الجمهورية العربية السورية

وزارة التعليم العالي والبحث العلمي

جامعة دمشق

قسم الهندسة الطبية

بناء نموذج لتقييم هشاشة العظام لمفصل الورك باستخدام الذكاء الاصطناعي

رسالة مقدمة لنيل درجة الماجستير في الهندسة الطبية الحيوية

إعداد

المهندسة خلود احمد سويقات

إشراف

الأستاذة الدكتورة رشا مسعود

إشراف مشارك

الأستاذ الدكتور ممدوح منيف

2025

الجمهورية العربية السورية

وزارة التعليم العالي والبحث العلمي

جامعة دمشق

قسم الهندسة الطبية

بناء نموذج لتقييم هشاشة العظام لمفصل الورك باستخدام الذكاء الاصطناعي

رسالة مقدمة لنيل درجة الماجستير في الهندسة الطبية الحيوية

إعداد المهندسة خلود احمد سويقات

إشراف

الأستاذة الدكتورة رشا مسعود

إشراف مشارك

الأستاذ الدكتور ممدوح منيف

أعضاء لجنة الحكم على رسالة الماجستير

الأستاذة الدكتورة رشا مسعود	**الأستاذ الدكتور هاني عماشة**	**الأستاذ الدكتور ايمن صابوني**
جامعة دمشق	**جامعة دمشق**	**جامعة دمشق**

2025

صفحة قرار لجنة الحكم، وتوقيعات لجنة المناقشة، Approval Page

تصريح خطي

أنا الموقع أدناه أصرح بعلمي الكامل وقبولي:

1. أن كل ما ينتج عن البحث والأطروحة هو ملكية فكرية ومالية بالتشارك مع جامعة دمشق، وأنني ألتزم بأخذ موافقة الجامعة في حال رغبتي بنشر البحث أو الأطروحة أو جزء منها نصا أو مضمونا خارج إطار الجامعة (من دور نشر أو مكتبات أو مواقع إلكترونية وغيرها من وسائل النشر).
2. أنه لا يوجد جزء من هذه الأطروحة تم اقتباسه من عملي آخر أو أنجز للحصول على شهادة أخرى في جامعة دمشق أو أية جامعة أو معهد تعليمي داخل أو خارج الجمهورية العربية السورية.

الاسم والتوقيع

المهندسة خلود احمد سويقات

شكر وتقدير

من أيّ أبواب الشكر ندخل، وبأي عبارات الامتنان نُعبّر، فلكل لمسة منكم، ولكل جهد بذلتموه، حروفُ شكرٍ لا تكفي، وعبارات عرفان لا تفي.

أتوجه بجزيل الشكر وخالص التقدير إلى السادة المشرفين الكرام، لما قدّموه من دعم وتوجيه خلال جميع مراحل هذا البحث، فكان لعطائهم أثر بالغ في إنجازه.

وأخص بالشكر والامتنان أستاذتي القديرة **الدكتورة رشا مسعود**، التي كانت خير سند علمي وإنساني، فلم تبخل عليّ يوماً بعلمها أو وقتها، وكانت حاضرة في كل مرحلة من مراحل هذا البحث بدعمها الكريم وتوجيهها البنّاء. لقد أثرت العمل بملاحظاتها الدقيقة ونصائحها الغنية، فكان لما قدّمته من ملاحظات قيمة أعظم الأثر في تطوير هذا البحث وصقله. تعلمت منها الدقة في العمل، والنقد البنّاء، والحرص على التفاصيل، فجزاها الله عني خير الجزاء، وبارك في علمها وأخلاقها كما باركتني بعطائها.

كما أتقدم بوافر الشكر وخالص الامتنان لأستاذي الفاضل **الدكتور ممدوح منيف**، الذي كان منذ عامي الثالث في كلية الهندسة الطبية أباً عطوفاً ومرشداً كريماً، فكان نعم السند والموجه، وأتم فضله بإشرافه الكريم على هذا البحث في مرحلة الماجستير، فزودني من علمه الغزير وخبرته الواسعة، وكان صاحب الفضل في اقتراح فكرة البحث. فله مني كل الشكر والعرفان، ولعله من الوفاء أن أقول: كلماتي تعجز عن التعبير عما أكنّه له من تقدير.

ولا يفوتني أن أتوجه بجزيل الشكر والعرفان للأستاذ **الدكتور أيمن صابوني**، الذي لطالما أفاض علينا من علمه، واحتضننا بتواضعه وطيبته، وأشكره على تحكيم هذا البحث وتوجيهاته القيّمة التي ساهمت في تقويمه وإغنائه.

كما أخص بالشكر الأستاذ **الدكتور هاني عماشة**، الذي كان مثال المعلم المخلص، وأشكره على جهوده في تحكيم هذا البحث، وملاحظاته القيّمة التي كان لها الأثر الكبير في رفع جودة العمل وتحسين مخرجاته.

وكل الامتنان والوفاء أقدّمه لأساتذتي الكرام في برنامج ماجستير الهندسة الطبية لما قدموه لنا من علمٍ ومعرفة وتوجيه سديد طوال سنوات الدراسة، فكانوا خير معلمين ومشجعين.

وختاماً، لا يسعني إلا أن أتوجه بالشكر والتقدير إلى **كلية الهندسة الكهربائية والميكانيكية**، وإلى جميع العاملين والإداريين في **كلية الهندسة الطبية**، على جهودهم المخلصة في تهيئة البيئة المناسبة لإنجاز هذا البحث.

فهرس المحتويات

العنوان	الصفحة
فهرس الأشكال	X
فهرس الجداول	XIV
جدول بعض المصطلحات المستخدمة في البحث	XV
فهرس المعادلات	XIX
الملخص	1
الفصل الأول: الإطار العام للبحث	
1.1 المقدّمة	3
2.1 الإشكالية البحثية	4
3.1 الهدف من البحث	4
4.1 أهمية البحث	5
5.1 طرائق البحث	5
6.1 الوصف التوثيقي لمحتوى البحث	6
الفصل الثاني: مرض هشاشة العظام	
1.2 المقدّمة	8
2.2 هشاشة العظام	8
1.2.2 مقدمة	8
2.2.2 بنية العظام الطبيعية	8
3.2.2 التغيرات في العظام عند الإصابة بهشاشة العظام	10
4.2.2 تغيرات الكتلة العظمية على مدى الحياة	11
5.2.2 تعريف هشاشة العظام	11
6.2.2 العوامل المؤدية إلى حدوث مرض هشاشة العظام	11
7.2.2 تأثير مرض هشاشة العظام	14
1.7.2.2 كسر الورك Hip	14
8.2.2 تشخيص هشاشة العظام	15

9.2.2 المبدأ العام لقياس وتقييم الكثافة بالأشعة	16
1.9.2.2 مفهوم T-score	16
2.9.2.2 مفهوم Z-score	17
10.2.2 تصنيف مرض هشاشة العظام وفق كثافة المعادن	17
11.2.2 التصوير الطبي في هشاشة العظام	18
12.2.2 هشاشة العظام وصور الأشعة السينية البسيطة X-ray	19
13.2.2 علاج هشاشة العظام	20
14.2.2 الخاتمة	20
الفصل الثالث: الأسس النظرية للبحث	
1.3 مقدمة	22
2.3 تعاريف أساسية	22
1.2.3 الذكاء الاصطناعي	22
2.2.3 تعلم الآلة	22
3.2.3 التعلم العميق	23
1.3.2.3 الشبكات العصبونية الاصطناعية	25
2.3.2.3 بيرسيبترون	26
3.3.2.3 بيرسيبترون متعدد الطبقات	26
4.2.3 شبكات الطي العصبونية	29
1.4.2.3 معمارية شبكة CNN	29
5.2.3 اكتشاف الأشياء والتصنيف	32
1.5.2.3 تصنيف الصور	33
6.2.3 خوارزميات اكتشاف الأشياء	37
7.2.3 المصنفات وتقنيات التحسين المستخدمة في البحث	45
1.7.2.3 خوارزميات التصنيف	45
2.7.2.3 تقنيات التحسين المستخدمة في البحث	48
8.2.3 الأدوات المستخدمة في تقييم النماذج	49
الفصل الرابع: الدراسات المرجعية	

1.4 المقدّمة	55
2.4 أدوات تقييم المخاطر التقليدية	55
3.4 الدراسات المرجعية المعتمدة على البيانات السريرية	56
4.4 الدراسات المرجعية المعتمدة على الصور الشعاعية للورك	59
5.4 الدراسات المرجعية المعتمدة على الصور الشعاعية للورك والبيانات السريرية	63
6.4 الخاتمة	67
الفصل الخامس: الإجراء العملي	
1.5 المقدّمة	72
2.5 منهجية البحث	72
3.5 بيئة العمل	73
4.5 قواعد البيانات المستخدمة في البحث	74
1.4.5 الحصول على البيانات	75
1.1.4.5 مجموعة البيانات الهندية	75
2.1.4.5 مجموعة البيانات السورية	76
5.5 بروتوكول التصوير	78
6.5 بناء النماذج	78
1.6.5 نموذج البيانات السريرية	78
1.1.6.5 تحليل استكشافي للبيانات السريرية	79
2.1.6.5 المعالجة الأولية للبيانات	80
3.1.6.5 بناء النموذج باستخدام بحث الشبكة والتحقق المتبادل K-fold	81
4.1.6.5 تخفيض عدد الميزات	82
5.1.6.5 دمج البيانات السريرية	83
2.6.5 نموذج الصور	83
1.2.6.5 استخدام شبكة Yolov5 للكشف عن مفصل الورك في مجموعة البيانات الهندية	84
2.2.6.5 استخدام شبكة Yolov9 في تصنيف هشاشة العظام	85
3.6.5 النموذج الهجين	89

الفصل السادس: النتائج ومناقشتها	
1.6 مقدمة	**93**
2.6 نتائج تصنيف البيانات السريرية السورية	**93**
3.6 نتائج تصنيف البيانات السريرية الهندية	**97**
4.6 نتائج تصنيف دمج البيانات السريرية السورية والهندية	**97**
5.6 نتائج تصنيف صور الأشعة السينية	**100**
1.5.6 نتائج نموذج Yolov5 المدرب على مجموعة البيانات الهندية	**100**
2.5.6 نتائج نموذج Yolov9 المدرب على مجموعة البيانات السورية	**101**
3.5.6 مناقشة نتائج الصور	**106**
6.6 نتائج النموذج الهجين	**107**
7.6 المناقشة والمقارنة مع الدراسات السابقة	**108**
الفصل السابع: الاستنتاجات والآفاق المستقبلية	
1.7 الاستنتاجات	**114**
2.7 الآفاق المستقبلية	**115**
المراجع	**116**

فهرس الأشكال

الشكل	الصفحة
الشكل (1.2): البنية الداخلية الإسفنجية للعظم.	9
الشكل (2.2): الفرق بين العظام الطبيعية والعظام المصابة بمرض هشاشة العظام.	10
الشكل (3.2): (أ): نسيج عظم إسفنجي طبيعي، (ب): نسيج عظم إسفنجي مصاب بهشاشة العظام.	10
الشكل (4.2): قياس كثافة العظام باستخدام آلة التصوير بالأشعة السينية مزدوجة الطاقة.	15
الشكل (5.2): العلاقة بين الكتلة العظمية والعمر.	18
الشكل (6.2): صورة إشعاعية للحوض عند مريض هشاشة العظام	19
الشكل (1.3): البرمجة التقليدية مقابل تعلم الآلة	23
الشكل (2.3): الفرق بين التعلم الآلي والتعلم العميق في استخراج الميزات.	24
الشكل (3.3): العلاقة بين الذكاء الاصطناعي والتعلم الآلي والتعلم العميق.	25
الشكل (4.3): البنية العامة لشبكة عصبونية اصطناعية.	25
الشكل (5.3): مخطط بيرسيبترون.	26
الشكل (6.3): شبكة عصبية ذات طبقتين مخفيتين.	27
الشكل (7.3): عملية تدريب الشبكة العصبونية باستخدام خوارزمية تعلم الانتشار الخلفي.	28
الشكل (8.3): بنية شبكة CNN.	29
الشكل (9.3) تمثيل لعمليّة طّي المرشح على الصورة.	30
الشكل(10.3): مثال على طبقة التجميع. مقدار الإزاحة stride هو 2.	31
الشكل (11.3): الاختلافات بين التصنيف والتحديد والكشف والتجزئة.	32

الشكل (12.3): خطوات عملية تصنيف الصور. أ. طريقة التصنيف التقليدية. ب. طريقة التعلم العميق.	33
الشكل (13.3): اتصالات شبكة CNN التقليدية.	34
الشكل(14.3): وحدة الراسب.	34
الشكل(15.3): الاتصال المختصر.	35
الشكل(16.3): بنية ResNet50.	36
الشكل (17.3): نظرة عامة على نظام R-CNN. يتم استخلاص المناطق المقترحة من الصورة المدخلة باستخدام البحث الانتقائي، ثم يتم حساب الميزات بواسطة CNN واستخدامها لتصنيف المناطق باستخدام مصنف SVM.	38
الشكل (18.3) يقسم YOLO الصورة إلى شبكة S × S خلية، ويتوقع كل خلية بعدد من إطارات التحديد، وبمعدل عتبة الدقة (الثقة) لهذه الإطارات. بالإضافة إلى توقعات الأصناف.	39
الشكل(19.3): مثال عن كيفية حساب IoU.	40
الشكل (20.3): أمثلة على اكتشاف الكائنات عند عتبات IoU مختلفة.	41
الشكل(21.3): مقارنة بين بنية الكاشف أحادي المرحلة ومكون من مرحلتين.	41
الشكل (22.3): بنية نموذج YOLOv1.	42
الشكل (23.3): بنية نموذج YOLOv6	43
الشكل (24.3): معلومات التدرج القابلة للبرمجة (PGI).	44
الشكل (25.3): بنية GELAN.	44
الشكل (26.3): شكل المستوي الفائق في فضاء ثنائي الأبعاد.	46
الشكل (27.3): المستوي الفائق الذي يحقق الهامش الأكبر بين الأصناف	47
الشكل (28.3) آلية عمل خوارزمية الغابة العشوائية.	47
الشكل (29.3) مثال على البحث الشبكي.	49

الشكل (30.3) معايير أداء المصنف من مصفوفة الإرباك.	51
الشكل (31.3) المساحة الواقعة تحت منحنى ROC.	52
الشكل (32.3) مثال على التنبؤات مع عتبة IoU مضبوطة على α=0.5 .	53
الشكل (1.4) المنطقة محل الاهتمام التي تم اقتصاصها في صورة شعاعية بسيطة للورك.	60
الشكل (2.4) الورك الأيمن: لا يوجد كسر، نتيجة سلبية حقيقية؛ الورك الأيسر: كسر بين المدورين، نتيجة إيجابية حقيقية.	62
الشكل (3.4) مخطط تدفق لاختيار الميزات وتطوير نموذج التصوير الشعاعي العميق.	64
الشكل (4.4) صورة شعاعية للورك قبل التحليل، توضح منطقة الاهتمام التي تم اقتصاصها.	65
الشكل (1.5) إطار متعدد المراحل للكشف عن هشاشة العظام وتشخيصها	72
الشكل (2.5) أهمية الميزات باستخدام شرح شابلي لمجموعة البيانات الهندية	77
الشكل (3.5) تسلسل مراحل العمل لبناء نموذج الكشف عن هشاشة العظام باستخدام البيانات السريرية	79
الشكل (4.5) توزيع ميزة "العمر".	79
الشكل (5.5) توزيع ميزة العمر مع التشخيص.	80
الشكل (6.5) أهمية الميزات المدربة باستخدام مصنف الغابة العشوائية للبيانات السريرية السورية.	82
الشكل (7.5) سير العمل للتنبؤ بمخاطر الإصابة بهشاشة العظام باستخدام التصوير الشعاعي لصور الأشعة السينية للحوض.	83
الشكل (8.5) عينة من الصور المعنونة المستخدمة في التدريب. يدل الإطار حول مفصل الورك على إطار الحقيقة المرجعي الذي يحدد يدوياً، وتستخدمه الشبكة في التنبؤ بإطارات التحديد. وتدل الأرقام على معلومات الإطار.	85
الشكل (9.5) بنية نموذج YOLOv9 لتصنيف صور الأشعة السينية في الكشف عن هشاشة العظام.	85

الشكل (10.5) عينة من الصور المعنونة المستخدمة في التدريب. يدل الإطار حول مفصل الورك على إطار الحقيقة المرجعي الذي يحدد يدوياً، وتستخدمه الشبكة في التنبؤ بإطارات التحديد.	86
الشكل (11.5) نتيجة المعالجة على الصور مقارنة بالصور الأصلية.	87
الشكل (12.5) صور لكل فئة من التّقنيّات المتّبعة لتعزيز البيانات.	88
الشكل (13.5) سير العمل للتنبؤ بمخاطر الإصابة بهشاشة العظام باستخدام التصوير الشعاعي لصور الأشعة السينية للحوض والمتغيرات السريرية.	89
الشكل (1.6) معامل الارتباط بين الميزات في مجموعة البيانات السورية.	93
الشكل (2.6) توزيع الميزات المستمرة	94
الشكل (3.6) منحنيات ROC لنماذج تعلم الآلة المختلفة SVM وRF.	98
الشكل (4.6) أداء التصنيف باستخدام البيانات السريرية من مجموعات البيانات السورية (D1) والهندية (D2) على مجموعة بيانات واحدة واختبارها على مجموعة أخرى.	99
الشكل (5.6) عينة من صور الاختبار باستخدام YOLOv5.	100
الشكل (6.6) عينة من صور الاختبار باستخدام YOLOv9. يدل الإطار حول مفصل الورك على إطار التنبؤ التي تنبأت به الخوارزمية. وتدل الأرقام على احتمال أن تكون المنطقة المحددة سليمة أو مصابة بهاشة العظام.	101
الشكل (7.6) أداء نموذج Yolov9.	102
الشكل (8.6) عينة من صور الاختبار باستخدام YOLOv9-e بعد المعالجة الأولية للصور.	102
الشكل (9.6) مصفوفة الإرباك لنموذج التصنيف عند التكرار 20.	103
الشكل (10.6) مصفوفة الإرباك لنموذج التصنيف عند عدد تكرارات epochs=35.	103
الشكل (11.6) عينة من صور اختبار النموذج عند عدد تكرارات epochs=35.	104

الشكل (12.6) مصفوفة الإرباك لنموذج التصنيف عند عدد تكرارات epochs=35، واستخدام التنعيم label-smoothing.	105
الشكل (13.6) عينة من صور اختبار نموذج التصنيف عند عدد تكرارات epochs=35، واستخدام التنعيم label-smoothing.	105
الشكل(14.6) نتائج الكشف عن هشاشة العظام باستخدام YOLOv9 على بيانات التصوير بالأشعة السينية.	107
الشكل (15.6) نتائج دمج السجلات السريرية مع صور الأشعة السينية لتصنيف البيانات السورية (D1).	108

فهرس الجداول

الجدول	الصفحة
الجدول (1.2) نسب الاصابات عند الرجال والنساء	14
الجدول (1.4) الأداء التشخيصي لنماذج التصوير الشعاعي العميق	64
الجدول (2.4) مقارنة بين الدراسات المرجعية.	68
الجدول (1.5) توزع درجات T-score في قواعد البيانات.	75
الجدول (1.6) الخصائص السريرية لمجتمع الدراسة، ومقارنة الأفراد الذين تم تشخيصهم بهشاشة العظام وغير المصابين به.	95
الجدول (2.6) المحددات الفائقة النهائية لكل نموذج	96
الجدول (3.6) أداء نماذج تعلم الآلة المختلفة للتنبؤ بهشاشة العظام.	96
الجدول (4.6) أداء النماذج بعدد متغيرات مختلفة للبيانات السريرية السورية.	96
الجدول (5.6) أداء نماذج تعلم الآلة للبيانات السريرية الهندية.	97
الجدول (6.6) أداء نموذج مشترك يستخدم ميزات من كلتا مجموعتي البيانات (السورية والهندية).	98
الجدول (7.6) مقارنة الدراسات المرجعية مع الدراسة الحالية.	110

جدول بعض المصطلحات المستخدمة في البحث

المصطلح العربي	الرمز	المصطلح الإنكليزي
منظمة الصحة العالمية	WHO	World Health Organization
كثافة المعادن في العظام	BMD	Bone Mineral Density
الانحرافات المعيارية	SD	Standard Deviation
قياس امتصاص الأشعة السينية ثنائية الطاقة	DXA	Dual-Energy X-Ray Absorptiometry
اللص الصامت (مرض بدون أعراض)	-	The Silent Thief
أداة التقييم الذاتي لهشاشة العظام للنساء الآسيويات بعد سن اليأس	OSTA	Osteoporosis Self-Assessment Tool For Asians
المنطقة ذات الاهتمام	ROI	Region Of Interest
آلة متجه الدعم	SVM	Support Vector Machine
الغابات العشوائية	RF	Random Forest
الشبكات العصبونية متعددة الطبقات	MLP	Multi- Layer Perceptron
شبكة الرواسب	-	Resnet50
تقييم أخطار حدوث الكسور	FRAX	The Fracture Risk Assessment Tool
الشبكات العصبونية الاصطناعية	ANN	Artificial Neural Network
أقرب الجيران	KNN	K-Nearest Neighbor
الانحدار التدريجي	LoR	Logistic Regression
المساحة تحت منحنى خاصية تشغيل مستقبل	AUROC	Area Under Receiver Operating Characteristic Curve
المتوسط العام للشباب البالغين	YAM	Young Adult Mean
تعزيز الأشجار	-	Gradient Boosting Trees
السكري من النوع الثاني	T2DM	Type 2 Diabetes Mellitus
تعلم الآلة	ML	Machine Learning
شبكة التعلم العميق	DNN	Deep Neural Network

Nonlocal Neural Network	**NLNN**	**الشبكة العصبية غير المحلية**
Intersection Over Union	**IoU**	**التقاطع على الاتحاد**
You Only Look Once	**YOLO**	**أنت تنظر مرة واحدة**
Least Absolute Shrinkage And Selection Operator	**LASSO**	**عامل الانكماش**
Osteopororsis	–	**هشاشة العظام**
Porous Bones	–	**العظام المسامية**
Age	–	**العمر**
Sex	–	**الجنس**
Genome	–	**المادة الوراثية**
Lifestyle	–	**نمط الحياة**
Hip	–	**الورك**
Artificial Intelligence	–	**الذكاء الاصطناعي**
Deep Learning	**DL**	**التعلُّم العميق**
Neurons	–	**العصبونات**
Activation Function	–	**تابع تنشيط**
Perceptron	–	**شبكة عصبية تحتوي على طبقة واحدة**
Feedforward Neural Network	–	**الشبكات العصبية أمامية التغذية**
Backpropagation	–	**الانتشار الخلفي**
Convolutional Neural Networks	**CNN**	**شبكات الطي العصبونية**
Features Extraction	–	**استخراج الميزات**
Pooling	–	**التجميع**
Convolution	–	**الالتفاف (الطي)**
Fully Connected Layers	**FC**	**الطبقات المتصلة كلياً**
Over-Fitting	–	**الملاءمة الزائدة**
Max Pooling	–	**تجميع ماكس**

Flattening Operation	–	عمليّة بَسْط
Softmax	–	دالة التفعيل
Sigmoid	–	تابع سيغمويد
Computer Aided Detection	CAD	التشخيص بمساعدة الكمبيوتر
Object Detection	–	اكتشاف الكائنات
Classification Algorithms	–	خوارزميات التصنيف
Bounding Boxes	–	إطارات تحديد
Residual Networks	–	شبكات الرواسب
Vanishing Gradient	–	تلاشي المشتق
Shortcut Connections (Skip Connections)	–	الاتصالات المختصرة (وصلات تخطي)
Residual Unit	RU	كتلة الراسب
Residual Knowledge	–	معرفة الراسب (المتبقية)
Bottleneck Blocks	–	كتل عنق الزجاجة
Identity Mapping	–	خريطة الهوية
Region Proposal	–	اقتراح المنطقة
Sliding Window Approach	–	مبدأ النافذة المتحركة
Confidence Scores	–	مستويات الثقة
Ground Truth Box	–	إطار حقيقة مرجعي
Feature Pyramid Network	FPN	شبكة هرم الخصائص
Programmable Gradient Information	PGI	معلومات التدرج القابلة للبرمجة
Hyper Plane	–	المستوى الفائق
Training Dataset	–	بيانات التدريب
Supervised Learning	–	الخاضعة للإشراف
Precision	–	الإحكام
Sensitivity	–	الحساسية
Specificity	–	النوعية

F1-Score	**-**	**مقياس إف1**
Accuracy	**-**	**دقة المصنّف الكلية**
Confusion Matrix	**-**	**مصفوفة الإرباك**
True Positive	**TP**	**إيجابية صحيحة**
True Negative	**TN**	**سلبية صحيحة**
False Positive	**FP**	**إيجابية خاطئة**
False Negative	**FN**	**سلبية خاطئة**
Average Precision	**AP**	**متوسط الإحكام**
Mean Average Precision	**Map**	**متوسط الإحكام المتوسطة**
Mendeley	**-**	**قاعدة بيانات عالمية**
Google Colab	**-**	**البيئة البرمجية كولاب**
X-Ray Images Of The Hip Joints	**-**	**صور الأشعة السينية لمفصل الورك**
Scaler Standard	**-**	**التوحيد القياسي للبيانات**
Data Augmentation	**-**	**زيادة عدد البيانات**
Images Labeling	**-**	**عنونة الصور**
Images Annotation	**-**	**تسمية الصور**
Epochs	**-**	**تكرارات**
Label-Smoothing	**Ls**	**مرشح التنعيم**
Learning_Rate	**Lr**	**معدل التعلم**

فهرس المعادلات

المعادلة	الصفحة
المعادلة (2–1): صيغة T-score.	16
المعادلة (3–1): حساب مجموع أوزان شبكة بيرسيبترون.	26
المعادلة (3–2): حساب الحساسية.	49
المعادلة (3–3): حساب النوعية أو الخصوصية.	50
المعادلة (3–4): حساب الدقة الكلية.	50
المعادلة (3–5): حساب الإحكام.	50
المعادلة (3–6): مقياس إف1.	50
المعادلة (3–7): معدل الإيجابية الحقيقية والكاذبة.	51
المعادلة (3–8): التقاطع على الاتحاد (IoU).	52

الملخَّص

هشاشة العظام هي حالة مزمنة تتميز بانخفاض كثافة العظام وزيادة خطر لإصابة بالكسور والمضاعفات الصحية المرتبطة بها، ويشكل التشخيص الدقيق تحدياً كبيراً خاصة عبر مجتمعات مختلفة. تهدف هذه الدراسة إلى تطوير إطار متعدد المراحل للكشف عن هشاشة العظام من خلال دمج المؤشرات الحيوية السريرية وميزات صور الأشعة السينية لتحسين دقة التشخيص وتقييم إمكانية تعميم النموذج عبر مجموعات بيانات متنوعة.

في المرحلة الأولى، تم تصنيف صور الأشعة السينية لمجموعة بيانات سورية (D1) باستخدام نموذج YOLOv9، حيث حقق دقة وصلت إلى 95.39%. كما تم تحليل المؤشرات الحيوية السريرية عبر خوارزميات آلة متجه الدعم (SVM) والغابات العشوائية (RF) بدقة بلغت 87.34% و84.81% على التوالي، مع تفوق النماذج المعتمدة على الصور في استخراج الميزات العميقة مقارنة بالبيانات السريرية فقط. في المرحلة الثانية، جُمعت البيانات السريرية من مجموعتي البيانات السورية (D1) والهندية (D2) لاستكشاف التكامل بينهما، كما تم تقييم إمكانية تعميم النموذج عبر مجموعات البيانات من خلال التدريب على مجموعة سكانية واحدة والاختبار على الأخرى. وحقق النموذج السريري المشترك باستخدام خوارزمية الغابة العشوائية دقة بلغت 90.58٪، مما يشير إلى تحسن الأداء نتيجة لتنوع وزيادة حجم البيانات، بالإضافة إلى ضمان دمج البيانات بشكل صحيح ومتوازن، مع الاعتماد على بيانات حقيقية دون الحاجة إلى توليد عينات اصطناعية. ومع ذلك، برزت تحديات في التعميم الكامل عبر المجموعات المختلفة. أما في المرحلة الثالثة، فقد تم تطوير نموذج هجين سوري يجمع بين الخصائص العميقة المستخرجة من صور الأشعة باستخدام ResNet50 والمؤشرات الحيوية السريرية، وحقق دقة بلغت 85.94% باستخدام Perceptron متعدد الطبقات (MLP)، على الرغم من الأداء الجيد، لم يتفوق هذا النموذج على النماذج التي تعتمد على نوع بيانات واحد، ويعزى ذلك إلى محدودية حجم قاعدة البيانات المشتركة. وبالمقارنة مع الدراسات الحالية، تُظهر النماذج المقترحة أداءً تنافسياً في تشخيص هشاشة العظام، ومدى فعالية دمج البيانات من مجتمعات مختلفة مؤكداً على إمكانية معالجة التحيزات الخاصة بالسكان لتحسين الأداء التشخيصي.



الفصل الأول

الإطار العام للبحث



1.1 المقدّمة

هشاشة العظام، كما عرفتها منظمة الصحة العالمية World Health Organization (WHO) هي اضطراب هيكلي جهازي يتميز بانخفاض كتلة العظام وتدهور البنية الدقيقة لأنسجة العظام، مما يؤدي إلى زيادة هشاشة العظام وقابليتها للكسور [1–3]. هشاشة العظام هي حالة شائعة تشكل تحديات صحية عامة كبيرة بسبب تأثيرها على جودة الحياة وارتباطها بزيادة خطر الإصابة بالكسور، وخاصة بين كبار السن والنساء بعد انقطاع الطمث [4–8]. تعد كثافة المعادن في العظام Bone mineral density (BMD) مقياساً حاسماً لتشخيص هشاشة العظام، مع تصنيفات تعتمد على الانحرافات المعيارية Standard deviation(SD) من متوسط مستوى كثافة المعادن في العظام لفئة مرجعية من الشباب البالغين [9]. يُعد قياس امتصاص الأشعة السينية ثنائية الطاقة Dual-energy X-ray absorptiometry (DXA) المعيار الذهبي لقياس كثافة المعادن في العظام ويلعب دوراً محورياً في تشخيص هشاشة العظام ومراقبة صحة العظام وتقييم خطر الكسر من خلال توفير درجات T-score دقيقة وموثوقة لتصنيف كثافة العظام وفقاً لمعايير منظمة الصحة العالمية [13–17]. لقد حفزت التطورات في تقنيات الذكاء الاصطناعي وتعلم الآلة تطوير أدوات مبتكرة لتشخيص أكثر دقة لهشاشة العظام وتقييم مخاطر الإصابة بالكسور [21–23]. تستفيد هذه الأساليب من البيانات السريرية والتصويرية، بما في ذلك صور الأشعة السينية وDXA، لتحديد الأنماط المعقدة التي قد لا تكون واضحة من خلال طرق التقييم التقليدية. وقد أظهرت الدراسات الناشئة إمكانيات خوارزميات التعلم العميق في تحليل صور العظام لتقدير كثافة العظام والتنبؤ بمخاطر الكسر بدقة عالية [24–25]. تُقدم مثل هذه الأساليب نهجاً واعداً يدمج تحليل الصور الرقمية مع المؤشرات الحيوية السريرية، مما يتيح تقييمات سريعة ودقيقة في الممارسة السريرية.

يلخص هذا الفصل إشكالية البحث، وأهدافه وأهميته والطرائق المستخدمة لإنجازه، فضلاً عن محتوى الرسالة من فصول.

6.1 الإشكالية البحثية

يُشار إلى هشاشة العظام باسم "اللص الصامت" "the silent thief" حيثُ يمكن للعظام أن تتدهور على مدى عدة سنوات دون أي أعراض. لذلك يعد الفحص المبكر لهشاشة العظام باستخدام تقنية قياس امتصاص الأشعة السينية ثنائية الطاقة (DXA) لتقييم كثافة المعادن في العظام، أداة مهمة للتشخيص في الوقت المناسب ويمكن أن يقلل من مخاطر الإصابة بالكسور، ومع ذلك أن التكلفة المرتفعة نسبياً وندرة توافرها في البلدان النامية تُحد من استخدامها للفحص والمتابعة بعد العلاج.

أدى ذلك إلى تطوير أدوات تقييم المخاطر المختلفة سهلة الوصول إليها ومفيدة؛ على وجه الخصوص أداة التقييم الذاتي لهشاشة العظام Osteoporosis Self-Assessment Tool for Asians (OSTA) للنساء الآسيويات بعد سن اليأس التي تعتمد على الوزن والعمر فقط.[2]

ومع ذلك توجد بعض القيود، مثل عدم مراعاة اختلاف المجموعات العرقية، لا سيما تلك المتعلقة بمؤشر كتلة الجسم ومعدل الوفيات. علاوة على ذلك، تم تجاهل التحقق عبر مجموعات البيانات، وهو أمر بالغ الأهمية لتعميم نماذج الذكاء الاصطناعي عبر مجموعات سكانية متنوعة إلى حد كبير، حيث تقتصر معظم الدراسات على مجموعات بيانات فردية نشأت من مجموعات سكانية أو مناطق محددة. هناك أيضاً غياب ملحوظ لنهج متكامل يستفيد من كل المؤشرات الحيوية وميزات التعلم العميق في نموذج موحد لتحسين دقة التشخيص والمتانة. بالتالي، لا تزال هناك حاجة إلى أداة فحص متقدمة لهشاشة العظام في الممارسة السريرية.

3.1 الهدف من البحث

يهدف البحث إلى:

1. تصميم نموذج للكشف عن هشاشة العظام من التصوير الشعاعي للورك والبيانات السريرية.
2. دراسة إمكانية التعميم ومتانة النماذج القائمة على الذكاء الاصطناعي لاكتشاف هشاشة العظام عبر مجموعات سكانية متنوعة.

4.1 أهمية البحث

تكمن أهمية البحث في النقاط التالية:

- تشخيص هشاشة العظام والكشف عن انخفاض كثافة العظام قبل الإصابة بهشاشة العظام.
- التنبؤ بخطر الإصابة بكسور في المستقبل ومراقبة فعالية العلاج المستمر لهشاشة العظام.
- الكشف عن هشاشة العظام من خلال الصور الشعاعية للورك نتيجة لاختلاف هندسة كثافة المعادن في العظام وهندسة الورك وفقاً للعرق والجنس.
- استخدام بيانات من سكان سوريين لبناء نموذج ذكاء صنعي يتنبأ بهشاشة العظام.
- رفد قواعد البيانات العالمية بقاعدة بيانات سورية تساهم في تشخيص هشاشة العظام.
- تقييم قدرة تعميم النماذج عبر مجتمعات مختلفة.

5.1 طرائق البحث

يتطرق هذا البحث إلى دراسة مرض هشاشة العظام وكيفية معالجته والعوامل المُسببة لهذا المرض للتوصل إلى نظام تشخيص يعتمد على البيانات السريرية وميزات الصور الشعاعية للورك، ومن ثم اختبار هذا النظام باستخدام مجموعات سكانية مختلفة.

بعد تجميع قاعدة البيانات الخاصة بمرض هشاشة العظام، تم إجراء ما يلي:

أولاً، تحديد المنطقة ذات الاهتمام Region of Interest (ROI) من الصورة وتصنيفها باستخدام نموذج Yolov9.

ثانياً، استخدام خوارزمية آلة متجه الدعم Support Vector Machine (SVM) ومصنفات الغابات العشوائية Random forest (RF) لتحليل البيانات السريرية.

ثالثاً، تمت دراسة التكامل بين مجموعات البيانات، من خلال الجمع بين البيانات السريرية من مجموعات البيانات الهندية والسورية لتقييم فعالية التدريب على مجموعة سكانية واحدة والاختبار على أخرى.

رابعاً، تم تقديم نموذجاً هجيناً يدمج الخصائص العميقة من بيانات الأشعة السينية المستخرجة بواسطة ResNet50 مع المؤشرات الحيوية السريرية لنفس المريض، والاستفادة من الشبكات العصبونية Multi-Layer Perceptron (MLP) للتصنيف.

6.2 الوصف التوثيقي لمحتوى البحث

الفصل الأول: يتضمَّن الإطار العام للبحث بما فيها المقدّمة وتعريفاً بمشكلة البحث، والتي هي تصنيف مرض هشاشة العظام، وتمَّ توضيح الهدف والأهمية لإجراء البحث، ويحتوي أيضاً، وصفاً توثيقياً عن محتوى الرسالة، فضلاً عن طريقة العمل المتَّبعة في إنجاز هذا البحث.

الفصل الثاني: يحوي على المفاهيم النظرية الأساسية التي استند إليها البحث، وتتضمَّن شرحاً طبياً عن مرض هشاشة العظام، أنظمة التصوير المستخدمة، العوامل السريرية المسببة للمرض، معايير التصنيف العالمية.

الفصل الثالث: يتضمَّن شرحاً عن الذكاء الاصطناعي والتعلُّم العميق، بما فيها شبكات الطي العصبونية، بنيتها، أنواعها، واستخدامها في اكتشاف الأشياء في الصور واستخراج الخصائص من الصور وتصنيفها. كما يعرض بعض خوارزميات تعلَّم الآلة المستخدمة في تحليل البيانات السريرية، ثمَّ استعراض للنظام العام في البحث.

الفصل الرابع: يعرض هذا الفصل دراسات مرجعية مختلفة استند إليها البحث، في مجال تصنيف الصور الطبية، وبشكل خاص صور الأشعة السينية، بالإضافة إلى الدراسات العالمية التي تناولت البيانات السريرية، بما في ذلك الأساليب المتبعة لاستخلاص الخصائص وطرق التصنيف.

الفصل الخامس: يحوي شرحاً مفصلاً عن المراحل العملية المُتبعة ابتداء من اختيار بيئة العمل، وقاعدة البيانات واستخلاص الخصائص وانتهاءً بالتصنيف.

الفصل السادس: يعرض هذا الفصل نتائج تدريب خوارزميات التصنيف المستخدمة وتقيم أداء الخوارزميات بمقارنتها مع بعضها ومع الدراسات المرجعية.

الفصل السابع: يعرض التوصيات والآفاق المستقبلية لتطوير البحث.



