على طول المحور Y)، وبعرض 10m (على طول المحور X): وهذا يمثل طول خط المسح الذي سيتم وفقه سير القسم الأرضي باستعمال جهاز GPR. في هذا القسم تتم محاكاة أنواع مختلفة من التربة وذلك حسب الجدول (4-1)، ومحاكاة الأنابيب المضمورة التي تم محاكاتها على شكل أسطوانات مختلفة بالأقطار، وبمادة الصنع،

وبالتوضّع ضمن هذا القسم، وعلى عمق من 0.25 m إلى 2 m (تمّ اختيار هذا العمق لكي نتيح لبصمة القطع الزائد بالظهور بشكلها الكامل في الصورة المحاكاة الناتجة).

- القسم الهوائي Air: وهو على شكل مستطيل، يحاكي المنطقة فوق سطح التربة المدروسة؛ إذ يتحرك جهاز GPR لمسح القسم الأرضي. هذا القسم ذو ارتفاع 1m (على طول المحور Y)، وعرض 10m (على طول المحور X). في هذا القسم يتم محاكاة جهاز الـ GPR، من حيث التوضّع، وطريقة حركته على خط مستقيم (خط المسح الذي طوله 10 m) في أثناء مسح القسم الأرضي.

تمّ محاكاة جهاز GPR بالموسطات الآتية:

الهوائي من النوع Dipole hertzian مستقطب؛ وفق المحور Z، وإشارة الإرسال ذات شكل موجي waveform من النوع Ricker بمطال واحد، وترددات العمل للجهاز ضمن المجال [100: 1000] MHz وهوائي الإرسال يرتفع عن سطح الأرض 5cm؛ وفق المحور Y، وهوائي الاستقبال يبعد عن هوائي الإرسال بمسافة أفقية؛ وفق المحور X قدرها 3cm، وخلال عملية المسح، فإن كلا الهوائيين يتحركان معاً وبوقت واحد في كل خطوة تحصيل معلومات على طول المحور X؛ إذ إنّ قيمة خطوة الحركة على طول خط المسح هي 5cm.

1.3.4 تصورات المحاكاة التي نُفذت في البحث:

تم محاكاة نوعين من الأنابيب المطمورة، واختيار ثلاث قيم لأقطارها: (10, 25, 50) cm، واختيرت أربعة أنواع من التربة المحيطة بالأنابيب (عُدّت الأنابيب والتربة مكونة من مواد متجانسة أي بتوزيع موحد)، كما يوضّح الجدول (1-4). نُفِّذَ 360 تصوّر محاكاة؛ إذ اختير في تصورات المحاكاة أعماق طمر عشوائية للأنابيب المطمورة بمجال [0.25: 2]m، وبخطوة 0.25m، ومواضع مختلفة للأنابيب؛ وفق المحور X ضمن القسم الأرضي من البيئة المحاكاة، كما واختيرت عدّد الأنابيب المطمورة ضمن القيم (1,2,3)، ووزّعت مواضع الأنابيب بصورة عشوائية؛

وفق المحور X في القسم الأرضي. كل تصوّر محاكاة ينتج عنه صورة واحدة من النمط B-Scan (المسح النصوعي).

الجدول (4-1): الخصائص الكهرومغناطيسية للتربة وللأنابيب المحاكاة في تصوّرات المحاكاة [22, 23, 37].

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

يبين المقطع البرمجي التالي ملف الإدخال لبرنامج المحاكاة gprMax (كُتِبَ بالبرنامج Visual Studio Code على شكل ملف بلاحقة .in) وهو يمثل أحد تصوّرات المحاكاة.

```
#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

الصورة الناتجة عن تصوّر المحاكاة المذكور موضحة بالشكل (7-4).



الشكل (7-4): صورة محاكاة ناتجة عن أحد تصوّرات المحاكاة (عمل الباحث).

في هذا التصوّر تم محاكاة جهاز GPR يتحرك على خط مسح مستقيم، وفق المحور X بطول 10m، وبخطوة مسح 5cm. اختيرت قيمة الدقة المكانية 2 mm، والنافذة الزمنية 30nsec. الشكل الموجي لنبضة الإرسال لجهاز GPR من النوع Ricker بمطال واحد (هذا يعبر في برنامج gprMax عن إرسال استطاعة من جهاز GPR بنسبة 100%)، وبتردد 400MHz، وتمّ محاكاة أنبوبين معدنيين بقطر 30cm للأنبوب، وعلى عمق 1m، والمسافة الأفقية بين الأنبوبين وفق المحور X، قدرها 2m، والأنبوبان مضموران في وسط half_space ذي الخصائص الكهرطيسية الآتية:

السماحية الكهربائية النسبية $\epsilon_r = 6$ ، الناقلية الكهربائية النوعية $\sigma = 0 \text{ S/m}$ ، والنفاذية المغناطيسية $\mu = 1$ ، والفقد المغناطيسي قيمته 0.0 Ohms/m . في نهاية تصوّر المحاكاة المذكور سابقاً، حُصلَ على 160 Traces (وتمثّل عدد المسوحات من النوع A-Scans) والتي دُمجت للحصول على صورة واحدة من النمط B-Scan؛ باستعمال الأمر التالي في موجه أوامر ويندوز Command Prompt:

```
python -m tools.outputfiles_merge user_models/cylinder_Bscan_2D --remove-files
```

نُقِّدَ 200 تصوّر محاكاة بوجود الأنابيب المطمورة في القسم الأرضي، عند تردد عمل 400 MHz ، وفي 4 أنواع للتربة المذكورة في الجدول (1-4)، وتم في النهاية الحصول على 200 صورة GPR B-Scan ملونة RGB تحتوي على قطوع زائدة ناتجة عن وجود الأنابيب المطمورة المحاكاة. بعد ذلك، نُقِّدَ 160 تصوّر محاكاة على البيئة المحاكاة السابقة نفسها، ولكن من دون وجود أنابيب مطمورة، وعند ترددات عمل لجهاز GPR؛ ضمن المجال $[100, 1000] \text{ MHz}$ ، وفي 4 أنواع للتربة المذكورة في الجدول (1-4) فحصلنا على 160 صورة محاكاة GPR B-Scan ملونة لا تحتوي على قطوع زائدة.