الفصل الثاني

مرض هشاشة العظام



1.2 المقدّمة

في هذا البحث تم استخدام صور الأشعة السينية لمفصل الورك والعوامل السريرية عند مرضى هشاشة العظام من أجل بناء نظام يُساعد في تشخيص هشاشة العظام، لذلك فإنَّ هذا الفصل سيتطرق إلى الحديث عن هذا المرض بالتفصيل، وسيتُّم إيضاح أدوات تصنيف المرض وأثره في مفصل الورك.

2.2 هشاشة العظام (Osteoporosis)

1.2.2 مقدّمة

كلمة هشاشة العظام (Osteopororsis) مشتقة من المصطلح اليوناني "porous bones" الذي يعني "العظام المسامية" حيث يدل الجذر osteo، أن الكلمة مرتبطة بـــــ "العظام" و تخبر اللاحقة osis إنه "مسامي".[26] لذا فإن هشاشة العظام هي حالة تكون فيها العظام مسامية أو ضعيفة، بما أن مرض هشاشة العظام يُصنَّفُ على أنه اضطراب في الهيكل العظمي يتميز بضعف قوة العظام، فمن الهام معرفة النظام الهيكلي في الجسم.[62]

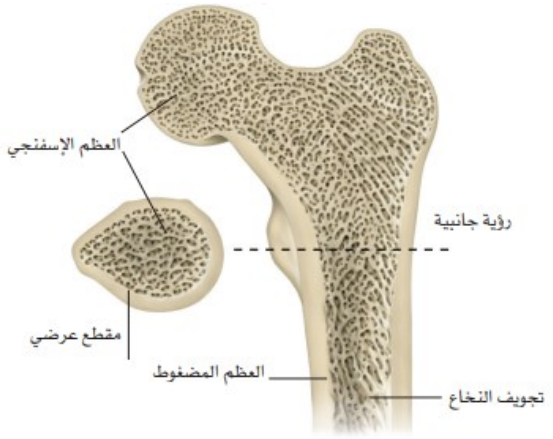
2.2.2 بنية العظام الطبيعية

تتألف العظام الطبيعية من هياكل من عظام مضغوطة أو صلبة تحيط بصفائح الربط وعيدان من العظام (العظم الاسفنجي) التي يقع داخلها النخاع العظمي، ويختلف سمك الهيكل الخارجي للعظم المضغوط بحسب أجزاء الهيكل العظمي، ويأتي جزء كبير من قوة الهيكل العظمي بسبب العظم المضغوط كما أن العظم الاسفنجي يساهم بشكل كبير في هذه القوة. ويتألف العظم أساساً من بروتين يسمى الكولاجين ومعادن العظام التي تحتوي على الكالسيوم.[27]

العظم هو نسيج حي يجب أن يتجدد باستمرار للحفاظ على قوته، والمكون الرئيسي لكل الحيوانات الفقارية، وتبدو العظام وكأنها بلا حياة لكنها في الحقيقة بناء حركي مكون من أنسجة حية كخلايا العظام والخلايا الدهنية والأوعية الدموية ومواد غير حية. وتتعرض العظام القديمة دائماً للكسور، فتُستبدل بعظام جديدة أكثر قوة. تعطي العظام الشكل والدعم لأجسامنا، كذلك تُشكل مواقع لتخزين المعادن وخلايا الدم التي تتكون داخل

النخاع. تلعب العظام دوراً حيوياً في حركة جسم الإنسان واعتدال قامته، كما تشكل درعاً واقياً للأعضاء الداخلية مثل القلب والرئتين والدماغ. [27]

يحتوي جسم الإنسان البالغ على 206 عظمة، منها 22 في الجمجمة، و29 في العمود الفقري. تحتوي العظام الطويلة (مثل عظام الفخذ والساعد) على تجاويف مملوءة بنخاع العظم، وهو مادة ذات لون أحمر مصفر، تقوم بالدور الرئيسي في تكوين خلايا الدم. تتكون العظام من طبقة خارجية صلبة، وكتلة داخلية إسفنجية، وترجع صلابة العظام إلى ترسب عدد من الأملاح والمواد المعدنية فيها، أهمها الكالسيوم [28]، يظهر الشكل (1.2) البنية الداخلية الإسفنجية للعظم.

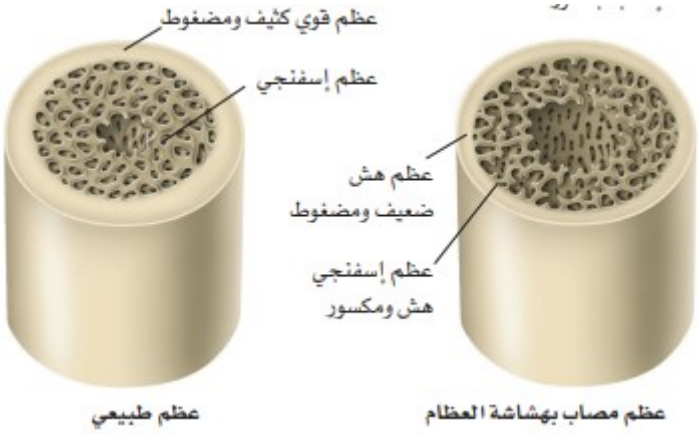


الشكل (1.2): البنية الداخلية الإسفنجية للعظم.[27]

تتكون العظام من طبقة خارجية (تسمى السمحاق) من العظم المضغوط الكثيف، وطبقة من العظم الإسفنجي. وفي حال الإصابة بهشاشة العظام تصبح الطبقتان الداخليتان أرق بكثير، ما يضعف العظام ويزيد من احتمال الإصابة بكسور. يظهر الشكل (2.2) كيف يغير مرض هشاشة العظام من بنية العظم.

وإن لم تكن هذه العملية التي تجري على سطح العظام، والتي تسمى إعادة تشكيل العظم موجودة، يبدأ الهيكل العظمي لدينا بالمعاناة من التعب حتى لو كنا في عمر صغير. هناك نوعان رئيسيان من الخلايا في العظام: ناقضة العظم التي تدمر العظام وبانية العظم التي تصنع عظاماً جديدة. ويتشكل النوعان على حد سواء في نخاع العظام. وكلما تقدمنا في السن، ازداد نشاط الخلايا ناقضة العظم وينقص نشاط خلايا بانية العظم، ما يعني خسارة أكثر في العظام وتجدد أقل.[27]

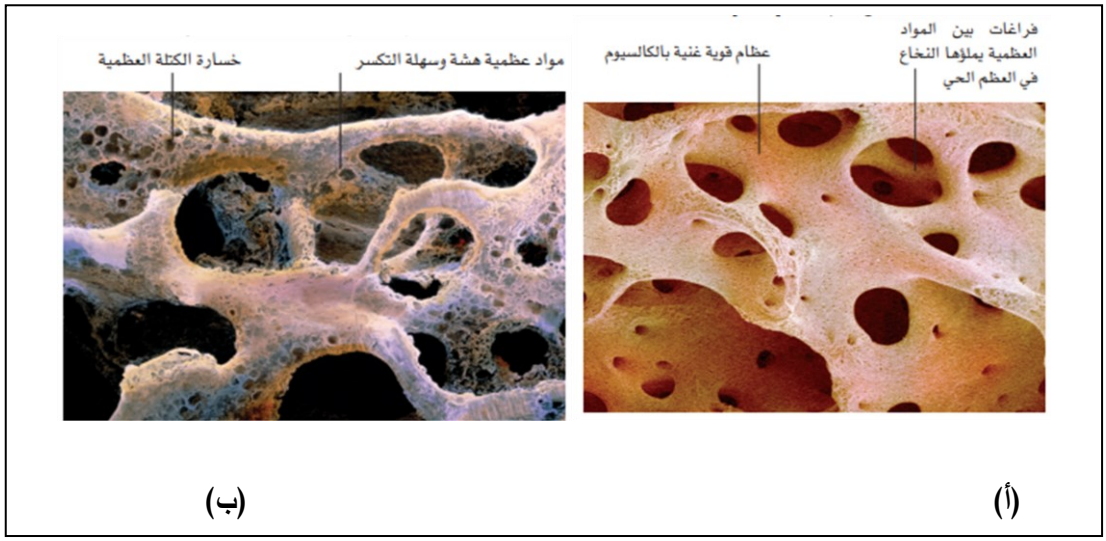
بناء نموذج لتقييم هشاشة العظام لمفصل الورك باستخدام الذكاء الاصطناعي، سويقات.



الشكل(2.2): الفرق بين العظام الطبيعية والعظام المصابة بمرض هشاشة العظام.[27]

3.2.2 التغيرات في العظام عند الإصابة بهشاشة العظام

في حال الإصابة بهشاشة العظام، يقل عدد كل من العظام المضغوطة والإسفنجية. وتُضعف هشاشة الطبقة الخارجية للعظم المضغوط من قوة العظم بشكل كبير ما يزيد من احتمال الإصابة بكسور. وتبدأ عملية التحول من عظام سليمة إلى عظام مصابة بهشاشة العظام كما في الشكل (3.2).



الشكل(3.2): (أ):نسيج عظم إسفنجي طبيعي،(ب): نسيج عظم إسفنجي مصاب بهشاشة العظام.[27]

عندما تحدث خسارة العظام في العظم الإسفنجي، تصبح الصفائح سميكة والعيدان رقيقة جداً وتفقد البنية استمراريتها. هذه التغييرات تضاف إلى ضعف العظام الناجم عن هشاشة الهياكل المضغوطة حول العظام.

4.2.2 تغيرات الكتلة العظمية على مدى الحياة

تنمو العظام في مرحلة الطفولة والمراهقة، وتصبح أكثر صلابة. وفي سن ال 25 عاماً، تصل كمية العظام في الهيكل العظمي إلى العدد الأقصى، ما يعرف باسم ذروة الكتلة العظمية. وتختلف ذروة الكتلة العظمية كثيراً بين الأفراد، فهي عادةً ما تكون لدى الرجال أكثر من النساء.

تعتبر ذروة الكتلة العظمية مهمة جداً لتحديد ما إذا كان الفرد معرّضاً للإصابة بهشاشة العظام في وقت لاحق من حياته. فإذا كانت الذروة منخفضة، فقد تؤدي حتى كميات صغيرة من فقدان العظام إلى الإصابة بالكسور لاحقاً، وإذا كانت مرتفعة يكون الفرد محمياً من مرض هشاشة العظام.[27]

5.2.2 تعريف هشاشة العظام

هشاشة العظام مرض يصيب النسج العظمية، وهو صامت وغير ملاحظ حتى حصول الكسر، ويوصف فيزيولوجياً كما يلي: إذا كانت العمليات الحيوية التي تؤدي إلى امتصاص البنى العظمية تفوق العمليات التي تؤدي إلى تشكلها، عند ذلك تتناقص قوة العظم ونوعيته (تزداد هشاشته) وتزداد مخاطر كسر العظم.[28]

عَّرفت منظمة الصحة العالمية مرض هشاشة العظام على أنه: مرض يُوصف بانخفاض في كتلة العظم، وتلف تدريجي للبنى المشكلة للنسج العظمية وهو ما يقود إلى تعزيز قابلية العظم للانكسار وحدوث تزايد متتالي في خطر حدوث هذا الانكسار.[29]

6.2.2 العوامل المؤدية إلى حدوث مرض هشاشة العظام

هناك عوامل سريرية عدة تكون السبب في حدوث مرض هشاشة العظام، يمكن تحديدها كما يلي:[27-29]

1. **العمر Age**: يتزايد خطر الإصابة بكسر ناتج عن ترقق عظمي مع التقدم في العمر، وهناك عدة عوامل تتعلق بالترقق العظمي وعلاقته مع العمر.
   - تراجع قدرة العظم على تشكيل عظم جديد.
   - هبوط في أداء وظائف الكلى مما يزيد مستويات البلاسما الفوسفاتية.

- تناقص في امتصاص الكالسيوم وذلك بسبب انخفاض عمليات امتصاص هيدروكسي فيتامين D في الكليتين.
- بعض الأشخاص الكبار في السن يمضون وقت أكبر داخل البيوت، وبالتالي يقل تعرضهم لضوء الشمس. إضافة إلى ذلك تراجع الجلد على توليد فيتامين D بوجود ضوء الشمس.
- تزايد إفراز هرمون Parathyroid لتعويض النقص في فيتامين D وهذا يؤدي إلى تزايد التحول العظمي وهو يترافق مع نقص في وظيفة البناء العظمي وهو ما يقود إلى زيادة في الامتصاص العظمي مع ضعف في تكوينه وبالتالي يصبح لدينا نقص في الكثافة العظمية.

2. **الجنس Sex:** تعتبر النساء أكثر ميولاً من الرجال للإصابة بمرض هشاشة العظام وهذا ناتج عن عاملين:
   - ذروة الكثافة العظمية التي تحصل عليها النساء أقل منها عند الرجال وبالتالي يكون الهيكل العظمي لهم أخف وأصغر.
   - تفقد النساء الأستروجين عند توقف الطمث وهذا يسرع من عملية فقدان الكثافة العظمية.
3. **المادة الوراثية (الجينوم) Genome:** لوحظ أن الشعوب الآسيوية والقوقازية أو أصحاب البشرة البيضاء أكثر ميولاً للإصابة بهشاشة العظام بالمقارنة مع الشعوب الأفريقية، وهذا يرتبط بكمية الكثافة العظمية "الذروة" التي تم الوصول إليها في مرحلة النضوج، فالشعوب القوقازية يصلون إلى أقل ذروة من الكثافة العظمية.
4. **العوامل الوراثية:** يمارس العامل الوراثي دوراً هاماً في الإصابة بهشاشة العظام، وعلى الرغم من أن هذا العامل ليس قوياً جداً، بعكس الحال في بعض الأمراض الأخرى مثل التليف الكيسي أو الناعور. ومع ذلك، يرتفع خطر الإصابة بهشاشة العظام لدى الأشخاص الذي يعانون من بنية جسدية ضعيفة، وهي عموماً سمة وراثية، وإن تاريخ العائلة الطبي في الإصابة بهشاشة العظام يمكن أن يكون مؤشر على إمكانية الإصابة بهشاشة العظام، حيث تبين تضاعف خطر الإصابة بكسر الورك لدى النساء التي أُصيبت

أمهاتهن بذلك في سن الشيخوخة.

5. عوامل قوية وراء الإصابة بهشاشة العظام

- **سن اليأس المبكر**: هو الوقت الذي تنقطع فيه الدورة الشهرية، وعادة ما يحدث في سن ال 50 أو ابتداءً من سن ال 45. وتكون النساء اللواتي يصبن بسن اليأس باكراً أكثر عرضة للإصابة بهشاشة العظام.
- **انقطاع الطمث**: تحدث الإصابة بانقطاع الطمث (غياب الدورة الشهرية) قبل سن اليأس بسبب انخفاض إنتاج الهرمونات الجنسية وهرمون الأستروجين.
- **العلاج بالستيرويد**: يوصف العلاج بالستيرويد لحالات كثيرة من بينها بعض أمراض الروماتيزم وبعض أمراض الرئة والتهاب الأمعاء وبعض أنواع السرطان. على الرغم من أن الستيرويد فعال جداً في علاج هذه الحالات، إلا أنه قد يسبب زيادة خسارة العظام، ما يؤدي إلى الإصابة بمرض هشاشة العظام.
- **تاريخ سابق من التعرض للكسور**: الأشخاص الذين أصيبوا بكسر أو أكثر بسبب هشاشة العظام معرضين أكثر للإصابة بكسور أخرى في المستقبل، وذلك بسبب بنية العظام التي تصبح أكثر هشاشة بعد التعرض لكسر ما.
- **اضطرابات الغدة الدرقية**: يسبب الإفراط في إنتاج الغدة الدرقية لهرمون الثيروكسين، خسارة العظام، وقد يؤدي إلى هشاشة العظام إذا لم يعالج في وقت مبكر.
- **السرطان**: ترتبط بعض أنواع السرطان مع التدمير السريع للعظم، ما يؤدي إلى هشاشة العظام. الأكثر شيوعاً هو الورم النقوي، وهو ورم خبيث يصيب النخاع العظمي.

6. عوامل تتعلق بنمط الحياة Lifestyle

يمكن أن يؤثر نمط الحياة اليومية في عظامنا، بما في ذلك **النظام الغذائي** فانخفاض كمية الكالسيوم في مرحلتي الطفولة والمراهقة يؤدي إلى انخفاض ذروة الكتلة العظمية، **والنشاط الجسدي** تؤدي المستويات

المنخفضـــة من النشـــاط البدني في مرحلة الطفولة والمراهقة إلى انخفاض ذروة الكتلة العظمية، **واحتســـاء المشـــروبات الممنوعة** يزيد من خطر الإصـــابة بكســـور **والتدخين** يُعتقد أن التبغ يضـــر بالخلايا التي تكوّن العظام (بانية العظم).[27–29]

7.2.2 تأثير مرض هشاشة العظام

لا يسبب مرض هشاشة العظام أعراضاً إلا في حال التعرض لكسر. وتسبب الكسور الناتجة عن هشاشة العظام الألم والعجز. وتعدّ الكســـور في المعصـــم والعمود الفقري والورك هي الأكثر شـــيوعاً.[27] ويوضـــح الجدول (1.2) نسب الاصابات عند الرجال والنساء.

الجدول (1.2): نسب الاصابات عند الرجال والنساء .[68]

موقع الكسر	النساء	الرجال
الورك	**%17.5**	**%6**
الفقرات	**%15.6**	**%5**
المعصم	**%16**	**%2.5**

1.7.2.2 كسر الورك Hip

يحدث كسر الورك بشكل رئيسي عند النساء اللواتي هن فوق سن الثمانين، ففقدان الأستروجين بعد انقطاع الطمث يرتبط بقوة مع الفقدان المتتالي للبنية العظمية وتطور مرض هشاشة العظام عند النساء. معظم النساء اللواتي تحت سن الخمسين لهن كثافة عظمية طبيعية، أي أن ال SD يساوي الواحد، وبشكل عام 30 % من النساء عند سن ال 80 لهن كثافة عظمية طبيعية، و70 % مصابات بهشاشة العظام، أي أن ال BMD يقارب فيه قيمة ال−SD=2.5، وهذا يؤدي عادة الى كســـر في الورك، وإلى فقدان تام في الحركة، ونصـــف هؤلاء المرضى يفقدون القدرة على المشي بشكل مستقل.[27–30] وقد دلّت الدراسات العلمية أن كسور الورك هي إحدى المسببات للموت حيث:

* يزداد الموت من 12% إلى 20% في الأشخاص المصابين في كسر في الورك.

* وخلال سنة واحدة فإن 20% إلى 40% من الناس الذين أصيبوا بكسر في الورك قد ماتوا.

8.2.2 تشخيص هشاشة العظام

بما أن هشاشة العظام مرض يمكن الوقاية منه، فينبغي إجراء التشخيص في أسرع وقت ممكن، ما يستوجب الكشف عن انخفاض الكتلة العظمية قبل حدوث الكسر. بالرغم من وجود عدة عوامل طبية مفيدة في تشخيص مرض هشاشة العظام ولكن القياس الكمي في حساب الـــ BMD هو الذي يملك معلومات مفيدة عن هشاشة العظام. ويتم ذلك باستخدام الأشعة السينية مزدوجة الطاقة لقياس الامتصاص، لقياس الكتلة العظمية في الورك أو العمود الفقري أو المعصـــم أو الهيكل العظمي بأكمله. وتُعرف قيمة الكتلة العظمية التي تنتج عن القياس بكثافة معادن العظام، والاسم العام للفحوصات التي تقيس كثافة العظام هو قياس كثافة العظام. يوضح الشكل (4.2) قياس كثافة العظام باستخدام آلة التصوير بالأشعة السينية مزدوجة الطاقة لقياس الامتصاص التي توجه حزم من الفوتونات أو الأشعة السينية إلى العظام وتقيس كمية الطاقة التي تم امتصاصها، فالعظم الأكثر كثافة يمتص المزيد من الطاقة.[27]



الشكل (4.2): قياس كثافة العظام باستخدام آلة التصوير بالأشعة السينية مزدوجة الطاقة.[27]

9.2.2 المبدأ العام لقياس وتقييم الكثافة بالأشعة

يستخدم جهاز DEXA نوعين من الأشعة السينية: واحدة منخفضة الطاقة والأخرى عالية الطاقة عندما تمر الأشعة عبر الجسم، يتم امتصاص جزء منها من قبل العظام والأنسجة الأخرى. كلما كانت العظام أكثر كثافة (من محتوى معدني أكبر) تمتص طاقة أكثر وتكتشف طاقة أقل على الجانب الآخر. ثم يتم مقارنة كمية الأشعة الممتصة بواسطة العظام مع كمية الأشعة التي تمر عبر الأنسجة الرخوة. من خلال هذه المقارنة، يستطيع الجهاز حساب كثافة العظام في المنطقة المستهدفة من خلال الكشف عن طاقة الإشعاع لكل بكسل ("عنصر الصورة") وتحويلها إلى "كثافة مساحة" تقاس بواحدة غرام لكل سنتيمتر مربع(g/cm^2) . يتم جمع عدد البكسلات في المنطقة، ثم يتم حساب مقدار العظم في كل بكسل. يسمح ذلك بحساب كثافة العظم المحدد. تظهر النتيجة بشكل معامل كثافة العظام (BMD)، والذي يعبّر عن مقدار العظام في جزء معين من الجسم، يتم بالنهاية اسقاط قيمة BMD المحسوبة على مخطط يبين الانحراف المعياري لقيم كثافة عظمية ضمن منطقة جغرافية ينتمي لها المريض لتظهر تقييم حالة المريض وفق T_score أو Z_score.[27]

1.9.2.2 مفهوم T-score

تُظهر T-score في تقرير كثافة العظام مدى اختلاف كتلة العظم عن كتلة عظام شخص بالغ يبلغ من العمر 30 عاماً يتمتع بصحة جيدة. وهي مؤشر شائع الاستخدام والتي تُعتبر امتداداً لحساب كثافة المعادن العظمية كأساس لتقييم وجود أو عدم وجود هشاشة العظام. T-score هي انحراف معياري – مصطلح رياضي يحسب مقدار انحراف نتيجة الكثافة الحالية عن المتوسط. يتم حساب الدرجة T-Score عن طريق قسمة الفرق بين كثافة المعادن العظمية المحسوبة بواسطة أداة متخصصة مثل DXA والمستوى الطبيعي المتوقع للشباب (YN) على الانحراف المعياري (SD) لكثافة المعادن العظمية لدى الشباب [64]. يتم تعريف صيغة T-score على أنها المعادلة التالية (1):

$$\text{T-Score} = (\text{BMD} - \text{YN})/\text{SD} \qquad (1)$$

تم تعريف مرض هشاشة العظام من قبل منظمة الصحة العالمية في عام 1994 على أنه T-score أقل بنسبة 25 ٪ من متوسط الانحرافات البالغ من العمر 30 عاماً.[30] في التشخيص السريري لهشاشة العظام في الورك، يعتمد تشخيص هشاشة العظام على تقرير DXA لعنق الفخذ والورك بالكامل. [65].

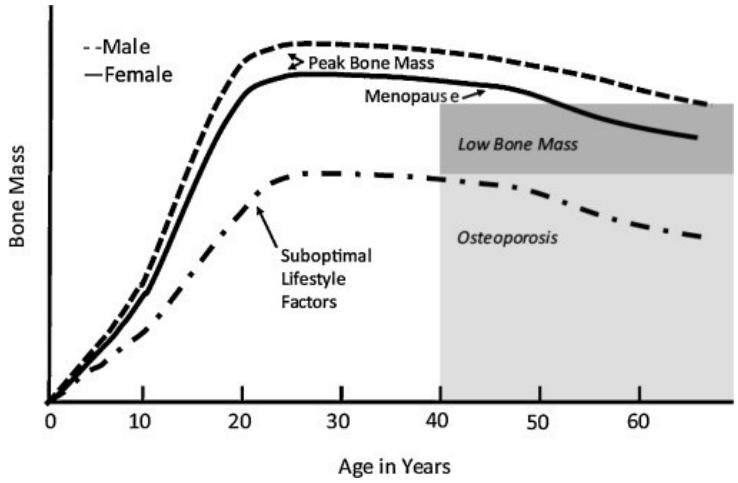
2.9.2.2 مفهوم Z-score

يقارن Z-score كثافة العظام لديك بمتوسط كثافة العظام للأشخاص الذين هم في سنك ونوع جنسك. على سبيل المثال من أجل أنثى بالغة من العمر 40 عاماً، فإن النتيجة Z تقارن كثافة عظامك بمتوسط كثافة العظام عند الإناث البالغات من العمر 40 عاماً. يعتبر Z-score مفيدة في تشخيص مرض هشاشة العظام الثانوي وتستخدم دائماً للأطفال والشباب والنساء الذين هم قبل انقطاع الطمث والرجال دون سن 50.[27]

10.2.2 تصنيف مرض هشاشة العظام وفق كثافة المعادن

تم اعتبار كثافة المعادن في العظام (BMD: Bone Mineral Density) مؤشر يحدد قوة العظم وخطر حدوث الكسر، وقد تم اعتماد نظام تصنيفي من قبل منظمة الصحة العالمية والذي يُقدم للأطباء وبأسلوب عملي آلية لتحديد مرض هشاشة العظام عند المصابين به [17–13]، وأيضاً للذين هم في خطر تطور المرض، وبذلك يمكن وضع برامج وقائية ومعالجة مباشرة لهؤلاء الذين هم في حاجة إلى ذلك مع تصنيفات تعتمد على الانحرافات المعيارية (SD) من متوسط مستوى كثافة المعادن في العظام لفئة مرجعية من الشباب البالغين [9]. يُعتبر الأفراد الذين لديهم درجة T-Score ضمن انحراف معياري واحد من المتوسط لديهم كثافة عظام طبيعية (درجة $T \geq -1.0$). يتم تشخيص انخفاض كتلة العظام أو انخفاض الكثافة العظمية عندما يكون كثافة المعادن في العظام بين 1.0 و2.5 انحراف معياري أقل من المتوسط (درجة T بين −1.0 و −2.5). يتم تشخيص هشاشة العظام عندما تنخفض كثافة المعادن في العظام بمقدار 2.5 انحراف معياري أو أكثر عن مستوى المتوسط (درجة $T \leq -2.5$). يحدث هشاشة العظام الشديدة أو الراسخة، وهو التصنيف الأكثر أهمية، عندما تكون كثافة المعادن في العظام أقل من المتوسط بمقدار 2.5 انحراف معياري أو أكثر ويصاحبه كسر واحد أو

أكثر [30–31]. فالـ BMD يتناقص طبيعياً مع التقدم بالعمر، وبالخسارة العظمية كما هو واضح في الشكل (5.2) والذي يربط العلاقة بين الكتلة العظمية مع العمر.



الشكل(5.2): العلاقة بين الكتلة العظمية والعمر.[32]

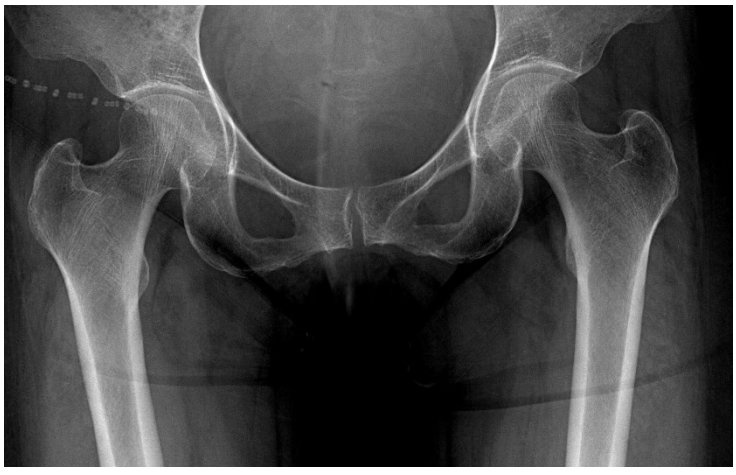
نلاحظ من هذا المنحني تزايد في الـ BMD ابتداءً من الطفولة، ثم المراهقة ووصولاً إلى الذروة في الكثافة عند عمر 20 سنة لدى الرجال و35 سنة لدى النساء، أي أن الرجال يصلون الى الذروة في الكثافة العظمية قبل النساء ولكن النساء يعانون من تسارع في الخسارة العظمية بعد انقطاع الطمث.[32]

11.2.2 التصوير الطبي في هشاشة العظام

في التصوير الإشعاعي، تخترق الأشعة الجسم ويقوم الكالسيوم الموجود في العظام بامتصاص هذه الأشعة مما يفسَّر ظهور بنية العظم باللون الأبيض في صور الأشعة. أنظمة التصوير المتاحة لتشخيص هشاشة العظام: التصوير المقطعي المُحوسب (QCT) اختبار لقياس كثافة المعادن في العظام، ولكن يتم التعرض لإشعاع عالي وتكلفة أكبر من DXA.[33] التصوير الشعاعي البسيط يمكن باستخدامه تقدير تقييم المخاطر باستخدام تقنيات كمية مثل تقدير العرض القشري إلى العرض الكلي[14]، على الرغم من تنوع أنظمة التصوير المستخدمة فإن المعيار الذهبي للتشخيص هو DXA إلا أن عيب هذه الطريقة أنها تصدر إشعاعات مؤينة، وندرة توافر هذه الأنظمة وارتفاع تكلفتها أدى إلى اللجوء إلى أنظمة تصوير متوفرة أقل تكلفة.[27]

12.2.2 هشاشة العظام وصور الأشعة السينية البسيطة x-ray

بالرغم من أنه حالياً يفضل الفحص المبكر لهشاشة العظام باستخدام تقنية قياس امتصاص الأشعة السينية ثنائي الطاقة (DXA)، يُعدٌ التصوير بالأشعة السينية البسيطة متوفر على نطاق واسع ويستخدم بشكل متكرر للعديد من المؤشرات السريرية في الممارسة اليومية. ويُمكنه من تمييز العلامات المبكرة لمرض هشاشة العظام، وعلى الرغم من هذه الخصائص، فقد تم استغلالها بشكل غير كافٍ نسبياً في إدارة هشاشة العظام؛ لأن تشخيص هشاشة العظام باستخدام الأشعة السينية فقط يمثل تحدياً حتى بالنسبة لأخصائي الأشعة ذوي الخبرة. تتضمن مؤشرات مرض هشاشة العظام الأساسية في صور الأشعة السينية: تغيير شكل العظم وفقدان في حجم العظم وتوسع في مشاشة العظام. وبالنسبة للمرضى الذين يعانون آلام الورك، غالباً ما يقوم أخصائيو الأشعة بتقييم نتائج صور الكسور والشروخ فقط، على الرغم من أن صور الأشعة السينية تحتوي على مزيد من المعلومات حول صحة عظام المريض وعضلاته، وغالباً ما يتم تجاهل هذه المعلومات أو اعتبارها أقل أهمية[18]. لا يمكن توصيف المرحلة المبكرة من المرض في صور الأشعة السينية [27]، بينما توصف المرحلة المتوسطة من المرض باتساع مشاشة العظم وتضرر الغضروف، أما المرحلة المتقدمة فتظهر واضحة في الصور على شكل تآكل العظم واتساع أكبر لمشاشة العظم. يوضح الشكل (6.2) صورة إشعاعية للحوض عند مريض هشاشة العظام والعلامات المرضية التي تظهر في المفصل من زيادة مسامية العظم وانخفاض كتلته مأخوذة من قاعدة البيانات السورية.



الشكل(6.2): صورة إشعاعية للحوض عند مريض هشاشة العظام.

13.2.2 علاج هشاشة العظام

تعمل معظم علاجات هشاشة العظام المرخص لها حالياً على الحد من خسارة العظام. فتقلل من خطر الإصابة بكسور، لكنها لا تشفي من هشاشة العظام، فعند الإصابة بالمرض لا يمكنها العمل على إعادة العظام إلى حالتها السابقة. لهذا من الأفضل اتخاذ خطوات وقائية أو علاجية باكراً لدى الأشخاص المعرضين لخطر الإصابة بالمرض. يبقى العلاج مع ذلك مفيداً دائماً، حتى لدى المصابين بهشاشة عظام مزمن، لأنه سوف يقلل من خطر الإصابة بالمزيد من الكسور، ولا ينبغي على أي مريض رفض علاج هشاشة العظام.[27] يتم علاج هشاشة العظام من خلال: تعديل نمط الحياة – الكالسيوم الغذائي – النشاط البدني – الوقاية من السقوط – تعتبر مكملات الكالسيوم وفيتامين د علاجاً من الدرجة الأولى في علاج هشاشة العظام.[34]

بالرغم من فعالية العلاج باستخدام بدائل الهرمونات في علاج هشاشة العظام، إلا أن الاستخدام المطوّل لها قد يرفع من خطر الإصابة بالسكتة الدماغية أو السرطان أو أمراض القلب. لهذا، لا يعتبر العلاج الهرموني الخيار الأول. ولذا، يُنصح بتناول مكملات الكالسيوم وفيتامين د في حال كانت الكميات المستهلكة من الكالسيوم عبر النظام الغذائي غير كافية أو إذا كان هناك شك بوجود نقص في فيتامين د. كما أن مكملات الكالسيوم وفيتامين D تُساهم في الوقاية من كسور الورك لدى كبار السن الذين يعانون من صعوبة في الخروج من منازلهم.–29] [27 وفيما يتعلق بالاتجاهات المستقبلية في علاج هشاشة العظام، فإن الأبحاث العلمية الحديثة تركز على تطوير علاجات أكثر فعالية وأقل تأثيراً جانبياً. أحد هذه الاتجاهات هو العلاج الجيني، الذي قد يُساعد في تحفيز نمو العظام بشكل أكثر فعالية في المستقبل. [63]

14.2.2 الخاتمة

يُعدُّ مرض هشاشة العظام من الأمراض طويلة الأمد التي تصيب العظام، وتؤثر سلباً في أسلوب وجودة حياة المريض حيث تخلق المعاناة والعجز مشكلة صحية كبيرة لدى المسنين. لذا فإنَّ أيَّ عمل أو إجراء من أجل التخفيف أو التقليل من الضغط الذي يتحمله هؤلاء المرضى (عبر الكشف المبكر عن مرض هشاشة العظام) يُعدُّ مساهمة جيدة في إيقاف المرض أو إبطائه وصولاً إلى إيجاد العلاج المناسب.



الفصل الثالث

الأسس النظرية للبحث



1.3 مقدمة: أن نظام التشخيص الآلي لمرض هشاشة العظام يتكون من مرحلتين، كشف المنطقة ذات الاهتمام واستخراج الميزات من هذه المنطقة وجمع هذه الميزات مع الميزات السريرية ومن ثم مرحلة التصنيف، لذا سيتناول هذا الفصل مبادئ أساسية عن العمل، شرح الطرق المستخدمة في تصنيف الصور، شرح الطرق المستخدمة في اكتشاف الأشياء، النظام العام للبحث.

2.3 تعاريف أساسية

1.2.3 الذكاء الاصطناعي Artificial Intelligence

الذكاء الاصطناعي هو مجال من العلوم يهتم ببناء أجهزة الكمبيوتر والآلات القادرة على التفكير والتعلم والتصرف بطريقة تتطلب عادةً الذكاء البشري أو تتضمن بيانات يتجاوز حجمها ما يمكن للبشر تحليله.

فالذكاء الاصطناعي هو الجهد المبذول لأتمتة المهام الذهنية (الفكرية) التي يمارسها البشر طبيعياً. حيث يُعد حقلاً عاماً يتضمن تعلم الآلة والتعلم العميق [36].

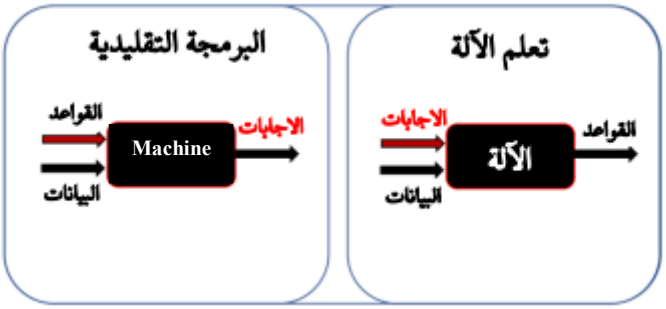
2.2.3 تعلم الآلة Machine Learning

تعلم الآلة هو مجموعة فرعية من الذكاء الاصطناعي، يُمكّن الكمبيوتر ليكون قادراً على التعلم من خلال التجربة دون تخطيط صريح. يجد هذا التعلم علاقة بين مدخلات ومخرجات المشكلة لاستخدامها بواسطة البيانات المعطاة لكل مشكلة لاستخدامها في مواجهة مشكلة مماثلة. تُعلم الآلة كيفية اتخاذ قرار بشأن مشكلة ما، وهي طريقة لتحقيق الذكاء الاصطناعي.