4.4 مجموعات البيانات المستعملة في البحث:

1.4.4 مجموعة بيانات التدريب Training Dataset:

- جُمِعت الصور GPR B-Scan المحاكاة والتي حُصلَ عليها؛ باستعمال برنامج المحاكاة gprMax والتي تحتوي على قطوع زائدة ناتجة عن وجود أنابيب مطمورة في البيئة المحاكاة (وعدها 200 صورة) في فئة تحت اسم: يوجد كشف للهدف Target detection وعُلمت بـ 0.

- أُضيف 40 صورة GPR B-Scan حقيقية لا تحتوي على أهداف مطمورة من قاعدة البيانات TU1208 إلى الصور GPR B-Scan المحاكاة التي لا تحتوي على قطوع زائدة (عددها 160) (فأصبح مجموع الصور التي لا

تحتوي على أنابيب مطمورة 200 صورة) وُجِعت هذه الصور في فئة تحت اسم:

لا يوجد كشف أهداف No Target detection وعُلمت بـ 1.

بالمجمل بيانات التدريب تحتوي على 400 صورة GPR B-Scan (200 صورة تحتوي على أنابيب مطمورة و 200 صورة تحتوي فقط على خلفية، تكون هذه الخلفية إما بسيطة وإما معقدة).

2.4.4 مجموعة بيانات الاختبار Testing Dataset:

اختيرت مجموعة من صور GPR B-Scan حقيقية (ملونة (RGB) وبالمجال الرمادي (Cray scale) مأخوذة من قاعدة البيانات TU1208 Open database [36] ومن مواقع انترنت مختلفة.

- جُمِعت الصور GPR B-Scan الحقيقية والتي تحتوي على قطوع زائدة ناتجة عن وجود أنابيب مطمورة (وعدها 50 صورة) في فئة تحت اسم: يوجد كشف للهدف Target detection وعُلمت بـ 0.

- تم تجميع الصور GPR B-Scan الحقيقية التي لا تحتوي على قطوع زائدة (عددها 40) في فئة تحت اسم: لا يوجد كشف للهدف No Target detection وعُلمت بـ 1.

بالمجمل بيانات الاختبار تحتوي على 90 صورة GPR B-Scan (50 صورة تحوي أنابيب مطمورة و 40 صورة تحوي فقط خلفية معقدة).


5.4 معمارية نموذج التصنيف المقترح المبني على الشبكة العصبونية الالتفافية CNN:

المهمة المطلوبة من النموذج: هي كشف وجود القطع الزائد (الناتج عن انعكاسات EMS عن الأنابيب المطمورة في التربة) أو عدم وجوده داخل صور GPR B-Scan؛ ومن ثم أُطِرت المهمة إلى مشكلة تصنيف ثنائي.

استُعمل أثناء بناء النموذج مبدأ التجربة والخطأ Trial and Error حيث قمنا بتغيير بنية النموذج والموسطات

.

الفائقة للطبقات الالتفافية، ولطبقات كاملة الاتصال من حيث: عدد وحجم المرشحات الالتفافية، وعدد العصبونات في كل طبقة، ومن ثم مراقبة النتائج للحصول على أفضلها. يبين الشكل (4-8) معمارية نموذج CNN المقترح.



الشكل (4-8): معمارية نموذج التصنيف المقترح في البحث (عمل الباحث).

نُفذَ النموذج باستعمال لغة البرمجة Python 3.9.12؛ مع المكتبات التالية:

Tensorflow 2.10.0، Keras 2.9.0؛ وذلك باستعمال منصة العمل Jupyter Notebook.

1.5.4 قسم استخراج الميزات: ويضم 6 طبقات التلافية Conv2D؛ إذ إنَّ أبعاد مرشح الالتفاف Krenel لكل طبقة التلافية هو (3*3)، أما عدد المرشحات الالتلافية فهو: 64 مرشحاً للطبقات الالتلافية الأولى والثانية، و128 مرشحاً للطبقات الالتلافية الثالثة والرابعة، و256 مرشحاً للطبقات الالتلافية الخامسة والسادسة. تابع التنشيط المستعمل Activation function لكل طبقة التلافية هو التابع Relu، أبعاد مرشح التجميع Max pooling2D هو (2*2)، وخطوة الالتفاف strides = (1, 1)، وتم استخدام الحشو Padding بإضافة اطار من قيم الأصفر حول مصفوفة دخل الطبقة الالتلافية قبل اجراء عملية الالتفاف عليها، بهدف جعل أبعاد خارطة الميزات Features map الناتجة عن عملية الالتفاف (وذلك قبل اجراء عملية التجميع عليها)، بنفس أبعاد مصفوفة الدخل، وبهدف استخدام العناصر في أطراف مصفوفة الدخل بشكل أكثر في عمليات الالتفاف.

2.5.4 المصنّف: يتكوّن من 4 طبقات كاملة الاتصال Dense، بعدد عصبونات 1024 عصبوناً للطبقة الأولى، و512 عصبوناً للطبقة الثانية، و64 عصبوناً للطبقة الثالثة، وعصبونان للطبقة الرابعة. تابع التنشيط المستعملة للطبقات الثلاث الأولى هي Relu، وللطبقة الأخيرة هي Softmax.

3.5.4 المعالجة الأولية Preprocessing لصور الدخل:

صور الدخل هي صور GBR B-Scan مختلفة المقاسات (الأبعاد)، وسواء ملونة RGB أو بالمجال الرمادي، وتشمل المعالجة الأولية لصور الدخل:

-حذف الموجة المباشرة من صور الدخل عن طريق إزالة الصفوف الأولى القليلة من الصورة التي تحتوي على الموجة المباشرة.

-ضبط السطوع والتباين لصور الدخل؛ وذلك باستعمال برنامج GPRSoft Viewer.

-توحيد أبعاد صور الدخل إلى 128*128 بيكسل: Image_size= (128,128,3)

6.4 تدريب نموذج التصنيف المقترح:

في هذا البحث ومن أجل تدريب نموذج التصنيف المقترح، استُعمل التدريب الخاضع للإشراف؛ حيث تكون عينات التدريب على شكل أزواج من: الميزات الممثلة لصور الدخل، والتسميات (الأهداف المطلوبة) المقابلة لها في الخرج. استُعمل نوعان من خوارزميات الأمثلة على نموذج CNN المقترح وهما خوارزمية الأمثلة SGD مع الزخم وخوارزمية الأمثلة Adam، وذلك بهدف المقارنة، واختيار الأنسب من حيث النتائج. قُسمت بيانات التدريب بنسبة: 80% للتدريب (320 صورة GPR B-Scan)، و20% للتحقق (80 صورة GPR B-Scan)، ونظراً لصغر حجم مجموعة بيانات التدريب المستعملة فقد استُعمل الآتي من تقانات توسيع بيانات التدريب Data-Augmentation: التغيير العشوائي لإضاءة الصور Random-Brightness (بنسبة 20%)، والتغيير العشوائي لتباين الصور Random-Contrast (بنسبة 20%). ولزيادة متانة النموذج أُدخل ضجيج غاوسي على الصور في أثناء التدريب بمتوسط حسابي 0 وبانحراف معياري 1 (حيث تتم عمليات توسيع بيانات التدريب المذكورة سابقاً في الوقت الحقيقي أثناء تدريب النموذج، وذلك عند إدخال بيانات التدريب للنموذج) وذلك وفق التعليمات التالية:

$X = \text{tf.keras.layers.RandomBrightness}(0.2)(\text{inputs})$

$X = \text{layers.RandomContrast}(0.2)(X)$

$X = \text{layers.noise.GaussianNoise}(0.1)(X)$

كما استُعمل الخلط العشوائي للبيانات في أثناء التدريب (Shuffle = True).

عدد موسطات نموذج التصنيف المقترح: وذلك حسب المعمارية المذكورة في الشكل (4-8)، وحسب موسطات الطبقات الالتفافية والطبقات المتصلة بالكامل التي تمّ اعتمادها، هي كما يلي:

Total parameters: 18491394, Trainable parameters: 18486402, Non-trainable parameters: 4992.

1.6.4 المتوسطات الفائقة للنموذج المقترح في هذا البحث:

أُخذت المتوسطات الفائقة التالية الموضحة في الجدول (2-4) في أثناء عملية التدريب للنموذج.

الجدول (2-4): المتوسطات الفائقة للنموذج المقترح (عمل الباحث):

عدد حقبة التدريب Max epochs	حجم دفعة البيانات Mini-Batch size	خوارزمية الأمثلة المستعملة Optimizer	تابع الخسارة Loss function	بارامترات القياس المراقبة Metrics	معدل التعلم Learning rate
100	16	-Adam -SGD with Momentum	Binary cross-entropy	Accuracy, Loss, Recall, Precision, F1-Score, auc	0.00001

2.6.4 تقانات التنظيم التي استُعملت في أثناء التدريب:

استُعملت تقانات التنظيم التالية؛ بهدف زيادة مناعة النموذج ضد الإفراط في التعليم Overfitting:

التسوية الدفعية Batch Normalization، وتقانة التسرب Dropout ونسبة 20%، وإضافة الضجيج الغاوسي لصور الدخل.

7.4 الأدوات البرمجية والعادية التي استُعملت في البحث:

- gprMax v3.1.6 (big smoke).
- GPRSoft Viewer ver1.4.2 .
- Python 3.9.12 [MSC v.1916 64 bit (AMD64)].
- Tensorflow 2.10.0 مع Keras 2.9.0.


- المكتبات البرمجية الآتية:

- مكتبة Matplotlib، واستدعينا منها الحزمة pyplot؛ من أجل تنفيذ الرسم البياني.
- مكتبة Utils التي استدعينا منها الحزمة np_utils؛ من أجل تحويل التسميات Labels المرتبطة بالصور في قاعدة البيانات إلى الترميز الواحد الساخن One-hot-encoding.
- مكتبة Sklearn؛ لحساب قيم مقاييس التصنيف F1-Score, Acc, Pre, Rec, AUC، ولرسم منحنى ROC، ولإستخراج قيم مصفوفة الارتباك Confusion matrix.
- مكتبة Numpy؛ لتحويل صور الدخول إلى مصفوفات من نوع Numpy.
- إطار العمل المستعمل: Jupyter Notebook (anaconda3).

-لاب توب بالمواصفات الآتية: Intel(R) Core (TM) i3-5005U CPU@2.00 GHZ ,RAM 4 G Byte

8.4 مقاييس الأداء لنماذج التصنيف Metrics in classification:

نُستعمل لتحديد أداء نموذج التصنيف. فبعد تدريب النموذج باستعمال بيانات التدريب، يجب تقويم دقة عمل هذا النموذج باستعمال بيانات الاختبار. يُقوّم عادةً أداء نموذج التصنيف من خلال مجموعة من المقاييس التي تعكس جودة أداء النموذج، سنذكر منها المقاييس التي تستند إلى مصفوفة الارتباك Confusion matrix [24] التي تمثل بدورها عدد القيم التنبؤية الإيجابية والسلبية الصحيحة والخاطئة. يبين الشكل (4-9) شكل مصفوفة الارتباك في المصنفات الثنائية: تمثّل أعمدة مصفوفة الارتباك الفئات التي تنبأ بها نموذج التصنيف، أمّا أسطرها، فتمثّل الفئات الحقيقية المطلوبة.



الشكل (9-4): مصفوفة الارتباك Confusion matrix في المصنّفات الثنائية [24].

حيث أن:

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

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

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

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

1.8.4 الدقة (Precision):

وتمثل نسبة التنبؤات الموجبة الصحيحة؛ ضمن كل التنبؤات الموجبة (التنبؤات الموجبة الصحيحة والخاطئة)،

وهي موضحة بالعلاقة (4-1) [24].

$$\text{Pre} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (1 - 4)$$

2.8.4 الاستدعاء (Rec): Recall

ويمثل معدل التنبؤات الموجبة الصحيحة True Positive Rate (TPR)، وتُعرف كما بالعلاقة (2-4) [24].

$$\text{Rec} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2 - 4)$$

3.8.4 الخصوصية (Spe): Specificity

وتمثل معدل التنبؤات السالبة الصحيحة True Negative Rate (TNR)، وتُحسب من العلاقة (3-4) [24].