تبدأ عملية تعلم الآلة باستخدام البيانات الأولية لاستخراج معلومات مفيدة للمساعدة في اتخاذ قرارات أفضل. في تعريف أكثر دقة، يمكن التعبير عن تعلم الآلة على النحو التالي: يركز تعلم الآلة على تصميم النماذج في مجال معين، تم الحصول على خوارزميات الكمبيوتر بناءً على بيانات التدريب المعطاة لنموذج التعلم تلقائياً من خلال التجربة والاختبار من البيانات، بحيث في مواجهة البيانات الجديدة في نفس المجال، يمكن أن تظهر سلوكاً شبيهاً بالبشر. مناهجها الرئيسية الثلاثة هي التعلم الخاضع للإشراف والتعلم غير الخاضع للإشراف والتعلم المعزز. [66]

البرمجة التقليدية مقابل تعلم الآلة

عندما يتعلق الأمر باستخدام أجهزة الكمبيوتر لأداء مهام بشرية، يجب دائماً إعطاء التعليمات للكمبيوتر في شكل برنامج كمبيوتر. لغات البرمجة التقليدية هي عملية يدوية (بمعنى أنه يجب على المبرمج إنشاء البرنامج) وعادة ما يأخذ البيانات ومجموعة من القواعد كمدخلات، ومن خلال تطبيق هذه القواعد على البيانات، يحصلون على الإجابات كمخرجات. في تعلم الآلة، من ناحية أخرى، يتم تقديم البيانات والإجابات (أو العلامات) كمدخلات، ويتم استخدام القواعد (النماذج) كمخرجات (الشكل (1.3)). نمط تعلم الآلة له قيمة لا مثيل لها، لأنه يسمح للآلة بتعلم قواعد جديدة في مساحة معقدة وكبيرة يصعب على البشر فهمها.[66]



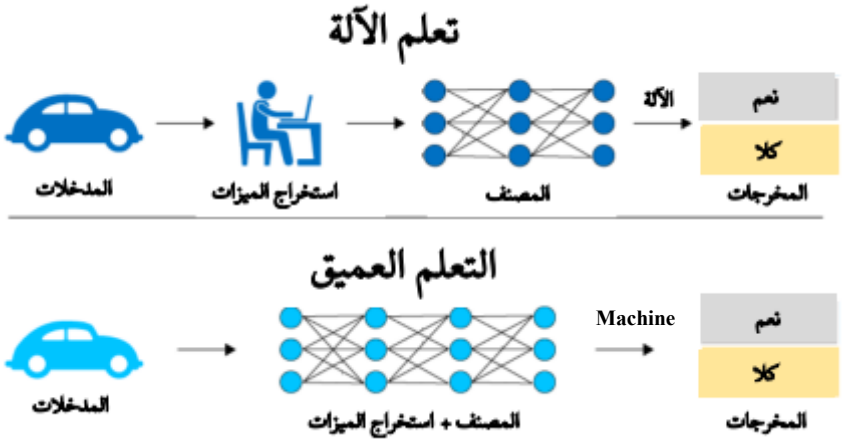
الشكل (1.3): البرمجة التقليدية مقابل تعلم الآلة. [66]

3.2.3 التعلُّم العميق Deep Learning

التعلم العميق هو مجموعة فرعية من تعلم الآلة ويستخدم بُنية الشبكات العصبونية لتقليد عملية صنع القرار لحل مشكلة مشابهة للدماغ البشري، ويقوم بنفس الشيء مثل تعلم الآلة، ولكن بقدرات مختلفة. بمقارنة تعلم الآلة مع التعلم العميق، يمكن القول إنه بينما يستخرج التعلم العميق الميزات تلقائياً من بُنية البيانات، يجب أن يتم ذلك يدوياً عن طريق تعلم الآلة. وإذا قام بتنبؤات خاطئة في تقرير حل المشكلة، فإن الخبير أو المبرمج يجب أن يحل المشكلة بشكل صريح. لذلك يمكن اعتبار التعلم العميق نسخة متطورة ومتقدمة من تعلم الآلة.[66]

قبل ظهور التعلم العميق كانت أنظمة تعلم الآلة بحاجة إلى متخصص في مجال الموضوع لاستخراج الميزات يدوياً. اختيار الخصائص لمجموعة البيانات له تأثير كبير على نجاح نموذج تعلم الآلة، في حين أن استخراج

الخصائص يدوياً سيكون عملية معقدة وتستغرق وقتاً طويلاً. يتيح لك التعلم العميق تحويل البيانات الأولية إلى متجهات وإدخالها إلى الشبكة دون الحاجة إلى استخراج الميزة يدوياً من هذه البيانات. يؤدي التعلم العميق لاستخراج هذه الميزة بشكل أفضل من الخبير من خلال عدد الطبقات المختلفة في هيكلها، من أجل حل المشكلة بناءً على البيانات التعليمية المتعلقة بالمشكلة. يمكن لهذه الطبقات أن تتعلم بشكل مباشر ومنفردة تمثيلاً تجريدياً للبيانات الخام. يوضح الشكل (2.3) الفرق بين هذه الممارسة في تعلم الآلة والتعلم العميق. هنا، يتم إنشاء تمثيل مجرد ومضغوط للبيانات الخام في طبقات متعددة في الشبكة. بعد ذلك، يتم استخدام هذا العرض المضغوط لبيانات الإدخال لتوليد الإخراج.[66]



الشكل (2.3): الفرق بين التعلم الآلي والتعلم العميق في استخراج الميزات.[66]

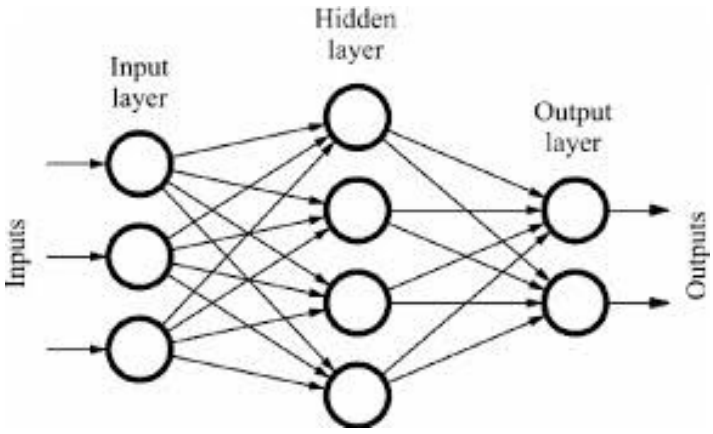
على الرغم من أن مصطلحات الذكاء الاصطناعي وتعلم الآلة والتعلم العميق تستخدم غالباً بشكل متبادل ومتشابك، إلا أنها لا تشير جميعها إلى نفس الشيء. يوضح الشكل (3.3) العلاقة بين الذكاء الاصطناعي وتعلم الآلة والتعلم العميق وكيفية ارتباطهم ببعضهم البعض، وكما يمكن رؤيته، فإن التعلم العميق هو مجموعة فرعية من تعلم الآلة وكذلك الذكاء الاصطناعي.[66]



الشكل(3.3): العلاقة بين الذكاء الاصطناعي والتعلم الآلي والتعلم العميق.[66]

1.3.2.3 الشبكات العصبونية الاصطناعية ANN

تتكون الشبكات العصبونية الاصطناعية من وحدات حسابية بسيطة تُسمى العصبونات Neurons الأشكال الدائرية في الشكل (4.3) منظمة في طبقات. تتصل العصبونات مع بعضها عبر موصلات ذات أوزان معينة. عند تطبيق بيانات الدخل على الشبكة العصبونية، يتم ضرب إشارة الدخل بأوزان الطبقة ثم تجمع هذه المدخلات الموزونة ويطبق عليها تابع تنشيط Activation function. يتم تغذية الناتج إلى الطبقة التالية في الشبكة، والتي تقوم بالحسابات نفسها حتى نصل إلى طبقة الخرج، حيث يتم توليد توقعات الشبكة. عند تدريب (:ANN Artificial Neural Network) يكون الهدف تعديل أوزان الطبقات من أجل تقليل الخطأ بين خرج الشبكة المتوقع والخرج الحقيقي المقابل لبيانات الدخل. [35]



الشكل (4.3): البنية العامة لشبكة عصبونية اصطناعية[35] .

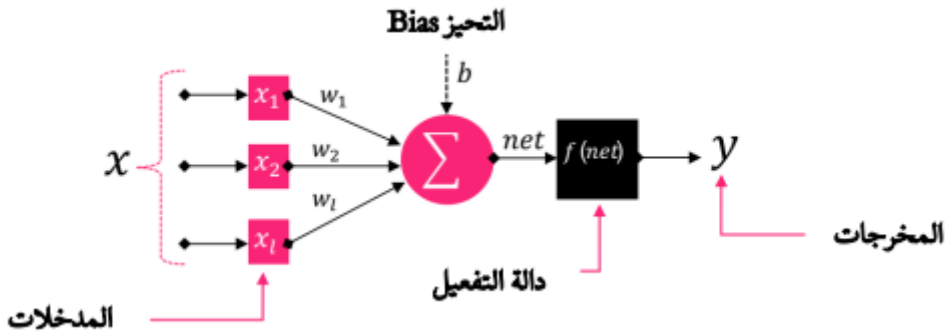
2.3.2.3 بيرسيبترون perceptron

الخلايا العصبونية هي عنصر أساسي في أي شبكة عصبية اصطناعية. يُطلق على أبسط نوع من نمذجة الخلايا العصبونية اسم بيرسيبترون Perceptron، والذي يمكن أن يحتوي على عدد كبير من المدخلات بمخرج واحد، يستخدم Perceptron التعلم الخاضع للإشراف لتصنيف أو توقع المخرجات. يوضح الشكل (5.3) مخططاً لبيرسيبترون.[67] يُظهر هناك عدد كبير من المدخلات في هذه الشبكة، والتي يتنبأ مجموعها بعد الحساب بالإخراج باستخدام دالة التنشيط. مع قائمة المدخلات X={X1,X2 ..., Xn}. سيكون لكل إدخال متجه وزن W = {W1,W2 ..., Wn}. يتم حساب مجموع الاوزان بالمعادلة (1-3):[66]

$$net = \sum_{i=0}^{n} w_i * x_i + b \qquad (1-3)$$

ثم تحصل دالة التنشيط على الناتج y بناءً على العتبة ɵ: [5]

$$y = f(net) = \begin{cases} 1, if\ net \geq \theta \\ 0, if\ net < \theta \end{cases}$$

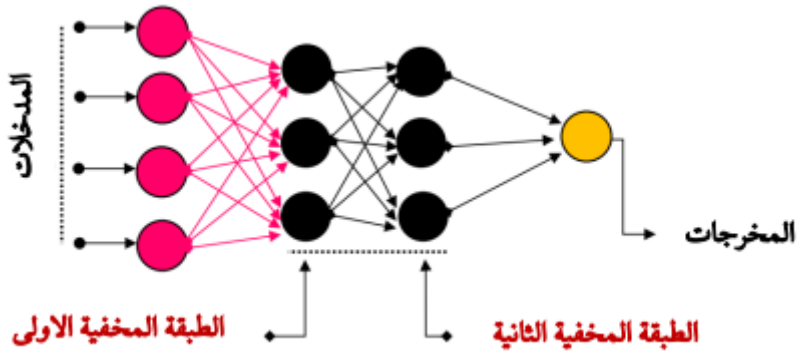


الشكل (5.3): مخطط بيرسيبترون.[67]

3.3.2.3 بيرسيبترون متعدد الطبقات (الشبكة العصبونية أمامية التغذية)

إن التقييد الرئيسي للشبكات العصبونية بيرسيبترون هو عدم القدرة على تصنيف البيانات التي لا يمكن فصلها خطياً. لذلك يُعد استخدام طبقة مخفية في هيكلية الشبكة بمثابة هروب من هذا التقييد. بمعنى آخر، لحل هذا التقييد يمكن استخدام الطبقة المخفية بين طبقات الإدخال والإخراج. يوضح الشكل (6.3) مخططاً لشبكة عصبية مع طبقتين مخفيتين. ومن الأمثلة على هذه الشبكات، والتي تعتبر أيضاً أساس التعلم العميق، شبكات

بيرسيبترون متعدد الطبقات Multi Layer Perceptron (MLP)، والتي تسمى أيضاً الشبكات العصبونية أمامية التغذية.(Feedforward Neural Network) تعد هذه الشبكات واحدة من أكثر الشبكات استخداماً في التعلم العميق نظراً لتوافقها مع مجموعة متنوعة من المشكلات. لأنه لا يوجد حد لإدخاله سواء كانت البيانات صورة أو نص أو فيديو[67].

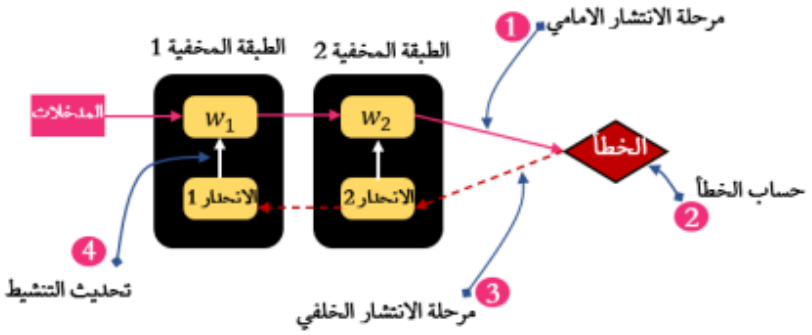


الشكل(6.3): شبكة عصبية ذات طبقتين مخفييتين.[67]

في MLP، تتدفق البيانات في الاتجاه الأمامي من طبقة الإدخال إلى الإخراج. في هذا النوع من الشبكات، بالانتقال من طبقة إلى أخرى يتم حساب مجموع الاوزان لمجموعة الخلايا العصبونية في الطبقة السابقة ونقلها إلى طبقة أخرى عن طريق تطبيق دالة تنشيط غير خطية. سبب تسمية التغذية الامامية (Feed forward) هو عدم وجود اتصال تغذية مرتدة يتم من خلاله اعتبار مخرجات النموذج مرة أخرى كمدخلات للنموذج (القيم تنتقل فقط من الإدخال إلى الطبقات المخفية ثم إلى الإخراج، ولا توجد قيم يتم إرجاعها إلى الطبقات السابقة، وعلى النقيض من ذلك، تسمح شبكة العودة بإرجاع القيم مرة أخرى). هذه الشبكة هي أيضاً طبقة متصلة بالكامل (Fully Connected)، لأن كل خلية من الخلايا العصبونية للشبكة مترابطة بطريقة تستقبل مدخلات من جميع الخلايا العصبونية في الطبقة السابقة وتنقل تنشيط مخرجاتها إلى جميع الخلايا العصبونية في الطبقة التالية. الطبقات الداخلية للشبكة التي ليست طبقة الإدخال ولا طبقة الإخراج تسمى الطبقات المخفية. عمق الشبكة العصبونية يساوي عدد الطبقات المخفية بالإضافة إلى الطبقة الناتجة. لذلك، تتكون الشبكة في الشكل (6.2) من ثلاث طبقات. يتم تدريب الخلايا العصبونية فىMLP باستخدام خوارزمية تعلم الانتشار الخلفي.[67]

الانتشار الخلفي Backpropagation

التعلم في شبكة عصبية متعددة الطبقات يشبه بشكل عام تعلم بيرسيبترون مع الأوزان المتطابقة. ومع ذلك، فإن الطريقة التي يجب أن يتغير بها كل وزن تكون أكثر صعوبة بقليل. في حالة بيرسيبترون، فإن الضرب الداخلي فقط بين بيانات الإدخال والأوزان هو المطلوب للحصول على ناتج العقدة. نظراً لوجود طبقات متعددة في MLP، يتم تحديد ناتج العقدة في الطبقة الأخيرة من خلال أخذ الضرب الداخلي للأوزان ومخرجات العقد في الطبقة السابقة. يتم حساب كل من هذه القيم الحديثة بنفس الطريقة. هذا يعني أن الخطأ في إخراج الطبقة النهائية يمكن أن يكون بسبب أوزان الطبقة الأخيرة بالإضافة إلى أوزان الطبقة (الطبقات) السابقة، لذا فإن السؤال هو وزن أي طبقة سبب هذا الخطأ. يشار إلى هذه المشكلة أحيانًا باسم تخصيص الائتمان (credit Assignment). الطريقة التي يمكن أن تحل هذه المشكلة تسمى الانتشار الخلفي. ربما تكون خوارزمية الانتشار الخلفي هي اللبنة الأساسية في الشبكة العصبونية. يعد الانتشار الخلفي في الأساس طريقة ذكية لحساب التدرجات بشكل فعال في الشبكات العصبونية متعددة الطبقات. تستخدم هذه الخوارزمية قاعدة حساب التفاضل والتكامل وتحسب تدرج الخطأ في مسارات مختلفة من عقدة واحدة إلى المخرجات وتتكون من مرحلتين رئيسيتين تسمى مرحلة الانتشار الامامي ومرحلة الانتشار الخلفي. في هذه الخوارزمية، بعد كل تمريرة للأمام في الشبكة، تقوم مرحلة الانتشار الخلفي بإجراء تمريرة عكسية وفي نفس الوقت تعدل معاملات النموذج (الأوزان والتحيزات). يعرض الشكل (7.3) خطوات عملية تدريب الشبكة العصبونية باستخدام خوارزمية الانتشار الخلفي. تكرر الشبكة العصبونية هذه الخطوات وتنفذها عدة مرات أثناء التدريب. [67]



الشكل(7.3): عملية تدريب الشبكة العصبونية باستخدام خوارزمية تعلم الانتشار الخلفي.[67]

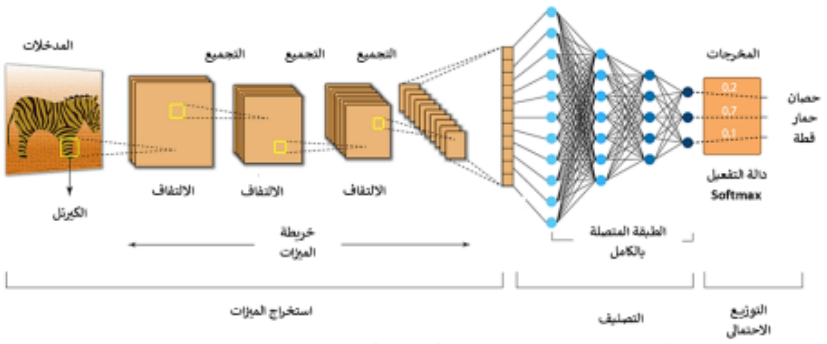
4.2.3 شبكات الطي العصبونية CNN

تعد شبكات الطي العصبونية Convolutional Neural Networks (CNN) ثورة في مجال معالجة الصورة ورؤية الحاسب. [38] الشبكات العصبونية الالتفافية هي فئة من الشبكات العصبونية أمامية التغذية التي تستخدم طبقات الالتفاف لتحليل المدخلات باستخدام طبولوجيا الشبكة، مثل الصور ومقاطع الفيديو. يعتمد اسم هذه الشبكات على دالة رياضية تسمى الالتفاف. ما يميز الشبكة العصبونية الالتفافية هو الطريقة التي يتم بها تنظيم الاتصالات بين الخلايا العصبونية وبنية الطبقة المخفية الفريدة المستوحاة من آلية معالجة البيانات المرئية الخاصة بنا داخل القشرة البصرية لدينا. على عكس الشبكات العصبونية أمامية التغذية، الطبقات في CNN تنتظم بثلاثة أبعاد: العرض والارتفاع والعمق.[67]

1.4.2.3 معمارية شبكة CNN

واحدة من أهم ميزات الشبكة الالتفافية بغض النظر عن عدد الطبقات الموجودة في بُنيتها، هي أن البنية الكاملة لشبكة CNN تتكون من جزأين رئيسيين:[71]

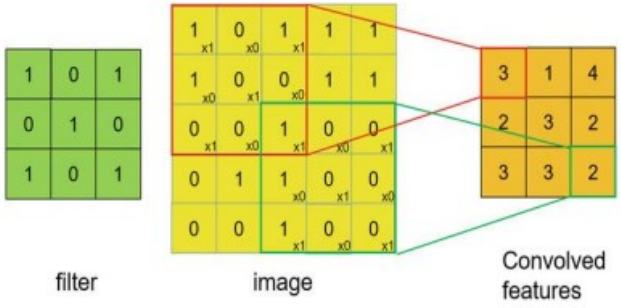
استخراج الميزات (Features Extraction): في هذه الطبقة، تقوم الشبكة بتنفيذ سلسلة من عوامل الالتفاف (convolution) والتجميع (pooling). والتصنيف: هنا تعمل الطبقات المتصلة كلياً (fully connected layers)كمصنف بعد خطوة استخراج الميزة، تتكون بشكل عام من طبقات طي Convolution layers، طبقات تجميع Pooling layers، وطبقات متصلة كلياً Fully connected layers. بحيث تمرر صورة الدخل عبر سلسلة من طبقات الطي والتجميع من أجل استخلاص الخصائص ومن ثم تعبر عبر الطبقات المتصلة كلياً من أجل التصنيف. يُوضّح الشكل (8.3) بنية شبكة CNN.[67]



الشكل (8.3): بنية شبكة CNN.[67]

1. طبقة الطي (CONV: Convolution layers)

هذه الطبقة هي الأكثر أهميّة في بنية شبكة CNN حيث أنه يتمّ فيها استخدام المرشّحات لتعلّم الميزات من صورة الدّخل، فتتكوّن خريطة الخصائص من جداء الطيّ بين قيم المرشّح والمنطقة الممسوحة بحجم المرشّح المقابلة من صورة الدّخل؛ أي كلّ عصبون من هذه الطبقة سيتصل بمنطقة محدّدة من الدّخل وفقاً لحجم المرشّح. ونحصل على مصفوفة خصائص الصورة بعد أن يمسح المرشح كامل الصورة كما في الشكل (9.3).[67]



الشكل (9.3) تمثيل لعمليّة طّي المرشح على الصورة[45]

توظَّف الطبقات الخفيّة الأولى في استخراج المزايا البسيطة والواضحة، مثل الحوافّ في الاتجاهات المُختلفة وما إلى ذلك، ومع التعمّق أكثر في الطبقات الخفيّة في الشبكة، تزداد درجة تعقيد المزايا التي يجب تحديدها واستخراجها [39].

2. طبقة التنشيط Activation Layer

تُغذى خرائط الخصائص الناتجة من طبقة الطي إلى طبقة التنشيط، حيث يتم استخدام توابع تنشيط غير خطية. أكثر توابع التنشيط استخداماً هو تابع الوحدة الخطية المصححة(Rectified linear units (ReLu. يُطبق تابع التنشيط على خرائط الخصائص [39].

3. طبقة التجميع Pooling Layer

في الشبكات العصبونية التلافيفية، تتم إضافة طبقة تجميع بين طبقات الالتفاف. إنّ الغاية من طبقة التجميع هي تخفيض حجم خريطة الخصائص (تستخدم كلمة خرائط لإمكانيّة استخدام أكثر من مُرشِّح). وتقليل عدد

البيانات في الطبقة المتصلة كلياً. يُسرع استخدام طبقة التجميع العملية الحسابية للشبكة لأنها تقلل عدد بارامترات التدريب ويمنع حدوث الملاءمة الزائدة over-fitting. [45]

يتم تخفيض حجم المصفوفات الكبيرة، من خلال تطبيق إحدى الدّالتين الآتيتين:

Max: تحديد القيم العُظمى في كلّ نافذة.

Average: حساب المتوسط الحسابيّ للقيم الموجودة في النافذة الواحدة.

أشهر أنواع التجميع المستخدمة هو تجميع ماكس max pooling. يتم تمرير مرشح على المصفوفة بخطوة إزاحة محددة، عند كل انزلاق للمرشح، تُؤخذ القيمة الكبرى من بين قيم المرشح. وتكون هذه القيمة عنصراً في مصفوفة التجميع pooled matrix الناتجة. [41–39] وتكرر هذه العملية حتى يمسح المرشح كامل المصفوفة. كما هو موضح بالشكل (10.3).



الشكل(10.3): مثال على طبقة التجميع. مقدار الإزاحة stride هو 2.[45]

إذن يتمّ في طبقات التجميع استخراج أفضل القيم (الخصائص) الموجودة في مصفوفة الخصائص التي نتجت عن طبقة الطّي [39].

4. طبقة ذات الاتصال الكامل(FC: Fully Connected Layer)

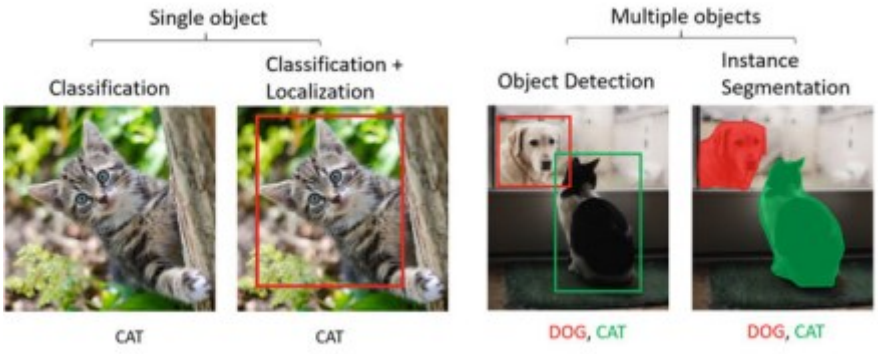
تكون هذه الطبقة هي الأخيرة في شبكة الطي وهي من نوع بيرسيبترون متعدد الطبقات (multi-layer perceptron) حيث العصبونات مُرتبطة بالكامل مع كُلّ عُقد الطبقة السابقة لها. سبب وجودها في النهاية لأنّ عمليّة التصنيف النهائيّة تتمّ فيها، تُطبق فيها عمليّة بَسْط (flattening operation) بَسط الدّخل إلى شُعاع مزايا، ومن ثَمّ تمريره إلى شبكة من العصبونات للتنبؤ باحتمالات الخرج.

تحتوي الطبقة ذات الاتصال الكامل FC في شبكات الطّي CNN كما في ANNs على عصبونات متصلة بالكامل بالخلايا العصبونيّة في الطبقة السابقة. غالباً ما يتمّ الاحتفاظ بطبقة FC كطبقة نهائيّة لشبكة CNN مع طبقة "SOFTMAX" كدالة التفعيل في مسائل التصنيف لعدّة أصناف. أو تابع سيغمويد sigmoid في حالة التصنيف الثنائي. تكون الطبقة ذات الاتصال الكامل FC مسؤولة عن التنبؤ بالصنف النهائيّ، ويكون بُعد الخرج [1×1×N] حيث تشير N إلى عدد الأصناف[39].

5.2.3 اكتشاف الأشياء والتصنيف

الكشف الدقيق والسريع عن الهياكل التشريحية أو المرضية في المجال الطبي هو أمر بالغ الأهمية لمهام متعددة، مثل تطوير أنظمة الكشف والتشخيص بمساعدة الكمبيوتر Computer Aided Detection (CAD) يعتبر اكتشاف الآفات خطوة أساسية في هذه الأنظمة. تختلف خوارزميات اكتشاف الكائناتObject detection عن خوارزميات التصنيف Classification Algorithms في أنها لا تقتصر فقط على التعرف على الكائنات أو الهياكل في الصورة، بل تركز أيضاً على تحديد موقعها الدقيق داخل الصورة من خلال إحاطتها بإطارات تحديد (Bounding boxes) .

يعد تحديد الموقع والكشف مهمتين متشابهتين: عادةً ما تحدد خوارزميات تحديد الموقع كائناً واحداً في الصورة، بينما تستطيع خوارزميات اكتشاف الكائنات تحديد وجود وموقع العديد من الكائنات في الصورة. كما هو موضَّحٌ في الشكل (11.3). لذلك، في خوارزمية الكشف يتم إخراج إطار تحديد لكل كائن موجود في الصورة، ويرتبط بكل إطار نوع الكائن واحتمالية انتمائه إلى الفئة المعنية[45].

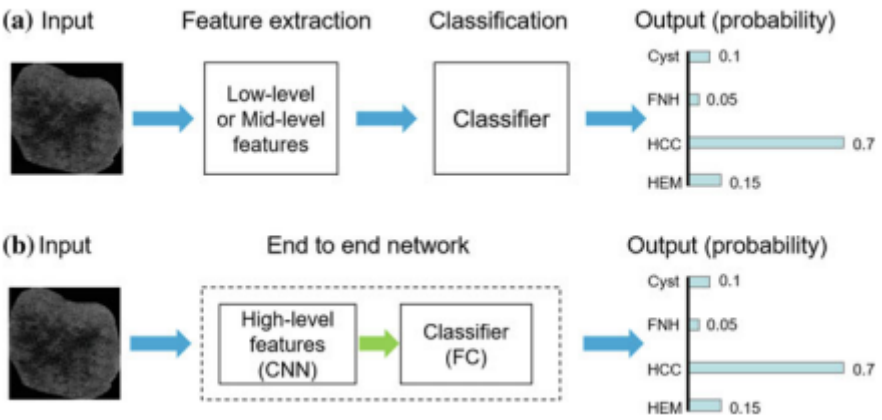


الشكل (11.3): الاختلافات بين التصنيف والتحديد والكشف والتجزئة.[45]

1.5.2.3 تصنيف الصور

تصنيف الصور هو عملية تعيين تسمية واحدة أو أكثر للصورة، تتكون عملية تصنيف الصور من استخراج ميزات الصورة ثم تصنيفها بناءً على هذه الميزات.

طرق التصنيف التقليدية تعتمد على الميزات منخفضة ومتوسطة المستوى مثل كثافة التدرج الرمادي، اللون، الملمس، الشكل والموقع، وهي ميزات يتم تحديدها يدوياً. ثم يتم استخدام مصنفات مثل آلة متجه الدعم SVM أو الغابات العشوائية بعد استخراج الميزات لتعيين تسمية الصورة. يظهر الشكل (a,12.3) **طريقة التصنيف التقليدية**. ومع ذلك، في التعلم العميق كما في الشكل (b,12.3)، يتم دمج استخراج الميزات وتصنيفها في شبكة واحدة. هذه الطريقة تعد متفوقة لأنها تستخدم تمثيلات عالية المستوى للميزات التي يتم تعلمها تلقائياً من البيانات. الميزة الأساسية للتعلم العميق هي أنه يمكنه تعلم الميزات الخاصة بالمهمة من البيانات بشكل تلقائي، مما يؤدي إلى تحسين الأداء بشكل كبير في تصنيف الصور[45].

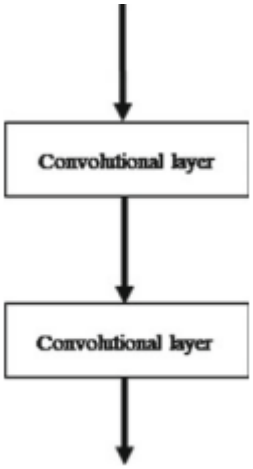


الشكل (12.3): خطوات عملية تصنيف الصور. أ. طريقة التصنيف التقليدية. ب. طريقة التعلم العميق[45].

من البُنى التصميميّة الشهيرة لها ResNet، AlexNet، GoogLeNet، VGGNet. وهم أمثلة عن شبكات CNN مدربة مسبقاً، ومستخدمة في تصنيف الصور الطبية.[45]

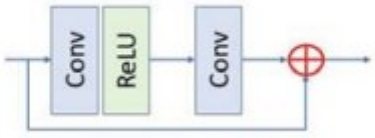
شبكات الرواسب Residual Networks

شبكات الرواسب ResNets هي بنية شبكة عصبية تلافيفية عميقة متطورة تم تطويرها بواسطة Microsoft Research في عام 2015. وذلك بسبب مشكلة تلاشي المشتق Vanishing gradient التي تحدث أثناء عملية التدريب عندما يخفق الخطأ في الطبقة الأخيرة في الوصول إلى الطبقات البعيدة عنه، ومن ثم لا يتم تعديل أوزان هذه الطبقات، لذلك فإنَّ الطبقات القريبة من طبقة الدخل لا يتم تدريبها في الشبكات العصبونية العميقة التقليدية. في شبكة CNN التقليدية، يكون خرج طبقة الالتفاف العلوية هو المدخل لطبقة الالتفاف التالية، كما هو موضح في الشكل (13.3)[45]



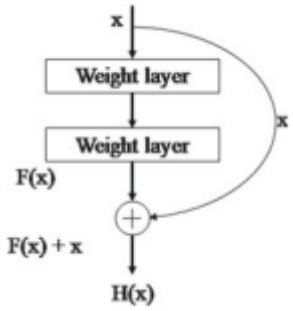
الشكل (13.3): اتصالات شبكة CNN التقليدية.[45]

تحل شبكات ResNets هذه المشكلة من خلال استخدم مبدأ الاتصالات المختصرة Shortcut Connections أو تُسمى وصلات تخطي Skip Connections التي تتجاوز طبقة واحدة أو أكثر، ومن هنا جاءت تسميته بوحدة الراسب أو كتلة الراسب Residual Unit (RU). الموضحة في الشكل(14.3)



الشكل(14.3): وحدة الراسب.[45]

وكما يظهر في الشكل (15.3)، يُمثل x (الاتصال المختصر) الخاصية (الميزة) المدخلة، ويمثل F(x) معرفة الراسب (المتبقية) Residual knowledge. تعبر المعلومات خلال الشبكة عبر هذه الممرات المنشأة بين الطبقات السابقة والطبقات التالية للطبقة الحالية (وحدة الراسب)، بحيث يُضاف دخل الطبقة السابقة x إلى الطبقة التالية، ومن ثم أثناء عملية التدريب إذا بلغت قيمة أوزان الطبقة الحالية الصفر، فإنها لن تؤثر في الطبقات التي تسبقها وإنما سيكون خرج هذه الطبقة هو الدخل المضاف عبر الاتصال المختصر، ومن ثم لن يتلاشى المشتق. وهذا يضمن أن الأداء لن ينخفض مع نمو الطبقات من 20 إلى 50 أو من 50 إلى 100. إذا كانت طبقات الوزن عديمة الفائدة، فإن التنظيم يصبح صفراً، لذا فإن تخطي هذا الاتصال سيكون مفيداً.



الشكل(15.3): الاتصال المختصر[45].

بعض أنواع شبكات ResNets هي: ResNet34 ، ResNet50، ResNet101 ، ResNet152. حيث يشير رقم اللواحق إلى عدد الطبقات المستخدمة في بنية الشبكة الخاصة بها. [45]

ResNet50

تُعد ResNet50 شبكة عصبية عميقة تتكون من 50 طبقة، وهي جزء من عائلة شبكات الرواسب(ResNet) التي تم تقديمها من قبل He وزملائه في عام 2015.[43] يعرض الشكل (16.3) البنية المعمارية لشبكة ResNet-50.

1. **كتل الراسب Residual Blocks**

يَستخدم ResNet-50 كتل الراسب، حيث يتم تمرير الإدخال عبر عدة طبقات ثم يتم إضافته إلى الناتج عبر اتصال تمرير. هذه الطريقة تساعد في تقليل مشكلة تلاشي التدرج وتسمح بتدريب الشبكات العميقة جداً.

2. **كتل البناء Building Blocks**

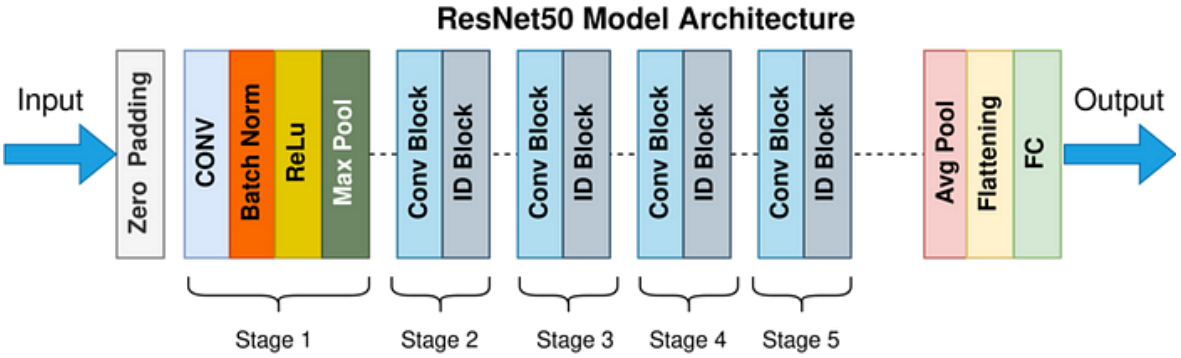
يستخدم ResNet-50 كتل عنق الزجاجة (Bottleneck Blocks) التي تتكون من ثلاث طبقات بدلاً من طبقتين كما في الشبكات التقليدية، هذا يقلل من التكلفة الحسابية دون التأثير على الأداء.

3. **الطبقات الالتفافية Convolutional Layers**

تبدأ الشبكة بطبقة التفاف 7X7 مع 64 مرشحاً وبخطوة 2، تليها تابع التنشيط ReLU.

4. **خريطة الهوية Identity Mapping**

يقوم الاتصال الراسب بتمرير الإدخال إلى الناتج عبر الهوية، مما يساعد في تجنب مشكلة تدهور الشبكة في الشبكات العميقة. هذا الهيكل يجعل ResNet-50 قوياً للغاية في مهام تصنيف الصور، ويمكن تعديله بسهولة للتطبيقات المختلفة في التعرف على الصور.



الشكل(16.3): بنية ResNet50. [40]

تم تدريب ResNet50 على مجموعة بيانات ImageNet الكبيرة، مما أدى إلى تحقيق معدل خطأ على قدم المساواة مع الأداء البشري، مما يجعله نموذجاً قوياً لمهام تصنيف الصور المختلفة مثل اكتشاف الكائنات والتعرف على الوجه وتحليل الصور الطبية. بالإضافة إلى ذلك، تم استخدامه أيضاً كمستخرج للسمات (الخصائص) لمهام أخرى، مثل اكتشاف الكائنات. [44] وهي الخوارزمية المتبعة في هذه الدراسة لاستخلاص الخصائص من الصور الطبية.

6.2.3 خوارزميات اكتشاف الأشياء

تتكون أنظمة اكشاف الأشياء بشكل عام من مرحلتين [45]:

اقتراح المنطقة Region Proposal، التي تعني استخلاص عدة مناطق من الصورة من أجل إيجاد المناطق المحتمل أن تحتوي الشيء ذا الاهتمام. يمكن مسح كامل الصورة وتقسيمها الى مناطق باستخدام مبدأ النافذة المتحركة أو النافذة المنزلقة Sliding Window Approach أو باستخدام خوارزميات محددة لاقتراح المناطق، من أجل إيجاد المناطق التي من المرجح أن تحتوي أشياء معينة.

تصنيف المناطق المستخلصة لإنتاج إطارات تحديد مع قيمة احتمال احتواء كل إطار منها على الشيء المكتشف.

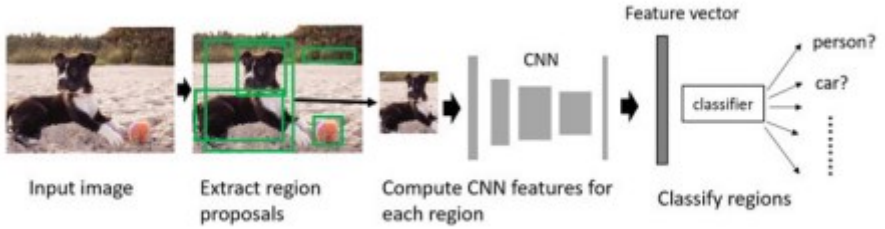
في الطرق التقليدية يتم استخدام خوارزميات استخلاص الخصائص في تحديد مناطق الصورة، ثم يتم إدخال هذه الخصائص إلى مصنف مثل SVM أو الغابة العشوائية Random forest. استُخدم هذا النهج كثيراً في حالات التشخيص الطبي باستخدام الصور الطبية. [45]

في التعلم العميق، تستخلص خصائص الصورة بواسطة CNN بدلاً من الخصائص المستخلصة يدوياً، ومن ثم يتم استخدام المصنف لإعطاء النتيجة النهائية. لكن هناك تحدَّيين رئيسين لمعظم الخوارزميّات المستخدمة: أوّلاً: نحتاج تقسيم الصورة إلى أقسام، بحيث يحتوي كلّ قسم على كائن من الكائنات التي نريد التعرّف عليها، ثانياً: تصنيف هذا الجزء من الصورة.