$$\text{Spe} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (3 - 4)$$

ومنه، فإنَّ معدّل التنبؤات الموجبة الخاطئة False Positive Rate (FPR)، يُحسب بالعلاقة (4-4) [24]:

$$\text{FPR} = 1 - \text{SPE} \quad (4 - 4)$$

4.8.4 الضبط (Acc): Accuracy

يقيس الضبط نسبة التنبؤات الصحيحة (السالبة الصحيحة والموجبة الصحيحة) إلى العدد الكلي من الحالات

الخاضعة للاختبار، كما هو موضّح بالعلاقة (5-4) [24].

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FN} + \text{TN} + \text{FP}} \quad (5 - 4)$$

5.8.4 مؤشر التقويم F1-Score: الصيغة العامة لهذا المؤشر F_β-Score [24]:

$$F_{\beta} - \text{Score} = \frac{(1 + \beta)^2 (\text{Pre} * \text{Rec})}{\beta^2 (\text{Pre} + \text{Rec})} \quad (6 - 4)$$

β: معامل وزن الدمج، إذ F تشير إلى دمج Fusion لمقاييس التقويم: Pre, Rec.

وعليه، فإن الصيغة F1-Score تُعطى بالعلاقة (7-4).


$$\text{F1} - \text{Score} = 2 * \frac{\text{Rec} * \text{Pre}}{\text{Rec} + \text{Pre}} \quad (7 - 4)$$

6.8.4 منحنى خصائص التشغيل (ROC): Receiver Operating Characteristic

هو منحنى بياني، يُستعمل كمقياس لجودة نظام التصنيف، إذ توضح نتائج النظام وقدرته باستعمال العلاقة بين الحساسية Rec والخصوصية Spe. تمتد محاور المنحنى ROC على المجال $[0,1]$ ، ويمثل هذا الرسم البياني الإظهار لمعدل التنبؤات الموجبة الحقيقية (إذ $TPR = Rec$) على المحور الرأسي؛ مقابل معدل التنبؤات الموجبة

الكاذبة على المحور الأفقي والتي تساوي $FPR = 1 - Spe$ ، كما هو موضح بالشكل (4-10)[38].

يعطي منحنى ROC تصوراً ثنائي الأبعاد لأداء المصنف، قد نرغب في تمثيل أداء ROC بقيمة عددية واحدة تمثل الأداء المتوقع، وإحدى الطرائق الشائعة تتم عن طريق حساب Area Under Curve (AUC) والتي هي المنطقة الواقعة تحت منحنى خصائص التشغيل ROC .



الشكل (4-10): منحنى خصائص التشغيل ROC [38].

نظراً لأن AUC يمثل جزءاً من مساحة مربع الوحدة، فستكون قيمته دائماً بين 0 و 1 ، وهذه القيمة تخبر عن مدى قدرة النموذج على التمييز بين الفئات، فكلما اقترب AUC من 1 كان أداء المصنف أفضل. فمن أجل

AUC=0.5 نحصل على منحنى ROC المسمى على الشكل (3-4) بـ Random classifier وكلما ازدادت قيمة AUC عن 0.5، اقترب منحنى ROC من النقطة Perfect classifier وأصبح أداء المصنف أفضل. يبين الجدول (1-6) القاعدة الأساسية لتفسير قيمة AUC.

الجدول (3-4): قواعد تفسير قيمة AUC [38]:

$AUC \leq 0.5$	لا يوجد تمييز No discrimination
$0.5 < AUC \leq 0.6$	تمييز ضعيف Poor discrimination
$0.6 < AUC \leq 0.7$	تمييز مقبول Acceptable discrimination
$0.7 < AUC \leq 0.9$	تمييز ممتاز Excellent discrimination
$AUC > 0.9$	تمييز بارز Outstanding discrimination

9.4 النتائج والمناقشة: Results and Discussion


1.9.4 تقويم أداء نموذج التصنيف المقترح المبني على الشبكة العصبونية الالتفافية مع

استعمال خوارزمية الأمثلة SGD مع الزخم:

1.1.9.4 نتائج التدريب مع استعمال خوارزمية الأمثلة SGD؛ مع الزخم:


تتكوّن مجموعة بيانات التدريب من 400 صورة GPR B-Scan محاكاة وملونة، قُسمت بنسبة 80% للتدريب، و20% للتحقق بعد أن طُبقت بعض تقانات توسيع البيانات عليها المذكورة سابقاً.

يوضّح الشكل (4-11) والشكل (4-12) عملية Model fitting لنموذج التصنيف المقترح (باستعمال خوارزمية الأمثلة SGD؛ مع الزخم) في أثناء عملية التدريب.



الشكل (4-11): منحنى الخسارة لمرحلة التدريب والتحقق باستعمال خوارزمية الأمثلة SGD؛ مع الزخم (عمل الباحث).

كما هو متوقع تبدأ الخسارة بقيم عالية، وتتخفض تدريجياً في أثناء عملية التدريب، لتصل أفضل قيمة للخسارة على بيانات التدريب إلى 0.2488، وعلى بيانات التحقق إلى 0.1826.



الشكل (4-12): منحنى الضبط لمرحلة التدريب والتحقق باستعمال خوارزمية الأمثلة SGD؛ مع الزخم (عمل الباحث).


يبدأ الضبط بقيمة صغيرة، وتزداد القيمة تدريجياً مع عملية التدريب؛ لتصل أفضل قيمة للضبط على بيانات التدريب إلى 0.9406، وعلى بيانات التحقق إلى 0.9625.

في المنحنيين السابقين، نلاحظ أنّ هناك تغيّرات كبيرة في الجزء الأول من المنحني (خاصةً في أول 35 حقبة تدريبية)، وهذا سببه أن النموذج في بداية التدريب لا زال في مرحلة التعلم، يُخطئ في حقبة تدريب حالية، ثمّ يحاول تصحيح أخطأه في حقبة التدريب اللاحقة، وفي النهاية نلاحظ استقرار منحني التدريب، وهذا يعني أنّ النموذج قد تمّ تدريبه، أي تمّت ملاءمته على بيانات التدريب.

2.1.9.4 نتائج الاختبار باستعمال خوارزمية الأمثلة SGD؛ مع الزخم على مجموعة بيانات الاختبار:

يبين الشكل (4-13) مصفوفة الارتباك الناتجة عن اختبار نموذج التصنيف المقترح (باستعمال خوارزمية الأمثلة SGD؛ مع الزخم) على مجموعة بيانات الاختبار المكونة من 90 صورة GPR B-Scan حقيقية ملونة، وبالمجال الرمادي، تشكّل هذه المجموعة بيانات غير مرئية بالنسبة للنموذج المقترح، وهي قريبة من البيانات التي تُربّ النموذج عليها وتضم:

- 50 صورة ناتجة عن وجود أنابيب مطمورة: نجحت الخوارزمية بتصنيف 37 صورة منها بصورة صحيحة وأخطأت في تصنيف 13 صورة.
- 40 صورة لا تحتوي على أنابيب مطمورة: وقد نجحت الخوارزمية بتصنيف جميع هذه الصور بصورة صحيحة.




الشكل (4-13): مصفوفة الارتباك الناتجة عن اختبار نموذج التصنيف المقترح (باستعمال خوارزمية الأمثلة SGD؛ مع الزخم)

على مجموعة بيانات الاختبار (عمل الباحث).

يبين الشكل (4-14) منحنى خصائص التشغيل ROC لنموذج التصنيف المقترح (باستعمال خوارزمية

الأمثلة SGD؛ مع الزخم) عند اختباره على مجموعة بيانات الاختبار، وكما هو ملاحظ، فإنّ مقياس auc أعطى قيمة 0.870، وهذا يدل على جودة جيدة لخوارزمية التصنيف.



الشكل (4-14): منحنى خصائص التشغيل ROC لنموذج التصنيف (باستعمال خوارزمية الأمثلة SGD؛ مع الزخم)

عند اختباره على مجموعة بيانات الاختبار (عمل الباحث).

إنّ تفسير شكل منحنى ROC السابق هو كما يلي:

باستعمال عدد التنبؤات الموجبة والسالبة الحقيقية والخاطئة التي تُظهرها مصفوفة الارتباك الناتجة في الشكل (4-13)، فإننا نستطيع حساب كل من معدّل التنبؤات الموجبة الصحيحة TPR، ومعدّل التنبؤات الموجبة الخاطئة FPR للنموذج أثناء اختباره على مجموعة بيانات الاختبار كما يلي:

$$FPR = 1 - \frac{TN}{TN + FP} = 1 - \frac{40}{53} = 0.245$$

$$TPR = \frac{TP}{TP + FN} = \frac{37}{37} = 1$$

وعليه يكون منحنى ROC في بدايته على شكل خط مستقيم يمر من المبدأ (0, 0) ومن النقطة (0.25, 1)، ومن ثمّ يتم اكمال رسم المنحنى حتّى يصل كل من المعدّلين TPR, FPR إلى قيمهم الأعظمية المتمثلة بالقيمة 1. لذلك يظهر منحنى ROC بعد ذلك على شكل خط مستقيم يمر بالنقطة (0.25, 1) والنقطة (1, 1).

استُعملت قيم مصفوفة الارتباك التي حصلنا عليها في حساب مقاييس أداء النموذج المقترح (باستعمال خوارزمية الأمثلة SGD؛ مع الزخم) على بيانات الاختبار، كما هو موضّح في الجدول (4-4).

الجدول (4-4): نتائج الاختبار باستعمال خوارزمية الأمثلة SGD؛ مع الزخم (عمل الباحث):


Acc	Rec	Pre	F1-score	AUC
0.855	1	0.754	0.860	0.87

2.9.4 تقويم أداء نموذج التصنيف المقترح؛ مع استعمال خوارزمية الأمثلة Adam:

1.2.9.4 نتائج التدريب؛ مع استعمال خوارزمية الأمثلة Adam:


يوضّح الشكل (4-15) والشكل (4-16) عملية Model fitting لنموذج التصنيف المقترح؛ مع استعمال خوارزمية

الأمثلة Adam في أثناء عملية التدريب على بيانات التدريب نفسها المستعملة عند اختيار خوارزمية الأمثلة SGD؛ مع الزخم.



الشكل (4-15): منحنى الخسارة لمرحلة التدريب والتحقق؛ باستعمال خوارزمية الأمثلة Adam (عمل الباحث).

كما هو متوقع تبدأ الخسارة بقيم عالية، وتتناقص تدريجياً لتصل أفضل قيم الخسارة على بيانات التدريب إلى 0.0961، وعلى بيانات التحقق إلى 0.0487.



الشكل (4-16): منحنى الضبط لمرحلة التدريب والتحقق؛ باستعمال خوارزمية الأمثلة Adam (عمل الباحث).

يبدأ الضبط بقيم صغيرة، وتزداد القيمة تدريجياً مع عملية التدريب، لتصل أفضل قيم الضبط على بيانات التدريب إلى 1.00، وعلى بيانات التحقق إلى 1.00.


في المنحنيين السابقين، نلاحظ أن التغيرات في منحنيات التدريب قليلة بالمقارنة مع منحنيات التدريب عند استعمال خوارزمية SGD مع الزخم، كما وأن فجوة التعميم أقل منها في حال استعمال خوارزمية SGD مع الزخم، وهذا يدل على أن أداء نموذج التصنيف أثناء التدريب في حال استعمال خوارزمية Adam أفضل منه في حال استعمال خوارزمية SGD مع الزخم.

2.2.9.4 نتائج الاختبار؛ مع استعمال خوارزمية الأمثلة Adam على مجموعة بيانات الاختبار:

يبين الشكل (4-17) مصفوفة الارتباك الناتجة عن اختبار نموذج التصنيف المقترح (باستعمال خوارزمية الأمثلة Adam) على مجموعة بيانات الاختبار المكونة من 90 صورة GPR B-Scan والتي هي البيانات نفسها التي اختُبر النموذج عليها عند استعمال خوارزمية الأمثلة SGD؛ مع الزخم.

- 50 صورة ناتجة عن وجود أنابيب مطمورة: وقد نجحت الخوارزمية بتصنيف جميع هذه الصور بصورة صحيحة.

- 40 صورة لا تحتوي على أنابيب مطمورة: نجحت الخوارزمية بتصنيف 38 صورة منها بصورة صحيحة، وأخطأت في تصنيف صورتين منها.