لهذا الغرض تُدخل هذه الأجزاء من الصورة في شبكة طيّ عصبونيّة CNN مدرّبة مسبقاً، وستتحوّل العمليّة إلى تصنيف الصور. فاقترح باحثو الشبكات العصبونية استخدام المناطق حيث نجد مناطق صور من المحتمل أن تحتوي على كائنات[42].

فكان النموذج الأوّل الذي أُطلق هو R-CNN شَبَكَةُ الطَّيِّ العُصبُونِيَّةِ المناطِقيَّةِ، تقوم أوّلاً بمسح صورة الدّخل بحثاً عن كائنات محتملة باستخدام خوارزميّة تسمى البحث الانتقائيّ، مما يؤدّي إلى إنشاء 2000 اقتراح منطقةٍ تقريباً. ثمّ تقوم بتشغيل CNN فوق كلّ من مقترحات المنطقة هذه، وأخيراً تأخذ خرج كلّ CNN وتُغذّيه في

آلة مُتَّجه الدعم SVM لتصنيف المنطقة[46]. يُوضّح الشكل (17.3) مبدأ عمل R-CNN. منذ ذلك الوقت تم تصميم وتطوير الكثير من النماذج القائمة على CNN من أجل الكشف عن الصورة. مثل، Fast R-CNN, Mask R-CNN وFaster RCNN. بالتالي تتكون بنية الشبكة من ثلاث وحدات: اقتراح مناطق + استخلاص خصائص بواسطة (CNN) + التصنيف باستخدام مُصنّفات آلة مُتَّجه الدعم (SVM). [46]



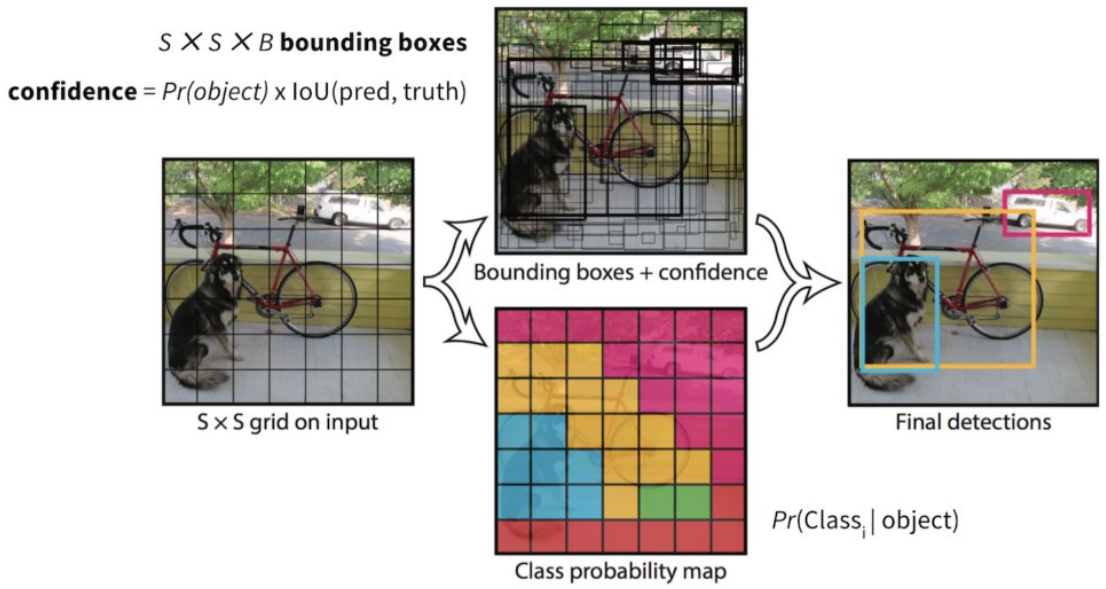
الشكل (17.3): نظرة عامة على نظام R-CNN. يتم استخلاص المناطق المقترحة من الصورة المدخلة باستخدام البحث الانتقائي، ثم يتم حساب الميزات بواسطة CNN واستخدامها لتصنيف المناطق باستخدام مصنفSVM.[45]

في السنوات الأخيرة تحوّلت اتجاهات اكتشاف الكائنات الرئيسيّة نحو أنظمة متكاملة end-to-end ذات اتجاه معالجة مباشر بين صورة الدخل وتوقعات الخرج. لذلك تُسمى نظام اكتشاف الأشياء أحادي المرحلة، حيث تستخدم هذه البنى خصائص من كامل الصورة لتتوقع إطارات التحديد، بدلاً من معالجة المناطق المستقلة [45]. والسبب الأساسيّ والمنطقيّ وراء الاتجاه نحو هذه الطرق؛ هو تجنب وجود خوارزميّات منفصلة تركز على المشاكل الفرعيّة الخاصة بكلّ منها بمعزل عن غيرها، لأنّ هذا عادةً ما يزيد من وقت التدريب ويمكن أن يقلل من دقة الشبكة.

ففي عام 2016 تم تقديم شبكة يولو You Only Look Once (YOLO). حيث تستطيع إنجاز مهمة الكشف عن الأشياء باستخدام شبكة عصبونية واحدة. في يولو يتم النظر إلى صورة الدخل مرة واحدة ثم التنبؤ بالأشياء الموجودة فيها وبأماكنها [47]. على عكس شبكات التعلم العميق المعتمدة على المناطق، حيث تدخل كل منطقة مقترحة من الصورة إلى شبكة CNN وتعبر خلال معمارية الشبكة وهذا يُنفذ بالنسبة لجميع المناطق المقترحة من الصورة. ومن ثم تُعد هذه الشبكة نظاماً سريعاً ويمكن من اكتشاف الأشياء في الوقت الحقيقي Real-time detection.

ومن حينها تم تطوير عدة إصدارات منها مثل: YOLOv2 وصولاً إلى YOLOv11، وتُعد يولو شبكة طي عصبونية مدربة مسبقاً على قاعدة بيانات COCO. [48]

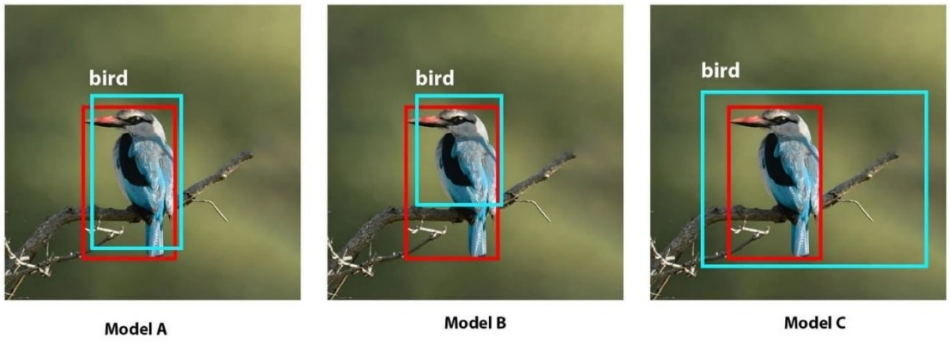
يولو YOLO في هذه الشبكة يتم النظر إلى صورة الدخل مرة واحدة ثم التنبؤ بالأشياء الموجودة فيها وبأماكنها. ومن هنا جاءت تسميتها، أنت تنظر لمرة واحدة You Only Look Once. حيث تتنبأ بإطارات التحديد تحديد مكان الشيء واحتمالات الصنف (التصنيف) من الصورة مباشرة، كما هو موضح في الشكل (18.3). واعتماداً على فكرة أن الشيء المراد كشفه، يشغل حيزاً من الصورة، ويتوضع مركزه في نقطة ما من هذا الحيز، يتم في يولو، [46–47] تقسيم صورة الدخل إلى شبكة SXS من الخلايا. حيث تتنبأ كل شبكة بإحداثيات إطار التحديد B ودرجة الثقة C وعدد من احتمالات الفئة. تتنبأ YOLO بمركز (x,y) الإطار المحدد وعرض (w) وارتفاع (h) الإطار. المركز نسبي لخلية الشبكة، لذا فهو بين 0 و1، والعرض والارتفاع نسبيان لحجم الصورة، والذي يأتي أيضًا في نطاق 0 و1. إذا وقع مركز الشيء المراد كشفه في إحدى هذه الخلايا، تكون هذه الخلية مسؤولة عن تحديد هذا الشيء. لذلك يتم إهمال باقي الخلايا حتى ولو كان ظهور الشيء مسجلاً في أكثر من خلية.



الشكل (18.3): يقسم YOLO الصورة إلى شبكة S × S خلية، ويتوقع كل خلية بعدد من إطارات التحديد، وبمعدل عتبة الدقة (الثقة) لهذه الإطارات. بالإضافة إلى توقعات الأصناف.[47]

من أجل اكتشاف الأشياء في الصورة فإنَّ كلَّ خلية تتنبأ بعدد B من إطارات التحديد التي من المحتمل أن يظهر الشيء ضمنها، وبمعدل عتبة الدقة (الثقة) Confidence scores لهذ الإطارات. فضلاً عن توقعات الأصناف. يمتلك كل شيء من الأشياء الموجودة في الصورة، إطار حقيقة مرجعي Ground truth box (الإطار الأحمر) في الشكل (19.3). يتم تعيين هذا الإطار من قبل المستخدم بهدف تدريب يولو. يُحدد هذا الإطار الأبعاد الحقيقية للشيء الموجود في الصورة، ويُستخدم كنقطة مرجعية في عملية اختيار إطار التحديد الأفضل من بين جميع إطارات التحديد التي تنبأت بها الخلية التي يقع مركز الشيء ضمنها.

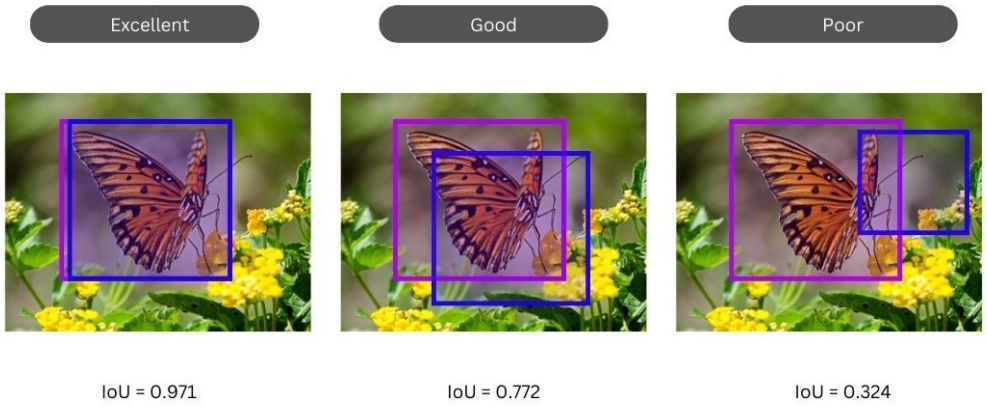
من أجل كل إطار تحديد، تُستخدم أداة قياس التقاطع إلى الاتحاد Intersection over Union (Iou) للحصول على نتائج اكتشاف الأشياء. وتُمثل منطقة التقاطع بين إطار التحديد المتوقع الذي تنبأت به الخلية الإطار الأخضر وإطار الحقيقة المرجعي الأحمر.[49]



الشكل(19.3): مثال عن كيفية حساب IoU.[46]

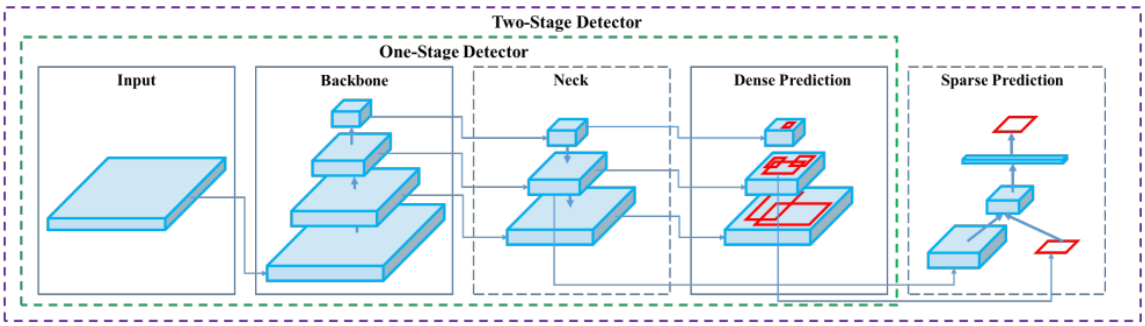
يبين الشكل أن الإطار المتوقع للنموذج A يتداخل أكثر مع إطار الحقيقة المرجعي مقارنة بالنموذج B. ومع ذلك، فإن إطار النموذج C يتداخل بشكل أكبر مع إطار الحقيقة المرجعي. ولكنه يتداخل أيضاً بشكل كبير مع الخلفية. لذلك من النموذجين B وC، من الواضح أن المقياس الذي يعتمد على التداخل فقط ليس مقياساً عادلاً، أي أن الأمر لا يتعلق فقط بمطابقة الحقيقة المرجعية، بل يتعلق أيضاً بمدى تطابق التنبؤ مع إطار الحقيقة المرجعي. لذلك، نحتاج إلى مقياس يأخذ بعين الاعتبار كلما فشل التنبؤ في التنبؤ بالمنطقة داخل الحقيقة المرجعية، أو تجاوز التنبؤ الحقيقة المرجعية. لذلك تم تصميم مقياس IoU.[49] بالنسبة لـ IoU، تتراوح القيم

من 0 إلى 1. إذا كانت درجة IoU أكبر من 0.5، فهذا يعتبر جيداً، أكبر من 0.7، فهذا يعتبر جيداً جداً، أكبر من 0.9، فهذا يعتبر مثالياً تقريباً كما في الشكل (20.3).



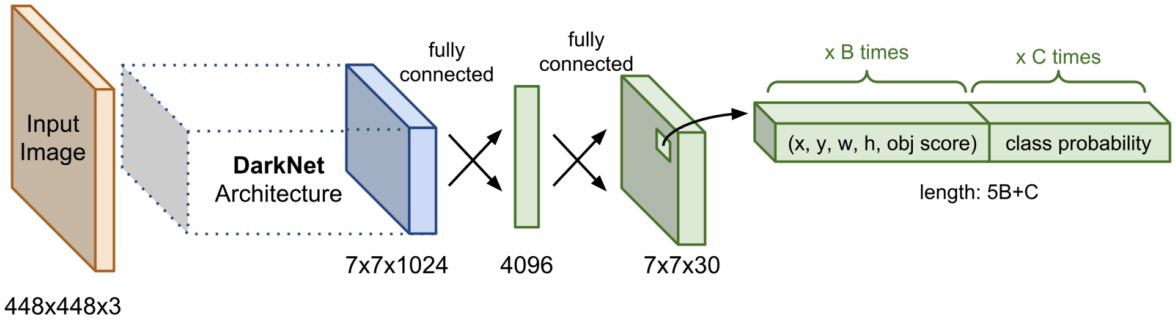
الشكل (20.3): أمثلة على اكتشاف الكائنات عند عتبات IoU مختلفة.[10]

بشكل عام، هناك نوعان من نماذج اكتشاف كائنات التعلم العميق: نماذج أحادية المرحلة ومرحلتين كما في الشكل(21.3). يتبع نموذج المرحلة الواحدة نمط تصميم محدد، وهو العمود الفقري–الرقبة–الرأس. [47]



الشكل(21.3): مقارنة بين بنية الكاشف أحادي المرحلة ومكون من مرحلتين. [54]

ومع ذلك، في بنية نموذج **YOLOv1** كما في الشكل (22.3) لا يوجد مفهوم للرقبة، فقط العمود الفقري والرأس. مستوحاة بنية YOLOv1 من بنية GoogleNet، ولديها 24 طبقة التفافية وطبقتان متصلتان بالكامل. في هذه الطبقات، تعمل الطبقات العشرون الأولى كعمود فقري، وتؤدي بقية الطبقات إلى طبقتين إضافيتين متصلتين بالكامل، تعملان كرأس كشف. وبدلاً من وحدة البداية، استخدموا طبقة التفاف 1×1 مع 3×3 طبقات التفافية في العمود الفقري. ساعد هذا في تقليل عدد القنوات دون الحاجة إلى تقليل الأبعاد المكانية، وأصبح عدد المحددات منخفضاً نسبياً.[48]



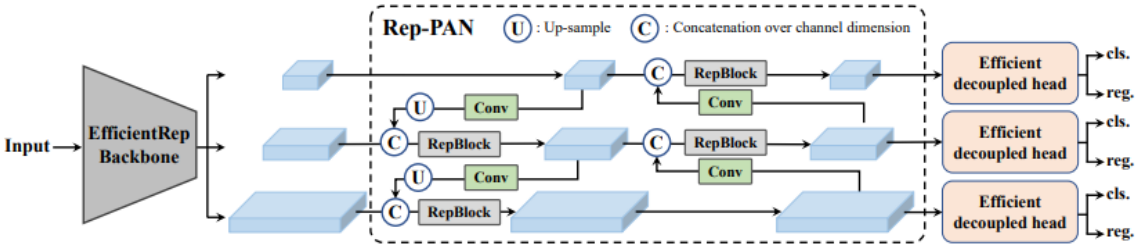
الشكل (22.3): بنية نموذج YOLOv1. [48]

نُشر YOLOv2، في عام 2017، بواسطة نفس مؤلفي YOLOv1. لقد قاموا بتعديل بنية YOLOv1 بشكل طفيف وتحسين عملية التدريب لجعل YOLOv2 أسرع وأكثر دقة. قدم YOLOv3 العديد من التحسينات من حيث بنية الشبكة، استلهم المؤلفون من طريقة (Feature Pyramid Network) FPN هو أسلوب يساعد في الاستفادة من الميزات الدقيقة في المراحل المبكرة من الشبكة والتدرجات المتقدمة، مما يساهم في تحسين التحديد الدقيق للكائنات في الصور. ودمجوا شبكات الرواسب في Darknet−19، مما يسمح للشبكة باستخراج ميزات أعمق وتقليل مشكلات الانحدار التدرجي. بالإضافة إلى ذلك، استبدل **YOLOv3** طبقات التجميع بطبقات التفافية بخطوة 2، مما يقلل من فقدان المعلومات أثناء عملية استخراج الميزات، ومع ذلك، فقد واجه صعوبة أكبر في اكتشاف الأشياء متوسطة وكبيرة الحجم. اما في **YOLOv4** كان التشابه الوحيد بين YOLOv4 وسابقاتها هو أنها بُنيت باستخدام إطار Darknet.

بشكل عام، يتألف كاشف الكائنات من: عمود فقري مدرب مسبقاً على ImageNet لاستخراج الخصائص ورأس لإجراء انحدار وتصنيف الإطار المحيط. ولكن من YOLOv3 وYOLOv4، قدم المؤلفون جزءاً آخر من البنية يسمى الرقبة، يوضع بين العمود الفقري والرأس. ويتمثل استخدام هذه الكتلة في تحسين ودمج الميزات المستخلصة من العمود الفقري.

في **YOLOv5** ينقسم النموذج إلى 3 أجزاء، العمود الفقري عبارة عن CSP-DarkNet53، اما الرقبة فهي تجميع الهرم المكاني السريع (SPPF) والذي يعد أحد التحسينات التي قدموها في نموذجهم، مما يجعل العملية أسرع بكثير مع PANet (شبكة تجميع المسارات) بهدف إنشاء تسلسل هرمي غني متعدد المراحل للكشف عن

الكائنات. التعديل الوحيد هو أن PANet يربط خرائط الميزات بدلاً من إضافتها، بالإضافة الى أن الرأس هو YOLOv3. يُعد YOLOv7 استمراراً لـ Scaled-YOLOv4. تم نشر YOLOv4 وYOLOv7 بواسطة نفس المؤلفين. بعد شهرين من إصدار **YOLOv7**، أصدر باحثون من شركة Meituan Inc، YOLOv6، تم نشر YOLOv7 قبل YOLOv6. جرب المؤلفون العديد من التقنيات، وتم دمج الأساليب الناجحة الناتجة مع النموذج ونشرها باسم **YOLOv6** وهو عبارة عن بنية رأسية منفصلة مع هيكل أساسي فريد يسمى EfficientRep. كما في الشكل (23.3). [48–53]

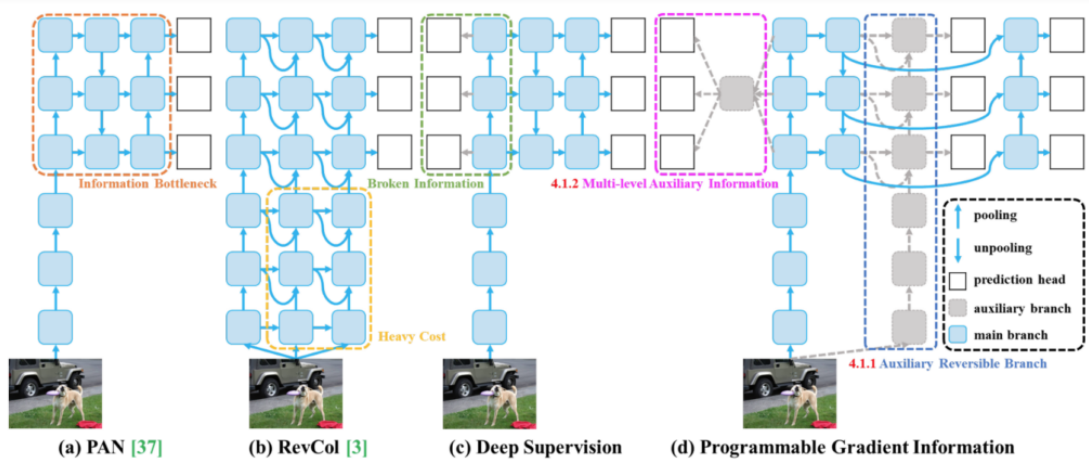


الشكل (23.3): بنية نموذج YOLOv6 [48]

يعد YOLOv6 إضافة مهمة للغاية إلى سلسلة نماذج YOLO، طرحت Ultralytics نموذج YOLOv8، تتبع بنية YOLOv8 نفس بنية YOLOv5، مع بعض التعديلات الطفيفة، في YOLOv9 تم تقديم معلومات التدرج القابلة للبرمجة Programmable Gradient Information (PGI) وبنية شبكة جديدة تسمى شبكة تجميع الطبقات الفعالة المعممة (GELAN) لمعالجة مشكلات فقدان البيانات في شبكات التعلم العميق أثناء استخراج الميزات وتحويلها. تم تصميم PGI للحفاظ على معلومات الإدخال الكاملة لحسابات التدرج الموثوقة، مما يعزز تحديثات الوزن. يعرض الشكل (24.3) معلومات التدرج القابلة للبرمجة (PGI). [55]

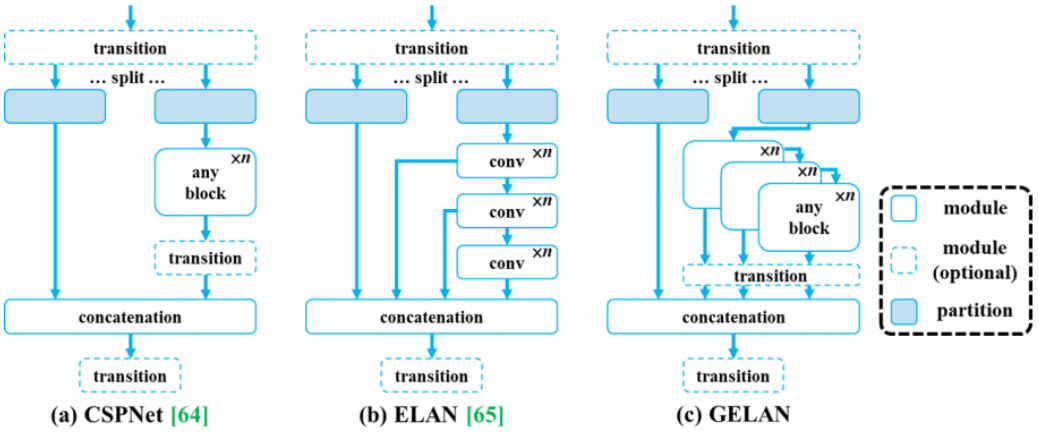
تجريبياً، يتفوق **YOLOv9**، باستخدام GELAN وPGI، على أجهزة الكشف عن الكائنات الأخرى في الوقت الفعلي من حيث الدقة والكفاءة. إنه يتفوق على النماذج التي تستخدم التفافاً عميقاً أو تعتمد على تدريب ImageNet المسبق.

بناء نموذج لتقييم هشاشة العظام لمفصل الورك باستخدام الذكاء الاصطناعي، سويقات.



الشكل (24.3): معلومات التدرج القابلة للبرمجة (PGI).[55]

يعود نجاح YOLOv9 إلى الاستخدام المتفوق للمحددات وقدرة PGI على الاحتفاظ بالمعلومات الحاسمة لرسم خرائط فعالة لأهداف البيانات. بالإضافة لذلك، تعمل كتل CSP داخل GELAN على تحسين الأداء باستخدام محددات أقل، مما يسمح بتصميم معماري مرن ومستقر. يعرض الشكل (25.3) بنية **GELAN**. كما يُظهر تكامل PGI مع مفاهيم الإشراف العميق تحسينات ملحوظة، وخاصة في النماذج العميقة.[55]



الشكل (25.3): بنية GELAN.[55]

تقدم بنية Yolov9 العديد من التطورات الجديدة والكتل المحسنة لتحسين دقة وفعالية اكتشاف الكائنات. تتكون YOLOv9 من أربعة مكونات رئيسية، وهي:[55]

العمود الفقري لـ YOLO-v9: مسؤول عن استخراج الميزات الأولية من صور الإدخال، مما يعزز تمثيل الميزات تدريجياً مع الحفاظ على الكفاءة الحسابية.

الرقبة Neck: تدمج وحدة Neck وتصقل الميزات المستخرجة بواسطة العمود الفقري، وتجهزها للكشف الدقيق عن الكائنات.

مساعد: يعزز قسم المساعد من قوة التدريب وتدفق التدرج، وهو أمر بالغ الأهمية لتحسين أداء النموذج أثناء مراحل التدريب. يعمل قسم المساعد، الذي يعمل فقط أثناء التدريب، بشكل كبير على تحسين تقارب النموذج من خلال توفير معلومات تدرج إضافية وضمان تحديثات دقيقة لأوزان الشبكة.

الرأس: يُنهي الرأس في YOLOv9 اكتشاف الكائنات من خلال التنبؤ بإطارات التحديد واحتمالات الفئة.

7.2.3 المصنفات وتقنيات التحسين المستخدمة في البحث

1.7.2.3 خوارزميات التصنيف

- **خوارزمية آلة متجه الدعم (SVM)**

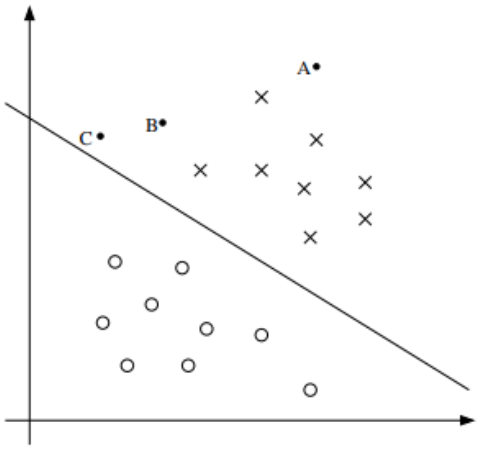
هي عبارة عن خوارزمية تعلم مراقب تُستخدم للتصنيف بناء على نظرية التعلم الإحصائية وإجراء تحليل الانحدار. إن تقنية آلة متجه الدعم كسبت أهمية كبيرة في مجال تعلم الآلة وتمييز الأنماط لأنها ابتكرت طريقة لحل هذه المسائل عن طريق تحديد المستوى الفائق (Hyper Plane) للبيانات المراد فصلها.

الهدف الأساسي من خوارزمية SVM هو العثور على المستوي الفائق في فضاء مكوّن من N بُعد حيث N يمثل عدد الخصائص التي تميز بين الأصناف بوضوح.

تتضمن عملية التصنيف باستخدام خوارزمية SVM مرحلتين: مرحلة التدريب ومرحلة الاختبار. في مرحلة التدريب يُوفّر مجموعة من البيانات تدعى بيانات التدريب Training Dataset هذه المجموعة تتضمن حالات كل حالة تحتوي على الصنف class والواصفات attributes. والهدف النهائي من التدريب هو أن ينتج بالاعتماد على بيانات التدريب نظاماً يتمكن من إعطاء الصنف لحالات تحتوي واصفات فقط.[50–69]

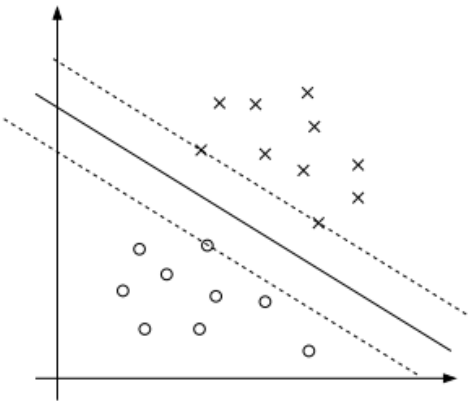
في الشكل (26.3)، حيث تمثل x أمثلة تدريب إيجابية، وتمثل o أمثلة تدريب سلبية، كما يظهر حد القرار (المستوى الفائق الفاصل)، وتم تسمية ثلاث نقاط أيضاً بـ A وB وC. تظهر النقطة A بعيدة جداً عن حدود القرار. إذا طُلب منا إجراء تنبؤ بقيمة y عند A، فيبدو أنه يجب أن نكون واثقين تماماً من أن y = 1 هناك.

وعلى العكس من ذلك، فإن النقطة C قريبة جداً من حدود القرار، وبينما تقع على جانب حدود القرار الذي نتوقع فيه أن تكون $y = 1$، يبدو من المحتمل أن مجرد تغيير صغير في حدود القرار كان من الممكن أن يتسبب بسهولة في أن يكون تنبؤنا $y = 0$. وبالتالي، فإننا أكثر ثقة في تنبؤنا عند A مقارنة بـ C. تقع النقطة B بين هاتين الحالتين، وعلى نطاق أوسع، نرى أنه إذا كانت النقطة بعيدة عن المستوى الفائق الفاصل، فقد نكون أكثر ثقة بشكل كبير في تنبؤاتنا.



الشكل (26.3): شكل المستوي الفائق في فضاء ثنائي الأبعاد.[11]

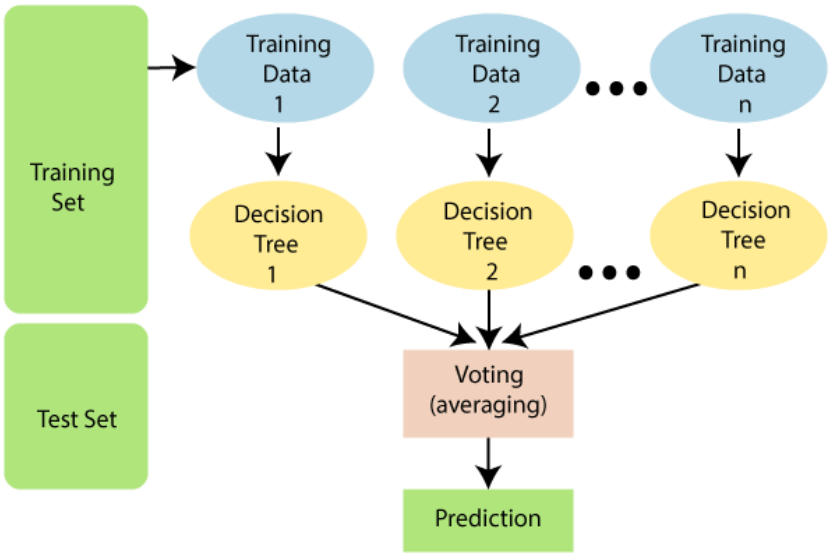
في الشكل (26.3) تمثل x أمثلة تدريب إيجابية، وتمثل o أمثلة تدريب سلبية، يمكن ملاحظة أن كل مجموعة نقاط من الصنف نفسه تتجمع في جهة من جهات المستوي، للفصل بين صنفين من نقاط البيانات، هناك العديد من المستويات الفاصلة التي يمكن اختيارها. لكن هدفنا هو العثور على مستوي يتحقق فيه الهامش الأكبر أو المسافة الأكبر بين نقاط الصنفين. كلما كانت مسافة الهامش أكبر كلما زادت وثوقية المصنف في تصنيف النقاط المستقبلة. في الشكل (27.3) النقاط ذات الهوامش الأصغر هي بالضبط النقاط الأقرب إلى حدود القرار؛ وهذه هي النقاط الثلاث (مثال سلبي ومثالان إيجابيان) التي تقع على الخطوط المتقطعة الموازية لحدود القرار.



الشكل (27.3) المستوي الفائق الذي يحقق الهامش الأكبر بين الأصناف.[11]

❖ خوارزمية الغابة العشوائية (RF)

هي من خوارزميات تعلم الآلة الخاضعة للإشراف (supervised learning)، تتكون خوارزمية الغابة العشوائية من مجموعة من أشجار القرار، يتمُّ تدريب كل شجرة قرار في خوارزمية الغابة العشوائية على مجموعة فرعية عشوائية من مجموعة بيانات التدريب، ثمَّ يتمُّ الحصول على القرار الناتج من كل شجرة قرار ويتمُّ توليد التنبؤ الذي يحصل على أكبر عدد من الأصوات بحيث يكون هو القرار النهائي لخوارزمية الغابة العشوائية.[51] يوضح الشكل (28.3) مبدأ عوامل خوارزمية الغابة العشوائية.



الشكل (28.3) آلية عمل خوارزمية الغابة العشوائية[51].

بارامترات خوارزمية الغابة العشوائية:

1. **عدد المُتنبئات:** وهو عدد الأشجار التي يبنيها النموذج قبل حساب غالبية الأصوات. عموماً زيادة عدد الأشجار يؤدي إلى تحسين الأداء وجعل التنبؤات أكثر استقراراً ولكن بنفس الوقت يؤدي لزيادة العبء الحسابي.
2. **عدد الخصائص:** وهو الحد الأقصى للسمات التي تُعتبر لتقسيم عقدة.
3. **عدد الأوراق:** يمثل الحد الأدنى لعدد العينات المطلوبة لتقسيم عقدة داخلية.

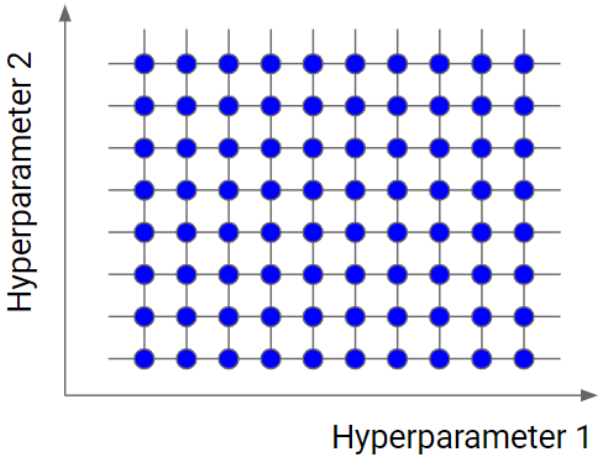
من ميزات خوارزمية الغابة العشوائية: يمكن استخدامها لحل أنواع مختلفة من المشاكل، وسهلة الفهم وعدد بارامتراتها قليل، كما أنها متينة ضد حصول زيادة في الملاؤمة overfitting.[51]

2.7.2.3 تقنيات التحسين المستخدمة في البحث

❖ **البحث الشبكي Grid Search**

البحث الشبكي هي خوارزمية تقليدية تستخدم في تعلم الآلة لضبط المحددات الفائقة. يعمل البحث الشبكي من خلال إنشاء شبكة من قيم المحددات الفائقة وتقييم أداء النموذج لكل نقطة على الشبكة، كما في الشكل (29.3)، ثم تقوم Grid Search باختيار النموذج وضبط المحددات الفائقة في وقت واحد من خلال تدريب نموذج لكل مجموعة من المحددات الفائقة ثم تحديد النموذج الذي يحقق أفضل أداء.[53]

المحدد الفائق هو سمة للنموذج تكون خارجية عنه ولا يمكن تقدير قيمتها من البيانات. يجب ضبط قيمة المحدد الفائق قبل بدء عملية التعلم. على سبيل المثال، c في آلة متجه الدعم، عدد الأوراق في خوارزمية الغابة العشوائية، عدد الطبقات المخفية في الشبكات العصبونية. يتم استخدام البحث الشبكي للعثور على المحددات الفائقة المثلى للنموذج والتي تؤدي إلى التنبؤات الأكثر "دقة".[52]



الشكل(29.3): مثال على البحث الشبكي. [53]

8.2.3 الأدوات المستخدمة في تقييم النماذج

يُقيَّم أداء **خوارزميات التصنيف** من خلال معايير الأداء ومنها: الإحكام (Precision) والحساسية (Sensitivity) والنوعية (Specificity) ومقياس إف1 (F1-Score) ودقة المصنّف الكلية (Accuracy) والمساحة الواقعة أسفل منحنى ROC.[70]

الحساسية (وتُعرف كذلك بأنها المعدل الموجب الحقيقي TPR): هي مقياس للأشياء الموجبة التي عُرفت بشكل صحيح (مثل النسبة المئوية للأشخاص الذين شُخّصوا بشكل صحيح بأنهم مصابون بمرض معين)، أي كم عينة صنّفت على أنها موجبة فعلاً من أصل كل العينات الموجبة وهي متممة للمعدل السالب الحقيقي. وهي نسبة العينات الموجبة الحقيقية (TP) إلى مجموع العينات الموجبة الحقيقية والسلبية الكاذبة (TN). تُعطى بالعلاقة (3−2).

$$sensitivity\ (Recall) = \frac{TP}{TP + FN} \qquad (2-3)$$

الخصوصية أو النوعية (وتعرف بأنها المعدل السالب الحقيقي TNR): وهي مقياس للأشياء السالبة التي عُرفت بشكل صحيح (مثل النسبة المئوية للأشخاص الأصحّاء الذين شُخّصوا بأنهم غير مصابين بمرض معين)، أي كم عينة صنّفت على أنها سلبية فعلاً من أصل كل العينات السلبية وهي متممة للمعدل الموجب الحقيقي. وهي

نسبة العينات السلبية الحقيقية (TN) إلى مجموع العينات السلبية الحقيقية والموجبة الكاذبة. تُعطى بالعلاقة (3-3)

$$specificiyt = \frac{TN}{FP + TN} \qquad (3-3)$$

الدقة الكلية: وهي دقة الكشف الصحيح السالب والصحيح الموجب على مجموع الكشف الكلي. تُعطى بالعلاقة (4-3).

$$Accuracy = \frac{TN + TP}{FN + TN + TP + FP} \qquad (4-3)$$

الإحكام: وهو مقياس لمعدل العينات الموجبة الحقيقية، أي كم عينة موجبة فعلاً من أصل كل العينات ذات التصنيف الموجب. تُعطى بالعلاقة (3-5)

$$precision = \frac{TP}{TP + FP} \qquad (5-3)$$

ومقياس إف1: يُحدّدُ مدى دقَّة النموذج. يُعطى بالعلاقة (3-6)

$$F1\ Score = 2 \times \frac{precision \times recall}{precision + recall} \qquad (6-3)$$

يمكن حساب هذه المعايير من مصفوفة الإرباك (Confusion Matrix) الناتجة عن المصنف، إذ تمثل مصفوفة الإرباك ملخص تنبؤات المصنف. فتوضح عدد التنبؤات الصحيحة وغير الصحيحة لكل صنف، وتساعد في فهم الأصناف التي يتم الخلط بينها وبين الأصناف الأخرى. يوضح الشكل (30.3) طريقة قياس معايير أداء المصنفات من مصفوفة الإرباك.