الشكل (4-17): مصفوفة الارتباك الناتجة عن اختبار نموذج التصنيف (باستعمال خوارزمية الأمثلة Adam)

على مجموعة بيانات الاختبار (عمل الباحث).

يبين الشكل (4-18) منحنى خصائص التشغيل ROC لنموذج التصنيف المقترح (باستعمال خوارزمية الأمثلة Adam) عند اختباره على مجموعة بيانات الاختبار، وكما هو ملاحظ المنحنى يتجه أعلى ويسار المخطط؛ أي باتجاه النقطة (1,0)، ومقياس auc أعطى قيمة 0.975، وهذا يدل على جودة عالية لخوارزمية التصنيف.


إنّ تفسير شكل منحنى ROC الناتج هو كما يلي:

باستعمال عدد التنبؤات الموجبة والسالبة الحقيقية والخاطئة التي تُظهرها مصفوفة الارتباك الناتجة في الشكل (4-17)، فإننا نستطيع حساب كل من معدّل التنبؤات الموجبة الصحيحة TPR، ومعدّل التنبؤات الموجبة الخاطئة FPR لنموذج التصنيف عند اختباره على مجموعة بيانات الاختبار كما يلي:

$$FPR = 1 - \frac{TN}{TN + FP} = 1 - \frac{38}{38} = 0$$

$$TPR = \frac{TP}{TP + FN} = \frac{50}{52} = 0.962$$

وعليه يكون منحنى ROC في بدايته على شكل خط مستقيم، يمر من المبدأ (0, 0) ومن النقطة (0, 0.96)، ومن ثمَّ يتم اكمال رسم منحنى ROC حتى يصل كل من المعدلين FPR, TPR إلى قيمهم الأعظمية المتمثلة بالقيمة 1. لذلك يظهر منحنى ROC بعد ذلك على شكل خط مستقيم يمر من النقطة (0, 0.96) والنقطة (1,1).



الشكل (4-18): منحنى خصائص التشغيل ROC للنموذج (باستعمال خوارزمية الأمثلة Adam)


عند اختباره على مجموعة بيانات الاختبار (عمل الباحث).

استُعملت قيم مصفوفة الارتباك التي حصلنا عليها في حساب مقاييس أداء النموذج المقترح (باستعمال خوارزمية الأمثلة Adam) على بيانات الاختبار، كما هو موضح في الجدول (4-5).

الجدول (4-5): نتائج الاختبار؛ مع استعمال خوارزمية الأمثلة Adam (عمل الباحث):

Acc	Rec	Pre	F1-score	AUC
0.977	0.95	1	0.974	0.975

يبين الشكل (4-19) نتيجة الإخراج لنموذج التصنيف المعتمد (باستعمال خوارزمية الأمثلة Adam) على عينة عشوائية من مجموعة بيانات الاختبار:



الشكل (4-19): نتيجة الإخراج لنموذج CNN على عينة عشوائية من مجموعة بيانات الاختبار (عمل الباحث).

10.4 تحليل النتائج والمناقشة:

يُلاحظ من الجدول (4-4) والجدول (5-4) أن استعمال خوارزمية الأمثلة Adam للشبكة المقترحة أعطى نتائج أفضل على مجموعة بيانات التدريب نفسها، وبيانات الاختبار نفسها، لذا اعتُمدت خوارزمية الأمثلة Adam في النموذج النهائي المقترح في هذا البحث. يمكن تعليل ذلك كما يأتي:

إن القيمة الابتدائية لمعدل التعلّم 0.00001، ففي حال استعمال خوارزمية الأمثلة Adam، تقوم الخوارزمية بتكييف معدل التعلّم؛ وذلك بمراقبة أداء النموذج على مجموعة بيانات التدريب، وتعديل معدل التعلّم استجابةً لذلك،

أما في حال استعمال خوارزمية SGD مع الزخم؛ فإن قيمة معدل التعلّم تبقى ثابتة كل فترة التدريب للنموذج.

قوم أداء النموذج النهائي المقترح في البحث، بالاعتماد على أهم مقاييس الأداء لخوارزميات التصنيف، وهي:

الدقة Pre، والاستدعاء Rec، والضبط Acc، والمساحة الواقعة تحت المنحني AUC، والمؤشر F1-Score.

حُسبت مقاييس الأداء المذكورة للنموذج المقترح وقورنت بدراسات مرجعية سابقة، كما هو موضح في الجدول (4-6).

الجدول (4-6): مقارنة النموذج المقترح بالدراسات السابقة:

الطريقة (Method)	المؤشر F1-score	الاستدعاء Rec	الدقة Pre	الضبط Acc	المرجع
Gabor filter, Wavelet analysis	0.12	0.98	0.06	-	Onyszko & Skibniewska, (2021) [7]
Traditional edge detection	0.24	0.86	0.14	-	
Encoder-decoder DNN	0.853	0.854	0.852	0.850	Wang et al (2021) [8]
DNN-based Migration	0.9264	0.9141	0.939	0.957	Feng et al (2021) [9]
LSGAN YOLO v4	0.803	0.764	0.849	-	Yue et al (2021) [16]
CNNs	0.9323	-	-	-	Wang et al (2022) [10]
End-to-End DL model based on Key point- regression model	-	-	-	0.97	Su et al (2023) [11]
YOIO V5s	0.881	0.866	0.896	0.967	Sun et al (2023) [12]
YOLO V3- FDL Four scales- detection layer	0.881	-	-	-	Liu et al (2023) [13]
Mask R-CNN	0.824	0.815	0.833	-	Liu et al (2023) [14]
CNNs	0.974	0.95	1	0.977	نموذج CNN المقترح

11.4 الاستنتاجات Conclusions:

الكشف الآلي عن الهدف المظمو؛ بالاعتماد على صور GPR B-Scan قابل للتحقيق باستعمال الشبكات العصبونية الالتفافية CNNs، فقد أظهرت النتائج موثوقية جيدة لنموذج CNN المقترح؛ إذ بلغت القيم:

Acc=0.977, Pre=1, Rec=0.95, F1-Score=0.974, AUC=0.975.

هذه القيم حُصل عليها بناءً على مجموعة بيانات الاختبار التي اختيرت في هذا البحث حتى تكون متناسبة مع الحالة الدراسية التي بُجِثت (كشف أنابيب مضمورة في التربة).