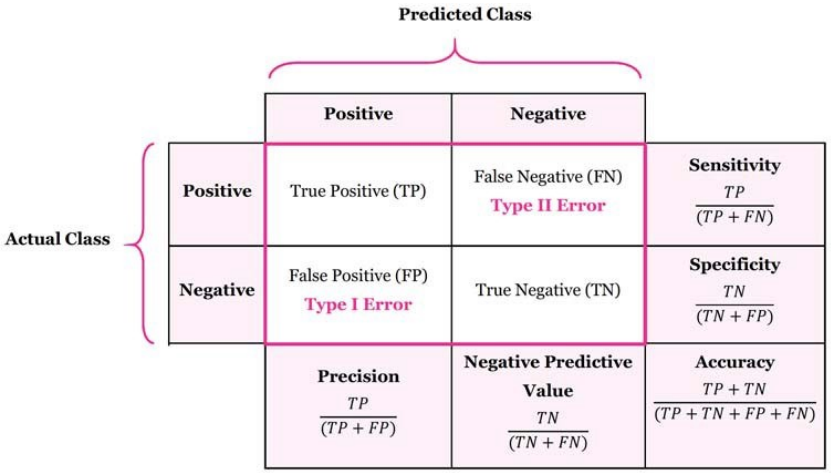
تُعد مصفوفة الإرباك بأنها جدول يُستخدم لتقييم أداء نموذج التصنيف حيث توضح عدد التنبؤات الصحيحة وغير الصحيحة التي قدمها النموذج مقارنة بالنتائج الفعلية .عادة ما يتم تمثيل المصفوفة في شكل جدولي بأربعة مكونات حيث يتم حساب هذه المكونات بناءً على توقعات النموذج والنتائج الفعلية:

1. إيجابية صحيحة :(TP) هذه القيمة تعبر عن عدد الحالات الإيجابية الفعلية التي توقعها النموذج بشكل صحيح على أنها إيجابية.

2. سلبية صحيحة :(TN) هذه القيمة تعبر عن عدد الحالات السلبية الفعلية التي توقعها النموذج بشكل صحيح على أنها سلبية.

3. إيجابية خاطئة :(FP) هذه القيمة تعبر عن عدد الحالات السلبية الفعلية التي توقعها النموذج بشكل غير صحيح على أنها إيجابية.

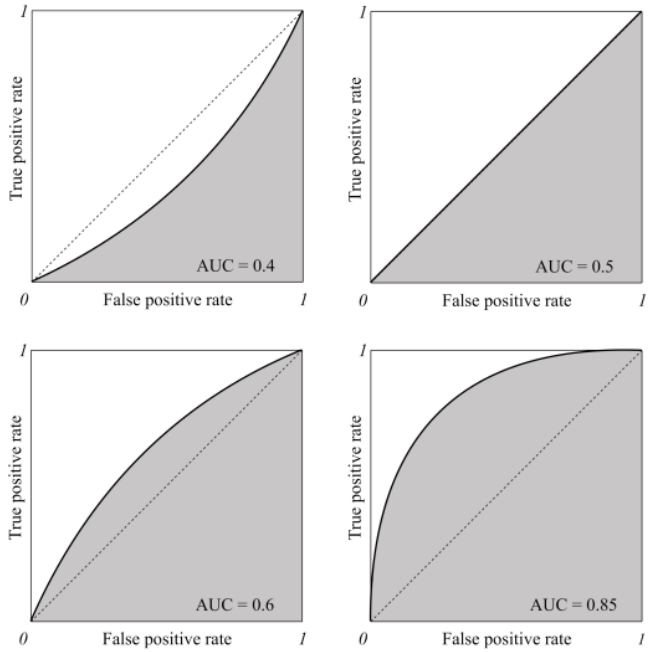
4. سلبية خاطئة :(FN) تعبر عن عدد الحالات الإيجابية الفعلية التي توقعها النموذج بشكل غير صحيح على أنها سلبية.



الشكل (30.3) معايير أداء المصنف من مصفوفة الإرباك.[56]

المساحة الواقعة تحت منحنى ROC (AUC): يُعد منحنى ROC طريقة شائعة الاستخدام لتقييم أداء نماذج التصنيف. تستخدم منحنيات ROC مزيجاً من معدل الإيجابية الحقيقية (المحدد تماماً على أنه الاستدعاء) ومعدل الإيجابية الكاذبة (نسبة الأمثلة السلبية التي تم التنبؤ بها بشكل غير صحيح) لبناء صورة موجزة لأداء التصنيف. يتم تعريف معدل الإيجابية الحقيقية (TPR) ومعدل الإيجابية الكاذبة (FPR) على التوالي. يُعطى بالعلاقة (3-7) [37]

$$\mathrm{TPR} \stackrel{\mathrm{def}}{=} \frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FN}} \quad \text{and} \quad \mathrm{FPR} \stackrel{\mathrm{def}}{=} \frac{\mathrm{FP}}{\mathrm{FP}+\mathrm{TN}}. \qquad (7-3)$$



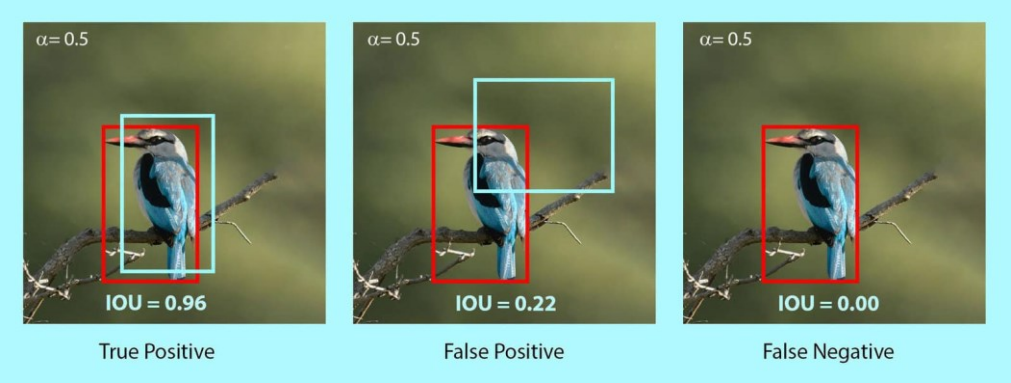
الشكل (31.3): المساحة الواقعة تحت منحنى ROC.[37]

مقاييس الكشف عن الكائن: يُقيَّم أداء **خوارزميات** الكشف عن الكائن من خلال معايير الأداء ومنها: التقاطع على الاتحاد (IOU) ومتوسط الدقة (AP)، ومقياس إف1.

من اكتشاف الكائنات نعلم أن IoU هي نسبة المساحة المتقاطعة إلى المساحة المجمعة للتنبؤ والحقيقة المرجعية. ونظراً لأن قيم TP وFP وFN ليست سوى مساحات أو عدد من وحدات البكسل؛ ف يُعطى IoU بالعلاقة (8−3)

$$IoU = \frac{TP}{(TP + FP + FN)} \qquad (8-3)$$

بمساعدة العتبة (α) التي تُشير إلى الحد الأدنى للقيمة التي يجب أن يتجاوزها الـ IoU لكي يتم اعتبار الكائن تم اكتشافه بشكل صحيح، يمكننا أن نقرر ما إذا كان التنبؤ إيجابياً حقيقياً (TP)، أو إيجابياً كاذباً (FP)، أو سلبياً كاذباً (FN). على سبيل المثال، إذا كانت العتبةα=0.5: وكان الـ IoU بين الإطار المرجعي والإطار الذي تم اكتشافه أكبر من أو يساوي 0.5، سيتم اعتبار هذا الكشف ناجحاً. أما إذا كان الـ IoU أقل من 0.5، سيتم اعتبار هذا الكشف فاشلاً.[49] يوضح الشكل (32.3) التنبؤات مع عتبة IoU مضبوطة على α=0.5 .



الشكل (32.3) مثال على التنبؤات مع عتبة IoU مضبوطة على α=0.5 .[46]

الدقة المتوسطة (AP): هي المنطقة الواقعة تحت منحنى الاستدعاء والدقة. تقيس الدقة نسبة الإيجابيات الحقيقية بين جميع التوقعات الإيجابية، وتقييم قدرة النموذج على تجنب الإيجابيات الكاذبة. تحسب الاستدعاء نسبة الإيجابيات الحقيقية بين جميع الإيجابيات الفعلية، وقياس قدرة النموذج على اكتشاف جميع حالات الفئة.

متوسط الدقة المتوسطة (mAP): توسع الدقة المتوسطة مفهوم الدقة المتوسطة من خلال حساب متوسط قيم الدقة المتوسطة عبر فئات متعددة من الكائنات. وهذا مفيد في سيناريوهات اكتشاف الكائنات متعددة الفئات لتوفير تقييم شامل لأداء النموذج.

mAP50: متوسط الدقة المتوسطة المحسوبة عند عتبة تقاطع على الاتحاد 0.50 (IoU). إنه مقياس لدقة النموذج مع مراعاة الاكتشافات "السهلة" فقط.

mAP50-95: متوسط الدقة المحسوبة عند عتبات IoU مختلفة، تتراوح من 0.50 إلى 0.95. وهو يوفر رؤية شاملة لأداء النموذج عبر مستويات مختلفة من صعوبة الاكتشاف.

مقياس إف1: درجة F1 هي المتوسط التوافقي للدقة والاستدعاء، مما يوفر تقييماً متوازناً لأداء النموذج مع مراعاة الإيجابيات الكاذبة والسلبيات الكاذبة.[55]



الفصل الرابع

الدراسات المرجعية



1.4 المقدمة

هناك العديد من أدوات تقييم المخاطر السريرية التي تم تطويرها للتنبؤ بهشاشة العظام، ولكن هناك بعض القيود لاستخدام هذه الأدوات، مثل عدم مراعاة اختلاف المجموعة العرقية، لا سيما تلك المتعلقة بمؤشر كتلة الجسم ومعدل الوفيات.[14] بالتالي، لا تزال هناك حاجة إلى أداة فحص متقدمة لهشاشة العظام في الممارسة السريرية. حاولت العديد من الدراسات تطبيق تقنية الذكاء الاصطناعي لتطوير أداة فحص لمرض هشاشة العظام، واستناداً إلى البيانات السريرية والشعاعية البسيطة، كانت هناك بعض التجارب للتنبؤ بهشاشة العظام باستخدام خوارزميات تعلم الآلة وخوارزميات التعلم العميق. سنستعرض بعض أدوات تقييم المخاطر التقليدية والدراسات المرجعية المتعلقة بتشخيص هشاشة العظام باستخدام الذكاء الاصطناعي بعد تقسيمها الى ثلاث مجموعات بناءً على نوع المدخلات.

2.4 أدوات تقييم المخاطر التقليدية

الأداة (FRAX: The Fracture Risk Assessment Tool) وهو برنامج وضعته منظمة الصحة العالمية بهدف تقييم أخطار حدوث الكسور لدى المرضى، تُقدم أداة FRAX احتمال حدوث الكسر خلال عشر سنوات القادمة. وهو عبارة عن نظام إلكتروني لحساب ورصد المتغيّرات الواجب أخذها بعين الاعتبار في علاج هشاشة العظام حيث يتم اعتماد مبدأ معالجة المرضى بناء على نتائج قياس مخاطر الكسور بدلاً من الاعتماد على نتائج قياس كثافة العظام فقط. وإلى جانب استخدام عوامل مخاطر الكسور يتمّ الاستعانة بنتائج جهاز فحص كثافة العظام (DXA) بهدف تحسين نتائج تقييم مخاطر الكسور، كما يمكن استخدامها بشكل مستقلّ دون الحاجة لاستخدام جهاز فحص كثافة العظام في تقييم مخاطر الكسور الناجمة عن هشاشة العظام، وتشمل هذه المتغيرات: **العمر، الجنس، الوزن، الطول، مؤشر كتلة الجسم، تاريخ الإصابة بكسور سابقة، تاريخ إصابة أحد الوالدين بكسر في الورك، التدخين الحالي، الاستخدام المزمن للكورتيكوستيرويدات، الإصابة بالتهاب المفاصل الروماتويدي، هشاشة العظام الثانوية، واستهلاك الكحول بمعدل ثلاثة وحدات أو أكثر يوميًا**، بالإضافة إلى **كثافة العظم في عنق الفخذ** كمتغير اختياري. [5]

الأداة (OSTA: Osteoporosis Self-Assessment Tool for Asians) للنساء الآسيويات بعد سن اليأس، يتم حساب OSTA باستخدام الصيغة التالية: [(وزن الجسم (كجم) − العمر (سنة)) × 0.2] مع تجاهل الأرقام العشرية. يتم تصنيف المرضى إلى مرضى منخفضي الخطورة (1- <OSTA) ومتوسطي الخطورة (4- ≤ OSTA ≤ 1-) وعالي الخطورة (4- > OSTA) للإصابة بهشاشة العظام.[2]

3.4 الدراسات المرجعية المعتمدة على البيانات السريرية

قام الباحثين Yang.W, Lai.C, Tsou.M, Hwang.L عام (2021) [6] بتطوير نماذج تشخيصية للتنبؤ بهشاشة العظام باستخدام خوارزميات تعلم الآلة لتكون بمثابة أدوات فحص لمرض هشاشة العظام لدى البالغين الذين تزيد أعمارهم عن خمسين عاماً. ومقارنة أداء هذه النماذج المطورة مع نماذج التشخيص التقليدية باستخدام خمس خوارزميات مختلفة للتعلم الآلي مثل (ANN: **A**rtificial **N**eural **N**etwork) و(SVM) : **S**upport **V**ector **M**achine و (RF : **R**andom **F**orest) و (KNN: **K**-**N**earest **N**eighbor) و (LoR: **Lo**gistic **R**egression).

قاموا بتصميم النماذج للرجال والنساء بشكل منفصل واختار الباحثين 16 ميزة إدخال للرجال و19 ميزة إدخال للنساء **كمحددات دخل للنظام** تضمنت ميزات الإدخال المطبقة على النماذج: العمر، وزن الجسم، ارتفاع الجسم، محيط الخصر، تاريخ التدخين، تاريخ شرب الكحول، مرض السكري، ارتفاع ضغط الدم، نتائج اختبارات الدم للألبومين، الهيموغلوبين، (ALT: Alanine transaminase)، الكرياتينين، الدهون الثلاثية، كوليسترول البروتين الدهني عالي الكثافة، الفوسفات القلوي، هرمون تحفيز الغدة الدرقية. بالنسبة للنساء، تم أيضاً تضمين حالة انقطاع الطمث وتاريخ العلاج بالهرمونات البديلة والتكافؤ(نسبة قيم الإناث إلى الذكور). بلغت عينة الدراسة 5982 مشاركاً كان 3053 (51.0٪) من الرجال و2929 (49.0٪) من النساء. في نماذج تعلم الآلة الخمسة والنموذج التقليدي (OSTA)، تم تقييم الأداء من خلال حساب (AUROC: Area under receiver operating characteristic curve) والحساسية والخصوصية.

بالنتيجة حصلت نماذج تعلم الآلة على حساسية **83–96٪** وخصوصية **53–73٪** للتنبؤ بهشاشة العظام لدى الرجال، بينما حصلت نماذج تعلم الآلة على حساسية 76–90٪ وخصوصية 62–69٪ للتنبؤ بهشاشة العظام عند النساء. وصلت النماذج إلى (AUROC) **من 0.821 – 0.843 في الرجال و0.767 – 0.811 في النساء**. بمقارنة AUROC بين نماذج تعلم الآلة و OSTA كان أداء النماذج في الرجال والنساء أفضل بكثير من النموذج التقليدي OSTA الذي أبلغ عن AUROC قدره **0.73 – 0.76**. خلصت الدراسة إلى تفوق نتائجهم الخاصة بنموذج تعلم الآلة بشكل عام على النموذج التقليدي OSTA. وأثبت الباحثون أن خوارزميات تعلم الآلة تحسن أداء فحص هشاشة العظام من خلال دمج النماذج في الممارسة السريرية، يمكن للمرضى الاستفادة من التشخيص والعلاج المبكر لهشاشة العظام.[6]

كما شخص الباحث Inui وزملاؤه عام (2023) [7] هشاشة العظام من بيانات اختبار الدم لدى النساء المسنات باستخدام نهج تعلم الآلة**.** بهدف التنبؤ بانخفاض كثافة المعادن في العظام (BMD) الذي يدل على هشاشة العظام لدى النساء المسنات دون إجراء قياس DXA مستخدمين المتوسط العام للبالغين الشباب :YAM). (Young Adult Mean وهو مصطلح يستخدم في الطب وعلم العظام للإشارة إلى المتوسط المرجعي للكثافة المعدنية للعظام لدى الأشخاص في مرحلة الشباب. فإن معايير التشخيص للهشاشة العظمية تتطلب أن يكون T-scoreأقل من −2.5 أو أقل من 70% من المتوسط العام للبالغين الشباب (YAM). مستهدفين فئة النساء حيث تم استخدام السجلات الطبية لـ 2541 امرأة (متوسط العمر 73.5 ± 9.2 سنة). حدد الباحثين عمر المريض ومؤشر كتلة الجسم وبيانات اختبار الدم على أنها **محددات الدخل للنظام** للحصول على التشخيص (هشاشة العظام أو سليم) بناءً على قيمة YAM(المتوسط المرجعي للبالغين الشباب) في عنق الفخذ.. استخدم الباحثين خمس خوارزميات للتعلم الآلي وهي: الانحدار اللوجستي، شجرة القرار، الغابة العشوائية، تعزيز الأشجار (Gradient Boosting Trees)، و lightGBM (نسخة محسّنة من تعزيز الأشجار). **أظهر النموذج lightGBM** أعلى دقة ومساحة تحت المنحنى (AUC=0.961)، وفسر الباحثين تنبؤات النموذج وإبراز أهمية كل معلمة في تشخيص هشاشة العظام مستخدمين قيمة Shapley (SHAP) على أنها مساهمة كل ميزة في

تنبؤ النموذج. نتيجة لذلك، تم تصنيف مؤشر كتلة الجسم والعمر وعدد الصفائح الدموية باعتباره أهم ثلاث محددات للتنبؤ بهشاشة العظام في نموذج LightGBM. تشير النتائج إلى أن تعلم الآلة يحمل إمكانات في تحسين رعاية مرضى هشاشة العظام من خلال الكشف المبكر عن المرض. وأشار الباحثين إلى بعض القيود التي تشمل اقتصار مجتمع الدراسة على المرضى الإناث، وغياب بيانات الذكور. وأوضحوا أن الاتجاهات المستقبلية قد تتضمن توسيع النموذج ليشمل حالات الذكور، ودمج بيانات التصوير.

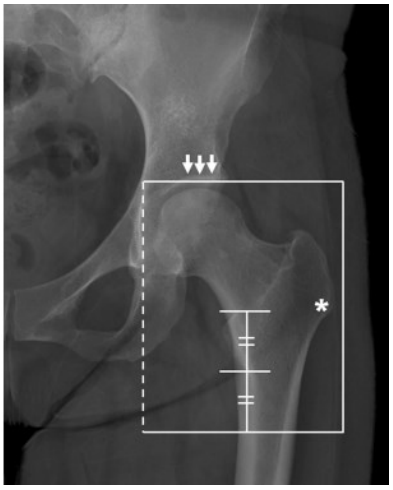
بينما قام الباحث Wu وزملاؤه عام (2023) [12] بمحاولة تطوير نماذج تعلم الآلة للتنبؤ بهشاشة العظام لدى المرضى المصابين بداء السكري من النوع الثاني Type 2 diabetes mellitus (T2DM). وذلك نتيجة العلاقة بين مرض السكري وهشاشة العظام التي أُجمعَ عليها في السنوات الأخيرة. تضمنت الدراسة الحالية محاولة جديدة لتطوير نموذج للتنبؤ بهشاشة العظام للرجال والنساء الذين يعانون من T2DM، تكونت العينة المدروسة من 433 مشاركاً تم تحليلها باستخدام تسع خوارزميات Machine learnin (ML)، على أساس الخصائص الفيزيائية والاختبارات المخبرية والتاريخ الشخصي وتاريخ المضاعفات والأمراض المصاحبة. كشفت مقارنة خوارزميات ML أن نموذج XGBoost قدم أفضل أداء. بالنتيجة حققت خوارزميات تعلم الآلة نطاق AP يتراوح بين 0.444 و1.000. وتم اختيار نموذج XGBoost كنموذج تنبؤ نهائي، محققاً دقة عالية مع AUROC يبلغ 0.940 في مجموعة التدريب، و0.772 في مجموعة التحقق و0.872 في مجموعة الاختبار. قام الباحثون بتقييم أهمية الميزة باستخدام شرح شابلي. وفقاً لتحليل قيمة ميزات نموذج الخوارزمية، تبين أن 25-OH vitamin D هو أبرز وأهم هذه الخصائص، أيضاً كان الجنس والعمر للسكان أهم متنبئ لكثافة المعادن في العظام. أشار الباحثون أن نتائجهم تتوافق مع النتائج التي توصل إليها Wang وزملاؤه [22] بأن معدل انتشار هشاشة العظام كان أعلى بكثير في مرضى T2DM الإناث (48.5٪) مقارنة بالمرضى الذكور (20.3٪). وكان العمر أيضاً عاملاً مهماً في تطور هشاشة العظام لدى مرضى T2DM. حيث كان معدل انتشار هشاشة العظام أعلى بين المرضى الذين يبلغ متوسط أعمارهم أكثر من 60 عاماً (40.1%) منه بين المرضى الذين تقل أعمارهم عن 60 عاماً (26.5%).

وكانت هذه النتائج متوافقة مع الاعتقاد السائد على نطاق واسع أن كتلة العظام البشرية ستنخفض مع تقدم العمر بعد الوصول إلى الذروة. سلط البحث الضوء على العلاقة بين مرض السكري وهشاشة العظام، وساعدت نتائج الدراسة في فهم واكتشاف هشاشة العظام في مرضى السكري من النوع الثاني في وقت مبكر، مما يوفر أداة قيمة للمرضى ومقدمي الرعاية الصحية لتقييم وتخفيف المخاطر المرتبطة بهشاشة العظام لدى الأفراد المصابين بالسكري.

4.4 الدراسات المرجعية المعتمدة على الصور الشعاعية للورك:

تمكن الباحث Jang وزملاؤه عام (2021) [14] من تشخيص هشاشة العظام من التصوير الشعاعي البسيط للورك من خلال تطوير نموذج الشبكة العصبونية العميقة Deep Neural Network (DNN) ، بحيث يمكن تقدير انخفاض كثافة المعادن في العظام من خلال انخفاض سمك القشرة وفقدان الترابيق العظمية في المراحل المبكرة في الصور الشعاعية البسيطة. كانت المجموعة المشاركة في هذه الدراسة 1012 امرأة أعمارهم 55 سنة خضعوا لكل من التصوير الشعاعي وDXA خلال شهر.

المنهجية المتبعة: قاموا بتجزئة صور الأشعة السينية البسيطة لعظام الورك يدوياً بمساعدة طبيب مختص، وتم اقتصاص جميع الصور على نفس الجانب والذي احتوى بالكامل على منطقة عظم الفخذ القريبة المشابهة لمنطقة اهتمام DXA، والتي تم تحديدها كما في الشكل (1.4) كان الحد العلوي للصورة المقصوصة هو سقف الحُق (الأسهم) ورأس الفخذ، وكان الحد السفلي يقع على طول الحدبة الصغرى من طرفها. كان الحد الأوسط (الخط المنقط)، وكان الحد الجانبي للصورة المقصوصة موجوداً على الجانب الجانبي من حافة العضلة ذات الرأسين (علامة النجمة). للتدريب، تم اختيار شبكة VGG16 كنموذج للتعلم العميق، لزيادة أداء الشبكة، قاموا بتنفيذ nonlocal neural network (NLNN) داخل شبكة VGG16. أظهر نموذج DNN دقة إجمالية تبلغ 81.2٪ وحساسية 91.1٪ وخصوصية 45.9٪. وكانت المنطقة الواقعة تحت منحنى ROC 86.7%. أكدت مجموعة التحقق الخارجية أداء النموذج بدقة إجمالية 71.8٪ وقيمة AUC 0.700.



الشكل(1.4): المنطقة محل الاهتمام التي تم اقتصاصها في صورة شعاعية بسيطة للورك.[14]

بينت النتائج أن باستخدام نموذج DNN المطور يمكن أن يتنبأ بهشاشة العظام فقط من صورة شعاعية واحدة للورك، بدقة> 80 ٪ وحساسية> 90 ٪ استناداً إلى VGG16 المجهز بنموذج الشبكة العصبونية غير المحلية (NLNN). تمكن الباحثون من استخراج الميزات التربيقية من الصور الشعاعية الرقمية للورك، وتحديد الأفراد الذين يعانون من انخفاض كثافة المعادن في العظام، مما يشير إلى أداء معقول لفحص هشاشة العظام عن طريق التصوير الشعاعي البسيط للورك.

حلل Feng وزملاؤه عام (2024) [15] صور الأشعة السينية للورك بهدف التنبؤ بهشاشة العظام، وذلك من خلال استخدام الذكاء الاصطناعي لمعالجة الصور والتحقق من إمكانية استخدام نموذج الشبكة العصبونية التلافيفية لقراءة هذه الصور ومن ثم التنبؤ بكثافة المعادن في العظام. اقترح الباحثون في هذه الدراسة نموذجاً لتجزئة صورة الأشعة السينية للورك وآخر للتصنيف، حيث قاموا بتحديد أربع مناطق على الصورة (عنق الفخذ، الحدبة الكبرى، مثلث وارد، والورك بالكامل) لدراسة تأثير تجزئة هذه المناطق على نتائج التصنيف. تألفت قاعدة البيانات من 134 مريضاً مصاباً بهشاشة العظام، وكان معظمهم من النساء في سن اليأس والرجال المسنين. استخدم الباحثون أداة Labelme المفتوحة المصدر لتجزئة صور الأشعة السينية لكل من المناطق الأربع ووضع العلامات عليها يدوياً. كما تم استخدام مقياس التقاطع على الاتحاد Intersection over Union (IoU) لتقييم دقة تجزئة الصورة.

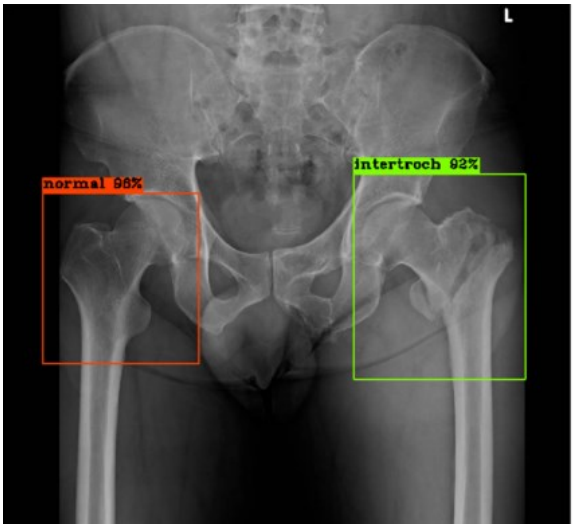
أظهرت النتائج أن نماذج U-Net و++U-Net التي تم بناؤها لكل جزء من الأجزاء الأربعة أنتجت صوراً متوقعة لأجزاء الورك، حيث كانت نتائج نموذج ++U-Net أفضل من نموذج U-Net، وتم استخدام نتائج تقسيم ++U-Net في التجارب اللاحقة. في تجارب التصنيف، تم استخدام نماذج مدربة مسبقاً مثل VGG16 و ResNet50 و DenseNet121، حيث أظهرت نتائج نموذج VGG16 المدرب مسبقاً أفضل أداء في تصنيف الورك الكلي بدقة 0.69 وحساسية 0.72 وخصوصية 0.66، بينما سجل DenseNet121 أسوأ أداء بدقة 0.50 فقط. وواجهت معظم التجارب مشكلة الإفراط في التدريب (overfitting) وعدم توازن البيانات في بعض الأجزاء مثل مثلث وارد والحدبة الكبرى.

في التجربة الثانية، تم استخدام تقنيات زيادة البيانات، حيث تم تكبير حجم البيانات بمقدار سبعة أضعاف، مما أدى إلى تحسين نتائج التصنيف. سجل نموذج DenseNet121 المدرب مسبقاً أفضل أداء في تصنيف الورك الكلي بدقة 0.74، بينما سجل نموذج VGG16 المدرب مسبقاً أسوأ أداء في تصنيف مثلث وارد بدقة 0.47. **أما في التجربة الثالثة**، فقد تم إضافة تجزئة الصور إلى النموذج. ومع ذلك، كانت نتائج التصنيف بعد إضافة التجزئة أقل من النتائج التي تم الحصول عليها باستخدام البيانات الأصلية، حيث انخفضت الدقة من 74% إلى حوالي 60%. وهذا يشير إلى أن تجزئة الصورة قد تؤدي إلى فقدان بعض المعلومات الهامة التي تؤثر على دقة النموذج.

أظهرت النتائج النهائية أن أفضل دقة تم تحقيقها في تصنيف الورك الكلي كانت 74%. كما أظهرت الدراسة أن استخدام صورة الورك بالكامل كان أكثر دقة في التنبؤ بهشاشة العظام مقارنة بتجزئة الصورة إلى أجزاء مختلفة. وأخيراً، أظهرت المقارنة بين النماذج أن نموذج VGG16 الأبسط كان أكثر كفاءة في تصنيف صور الأشعة السينية للورك مقارنة بنماذج الشبكات العصبونية الأعمق مثل DenseNet121 و ResNet50. تتمثل مساهمة هذه الدراسة في تطوير نموذج آلي لتجزئة صور الأشعة السينية ونموذج آخر لقراءة صور الأشعة السينية في تشخيص هشاشة العظام، مما قد يساعد جراحي العظام في تشخيص المرض بشكل أكثر دقة وفعالية.

حاول Twinprai وزملاؤه عام (2022) [16] تقييم دقة التشخيص وحساسية نموذج الذكاء الاصطناعي القائم على You Only Look Once (YOLO) للكشف عن كسور الورك وتمييز أنواع كسور الورك في صور الأشعة السينية للورك والحوض. اعتمدت الدراسة على مجموعة بيانات مكونة من 1000 صورة شعاعية للورك والحوض، تم رسم مربع حدود حول كل ورك، وضع التعليق التوضيحي يدوياً على كل مربع حدود إما طبيعي، أو كسر عنق الفخذ، أو كسر بين المدورين، أو كسر تحت المدورين. بعد ذلك، تم تدريب نموذج الذكاء الاصطناعي YOLOv4-tiny للشبكة العصبونية التلافيفية العميقة باستخدام صور مجموعة التدريب.

بالنتيجة كشفت مجموعة الاختبار أن نموذج الذكاء الاصطناعي أنتج مربعات حدودية حول كل منطقة من الورك، كما موضح في الشكل (2.4) تتكون من المربعات المحددة تلقائياً في مناطق الورك ونسبة الثقة، وصنف مناطق الكسر والورك الطبيعية بحساسية 96.2٪، وخصوصية 94.6٪، ودقة 95٪. وقام الأطباء البشريون بتقييم نفس مجموعة صور الاختبار، بحساسية تتراوح من 69.2 إلى 96.2٪. وبالمقارنة مع الأطباء البشريين، كانت حساسية معدل الكشف للنموذج أفضل بكثير من طبيب عام ومقيمين في السنة الأولى ومكافئة للأطباء المتخصصين.



الشكل(2.4): الورك الأيمن: لا يوجد كسر، نتيجة سلبية حقيقية؛ الورك الأيسر: كسر بين المدورين، نتيجة إيجابية حقيقية.[16]

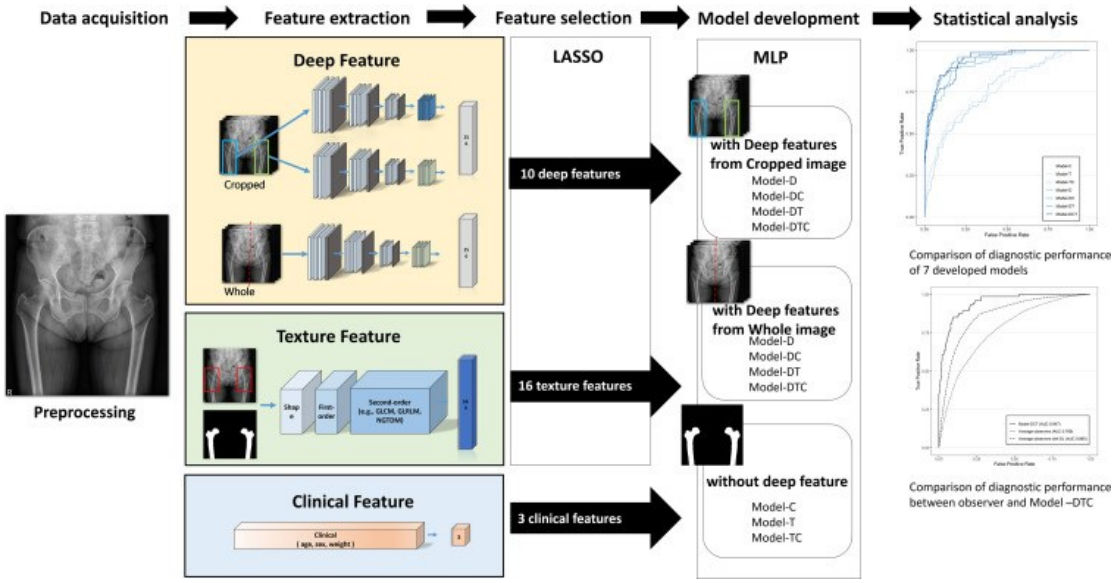
توصل الباحثون إلى أن نموذج YOLO يوفر حساسية اكتشاف كسور الورك مماثلة لأخصائي الأشعة وجراحي العظام المدربين جيداً ودقة عالية في تصنيف كسور الورك. بالتالي تطوير التطبيقات باستخدام هذا النموذج هو هدف مستقبلي.

5.4 الدراسات المرجعية المعتمدة على الصور الشعاعية للورك والبيانات السريرية:

طور الباحث Kim وزملاؤه عام (2022)[18] نهج قائم على التصوير الشعاعي العميق لتشخيص هشاشة العظام باستخدام صور الأشعة السينية للورك. اتبع الباحثون منهجية تجمع بين التصوير الشعاعي، وهي سلسلة من طرق معالجة الصور وتحليلها للحصول على معلومات من الصورة، مع التعلم العميق. تم تطوير نموذج التصوير الشعاعي العميق باستخدام 4924 صورة شعاعية للورك (3632 امرأة؛ متوسط العمر، 62 عاماً ± 13) مستخدمين **10 سمات عميقة** تم استخراجها باستخدام نسختين مختلفتين من نموذج DL باستخدام المنطقة المقصوصة من عظم الفخذ القريب الثنائي (نموذج الصورة المقصوصة) وصور الأشعة السينية للورك والحوض بالكامل (نموذج الصورة الكاملة) كمدخلات. و**16 سمة نسيجية** و**ثلاث سمات سريرية** تمثل عوامل الخطر لهشاشة العظام: العمر والجنس والوزن **لتدريب النموذج**. تم استخدام درجة T-Score المقاسة باستخدام قياس امتصاص الأشعة السينية ثنائية الطاقة كمعيار مرجعي لهشاشة العظام. مستخدمين طريقة عامل الانكماش Least Absolute Shrinkage and Selection Operator (LASSO)لاختيار الميزات العميقة والنسيجية.

ونتيجة لذلك، تم دمج 55 سمة إجمالية (10 سمات عميقة و16 سمة نسيج من كل مفصل ورك وثلاث سمات سريرية) لكل مريض في شبكة متعدد الطبقات. يظهر الشكل (3.4) مخطط تدفق لاختيار الميزات وتطوير نموذج التصوير الشعاعي العميق.

بناء نموذج لتقييم هشاشة العظام لمفصل الورك باستخدام الذكاء الاصطناعي، سويقات.