في الواقع العملي الحقيقي عند كشف الأجسام المضمورة بجهاز GPR، فإن البيانات الجيولوجية الحقيقية التي تحتوي على الأجسام المضمورة قد تكون أكثر تعقيداً مما دُرس، وكذلك الأجسام المضمورة قد تكون بأشكال معقدة عن حالة الأنابيب التي دُرس في هذا البحث كحالة دراسة، ونظراً لأن تقانات التعلم العميق الخاضعة للإشراف تقودها البيانات Data-driven، فمن الصعب تطبيق الشبكة المدربة تدريباً جيداً، مباشرة على مجموعة بيانات جديدة مختلفة بصورة كبيرة عن بيانات التدريب؛ ومن ثمّ قد يسوء أداء النموذج المقترح في الدراسة على الكشوفات الميدانية الحقيقية في بيئات أكثر تعقيداً. وعليه، يمكن اعتماد النموذج المقترح في البحث في الكشف الآلي عن الأنابيب المضمورة في صور GPR B-Scan، ليكون بمنزلة مساعد للمستثمرين الذين لا يملكون الخبرة الكافية في تفسير بيانات GPR؛ ومن ثمّ تقديم أداة داعمة دون استبدال الوكيل البشري الذي في النهاية سيكون صاحب القرار في التفسير النهائي للنتائج.

12.4 خاتمة البحث:

تُعدُّ تقانة GPR من التقانات المهمة المستعملة في التقييم اللا إتلافي NDE، والكشف عن الأهداف المظمورة، وقد استُعملت على نطاق واسع في هذا المجال. يُنتج الهدف المظمور في الصورة المحصّلة بجهاز GPR بصمة تكون على شكل قطع زائد، ووضوح هذه البصمة في الصورة يتوقّف بصورة كبيرة على تعقيد البيئة الجيولوجية تحت سطح الأرض، وبنوع مادة الهدف المظمور، وشكله، وأبعاده، وبنوع التربة، ومن ثمّ يحتاج تفسير الصور المحصلة إلى مستثمر ذي خبرة في مجال هذه التقانة، وبهدف تقليل الاعتماد على الخبرة البشرية في تفسير النتائج؛ مما يقلل من التكاليف المالية، ويوفّر الوقت اللازم لتفسير البيانات المحصّلة بجهاز GPR والتي قد تكون ضخمة، فقد استُعمل في هذا البحث الشبكات العصبونية الالتفافية CNNs كواحدة من تقانات التعلّم العميق من أجل أتمتة عملية الكشف الآلي عن الأنابيب المظمورة (كدراسة حالة)؛ بالاعتماد على الصور المأخوذة من جهاز GPR من النوع B-Scan images.

بُنِيَ في هذا البحث نموذجُ CNN لتصنيف صور GPR B-Scan إلى صور تحتوي على أنابيب مظمورة، وصور لا تحتوي على أنابيب مظمورة، وتظهر نتيجة الكشف في خرجه على شكل احتمال متوقّع، وأنشئت مجموعة تدريب النموذج المقترح من صور GPR B-Scan محاكاة، وتم التغلب على محدودية البيانات المستعملة باستعمال تقانات زيادة البيانات، واختُبر النموذج على مجموعة اختبار تضمّ صور GPR B-Scan حقيقية، وهي صور غير مرئية بالنسبة للنموذج. لأجل تقييم النموذج المقترح، حُسِبَت مقاييس الأداء التالية: الضبط، والاستدعاء، والدقّة، والخصوصية، والمؤشّر F1-score، وAUC: المساحة الواقعة تحت منحنى ROC، وقورنت هذه القيم مع نتائج تقييم نماذج أخرى في الأبحاث السابقة المرتبطة بموضوع البحث.

أظهرت النتائج موثوقية جيدة للنموذج المقترح؛ إذ بلغت القيم:

$$\text{Acc}=0.977, \text{Pre}=1, \text{Rec}=0.95, \text{F1-Score}=0.974, \text{AUC}=0.975$$

الآفاق المستقبلية

أهم الصعوبات التي كانت تواجه تصنيف صور GBR B-Scan هي محدودية البيانات، إذ إنَّ عدد الصور التي تُزبَّ نموذج CNN المقترح عليها في البحث كان 400 صورة، وعدد الصور التي تم اختبار النموذج عليها كان 90 صورة؛ لذلك يوصى بزيادة عدد البيانات لتطوير البحث في المستقبل.

ويوصى بتطوير النموذج، ليصبح مكون من ثلاث مراحل، على سبيل المثال: المرحلة الأولى: اكتشاف وجود أهداف مطمورة في صور GBR B-Scan أو عدم وجودها، والمرحلة الثانية: تحديد أبعاد الهدف المطمور الذي اكتُشِف بصورة آليّة من المرحلة الأولى، والمرحلة الثالثة: تحديد نوع مادة الهدف المطمور المكتشف.

ويوصى باستعمال طرائق فاعلة في تقليل الكثرات Clutters في صور GPR B-Scan؛ بهدف تحسين وضوح بصمة القطع الزائد فيها، والنتائج عن الهدف المطمور.

ويوصى بتحقيق الكشف الآلي عن الأهداف المطمورة باستعمال الصور GPR C-Scan (المسح المقطعي

العرضي).

المراجع References

- [1] Lombardi, F., Podd, F., & Solla, M. (2022). From its Core to the Niche: Insights from GPR Applications. *Remote Sensing*, 14(13), 1-30.
- [2] 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.
- [3] 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.
- [4] 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.
- [5] 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, 1-15. <https://doi.org/10.1016/j.forsciint.2021.110882>.
- [6] Alsharahi, G., Faize, A., Maftai, C., Bayjja, M., Louzazni, M., Driouach, A. & others. (2019). Analysis and Modeling of GPR Signals to Detect Cavities: Case Studies in Morocco. *Journal of Electromagnetic Engineering and Science*, 19(3), 177–187.
- [7] Onyszko, K., & Skibniewska, A. (2021). A New Methodology for the Detection and Extraction of Hyperbolas in GPR Images. *Remote Sensing*, 13(23), 1-30.
- [8] 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. *IEEE Access*, 9, 207-218.