(3.4) مخطط تدفق لاختيار الميزات وتطوير نموذج التصوير الشعاعي العميق.[18]

طور الباحثون سبعة نماذج تصوير شعاعي عميق تجمع بين أنواع مختلفة من الخصائص: السريرية (النموذج C)؛ النسيجية (النموذج T)؛ عميق (النموذج D)؛ النسيجي والسريري (النموذج TC)؛ عميق وسريري (النموذج DC)؛ عميق ونسيجي (النموذج DT)؛ والعمق، والنسيج، والخصائص السريرية (نموذج DTC). استخدام الباحثون مجموعه مكونه من 444 صورة شعاعية للورك تم الحصول عليها من مؤسسة أخرى للاختبار الخارجي. باستخدام المنطقة الواقعة أسفل منحنى خاصية التشغيل للمستقبل (AUC) تم تقييم الأداء التشخيصي للنماذج. يعرض الجدول (1.4) الأداء التشخيصي لنماذج التصوير الشعاعي العميق.

الجدول(1.4): الأداء التشخيصي لنماذج التصوير الشعاعي العميق[18].

	Internal Test Set			External Test Set		
Model	AUC (95% CI)	Sensitivity (%)	Specificity (%)	AUC (95% CI)	Sensitivity (%)	Specificity (%)
Model C	0.79 (0.72, 0.86)	84 (38/45)	48 (218/452)	0.83 (0.78, 0.88)	99 (73/74)	31 (116/370)
Model T	0.83 (0.78, 0.89)	93 (42/45)	51 (232/452)	0.77 (0.70, 0.83)	77 (57/74)	55 (205/370)
Model TC	0.83 (0.78, 0.88)	98 (38/45)	43 (196/452)	0.77 (0.71, 0.82)	88 (65/74)	49 (180/370)
Cropped-image model*						
Model D	0.92 (0.88, 0.95)	87 (39/45)	78 (354/452)	0.92 (0.89, 0.95)	91 (67/74)	71 (263/370)
Model DC	0.91 (0.87, 0.95)	78 (35/45)	81 (366/452)	0.95 (0.92, 0.97)	96 (71/74)	75 (277/370)
Model DT	0.92 (0.88, 0.96)	82 (37/45)	84 (378/452)	0.93 (0.90, 0.96)	80 (59/74)	83 (306/370)
Model DTC	0.93 (0.88, 0.97)	87 (39/45)	84 (378/452)	0.95 (0.92, 0.97)	89 (66/74)	83 (306/370)
Whole-image model†						
Model D	0.95 (0.93, 0.98)	87 (39/45)	87 (391/452)	0.88 (0.84, 0.93)	59 (44/74)	94 (349/370)
Model DC	0.95 (0.92, 0.98)	87 (39/45)	85 (386/452)	0.90 (0.86, 0.94)	70 (52/74)	90 (333/370)
Model DT	0.96 (0.93, 0.98)	82 (37/45)	89 (402/452)	0.89 (0.86, 0.93)	55 (41/74)	96 (356/370)
Model DTC	0.95 (0.92, 0.98)	91 (41/45)	87 (392/452)	0.91 (0.88, 0.95)	66 (49/74)	94 (347/370)

أظهر نموذج التصوير الشعاعي العميق مع الخصائص العميقة والسريرية والنسيجية أعلى أداء تشخيصي مع مجموعة اختبار خارجية (AUC، 0.95) مقارنة بالنموذج مع الخصائص السريرية فقط (AUC، 0.83) أو الخصائص النسيجية فقط (AUC، 0.77). بالنتيجة أكد الباحثون أنه يمكن استخدام نماذج التصوير الشعاعي العميق باستخدام صور الورك بالأشعة السينية لتشخيص هشاشة العظام بأداء عالٍ. على النقيض من ذلك، فإن الأشعة السينية العادية متاحة على نطاق واسع وتستخدم بشكل متكرر لمختلف المؤشرات السريرية في الممارسة اليومية. وعلى الرغم من هذه الخصائص، فقد تم استخدامها بشكل أقل نسبياً في إدارة هشاشة العظام لأن تشخيص هشاشة العظام باستخدام الأشعة السينية فقط يمثل تحدياً حتى بالنسبة لأخصائي الأشعة ذوي الخبرة. الباحث Yamamoto.N وزملاؤه عام (2020) [19] **قاموا** بتشخيص هشاشة العظام باستخدام الصور الشعاعية للورك باستخدام خوارزميات التعلم العميق، والتحقق مما إذا كانت إضافة البيانات السريرية ستحسن الأداء التشخيصي مقارنة بوضع الصورة وحده. بهدف توضيح أهمية إضافة متغيرات المريض للمساهمة في التطوير المستقبلي للبحوث التشخيصية في هشاشة العظام بالذكاء الاصطناعي. استخدم الباحثون 1131 صورة من المرضى الذين خضعوا لكل من قياس كثافة المعادن في الهيكل العظمي والتصوير الشعاعي للورك. وتم تجزئة البيانات لتقليد النطاق التشخيصي لهشاشة العظام في طريقة DXA، كما هو موضح في الشكل (4.4). ثم أضافوا المتغيرات المشتركة السريرية وهي العمر والجنس ومؤشر كتلة الجسم وتاريخ كسر الورك المستخرجة من السجلات السريرية إلى مجموعة البيانات.



الشكل(4.4): صورة شعاعية للورك قبل التحليل، توضح منطقة الاهتمام التي تم اقتصاصها.[19]

تم تقييم أداء نماذج CNN التالية: ResNet18، ResNet34، GoogleNet، EfficientNet b3، و EfficientNet b4. باستخدام الصور الشعاعية للورك فقط، كان EfficientNet b3 هو أفضل نموذج CNN بدقة وصلت ل 84.07%، بعد إضافة المتغيرات السريرية أظهرت شبكة EfficientNet b3 أعلى أداء بدقة: 88.5٪ بالتالي أثر إضافة المتغيرات المشتركة السريرية إلى زيادة في جميع مقاييس الأداء تقريباً في جميع شبكات CNN على تحليل الصور الشعاعية للورك وحده. أوصى الباحثون بإمكانية إنشاء شبكة يمكنها اكتشاف هشاشة العظام تلقائياً عن طريق اكتشاف موقع مفصل الورك من الصور الشعاعية للورك غير المقصوصة الذي سيكون التحدي التالي باستخدام شبكات مختلفة.

ثم توجه الباحث Yamamoto.N وزملاؤه عام (2021) [20] إلى قياس حجم تأثير إضافة المتغيرات السريرية للمريض في تصنيف هشاشة العظام باستخدام الأشعة السينية للورك إحصائياً، **استخدموا** في تقييم هشاشة العظام من صور الورك بالأشعة السينية نماذج الشبكة العصبونية التلافيفية (CNN) (ResNet18 و34 و50 و101 و152). ثم مع إضافة المتغيرات السريرية وهي العمر والجنس ومؤشر كتلة الجسم للمريض إلى كل CNN. بالنتيجة تم تحسين جميع المقاييس في النموذج الهجين باستخدام ResNet34 مقارنةً بنموذج الصورة فقط. تم تحسين درجة AUC في النموذج الهجين بشكل ملحوظ مقارنةً بنموذج الصورة فقط (فاصل الثقة 95%CI من 0.002 إلى 0.0007؛ p value = 0.0004، حجم التأثير: 0.871). حجم التأثير هو مؤشر على فعالية النتائج التجريبية وقوة العلاقات بين المتغيرات.

في هذه الدراسة، كان حجم التأثير في AUC لتحديد هشاشة العظام 0.871، والذي تم تصنيفه على أنه تأثير كبير. وكان هناك تحسن ذي دلالة إحصائية في درجات AUC. بذلك أكد الباحثين من خلال الدراستين السابقتين على أهمية إضافة المتغيرات للمريض وتأثيرها في تشخيص هشاشة العظام باستخدام شبكات CNN العميقة مع صور الأشعة السينية للورك.

6.4 الخاتمة

1- أدوات تقييم المخاطر السريرية التقليدية التي تم تطويرها للتنبؤ بهشاشة العظام، لديها بعض القيود مما دفع الباحثين إلى تطوير أدوات فحص متقدمة لهشاشة العظام في الممارسة السريرية.[2][5][6]

2- تطبيق تقنية الذكاء الاصطناعي لتطوير أداة فحص لمرض هشاشة العظام، استناداً إلى البيانات السريرية والشعاعية البسيطة.[20][19][18][16][15][14][12][7][6]

3- أثبتت الباحثون تفوق نتائجهم الخاصة بنموذج تعلم الآلة المتعمد على البيانات السريرية فقط بشكل عام على النموذج التقليدي OSTA. [6]

4- تمكن الباحثون من تشخيص هشاشة العظام من خلال سمات سريرية متعلقة بمرض هشاشة العظام باستخدام خوارزميات تعلم الآلة التي وصلت **(AUC=96%)**.[12][7][6]

5- تم تشخيص هشاشة العظام من التصوير الشعاعي البسيط للورك من خلال خوارزميات التعلم العميق باستخدام المصنف VGG16 التي وصلت إلى **(AUC=86.7%)**.[14][15]

6- يوفر نموذج YOLO حساسية اكتشاف كسور الورك مماثلة لأخصائي الأشعة وجراحي العظام المدربين جيداً ودقة عالية في تصنيف كسور الورك. بالتالي تطوير التطبيقات باستخدام هذا النموذج هو هدف مستقبلي.[16][19]

7- جمع الباحثون بين الخصائص السريرية وخصائص الصور لتشخيص هشاشة العظام باستخدام خوارزميات التعلم العميق والتي وصلت **(AUC=95%)**.[18][19]

في الجدول (2.4) مقارنة بين الدراسات المرجعية من حيث الهدف من الدراسة والعينات المستخدمة في الدراسة مع تحديد الجنس والعمر بالإضافة للسمات المستخدمة للإدخال في النماذج ونوع المصنفات المُختبرة ودقة التصنيف.

الجدول (2.4): مقارنة بين الدراسات المرجعية.

رقم الدراسة	اسم الباحث والعام والبلد	الهدف	المصنف	الدقة %	الخصائص المستخدمة	العينة	الجنس والعمر
الدراسة الأولى	Yang 2021 Taiwan	تطوير نماذج تشخيصية للتنبؤ بهشاشة العظام ومقارنة أداء هذه النماذج مع أدوات التشخيص التقليدية (OSTA)	Five ML algorithms (ANN) و (SVM) و (RF) و (KNN) و (LoR)	حصلت النماذج على (AUROC) من 82.1% - 84.3% في الرجال. و76.7%- 81.1% في النساء. و73% - 76%. في OSTA	16 ميزة إدخال للرجال و19 ميزة إدخال للنساء (نماذج منفصلة)	5982 مشاركاً كان 3053 (51.0٪) من الرجال و2929 (49.0٪) من النساء.	نساء ورجال بعمر 50 وأكبر
الدراسة الثانية	Inui 2023 Japan	بناء نماذج تشخيصية للتنبؤ بهشاشة العظام من بيانات اختبار الدم لدى النساء المسنات مستخدمين العامل YAM	Five ML algorithms (LoR) و (DT) و (RF) و (GB) و lightGBM	أظهر lightGBM أعلى الدرجات AUC تبلغ 83%	24 ميزة إدخال للنساء.	2541 امرأة	نساء فقط بمتوسط عمر (73.5 ± 9.2 سنة). أكبر من 64
الدراسة الثالثة	Wu 2023 China	تطوير نماذج للتنبؤ بهشاشة العظام لدى المرضى	XGBoost, LR, LightGBM, RF,	تم اختيار نموذج XGBoost كنموذج تنبؤ نهائي مع	31 ميزة إدخال	433 مشاركاً	نساء ورجال

		المصابين بداء السكري من النوع الثاني.	AdaBoost, GNB, MLP, SVM, KNN,	AUROC يبلغ 87.2% ودقة 80%.			
الدراسة الرابعة	Jang 2021 Korea	تشخيص هشاشة العظام من التصوير الشعاعي البسيط للورك.	VGG16	الدقة 81.2% AUC 86.7%	صور أشعة بسيطة للورك	1012	نساء فقط بعمر 55 سنة
الدراسة الخامسة	Feng 2024 Taiwan	تفسير صور الأشعة السينية البسيطة باستخدام الذكاء الاصطناعي	U-Net ++U-Net ResNet50 VGG16 DenseNet121	++U-Net لتجزئة الصور VGG16 للتصنيف بدقة 74%	صورة أشعة بسيطة للورك	134	نساء في سن اليأس ورجال مسنين
الدراسة السادسة	Twinprai 2022 Thailand	تقييم دقة تشخيص وحساسية نموذج الذكاء الاصطناعي للكشف عن كسور الورك.	YOLO	YOLOv4-tiny الدقة 95% الحساسية 96.2% خصوصية 94.6%	صور أشعة بسيطة للورك والحوض	1000	نساء ورجال بعمر 18 سنة وأكبر
الدراسة السابعة	Kim 2022 Korea	المقارنة بين نماذج مختلفة لتشخيص هشاشة العظام	MLP: multilayer perceptron	95% AUC	10 سمات عميقة. 16 سمة نسيجية. 3 سمات سريرية.	4924	نساء ورجال بمتوسط عمر 62 عاماً

الدراسة الثامنة	Yamamoto 2020 Japan	أهمية إضافة متغيرات المريض إلى نماذج التشخيص باستخدام صور الأشعة السينية.	ResNet18، ResNet34، GoogleNet EfficientNet b3 EfficientNet .b4	EfficientNet b3 بدقة 88.5%	صور أشعة بسيطة للورك و4 سمات سريرية.	1131	نساء ورجال بعمر 60 عاماً وأكبر
الدراسة التاسعة	Yamamoto 2021 Japan	قياس حجم تأثير إضافة المتغيرات السريرية للمريض في تصنيف هشاشة العظام باستخدام الأشعة السينية للورك.	ResNet18) و34 و50 و101 و152).	ResNet34 حجم التأثير AUC 87.1%	صور أشعة بسيطة للورك و3 سمات سريرية.	1699	نساء ورجال بعمر 60 عاماً وأكبر



الفصل الخامس

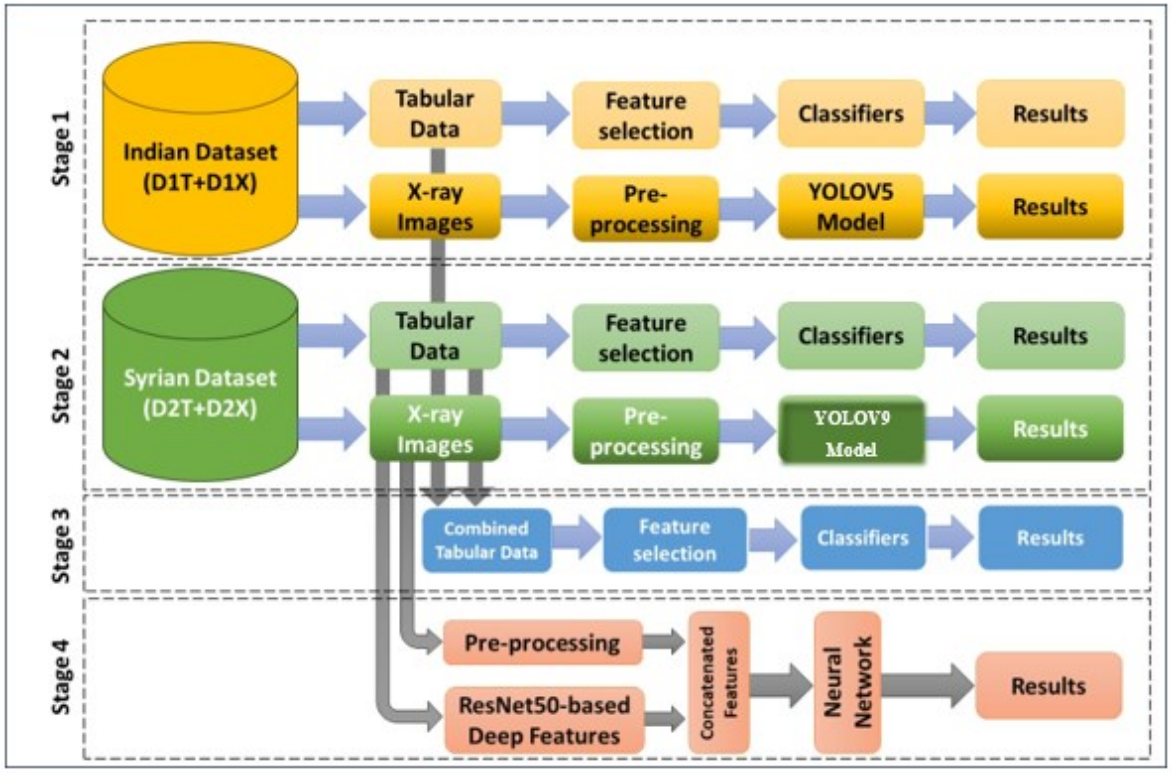
الإجراء العملي



1.5 المقدّمة: يحتوي هذا الفصل على الخطوات العلمية المُتبعة لإنجاز البحث، وتحقيق هدف هذه الدراسة. لذلك يستعرض هذا الفصل المراحل التي مر بها البحث بدءاً من اختيار بيئة العمل، البيانات المناسبة وقد تم اختيار قاعدة بيانات من قاعدة البيانات العالمية Mendeley، وتم تجميع قاعدة بيانات محلية، واختيرت مجموعة من البيانات السريرية وصور الورك لتدريب النموذج، ومن ثم اسُتخلصت الخصائص من البيانات وطبقت الخوارزميات وفي كل تجربة كان يُدرّب النظام باستخدام عدة مصنفات وتغيير بارامترات هذا المصنف لإيجاد الخوارزمية الأفضل والأسرع في التدريب والاختبار. وبعد التوصل للنموذج النهائي الذي صممناه باستخدام البيئة البرمجية Google Colab تم اختبار النموذج ومقارنته مع الدراسات المرجعية.

2.5 منهجية البحث

يوضح الشكل (1.5) الإطار العام المُستخدم في البحث للكشف عن هشاشة العظام وتشخيصها من البيانات السريرية إلى الميزات العميقة.



الشكل (1.5): إطار متعدد المراحل للكشف عن هشاشة العظام وتشخيصها.

يتكون البحث من أربع مراحل دراسية:

في المرحلة الأولى، تم استخدام البيانات السريرية وصور الأشعة السينية للورك من مجموعة البيانات الهندية لتحليل البيانات واكتشاف الأنماط والاتجاهات والحالات الشاذة في البيانات، للحصول على تفسير عن الميزات السريرية التي سيتم جمعها محلياً، واستخدام خوارزمية Yolov5 في الكشف عن المنطقة ذات الاهتمام (الورك) دون تصنيف حالة الورك (انخفاض كثافة معدنية أو سليم).

في المرحلة الثانية، تم استخدام البيانات السريرية وصور الأشعة السينية للحوض من مجموعة البيانات السورية، باستخدام Yolov9 لتصنيف صور الأشعة السينية عن طريق الكشف عن مفصل الورك الذي يملك كثافة معدنية منخفضة تحت مسمى osteoporosis والورك السليم بمسمى normal. جنباً إلى جنب مع مصنفات آلة متجه الدعم (SVM) والغابات العشوائية (RF) لتحليل البيانات السريرية.

في المرحلة الثالثة، تستكشف الدراسة التكامل بين مجموعات البيانات، من خلال الجمع بين البيانات السريرية من مجموعات البيانات الهندية والسورية لتقييم فعالية التدريب على مجموعة سكانية واحدة والاختبار على أخرى، لتوفير رؤية حول إمكانية التعميم ومتانة النماذج القائمة على الذكاء الاصطناعي لاكتشاف هشاشة العظام عبر مجموعات سكانية متنوعة، وهو نهج نادراً ما تم استكشافه في الأبحاث السابقة.

في المرحلة الرابعة، قدمَ البحث نموذجاً هجيناً يدمج الميزات العميقة من بيانات الأشعة السينية المستخرجة من ResNet50 مع المؤشرات الحيوية السريرية لنفس المريض، والاستفادة من الشبكات العصبونية للتصنيف.

3.5 بيئة العمل

كُتبت جميع النصوص والأكواد البرمجية بلغة بايثون Python version 3 ونفذت على منصة كولاب Colaboratory (Colab). تُعدُّ منصة كولاب منصة سحابية مجانية للتعلُّم العميق مطوَّرة من قبل غوغل Google. استخدم إطار Keras للتعلُّم العميق المفتوح المصدر المبني على TensorFlow المقدَّم من غوغل Google لبناء وتدريب شبكات الطي العصبونية فضلاً عن المكتبة المفتوحة لرؤية الحاسب OpenCV. ويشمل ذلك المكتبات المستخدمة بشكل شائع لعلوم البيانات مثل Numpy و Pandas و Scikit-Learn و

Tensorflow و Pytorch ، بالإضافة إلى مكتبات المخططات البيانية مثل Matplotlib و SeaBorn. دُرّبت النماذج على وحدة معالجة الرسوميات GPU (Processing Unit Graphics) Tesla T4 المقدَّمة من كولاب.

4.5 قواعد البيانات المستخدمة في البحث

تم الحصول على قاعدتي بيانات محلية سورية بالنسبة لمرض هشاشة العظام بالإضافة لقاعدتي بيانات خارجية هندية احداهما مسؤولة عن المرض والثانية كجزء من الخدمة الطبية الروتينية.

قاعدة البيانات الأولى Dataset_Net_1: تم استخلاص مجموعة البيانات الأولى من مجموعة البيانات الهندية المتاحة للجمهور [62]، تحتوي 240 عينة لمجموعة من البيانات السريرية المسؤولة عن هشاشة العظام مع قيم T-score التي تم الحصول عليها من نظام الموجات فوق الصوتية الكمية.

قاعدة البيانات الثانية Dataset_Local_1: تم استخلاص مجموعة البيانات الثانية من مجموعة البيانات السورية، تحتوي 439 عينة لمجموعة من البيانات السريرية المسؤولة عن هشاشة العظام مع قيم T-score التي تم الحصول عليها من جهاز قياس الكثافة العظمية.

قاعدة البيانات الثالثة Dataset_Local_2: هي مجموعة فرعية استُخلصت من قاعدة البيانات الثانية من مجموعة البيانات السورية، تحتوي 111 صورة أشعة سينية لمفصل الورك عند مرضى هشاشة العظام مع المتغيرات السريرية الخاصة بكل مريض.

قاعدة البيانات الرابعة Dataset_Net_2: تم استخلاص مجموعة البيانات الرابعة من مجموعة البيانات الهندية المتاحة للجمهور [61]، تحتوي 97 صورة أشعة سينية لمفصل الورك التي تم تنفيذها كجزء من الخدمة الطبية الروتينية.

في كل من قواعد البيانات المستخدمة تم تصنيف مرض هشاشة العظام وفق معيار الكثافة العظمية الذي وضعته منظمة الصحة العالمية بالاعتماد على قيم T-score باستثناء قاعدة البيانات الرابعة. يوضح الجدول (1.5) توزع درجات T-score في قواعد البيانات.

الجدول (1.5) توزع درجات T-score في قواعد البيانات.

المجموعات	عدد البيانات		الدرجات	
	بيانات سريرية	صور	T >= -1	T < -1
قاعدة البيانات الأولى	240	-	189	51
قاعدة البيانات الثانية	439	-	196	243
قاعدة البيانات الثالثة	111	111	43	45
قاعدة البيانات الرابعة	-	97	-	-

1.4.5 الحصول على البيانات

1.1.4.5 مجموعة البيانات الهندية

تم استخلاص مجموعة البيانات الهندية من مجموعة البيانات المتاحة للجمهور [62]. وهي تتألف من بيانات من 240 فرداً، بما في ذلك 14 ميزة سريرية مثل الجنس والعمر والطول (بالأمتار) والوزن (بالكيلوجرام) وحالة التدخين وتاريخ الكسور وغسيل الكلى والتاريخ العائلي لهشاشة العظام وأقصى مسافة للمشي (بالكيلومترات) ومؤشر كتلة الجسم وإدمان الكحول والسكري وقصور الغدة الدرقية وعادات الأكل اليومية. تتضمن مجموعة البيانات أيضاً قيم T-score وZ-score التي تم الحصول عليها باستخدام نظام الموجات فوق الصوتية الكمية (QUS)، والتي تم استخدامها لتشخيص هشاشة العظام. تم تصنيف المتغيرات على أنها ثنائية، حيث يشير "0" إلى الغياب و"1" إلى الوجود، باستثناء العمر ومؤشر كتلة الجسم، والتي تم التعامل معها كمتغيرات مستمرة. كشف تحليل كثافة المعادن في العظام لمجموعة البيانات أن 37 مشاركاً كان لديهم كثافة معادن طبيعية (18 ذكراً و19 أنثى)، وكان 154 مصاباً بهشاشة العظام (59 ذكراً و95 أنثى)، وكان 49 مصاباً بهشاشة العظام (31 ذكراً و18 أنثى).

بالإضافة إلى قاعدة بيانات X-ray images of the hip joints [61] تحتوي على 97 صورة أشعة سينية بسيطة للورك التي تم تنفيذها كجزء من الخدمة الطبية الروتينية.

2.1.4.5 مجموعة البيانات السورية

تم جمع بيانات من مرضى عيادة قياس كثافة العظام من قسم الأشعة من المشفى الوطني الجامعي في دمشق. **امتدت** عملية جمع البيانات من 1 كانون الأول 2023 إلى 13 حزيران 2024، مما أدى إلى مجموعة بيانات تسمى **مجموعة البيانات السورية** (D1)، والتي تتضمن 14 ميزة سريرية وهي: الجنس **و**العمر **و**الطول (بالأمتار) **و**الوزن (بالكيلوجرام) **و**حالة التدخين **و**تاريخ الكسور **و**مرض غسيل الكلى **و**التاريخ العائلي لهشاشة العظام **و**البروتوكول الرياضي **و**مؤشر كتلة الجسم **و**شرب الكحول **و**مرض السكري **و**قصور الغدة الدرقية **و**عادات الأكل اليومية.

تتألف مجموعة البيانات من **439** عينة، تضم 282 أنثى و157 ذكراً، بمتوسط عمر 50 ± 13 عاماً. **تحتوي مجموعة فرعية** من 111 عينة، يشار إليها باسم مجموعة البيانات المستخدمة، على كل من البيانات السريرية وصور الأشعة السينية لنفس المرضى. تشمل هذه المجموعة الفرعية 99 أنثى و12 ذكراً.

تم جمع البيانات من خلال استبيانات المرضى، تليها التشخيص بناءً على معايير كثافة العظام باستخدام جهاز DEXA. تضمنت مجموعة البيانات في البداية متغيرات شاملة لإنشاء قاعدة بيانات محلية قوية لأبحاث هشاشة العظام. أثناء تحليل البيانات، ظهرت العديد من الملاحظات.

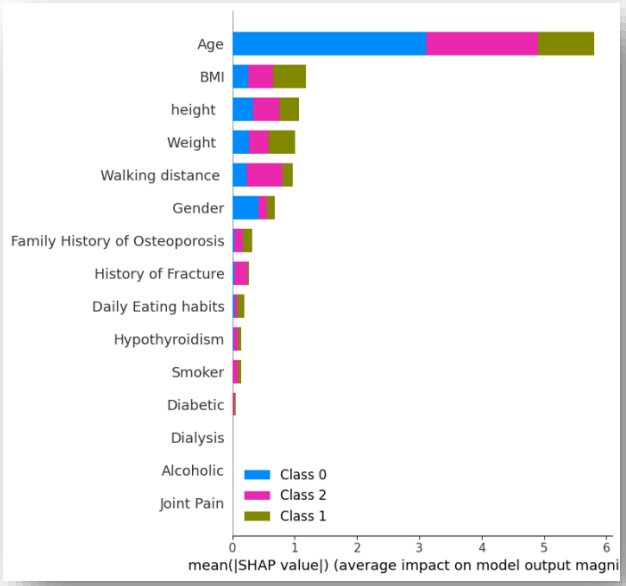
أولاً، لم تكن هناك حالات غسيل كلوي بين العينات. ثانياً، أفاد جميع المشاركين بعدم تناول الكحول.

ثالثاً، استبعدنا عينات من المرضى الذين يعانون من التهاب المفاصل لتجنب عوامل التداخل.

بالإضافة إلى ذلك، تم استبدال بيانات الطول والوزن بمتغير مؤشر كتلة الجسم (BMI) للحصول على أهمية تشخيصية أفضل. أخيراً، لُوحظ غياب أي روتين متعلق بالرياضة في أنماط حياة المرضى.

يُعد تحليل البيانات أداة مهمة لاكتشاف الأنماط والاتجاهات والحالات الشاذة في البيانات تلقائياً، لذلك تم استخدم قاعدة البيانات الهندية [62]، للحصول على تفسير للعلاقات بين الميزات ومعرفة مساهمة كل ميزة من الميزات في التشخيص. كشفت مقارنة مجموعة البيانات بالتفسيرات أن غسيل الكلى وشرب الكحول والتهاب المفاصل كانت من بين أقل السمات أهمية.

في المقابل، اعتُبر مؤشر كتلة الجسم مؤشراً أكثر أهمية من الطول أو الوزن وحدهما، كما حددته قيم شابلي.[7] يوضح الشكل (2.5) أهمية الميزات باستخدام شرح شابلي لمجموعة البيانات الهندية. الذي يظهر مساهمة كل ميزة في التشخيص والتي تقل من الأعلى باتجاه الأسفل.



الشكل (2.5) أهمية الميزات باستخدام شرح شابلي لمجموعة البيانات الهندية.

بناءً على هذا التحليل، تم تحسين مجموعة البيانات لإنتاج نسخة ثانية، D1T، والتي تضمنت تسع ميزات سريرية مهمة تتعلق بهشاشة العظام. وكانت هذه الميزات، التي تم اختيارها بناءً على أهميتها التشخيصية، هي الجنس والعمر والتدخين وتاريخ الكسور والتاريخ العائلي لهشاشة العظام ومؤشر كتلة الجسم والسكري وقصور الغدة الدرقية وعادات الأكل اليومية. بالإضافة إلى ذلك، تم تضمين قيم T-score وZ-score المستمدة من قياسات DEXA. وقد تم تعريف جميع المتغيرات بشكل فئوي، حيث يشير "0" إلى الغياب و"1" إلى الوجود، باستثناء العمر ومؤشر كتلة الجسم، والتي تم التعامل معها كمتغيرات مستمرة. ولتعزيز الفائدة السريرية لمجموعة البيانات، تم الحصول على صور الأشعة السينية البسيطة للحوض من مجموعة فرعية من المرضى في عيادة قياس كثافة العظام. وتضمنت هذه المجموعة الفرعية بيانات سريرية وصور الأشعة السينية البسيطة للحوض وصور كثافة العظام المستمدة من DEXA. تم دمج البيانات السريرية من هذه المجموعة الفرعية في الإصدار

الثاني من مجموعة البيانات، مما أدى إلى إصدار ثالث، D1X، والذي يجمع بين صور الأشعة السينية للحوض مع السمات السريرية والتشخيصية. تم تصنيف هذه الصور بناءً على معيار T-score لتوفير قاعدة بيانات شاملة ومتعددة الميزات لتحليل هشاشة العظام.

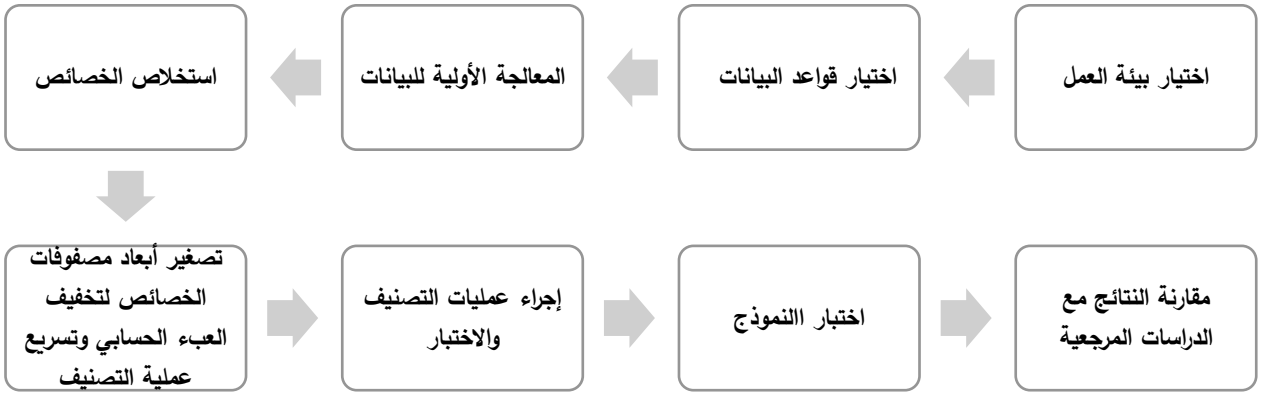
5.5 بروتوكول التصوير

تضمن بروتوكول التصوير جمع جميع البيانات المضمنة، مثل الأشعة السينية البسيطة للورك وسجلات DXA، من مؤسسة واحدة: المستشفى الوطني الجامعي، دمشق، الجمهورية العربية السورية. تم إجراء التصوير بالأشعة السينية الرقمية (GE Healthcare، ألمانيا) بإعدادات تتراوح بين 75–80 كيلو فولت و320–500 مللي أمبير. حرص فني الأشعة الماهر على الحصول على صور شعاعية قياسية للورك لمجتمع الدراسة. تم إجراء قياسات كثافة المعادن في العظام باستخدام نظام Discovery WI (DEXA) (Hologic، الولايات المتحدة الأمريكية). يضمن هذا البروتوكول التوحيد والتصوير عالي الجودة، مما يسهل جمع البيانات الموثوقة لتحليل الميزات السريرية والتصويرية المرتبطة بهشاشة العظام.

6.5 بناء النماذج

1.6.5 نموذج البيانات السريرية

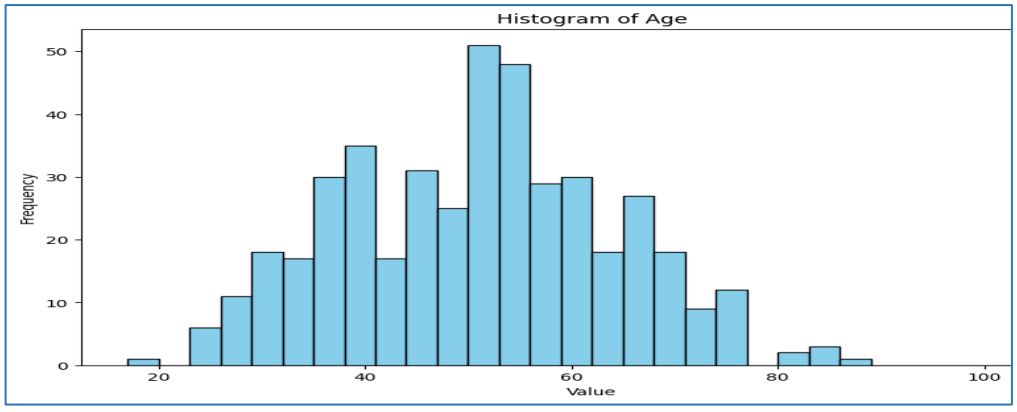
لتصنيف البيانات السريرية من مجموعة البيانات السورية بالاعتماد على قاعدة البيانات الثانية **Dataset_Local_1**، تم تنفيذ عدة خطوات من استكشاف البيانات والمعالجة المسبقة ثم التصنيف باستخدام SVM وRF. يوضح الشكل (3.5) تسلسل مراحل العمل لبناء نموذج الكشف عن هشاشة العظام باستخدام البيانات السريرية.



الشكل (3.5) تسلسل مراحل العمل لبناء نموذج الكشف عن هشاشة العظام باستخدام البيانات السريرية.

1.1.6.5 تحليل استكشافي للبيانات السريرية

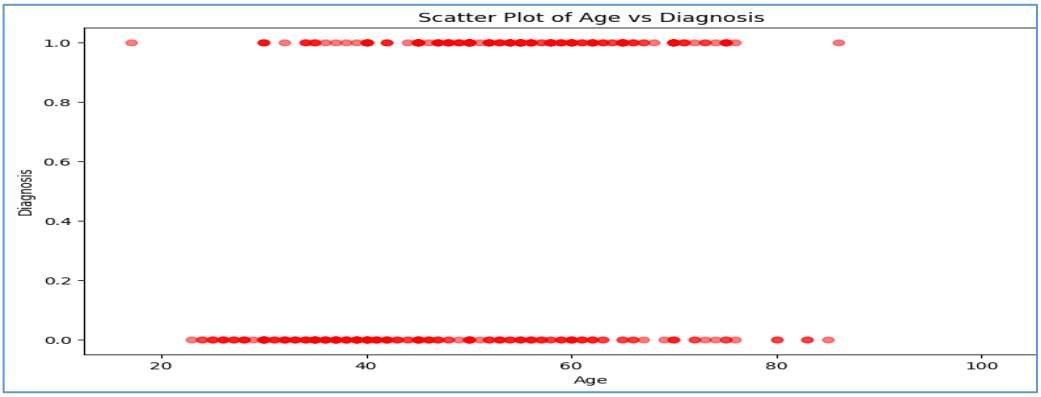
تم إجراء تحليل استكشافي للبيانات لفهم طبيعتها وميزاتها وتوزيعها العام. باستخدام الرسم البياني لتوزيع ميزة "العمر" كما في الشكل (4.5) تبيَّن أن البيانات تخص أعماراً مختلفة تبدأ من عمر 20 إلى 86 عام تتركز العينات الأكثر تكرار ضمن مجال [من 38 إلى 65 عاماً]، وهذا يدل على جودة كبيرة في عينة البيانات المأخوذة، حيث أنها لا تقتصر على فئة عمرية محددة.



الشكل(4.5): توزيع ميزة "العمر".

وباستخدام الرسم البياني في الشكل (5.5) لتوضيح العلاقة بين ميزة "العمر" و"التشخيص"، يَعرض الشكل العينات على شكل نقاط يشير المحور الأفقي إلى عمر العينة ويقابله على المحور العامودي التشخيص المناسب حيثُ يُرمز (0) للحالة السليمة و(1) للحالة المريضة. يبيَّن أن عينة المرضى (1) تغطي جميع الأعمار تقريباً

وتتجمع من عمر 35 إلى 75 عام، وهذا يدل على إمكانية إصابة الشخص بالمرض بغض النظر عن عمره، مع ازياد معدل الإصابة بالمرض مع التقدم بالعمر.



الشكل (5.5): توزيع ميزة العمر مع التشخيص.

2.1.6.5 المعالجة الأولية للبيانات

I. إزالة القيم الشاذة باستخدام Z-Score

إن وجود القيم الشاذة ضمن مجموعة من البيانات يؤثر بشكل كبير على نتائج التحليل الإحصائي للبيانات، القيم الشاذة هي نقاط بيانات تختلف اختلافاً كبيراً عن نقاط البيانات الأخرى في العينة. تتمثل إحدى طرق تحديد القيم الشاذة في استخدام طريقة **Z-Score** هي تقنية إحصائية تقيس عدد الانحرافات المعيارية **data. mean** التي تكون فيها نقطة البيانات من متوسط البيانات**data. mean** . غالباً ما تعتبر نقاط البيانات ذات قيمة **Z-Score** أكبر من 3 أو أقل من −3 القيم الشاذة.[57] باستخدام **Z-Score** المعطى وفق المعادلة (5−1) تم الحصول على 394 عينة بعد حذف القيم الشاذة والتي بلغ عددها 45 عينة شاذة.

$$\boldsymbol{Z - Scores = \frac{(data\ -\ data.mean)}{data.std}} \qquad \boldsymbol{(1-5)}$$

II. التوحيد القياسي للميزات

استخدمنا التوحيد القياسي للبيانات StandardScaler، حيث يحول توزيع كل ميزة ليكون متوسطها صفراً وانحرافها المعياري واحداً. تضمن هذه العملية أن تكون جميع الميزات على نفس المقياس، مما يمنع أي ميزة

واحدة من الهيمنة على عملية التعلم بسبب حجمها الأكبر.[58] جميع الميزات الموجودة في مجموعة البيانات ثنائية، لذا فهي لا تحتاج إلى توحيد، ولكن يوجد ميزتان هما (العمر، مؤشر كتلة الجسم). قيمها ليست ثنائية، لذا يجب توحيدها. وهذا يساعد النموذج على التعلم من كافة الميزات وعدم الانحياز لواحدة منها دون الباقي.

III. زيادة عدد البيانات (Data Augmentation)

قاعدة البيانات غير متوازنة حيث عدد الأصحاء لا يساوي عدد المرضى، لذلك سوف يتم تطبيق تقنية SMOTE، وهي تقنية لزيادة البيانات تساعد على موازنة توزيع الفئات عن طريق إنشاء مثيلات تركيبية لفئة الأقلية بالتالي الحصول على مجموعة البيانات متوازنة.[59] وهذا يساعد النموذج على تعلم مجموعة البيانات لكلا الفئتين (المريضة وغير المريضة) بنفس الطريقة بحيث لا يكون متحيزاً تجاه فئة واحدة على الأخرى. يتم تطبيق التقنية على مجموعة التدريب بعد تقسيم البيانات الى مجموعة تدريب واختبار حيث أن مجموعة الاختبار لا تحتاج لموازنة. كانت الفئة الأقلية في العينة هي الأصحاء وبلغت 143 والمرضى 172 بعد تطبيق زيادة البيانات بلغت عينة الأصحاء 172 وأصبحت مساوية لعدد المرضى.

3.1.6.5 بناء النموذج باستخدام بحث الشبكة و التحقق المتبادل K-Fold

أصبحت مجموعة البيانات نظيفة ومتوازنة، ومُقسمة إلى تدريب واختبار بنسبة 80% تدريب و20% اختبار، لذا فهي جاهزة تقريباً للإدخال في نماذج تعلم الآلة. تضمنت خوارزميات تعلم الآلة المستخدمة في البحث: آلة متجه الدعم (Support Vector Machine)، والغابة العشوائية (Random forest).

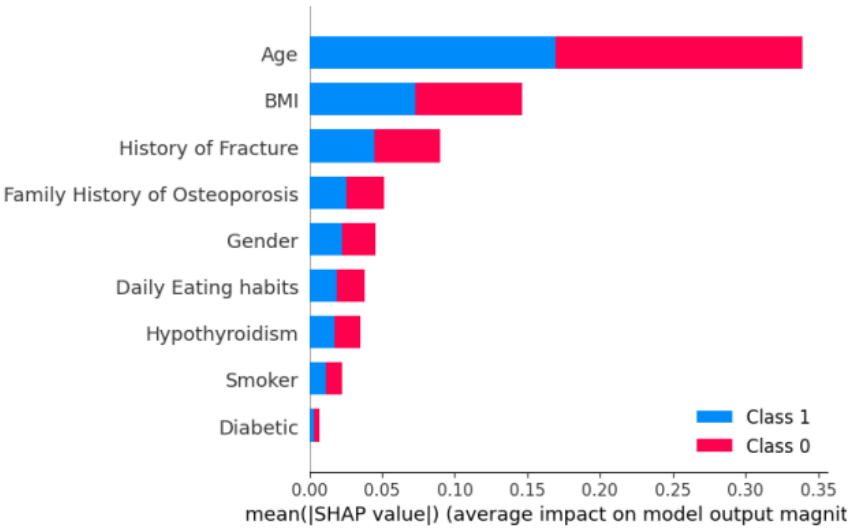
لتجنب الزيادة في التدريب overfitting. تم ضبط البيانات الفائقة لكل نموذج باستخدام بحث الشبكة[53] لنماذج SVM، RF، **بالنسبة لنموذج RF**، تم فحص عدد الأشجار (من 10 إلى 200)، والحد الأقصى لعمق الشجرة (من 0 إلى 20)؛ وحجم الورقة (من 1 إلى 4)، الحد الأدنى لعدد العينات المطلوبة (من 2 إلى 10)، مقاييس الأداء ('gini', 'entropy') ؛ **بالنسبة لنموذج SVM**، نوع النواة ('linear', 'poly', 'rbf', 'sigmoid')، معامل التنظيم C (من0.001 إلى 100) ، معامل gamma ('scale', 'auto', 0.001, 0.01,

(0.1, 1, 2). **البيانات النهائية المعتمدة لنموذج RF**، تم تعيين عدد الأشجار على 150، وتم تعيين أقصى عمق للشجرة على 10، تم تعيين حجم الورقة 1، الحد الأدنى لعدد العينات المطلوبة 2، تم تعيين مقياس الأداء ('entropy'). **بالنسبة لنموذج SVM**، تم الحصول على أداء أفضل باستخدام نواة rbf، تم تعيين معامل التنظيم C على 5 ، وتم تعيين معامل gamma على 1.

بعد أن تم تحديد البيانات الفائقة في كل نموذج، تم تدريب النموذج مرة أخرى باستخدام المجموعة المحددة من البيانات الفائقة عدة مرات لمجموعة بيانات التدريب، تم تحليل النموذج النهائي باستخدام مجموعة بيانات الاختبار، وتم تنفيذ نفس الإجراءات لتصنيف مجموعة البيانات الهندية.

4.1.6.5 تخفيض عدد الميزات

تم دراسة تأثير تقليل عدد الميزات على التشخيص وتمت عملية الاختيار باستخدام أهمية الميزة باستخدام شرح Shapley Additive (SHAP) يظهر الشكل (6.5) أهمية الميزات المدربة باستخدام مصنف الغابة العشوائية. حسب الأهمية التي أظهرها قيم شابلي كانت المحاولة الأول باستخدام 6 ميزات مبنية على: العمر، تاريخ كسر سابق، التاريخ العائلي للإصابة بهشاشة العظام، مؤشر كتلة الجسم، الجنس، عادات الأكل اليومية، **ثم أربع ميزات** توافق الميزات التي تم اعتمادها في الدراسة التي قام بها **Yamamoto** وزملاؤه.[19] **معتمدة على:** العمر، تاريخ كسر سابق، الجنس، مؤشر كتلة الجسم.



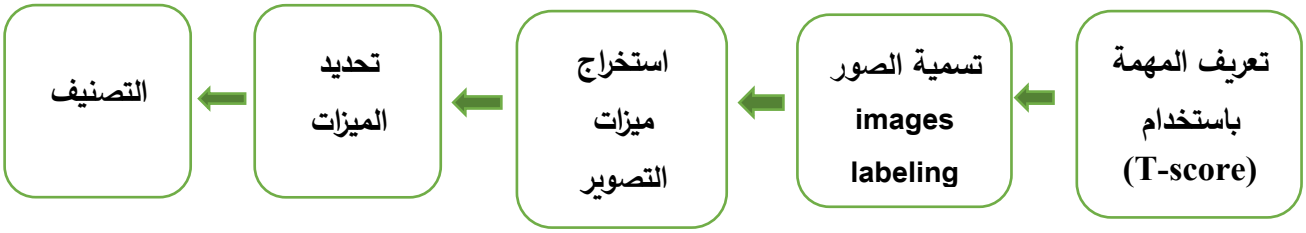
الشكل (6.5): أهمية الميزات المدربة باستخدام مصنف الغابة العشوائية للبيانات السريرية السورية.

5.1.6.5 دمج البيانات السريرية

تم دمج البيانات السريرية من مجموعتي البيانات السورية والهندية لأن السمات متطابقة. قبل دمج العينتين تم تنظيف كل عينة على حدا، والتأكد من عدم وجود تكرار وقيم مفقودة وحذف القيم الشاذة بشكل مماثل للمرحلة السابقة، ومن ثم معرفة عدد الأشخاص السليمة والمريضة في كل عينة واخذ عينة متوازنة من الفئتين ثم تقسيمها لمجموعات اختبار وتدريب، بعد ذلك تم دمج ملفي التدريب للعينتين وملفي الاختبار لضمان عملية الخلط الصحيحة. بالنهاية تم الحصول على قاعدة بيانات مختلطة بشكل صحيح مقسمة إلى مجموعات تدريب واختبار جاهزة للإدخال في نماذج تعلم الآلة. في هذه الطريقة تم تخطي عملية زيادة البيانات للمحافظة على عينة تدريب تضم بيانات حقيقية فقط.

2.6.5 نموذج الصور

في البداية تم بناء نموذج للصور باستخدام قاعدة البيانات الهندية التي تضم 97 صورة أشعة سينية للورك بهدف الكشف عن مفصل الورك في صور الأشعة السينية باستخدام Yolov5 لتقييم أداء خوارزميات اكتشاف الأشياء أحادية المرحلة (أي التي تقوم بمهمة الكشف عن المنطقة ذات الاهتمام وتصنيفها في وقت واحد) في القدرة على تحديد منطقة مفصل الورك. كانت نتائج yolov5 واعده في الكشف عن منطقة الورك بدقة عالية، لذلك تم استخدام أحدث إصدار حينها Yolov9 للكشف عن مفصل الورك وتصنيف صور الأشعة السينية في مجموعة البيانات السورية. يبين الشكل (7.5) سير العمل للتنبؤ بمخاطر الإصابة بهشاشة العظام باستخدام صور الأشعة السينية للحوض.



الشكل (7.5): سير العمل للتنبؤ بمخاطر الإصابة بهشاشة العظام باستخدام صور الأشعة السينية للحوض.

1.2.6.5 استخدام شبكة Yolov5 للكشف عن مفصل الورك في مجموعة البيانات الهندية

- ✓ **تحضير البيانات والتدريب**

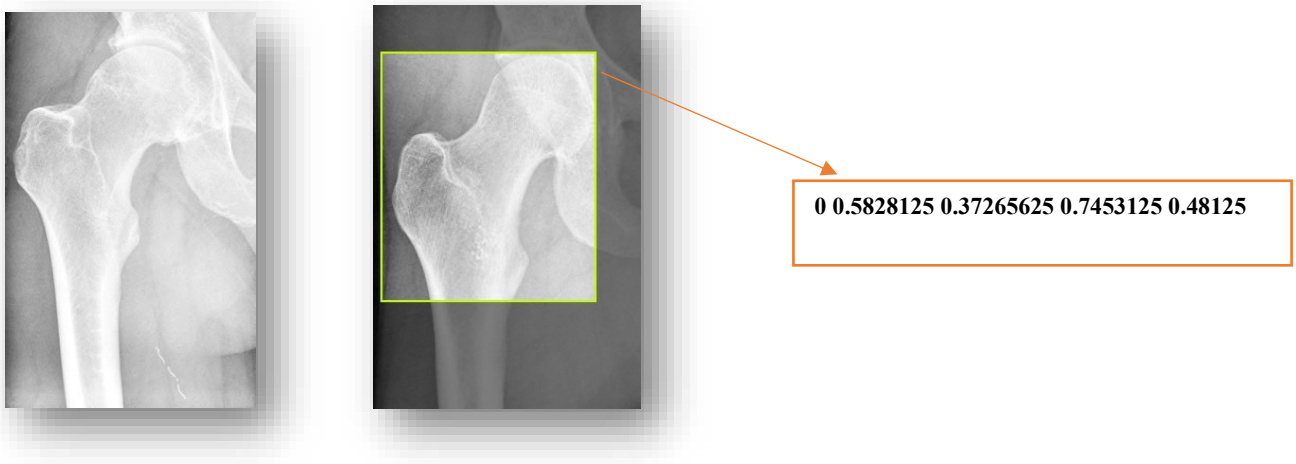
باستخدام قاعدة البيانات الرابعة من موقع data.mendeley.com التي تضم 97 صورة أشعة بسيطة للورك . لم يكن تشخيص حالة الورك باستخدام T-score موجود لدى قاعدة البيانات، لذلك تم بناء نموذج للكشف عن المنطقة ذات الاهتمام (منطقة الورك المماثلة لحقل الرؤيا في DEXA) وتصنيفها على إنها منطقة ورك (Hip) [أي تدريبها على تصنيف المنطقة على إنها ورك دون تحديد حالة الكثافة العظمية].

تمت عنونة الصور images labeling أو ما يسمى تسمية الصور images annotation عبر الأداة Roboflow. ونفذت الخطوات التالية:

1. تحضير مجموعة البيانات.
2. تحديد صنف الشيء المراد كشفه في الصور.
3. رسم إطار إحاطة (يمثل إطار الحقيقة المرجعي) حول الشيء المراد كشفه.
4. اختيار الصنف الذي يمثله ذلك الإطار (مفصل الورك).

وتكون النتيجة على شكل ملف، txt بحيث يحمل اسم الصورة التابع لها. ويحتوي الملف المقابل للصورة على صنف الشيء، أبعاد الشيء، الطول، والعرض. والشكل (8.5) يوضح مثالاً على أحد الصور المعنونة. حيث يدل الرقم (0) على حالة التصنيف (ورك)، تم تجزئة صور الأشعة السينية البسيطة للورك باستخدام yolov5، وتم اقتصاص جميع الصور على نفس الجانب والذي احتوى بالكامل على منطقة عظم الفخذ القريبة المشابهة لمنطقة اهتمام DXA، وقسمت البيانات إلى75 صورة تدريب، و22 صورة اختبار. في عملية التدريب، يتم ادخال كل من الصور والملفات المقابلة لها إلى يولو. وتم التدريب حتى الدورة: 100 epochs، كان زمن التدريب 12 دقيقة.

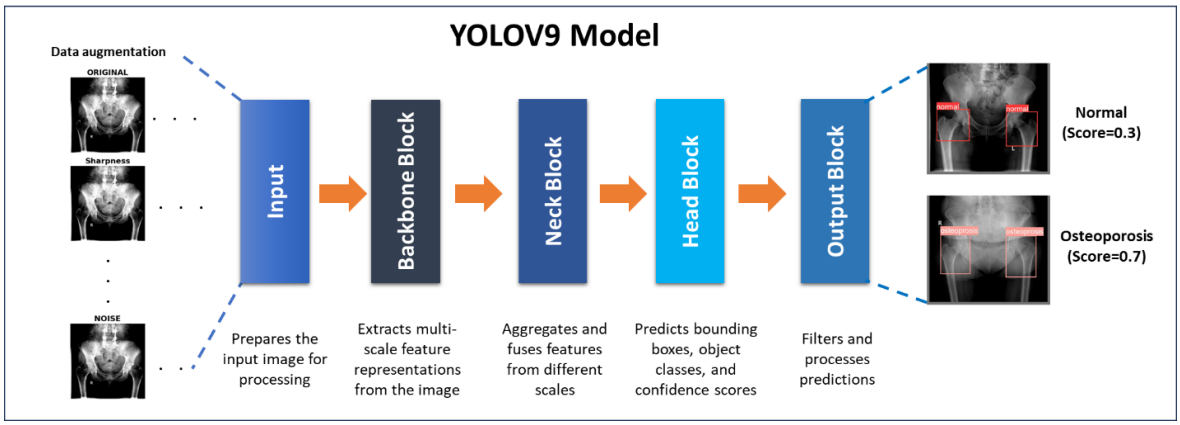
بناء نموذج لتقييم هشاشة العظام لمفصل الورك باستخدام الذكاء الاصطناعي، سويقات.



الشكل:(8.5) عينة من الصور المعنونة المستخدمة في التدريب. يدل الإطار حول مفصل الورك على إطار الحقيقة المرجعي الذي يحدد يدوياً، وتستخدمه الشبكة في التنبؤ بإطارات التحديد. وتدل الأرقام على معلومات الإطار.

2.2.6.5 استخدام شبكة YOLOV9 في تصنيف هشاشة العظام

لتصنيف صور الأشعة السينية للورك في مجموعة البيانات السورية أُستخدام شبكة YOLOv9-e، وتم تنفيذ العديد من الخطوات الموضحة في الشكل (9.5).

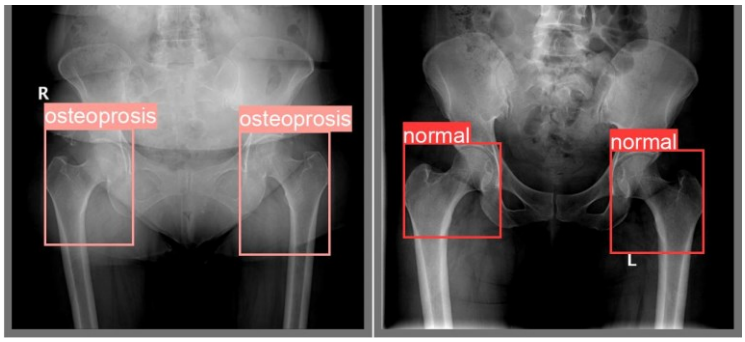


الشكل (9.5): بنية نموذج YOLOv9 لتصنيف صور الأشعة السينية في الكشف عن هشاشة العظام.

✓ **تحضير البيانات والتدريب**

في المرحلة السابقة كانت نتائج yolov5 واعده في الكشف عن منطقة الورك بدقة عالية، لذلك تم الاعتماد على خوارزمية yolov9 كونه إصدار متفوق على yolov5 للكشف عن مفصل الورك الذي يملك كثافة معدنية منخفضة تحت مسمى osteoporosis والورك السليم بمسمى normal، باستخدام 107 عينات من قاعدة البيانات الثالثة التي تضم صور للحوض والتي تم جمعها محلياً. قُسمت البيانات إلى مجموعتين

(مريض وسليم) وأُخذَ من كل مجموعة 80% تدريب و20% اختبار، تمت عنونة الصور images labeling أو ما يسمى تسمية الصور images annotation تم ذلك عبر الأداة labelimg. والشكل (10.5) يوضح مثالاً على أحد الصور المعنونة. حيث تكون النتيجة على شكل ملف، txt بحيث يحمل اسم الصورة التابع لها. ويحتوي الملف المقابل للصورة على صنف الشيء (Normal (0)، Osteoporosis (1))، أبعاد الشيء، الطول، والعرض. تم تدريب YOLOv9 للكشف عن منطقة مفصل الورك الأيمن والأيسر.



الشكل(10.5): عينة من الصور المعنونة المستخدمة في التدريب. يدل الإطار حول مفصل الورك على إطار الحقيقة المرجعي الذي يحدد يدوياً، وتستخدمه الشبكة في التنبؤ بإطارات التحديد.

تم العمل على تجربتين:

1. **التجربة الأولى (استخدام البيانات بدون إجراء المعالجة الأولية للصور).**

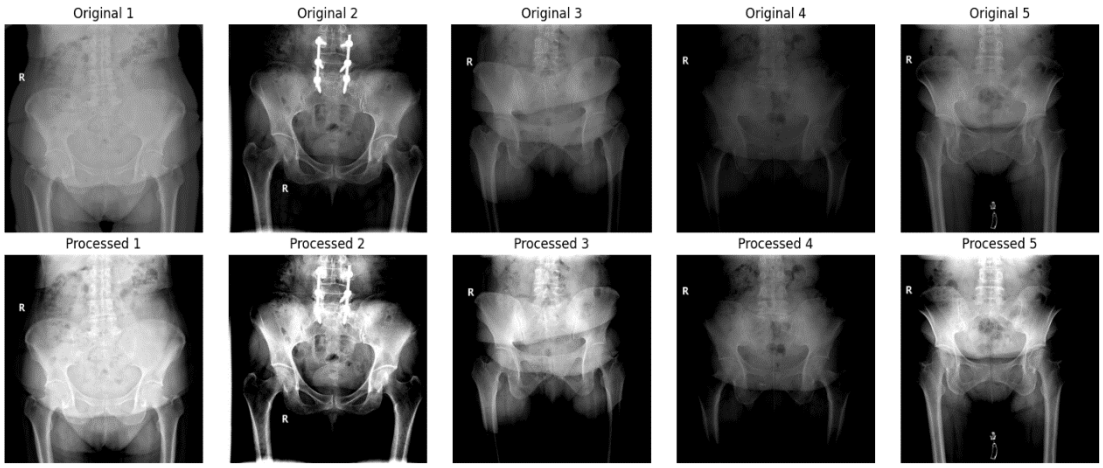
حيثُ قُسمت البيانات إلى86 صورة تدريب، و21 صورة اختبار. في عملية التدريب، يتم ادخال كل من الصور والملفات المقابلة لها إلى يولو دون إجراء أي عملية تحسين للصور. وتم التدريب ضمن بارامترات فائقة افتراضية، بحجم دفعه batch=8 حتى الدورة: epochs 30، كان زمن التدريب 14 دقيقة.

2. **التجربة الثانية (إجراء المعالجة الأولية للصور وتطبيق تقنيات التحسين).**

- ✓ **إجراء معالجة أولية للصور**

تحتوي قاعدة البيانات الثالثة على صور غير واضحة بشكل كافي وتحتاج إلى معالجة بحيث تصبح أفضل كأن تصبح الصورة أكثر وضوحاً أو أقل ضجيجاً. بالتالي تم تطبيق المعالجة المسبقة التالية على كل صورة، يعرض الشكل (11.5) نتيجة المعالجة على الصور مقارنة بالصور الأصلية:

1. تغيير حجم الصورة إلى 640 x 640 بكسل.
2. تحويل الصورة إلى تدرج الرمادي.
3. ضبط التباين لكل الصور.



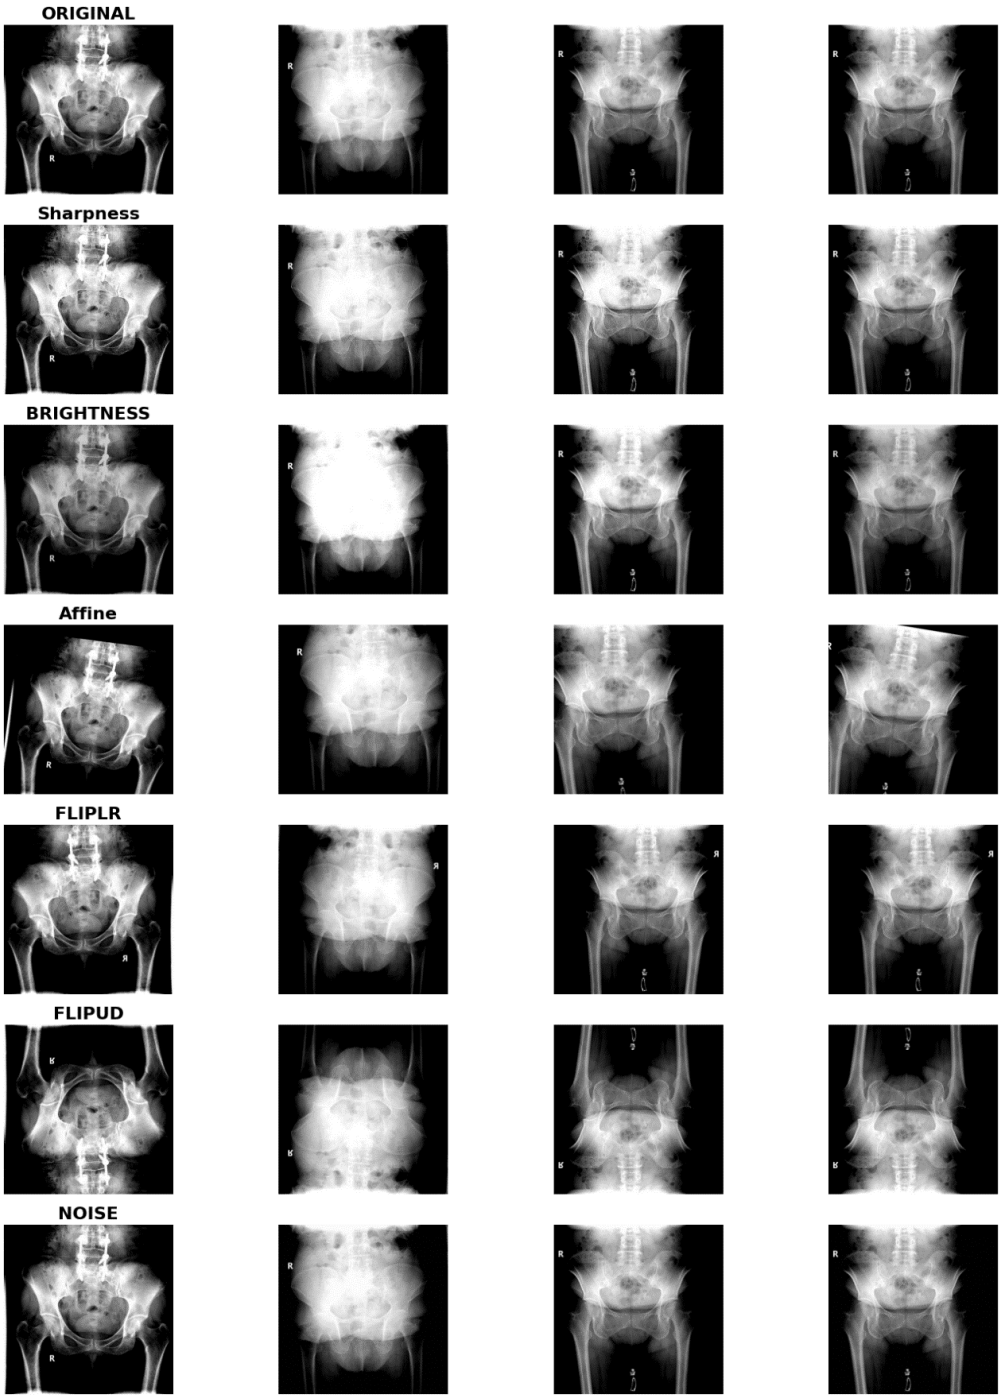
الشكل(11.5) نتيجة المعالجة على الصور مقارنة بالصور الأصلية.

- ✓ **التعامل مع مشكلة حجم البيانات المنخفض**

قُسمت البيانات في الحالة السابقة إلى مجموعتين (مريض وسليم) ثم أخذنا من كل مجموعة 80% تدريب و20% اختبار، بالتالي تأكدنا من عملية الدمج للفئتين بشكل جيد. ولكن نحن بحاجة إلى بيانات أكثر لتدريب النموذج لذلك تم تطبيق تقنيات الزيادة التالية لإنشاء 6 إصدارات لكل صورة مصدر موضحة في الشكل (12.5) وهي:

1. انعكاس أفقي بنسبة احتمال 100%.
2. انعكاس رأسي بنسبة احتمال 100%.
3. تغيير حدّة الصّورة بشكلٍ عشوائيٍّ.
4. دوران (10, 10− درجة).
5. ضبط السطوع بنسبة −30% إلى 30%.
6. تطبيق ضوضاء تصل إلى 1.88%.

إنّ التّقنيّات المتّبعة لتعزيز البيانات، تعدّ إحدى وسائل الولوج نوعاً ما إلى برّ الأمان للتّعامل بشكلٍ جيّدٍ مع مشكلة الملاءمة الزّائدة (Overfitting) بصدد التّخلّص منها، والّتي من المؤكّد أنّها ستؤثّر بشكلٍ أو بآخر على أداء النّموذج المدرّب وإمكانيته في الحصول على دقّةٍ عاليةٍ في عمليّة التّنبّؤ. بالنتيجة حصلنا على قاعدة بيانات تتضمن 749 صورة. تم تقسيمها إلى مجموعات تدريب واختبار والتحقق بنسبة (8:1:1).



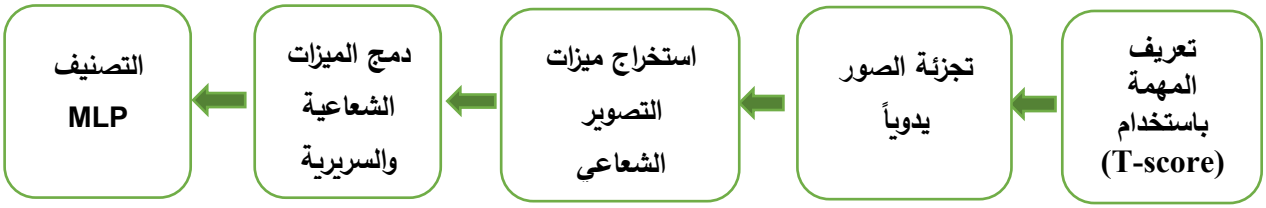
الشكل(12.5) صور لكل فئة من التّقنيّات المتّبعة لتعزيز البيانات.

✓ **ضبط البيانات الفائقة لخوارزمية yolov9**

استخدمنا نموذج YOLOv9-e المدرب مسبقاً بدقة إدخال 640×640 فيما يلي بعض المحددات الفائقة الافتراضية: حجم الدفعة batch=8، معدل التعلمlr0=0.01، عدد التكرارات epochs=20، استخدمنا المُحسن الافتراضي optimizer=SGD.

3.6.5 النموذج الهجين

أكدت نتائج النماذج السابقة أن لكل من المتغيرات السريرية والتصوير الشعاعي البسيط دور واضح في تشخيص هشاشة العظام، لذلك تم بناء نظام هجين يستخدم المتغيرات السريرية والتصوير الشعاعي معاً لتشخيص هشاشة العظام باستخدام قاعدة البيانات الثالثة التي تحتوي على 111 عينة من الصور الشعاعية البسيطة، تمتلك هذه العينات متغيرات سريرية خاصة بكل عينة تم استخدامها لبناء النموذج الهجين. يبين الشكل (13.5) سير العمل للتنبؤ بمخاطر الإصابة بهشاشة العظام باستخدام صور الأشعة السينية للحوض والمتغيرات السريرية.



الشكل (13.5) سير العمل للتنبؤ بمخاطر الإصابة بهشاشة العظام باستخدام صور الأشعة السينية للحوض والمتغيرات السريرية.

يتكون تصميم نظام تشخيص مرض هشاشة العظام باستخدام البيانات السريرية والصور من خمس مراحل:

1- مرحلة اقتطاع منطقة مفصل الورك من صور الأشعة السينية يدوياً.

2- مرحلة المعالجة الأولية للصور والبيانات.

3- مرحلة اختيار النموذج.

4- مرحلة استخلاص ميزات الصور ودمجها مع البيانات السريرية.

5- مرحلة التصنيف.

- ✓ **مرحلة اقتطاع منطقة المفصل**

في هذه المرحلة، تم اقتطاع المفصل الأيمن والأيسر لصور الحوض يدوياً لنفس الشخص والذي احتوى بالكامل على منطقة عظم الفخذ القريبة المشابهة لمنطقة اهتمام DXA، واعتبار كل مفصل مع البيانات السريرية الخاصة بنفس المرض عينة بهدف مضاعفة عدد العينات.

- ✓ **مرحلة المعالجة الأولية**

تم تطبيق المعالجة الأولية التالية على كل صورة: تغيير حجم الصورة إلى 640 x 640 بكسل وتحويل الصورة إلى تدرج الرمادي وضبط التباين لكل الصور.

- ✓ **ضبط توازن العينة**

العينة غير متوازنة من حيث عدد الناس الأصحاء والمرضى، لذلك تم استخدام تقنية زيادة البيانات للعينة الأقلية بتطبيق تقنيات (Hue, Blur, Exposure) للحصول على 27 عينة سليمة اصطناعية توازن العينة. حيثُ نتجَ 138 عينة نظيفة ومتوازنة.

- ✓ **التعامل مع مشكلة حجم البيانات المنخفض**

تم الحصول على 276عينة نظيفة ومتوازنة بعد تجزئة صورة الحوض ولكن نحن بحاجة إلى بيانات أكثر لتدريب النموذج لذلك تم تطبيق تقنيات الزيادة التالية لإنشاء 5 إصدارات مختلفة عن المطبقة من أجل توازن العينة لكل صورة مصدر. هذه التقنيات هي:

1. انعكاس أفقي بنسبة احتمال 100%.
2. انعكاس رأسي بنسبة احتمال 100%.
3. تغيير حدّة الصّورة بشكلٍ عشوائيٍّ.
4. دوران (10−،10 درجة).

5. تطبيق ضوضاء تصل إلى 1.88%.

بالنسبة للمتغيرات السريرية تم زيادة العينات من خلال إضافة الضجيج الغاوسي للمتغيرات العددية والتي هي (مؤشر كتلة الجسم والعمر)، وقمنا بتوحيد هذه الميزات باستخدام Scaler MinMax .

- ✓ **استخراج الميزات**

تم استخدام خوارزمية ResNet−50، بدون طبقة التصنيف الأخيرة لاستخراج ميزات الصور. حيث بلغ عدد الميزات لكل صورة 2057 ميزة تم دمجها مع الميزات السريرية.

- ✓ **التصنيف**

تم استخدام شبكة عصبونية (MLP) مكونة من خمس طبقات: طبقة الإدخالInput layer ، ثلاث طبقات مخفية Hidden layer، و طبقة الإخراجOutput layer. مستخدمين المحسن (Adam)، ومعدل التعلم (learning_rate=1e-4, weight_decay=1e-5)، عدد مرات التدريب epochs=200 مع حجم الدفعة batch_size=64 .



الفصل السادس

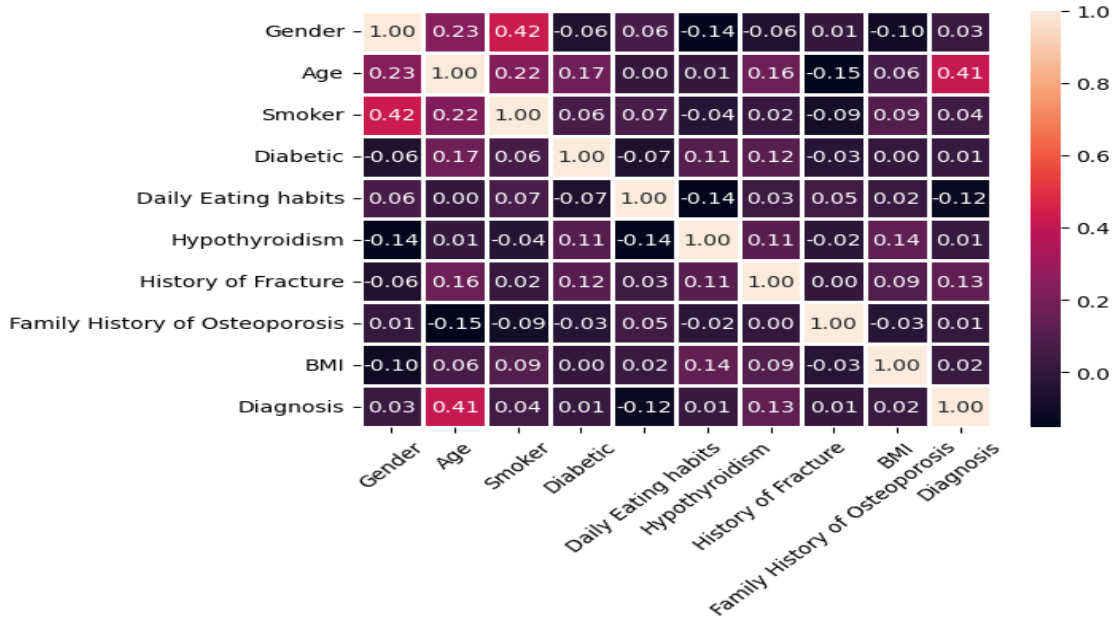
النتائج ومناقشتها



1.6 مقدمة: في هذا الفصل عُرضت نتائج المصنفات المختلفة المستخدمة في البحث لتصنيف البيانات السريرية وصور الأشعة السينية من مجموعة البيانات السورية والهندية، فضلاً عن نتائج دمج البيانات السريرية.

2.6 نتائج تصنيف البيانات السريرية السورية

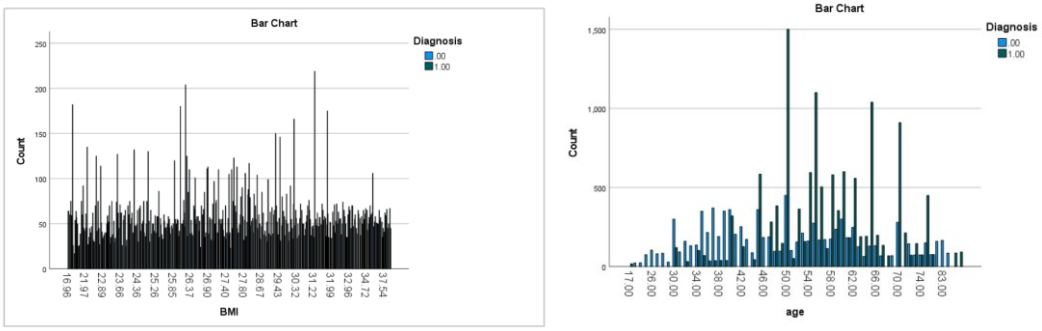
فيما يتعلق بالبيانات السريرية السورية، تم إيجاد معامل الارتباط بين الميزات (Pearson Correlation Coefficient) . حيث يوضح الشكل (1.6) مصفوفة ارتباط بيرسون، مما يسلط الضوء على العلاقات الخطية بين السمات. يمكن ملاحظة ارتباطات مهمة، مثل الارتباط الإيجابي القوي بين بين العمر والتشخيص بدرجة 0.41 وبلغ الارتباط بين الجنس والتدخين 0.42 درجة، مما يشير إلى أن هذه المتغيرات **قد** تساهم بشكل كبير في نموذج التصنيف. تُشير الارتباطات الضعيفة أو التي لا تذكر، مثل تلك الموجودة بين قصور الغدة الدرقية والميزات الأخرى، إلى قوة تنبؤية محدودة من هذه المتغيرات.