- [9] Feng, J., Yang, L., Wang, H., Tain, Y., & Xiao, J. (2021). Subsurface Pipes Detection Using DNN-Based Back Projection on GPR Data. *IEEE/CVS Winter Conference on Applications of Computer Vision*, 266-275.
- [10] Wang, H., Ouyang, S., Liu, Q., Liao, K., & Zhou, L. (2022). Buried Target Detection Method for Ground Penetrating Radar Based on Deep Learning. *Journal of Applied Remote Sensing*, 16(1), 1-21. <http://doi.org/10.1117/1.JRS.16.018503>.
- [11] 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. *Automation in construction*, 149, 1-19. <https://doi.org/10.1016/j.autcon.2023.104776>.
- [12] 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. *Agronomy*, 13(2), 1-18. <https://doi.org/10.3390/agronomy13020344>.

- [13] 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, 1-15. <https://doi.org/10.1016/j.autcon.2022.104698>.
- [14] 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, 1-43. <https://doi.org/10.1016/j.autcon.2022.104689>.
- [15] Pham, M.T., & Lefèvre, S. (2018). Buried Object Detection from B-scan Ground Penetrating Radar Data Using Faster-RCNN. *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium*, 6804-6807.
- [16] Yue, Y., Liu, H., Meng, X., Li, Y., & Du, Y. (2021). Generation of High-Precision Ground Penetrating Radar Images Using Improved Least Square Generative Adversarial Networks. *Remote sensing*, 13(22), 1-16.
- [17] Zhang, X., Han, L., Robinso, M., & Gallagher, A. (2021). A GANs-Based Deep Learning Framework for Automatic Subsurface Object Recognition from Ground Penetrating Radar Data. *IEEE Access*, 9, 9-18.
- [18] Kanafiah, S., Ali, H., Firdaus, AZ.A., Azalan, MS.Z., Jusman, Y., Khairi, AA., & 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), 1-10. <https://doi.org/10.1088/1757-899x/705/1/012028>.
- [19] Oliveira, R.J., Caldeira, B., Teixeira, T., & Borges, J.F. (2021). GPR Clutter Reflection Noise-Filtering through Singular Value Decomposition in the Bidimensional Spectral Domain. *Remote sensing*, 13(10), 1-15. <https://doi.org/10.3390/rs13102005>.
- [20] 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.
- [21] Rossi, M. (2022). Ground Penetrating Radar. *Engineering Geophysics*, 87-94.
- [22] Zhou, D., & Zhu, H. (2021). Application of Ground Penetrating Radar in Detecting Deeply Embedded Reinforcing Bars in Pile Foundation. *Advances in Civil Engineering*, 1-13.
- [23] Rasol, M., Perez-Gracia, V., Fernandes, F.M., Pais, J.C., Santos-Assuncao, S.S., & Roberts, J.S. (2022). Ground Penetrating Radar System: Principles. *Handbook of Cultural Heritage Analysis*, 705-738.
- [24] Zhang, A., Lipton, Z.C., Li, M., & Smola, A.J. (2021). Dive into Deep Learning. *arXiv preprint arXiv*, 1-1178.
- [25] Szandata, T. (2021). Review and Comparison of Commonly Used Activation Functions for Deep Neural Networks. *Bio-inspired neurocomputing*, 203-224.

- [26] Banerjee, K., Gupta, R.R., Vyas, K., & Mishra, B. (2020). Exploring Alternatives to Softmax Function. *arXiv preprint arXiv*, 1-8.
- [27] Wu, J. (2017). Introduction to Convolutional Neural Networks. *National Key Lab for Novel Software Technology*, 5(23), 1-31.
- [28] Ho, Y., & Wookey, S. (2019). The Real-World-Weight Cross-Entropy Loss Function: Modeling the Costs of Mislabeling. *IEEE Access*, 8, 4806-4813.
- [29] Liu, R., Wu, T., & Mozafari, B. (2020). Adam with Bandit Sampling for Deep Learning. *Neural Information Processing Systems*, 33, 5393-5404.
- [30] Hui, L., Belkin, M., & Nakkiran, P. (2022). Limitations of Neural Collapse for Understanding Generalization in Deep Learning. *arXiv preprint arXiv*, 1-13.
- [31] Li, Z., Liu, L., Dong, Ch., & Shang, J. (2020). Overfitting or Underfitting? Understand Robustness Drop in Adversarial Training. *arXiv preprint arXiv*, 1-10.
- [32] Li, L., & Spratling, M. (2023). Understanding and Combating Robust Overfitting via Input Loss Landscape Analysis and Regularization. *Pattern Recognition*, 136, 1-11.
- [33] Bacanin, N., Zivkovic, M., Al-Turjman, F., Venkatachalam, K., Trojovský, P., Strumberger, I., & Bezdan, T. (2022). Hybridized Sine Cosine Algorithm with Convolutional Neural Networks Dropout Regularization Application. *Scientific Reports*, 12(1), 1-20.
- [34] Huang, L., Zhou, Y., Wang, T., Luo, J., & Liu, X. (2022). Delving into the Estimation Shift of Batch Normalization in a Network. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 763-772.
- [35] Warren, C., Giannopoulos, A., & Giannakis, I. (2016). gprMax: Open Source Software to Simulate Electromagnetic Wave Propagation for Ground Penetrating Radar. *Computer Physics Communications*, 209, 163-170.
- [36] Derobert, X., & Pajewski, L. (2018). TU1208 Open Database of Radargrams: The Dataset of the IFSTTAR Geophysical Test Site. *Remote sensing*, 10(4), 1-50. <https://doi.org/10.3390/rs10040530>.
- [37] Sun, H.H., Cheng, W., & Fan, Z. (2022). Learning to Remove Clutter in Real-World GPR Images Using Hybrid Data. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-14.
- [38] Yang, S., & Berdin, G. (2017). The Receiver Operating Characteristic (ROC) Curve. *The Southwest Respiratory and Critical Care Chronicles*, 5(19), 34-36.

Syrian Arab Republic

Ministry of Higher Education and Scientific Research

Damascus University

Faculty of Mechanical and Electrical Engineering

Department of Electronics and Communication

Engineering



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

A dissertation submitted in partial fulfillment of the requirements for the degree
of Master in Applied Electronics Engineering

By

Eng. Hisham Naseer

Supervised by

Prof. Dr. Eng. Nadim Chahin

Academic year

2022-2023