الشكل (1.6) معامل الارتباط بين الميزات في مجموعة البيانات السورية.

تضم قاعدة البيانات عدد من المتغيرات الفئوية بالإضافة لمتغيرين مستمرين هما العمر ومؤشر كتلة الجسم، يبين الشكل (2.6) توزع الميزات المستمرة. لتحليل هذه المتغيرات، أُستخدم اختبار Chi-Square لتحليل

البيانات الفئوية، وهو أحد أكثر الاختبارات الإحصائية شيوعاً عندما يتم العمل مع البيانات الفئوية، حيث يُستخدم لاختبار ما إذا كان هناك علاقة ذات دلالة إحصائية بين متغيرين فئويين. يتم حساب مربع كاي بين كل ميزة والهدف، بحيث يقيس Chi-Square مدى انحراف العدد المتوقع والعدد المرصود لبعضهما البعض، تنص الفرضية الصفرية إنه لا يوجد علاقة ذات دلالة إحصائية بين الميزة والهدف، بينما الفرضية البديلة تقول أن هناك علاقة ذات دلالة إحصائية بين الميزة والهدف. بحساب القيمة **p-value نقول** إذا كانت القيمة $p > 0.05$ نقبل الفرضية الصفرية وإلا فإننا نرفضها.



الشكل(2.6): توزع الميزات المستمرة.

يبين الجدول (1.6) الخصائص السريرية لمجتمع الدراسة، ومقارنة الأفراد الذين تم تشخيصهم بهشاشة العظام وغير المصابين به. حيث يتم تقديم المتغيرات الفئوية كأعداد ونسب مئوية داخل كل مجموعة (WG)، في حين يتم تقديم المتغيرات المستمرة كمتوسط ± الانحراف المعياري (STD). تم حساب القيم الاحتمالية باستخدام اختبارات مربع كاي للمتغيرات الفئوية واختبار t لعينتين مستقلتين للمتغيرات المستمرة، باستخدام النظام الإحصائي Spss. تُشير نتائج اختبار مربع كاي إلى أن تاريخ الكسور هو المتغير التصنيفي الوحيد المرتبط بشكل كبير بالتشخيص، مع درجة مربع كاي 17.31 وقيمة $p < 0.001$. وعلى النقيض من ذلك، فإن المتغيرات التصنيفية الأخرى، بما في ذلك قصور الغدة الدرقية، والتاريخ العائلي لهشاشة العظام، والعادات الغذائية اليومية، ومرض السكري، والجنس، وحالة التدخين، لا تظهر علاقة ذات دلالة إحصائية مع التشخيص، كما يتضح من قيم p-value العالية (قيمة $p> 0.05$).

تُظهر نتائج اختبار t المستقل للعينتين للمتغيرات المستمرة فرقاً كبيراً في العمر (قيمة $p < 0.001$) بينما لا يظهر مؤشر كتلة الجسم (قيمة $p> 0.05$) فرقاً كبيراً بين الأفراد المصابين بهشاشة العظام وغير المصابين بها. وهذا يشير إلى أن العمر يلعب دوراً حاسماً في الحالة.

الجدول(1.6): الخصائص السريرية لمجتمع الدراسة، ومقارنة الأفراد الذين تم تشخيصهم بهشاشة العظام وغير المصابين به. يتم تقديم المتغيرات الفئوية كأعداد ونسب مئوية داخل كل مجموعة (WG)، في حين يتم تقديم المتغيرات المستمرة كمتوسط ± الانحراف المعياري (STD). تم حساب القيم الاحتمالية باستخدام اختبارات مربع كاي للمتغيرات الفئوية واختبار t لعينتين مستقلتين للمتغيرات المستمرة.

Feature	Osteoporosis (n=204)	Normal (n=235)	p-value
Gender (%WG)	86 (36.6%)	71 (34.8%)	0.7712
History of Fracture (%WG)	80 (34.0%)	33 (16.2%)	<0.001
Hypothyroidism (%WG)	46 (19.6%)	29 (14.2%)	0.1736
Family History of Osteoporosis (%WG)	53 (22.6%)	39 (19.1%)	0.4445
Diabetic (%WG)	20 (8.5%)	22 (10.8%)	0.5189
Smoker (%WG)	47 (20.0%)	41 (20.1%)	1
Age (mean ± STD)	55.2 (10.8)	45.9 (13.9)	<0.001
BMI (mean ± STD)	27.8 (4.1)	27.9 (4.2)	0.7315

يبين الجدول (2.6) المحددات الفائقة النهائية التي تم تحديدها لكل نموذج، بينما يظهر الجدول (3.6) أداء نماذج تعلم الآلة المختلفة للتنبؤ بهشاشة العظام للبيانات السريرية السورية. يتفوق SVM على RF في جميع المقاييس، محققاً دقة أعلى (87.34%) وحساسية (87.17%) وخصوصية (87.50%) والإحكام (87.17%) ودرجة F1 (87%).

تسلط هذه النتائج الضوء على قدرة نموذج SVM المتفوقة على التعامل مع العلاقات المعقدة داخل البيانات السريرية وملاءمته لمهام تصنيف البيانات السريرية. في المقابل، يحقق RF مقاييس أداء أقل قليلاً، مع قيم دقة وحساسية وخصوصية تبلغ 84.81% و84.61% و85% على التوالي، مما يشير إلى أنه على الرغم من كونه مصنفاً تنافسياً، إلا أن SVM يوفر تنبؤات أكثر قوة لهذه المجموعة من البيانات.

الجدول (2.6): المحددات الفائقة النهائية لكل نموذج.

Hyperparameter	Examined Range	Selected Hyperparameter for the Model
RF		
'n_estimators'	1 – 200	150
'max_depth'	0 – 20	10
'min_samples_split'	2 – 10	2
'min_samples_leaf'	1 - 4	1
'criterion	Gini – entropy	Entropy
SVM		
Penalty parameter C	[0.001 - 100]	5
'kernel'	['linear', 'poly', 'rbf', 'sigmoid']	'rbf'
'gamma'	['scale', 'auto', 0.001, 0.01, 0.1, 1, 2]	1

الجدول (3.6): أداء نماذج تعلم الآلة المختلفة للتنبؤ بهشاشة العظام.

Model's Name	Accuracy	Sensitivity	Specificity	Precision	F1-score
RF	**84.81%**	**84.61%**	**85%**	**84.61%**	**84.6%**
SVM	**87.34%**	**87.17%**	**87.5%**	**87.17%**	**87%**

كما تم دراسة تأثير تقليل عدد الميزات على التشخيص وتمت عملية الاختيار باستخدام أهمية الميزة باستخدام شرح Shapley Additive (SHAP). أدى تخفيض عدد الميزات إلى انخفاض أداء النماذج ويظهر الجدول (4.6) أداء النماذج بعدد متغيرات مختلفة.

الجدول(4.6) أداء النماذج بعدد متغيرات مختلفة للبيانات السريرية السورية .

النموذج	عدد الميزات		9	6	4
Local (السوري)	الدقة	SVM	87.34%	77%	75%
		RF	84.81%	76%	72.72%

3.6 نتائج تصنيف البيانات السريرية الهندية

أظهر الجدول (5.6) أداء النماذج المدربة على مجموعة البيانات السريرية الهندية بعد المرور بمراحل المعالجة الأولية للبيانات كما ذكرنا سابقاً، حيث أظهرت خوارزمية الغابة العشوائية أداء أفضل على مجموعة التدريب هذه بشكل كبير مقارنة مع خوارزمية متجه آلة الدعم التي حافظت تقريباً على أدائها السابق ولكن هناك مخاوف بسبب مجموعة التدريب المنخفضة.

الجدول(5.6) أداء نماذج تعلم الآلة للبيانات السريرية الهندية.

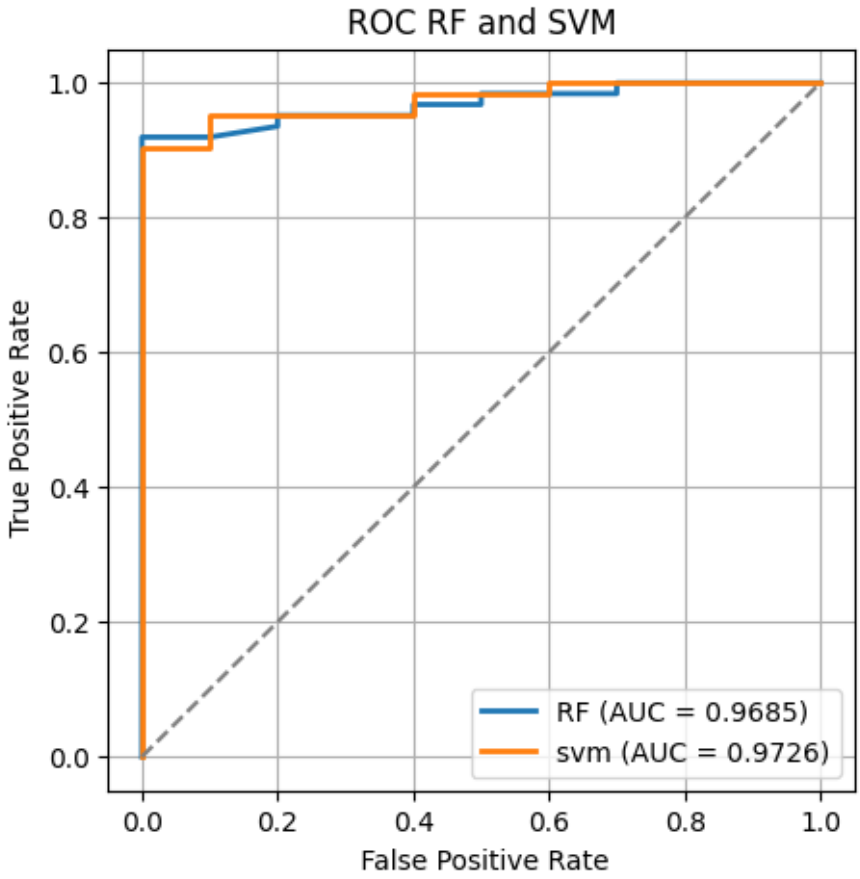
Model's Name	Accuracy	Sensitivity	Specificity	Precision	F1-score
RF	**95.6%**	**85.71%**	**97.43%**	**85.71%**	**85.5%**
SVM	**87%**	**57.14%**	**92.30%**	**57.14%**	**57%**

4.6 نتائج تصنيف دمج البيانات السريرية السورية والهندية

تُعرض نتائج تصنيف البيانات السريرية المجمعة من مجموعات البيانات السورية والهندية في الجدول (6.6)، يُظهر كل من مصنفي RF وSVM أداءً تنافسياً، حيث يتفوق RF قليلاً على SVM. يحقق النموذج المدمج دقة 90.58% (RF) و89.41% (SVM)، مع قيم حساسية 93.02% و90.69% على التوالي. تظل الخصوصية متسقة لكلا المصنفين عند 88.09%، في حين تكون الإحكام أعلى قليلاً بالنسبة لـ RF (88.88%) مقارنة بـ SVM (88.63%). كما أن درجات F1 قابلة للمقارنة، حيث حقق RF نسبة 90.90% و89.64% SVM. أظهرت النماذج قيم (AUCROC) عالية كما في الشكل(3.6) حيث وصلت إلى (AUC=96.85%)في RF. و**أظهر نموذج** SVM أعلى دقة ومساحة تحت المنحنى وصلت إلى (AUC=97.26%).

الجدول (6.6): أداء نموذج مشترك يستخدم ميزات من كلتا مجموعتي البيانات (السورية والهندية).

Model's Name	Accuracy	Sensitivity	Specificity	Precision	AUC	F1-score
RF	**90.58%**	**93.02%**	**88.09%**	**88.88%**	**96.85**	**90.90%**
SVM	**89.41%**	**90.69%**	**88.09%**	**88.63%**	**97.26**	**89.64%**

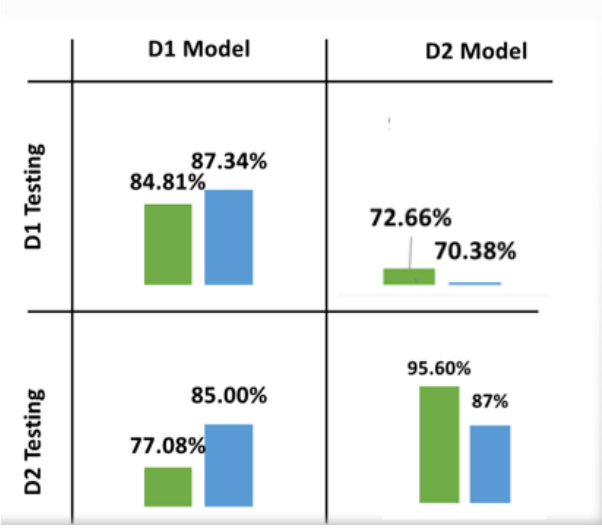


الشكل (3.6): منحنيات ROC لنماذج التعلم الآلي المختلفة SVM و RF.

يفحص الشكل (4.6) تقييم أداء النماذج المدربة على مجموعة بيانات واحدة واختبارها على مجموعة أخرى، حيث حقق النموذج السوري دقة اختبار تبلغ 87.34% و84.81% عند تطبيقه على البيانات السورية باستخدام SVM وRF على التوالي. ومع ذلك، عند اختباره على بيانات الهندية، ينخفض الأداء إلى 85.00% لـ SVM و77.08% لـ RF، تشير النتائج إلى تميز خوارزمية **SVM** بقدرة جيدة على التعامل مع العلاقات المعقدة بين البيانات والحفاظ على مستوى أداء مستقر نسبياً عند اختبار النموذج على بيانات من مجموعة مختلفة، وتُبرز

هذه النتائج متانة خوارزمية **SVM** في استخلاص الأنماط العامة وتمييز الفئات حتى مع وجود اختلاف في توزيع البيانات، مما يعكس كفاءتها في التعامل مع المساحات ذات الأبعاد العالية والأنماط غير الخطية، خاصة عند ضبط المعاملات بالشكل الأمثل.

كما يتضح أن **النموذج السوري** أظهر قدرة أعلى على التعميم مقارنة بالنموذج الهندي، حيث حافظ على مستوى أداء مرتفع نسبياً عند الانتقال إلى مجموعة البيانات الأخرى، على عكس النموذج الهندي الذي انخفض أداؤه من 95.60% مع RF و87% مع SVM على بياناته المحلية إلى 72.66% لـ RF و70.38% لـ SVM، عند اختباره على البيانات السورية. ويُرجح أن ذلك يعود إلى **كفاءة وجودة البيانات السورية المجمعة**، ربما من التنوع الكافي في العينات، مما أتاح للنموذج السوري تعلم تمثيل أكثر عمومية للأنماط وقدرة على التكيف مع بيانات جديدة.



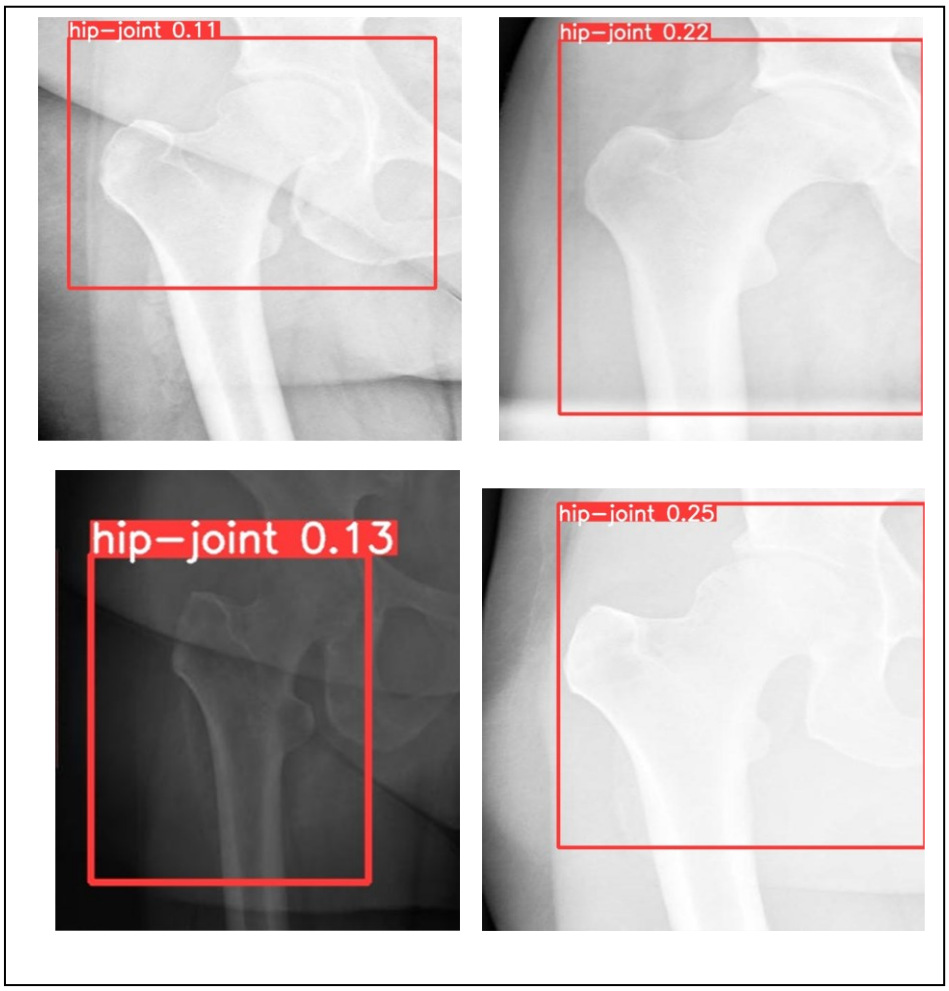
الشكل (4.6): أداء التصنيف باستخدام البيانات السريرية من مجموعات البيانات السورية (D1) والهندية (D2) على مجموعة بيانات واحدة واختبارها على مجموعة أخرى.

5.6 نتائج تصنيف صور الأشعة السينية

1.5.6 نتائج نموذج Yolov5 المدرب على مجموعة البيانات الهندية

تَّم ادخال الصور الهدف (الاختبار) إلى نموذج YOLOv5 من مجموعة البيانات الهندية التي يبلغ عددها 22 صورة، واستطاع النموذج إيجاد مفصل الورك في 22 صورة من أصل 22 صورة ومن ثم بلغت mAP50=0.89 وبلغ زمن إيجاد المنطقة ذات الاهتمام ROI، 221 ميلي ثانية.

يوضح الشكل (5.6) عينة من صور الاختبار باستخدام YOLOv5 نلاحظ أن النموذج استطاع رسم إطارات الإحاطة حول مفصل الورك بدقة جيدة.

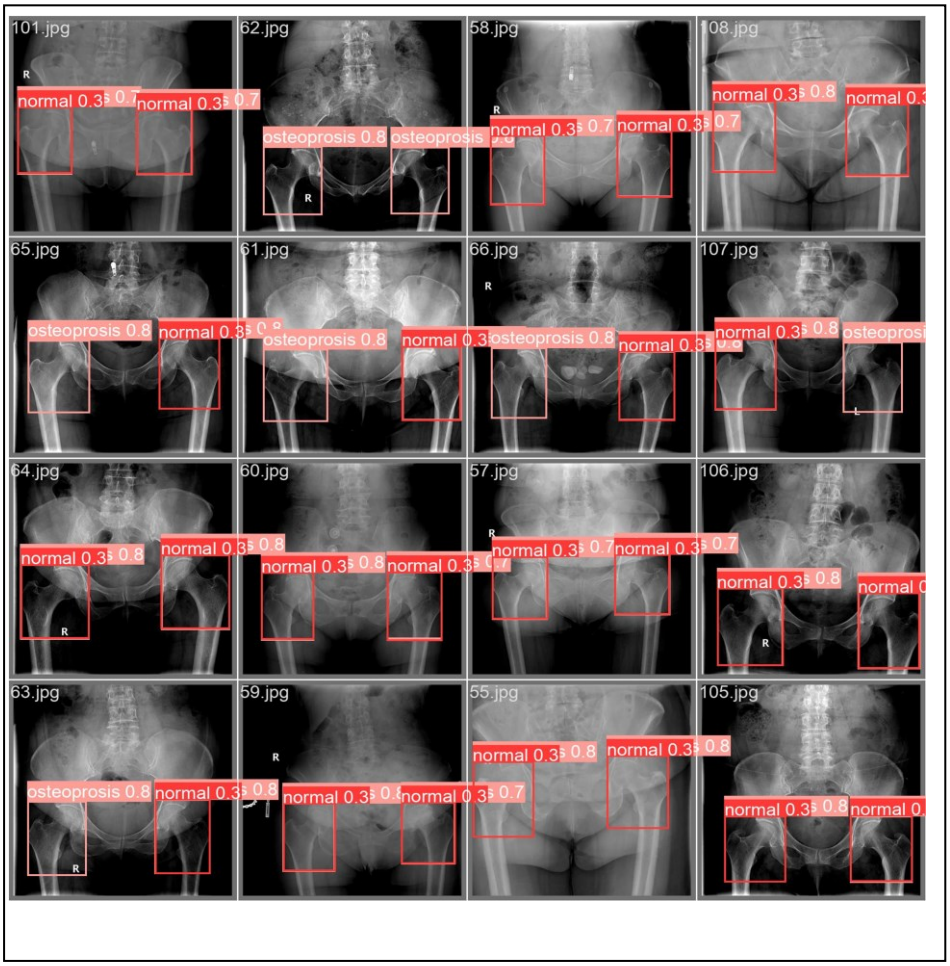


الشكل (5.6) عينة من صور الاختبار باستخدام YOLOv5.

2.5.6 نتائج نموذج Yolov9 المدرب على مجموعة البيانات السورية

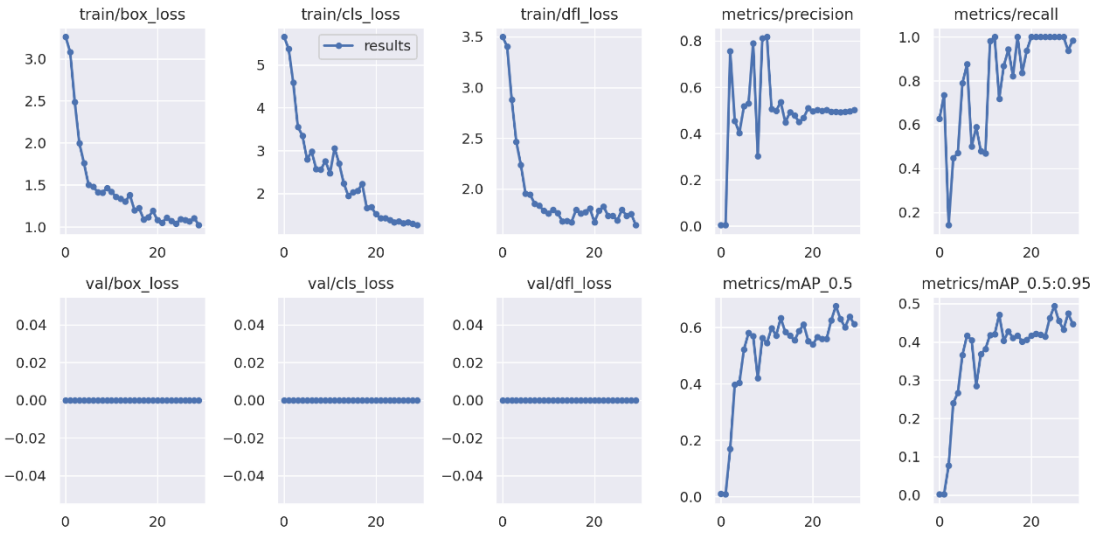
التجربة الأولى (استخدام البيانات بدون إجراء المعالجة الأولية للصور)

في التجربة الأولى أُدخلت الصور الهدف من مجموعة البيانات السورية إلى YOLOv9 التي يبلغ عددها 21صورة دون معالجة أولية. استطاع نموذج YOLOv9 رسم الإطارات حول مفصل الورك الأيمن والأيسر بدقة عالية في21 صورة من أصل 21 صورة ولكن تحديد حالة منطقة الورك بين منخفض الكثافة وطبيعي يحتاج لمعالجة أكثر كما هو واضح في الشكل (6.6) عينة من صور الاختبار باستخدام YOLOv9. ومن ثم بلغت mAP50= 0.676 وبلغ زمن إيجاد المنطقة ذات الاهتمامROI ، 121 ميلي ثانية. كما يظهر الشكل (7.6) أداء نموذج yolov9.



الشكل(6.6) عينة من صور الاختبار باستخدام YOLOv9. يدل الإطار حول مفصل الورك على إطار التنبؤ الذي تنبأ به النموذج. وتدل الأرقام على احتمال أن تكون المنطقة المحددة سليمة أو مصابة بهاشة العظام.

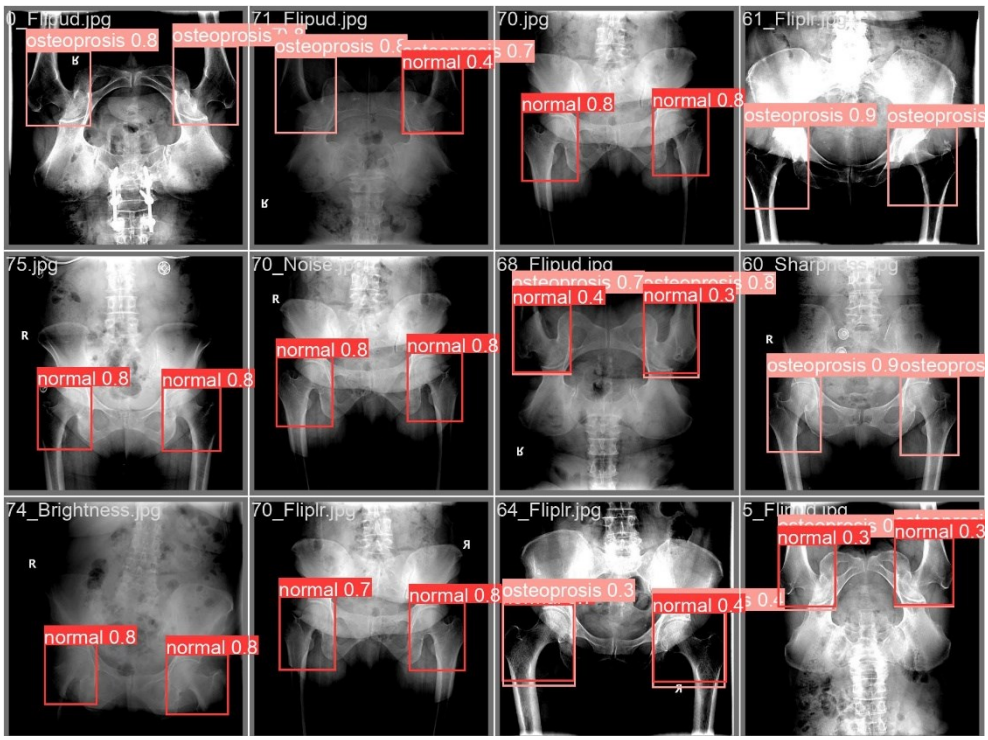
بناء نموذج لتقييم هشاشة العظام لمفصل الورك باستخدام الذكاء الاصطناعي، سويقات.



الشكل(7.6) أداء نموذج Yolov9.

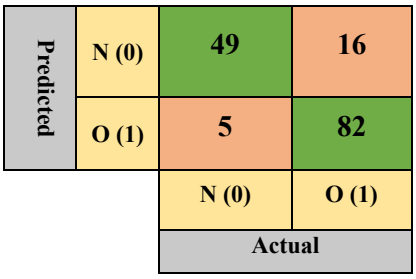
التجربة الثانية (إجراء المعالجة الأولية للصور وتطبيق تقنيات التحسين)

في التجربة الثانية بعد إجراء المعالجة الأولية للصور وبعد تدريب النموذج لعشرين دورة epochs=20، كان زمن التدريب 30 دقيقة. وصل النموذج إلى متوسط الدقة في مجموعة التحقق mAP50=88.3%، بينما بلغت متوسط دقة الاختبار mAP50= 78.6%. يبين الشكل (8.6) عينة من صور الاختبار باستخدام YOLOv9-e.



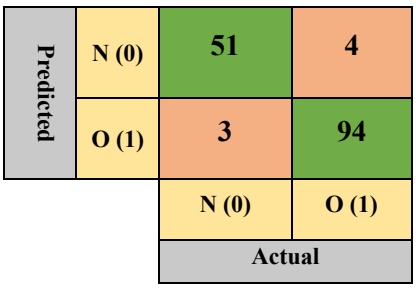
الشكل(8.6) عينة من صور الاختبار باستخدام YOLOv9-e بعد المعالجة الأولية للصور.

يوضح الشكل (9.6) مصفوفة الإرباك، التي تلخص أداء نموذج التصنيف وتوضح مدى نجاح التصنيفات. يحقق النموذج دقة 86.18%، مع حساسية 90.74% وخصوصية 83.67%. ويصنف بشكل صحيح 49 حالة من أصل 54 حالة طبيعية و82 حالة من أصل 98 حالة هشاشة عظام.



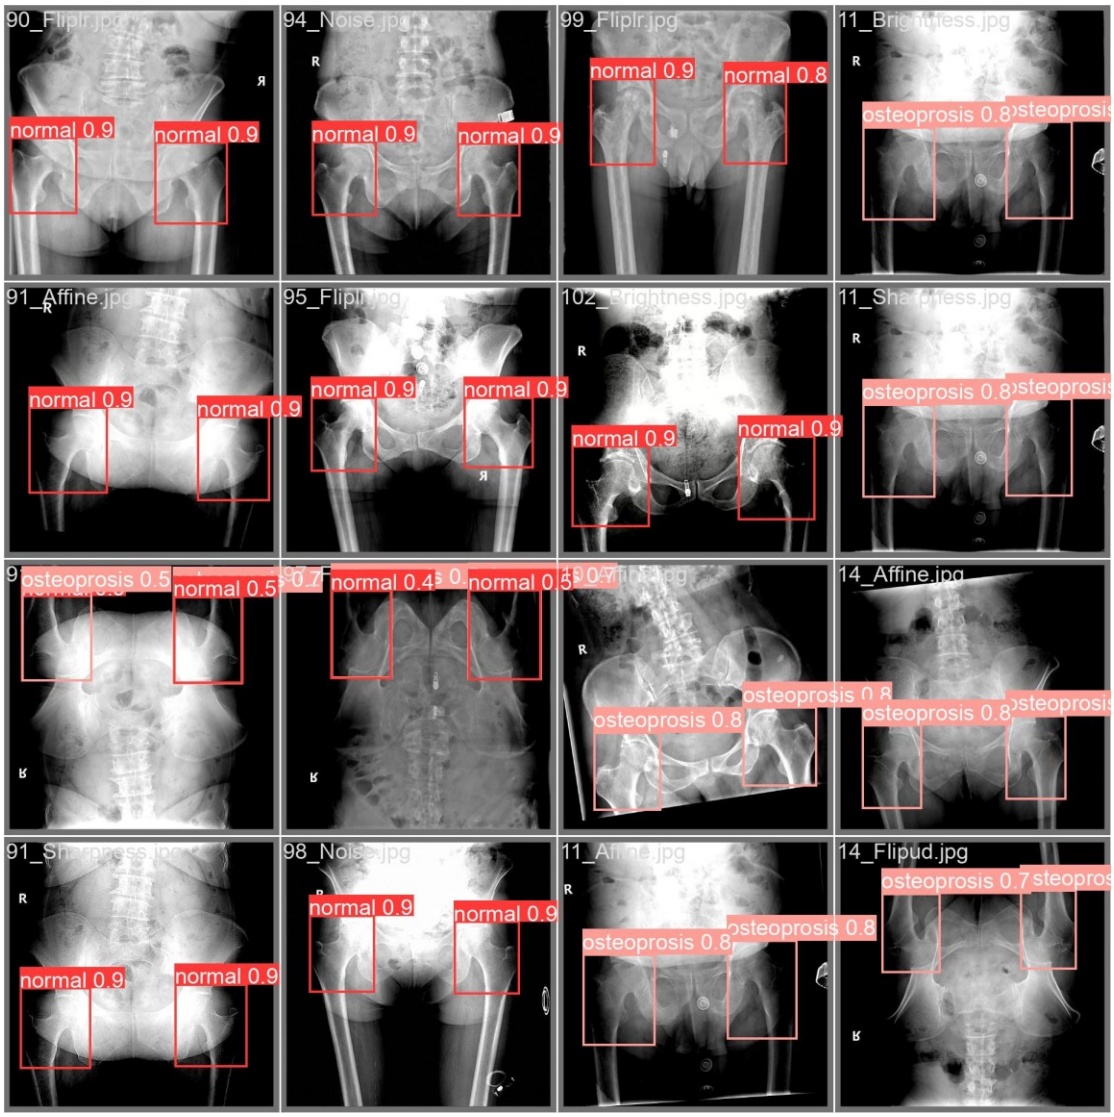
الشكل(9.6) مصفوفة الإرباك لنموذج التصنيف عند التكرار 20.

في محاولة كانت بزيادة عدد التكرارات حتى epochs=35، تم تحسين أداء النموذج بشكل واضح في الشكل (10.6) حيث وصل النموذج إلى متوسط الدقة في مجموعة التحقق mAP50=91.2%، بينما بلغت متوسط دقة الاختبار mAP50= 85.1%. وصلت دقة النموذج إلى 95.39%، مع حساسية 94.44% وخصوصية 95.92%. ويصنف بشكل صحيح 51 حالة من أصل 54 حالة طبيعية و94 حالة من أصل 98 حالة هشاشة عظام. كما يظهر الشكل (11.6) عينة من صور اختبار النموذج.



الشكل(10.6) مصفوفة الإرباك لنموذج التصنيف عند عدد تكرارات epochs=35.

بناء نموذج لتقييم هشاشة العظام لمفصل الورك باستخدام الذكاء الاصطناعي، سويقات.

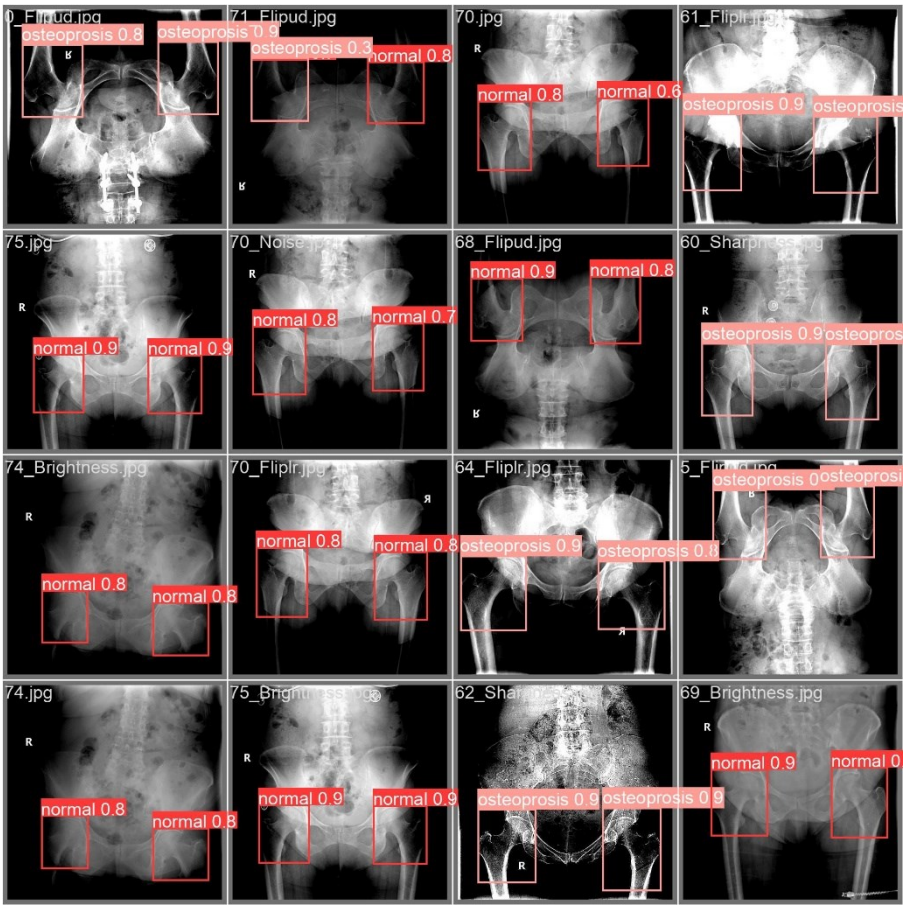


الشكل(11.6) عينة من صور اختبار النموذج عند عدد تكرارات epochs=35.

بعد زيادة عدد التكرارات حتى epochs=35، أُستخدم تنعيم التسميات (label-smoothing) وهي تقنية بسيطة وفعالة تستخدم في تدريب الشبكات العصبونية لتحسين أدائها عن طريق جعل التسميات المستهدفة أقل "تطرفاً" مما يقلل الملاءمة الزّائدة overfitting ويحسن التعلم، يوضح الشكل (12.6) مصفوفة الإرباك للنموذج عند التكرار 35 واستُخدم التنعيم **حيث** وصل النموذج إلى متوسط الدقة في مجموعة التحقق mAP50=93.1%، بينما بلغت متوسط دقة الاختبار mAP50= 83.8%. ووصلت دقة النموذج إلى 86.84%. بالتالي عملية التنعيم أدت إلى انخفاض الأداء في أغلب المقاييس، الشكل (13.6) عينة من صور الاختبار باستخدام YOLOv9-e.

Predicted	N (0)	45	11
	O (1)	9	87
		N (0)	O (1)
		Actual	

الشكل (12.6) مصفوفة الإرباك لنموذج التصنيف عند عدد تكرارات epochs=35، واستخدام التنعيم label_smoothing.



الشكل(13.6) عينة من صور اختبار نموذج التصنيف عند عدد تكرارات epochs=35، واستخدام التنعيم label_smoothing.

3.5.6 مناقشة نتائج الصور

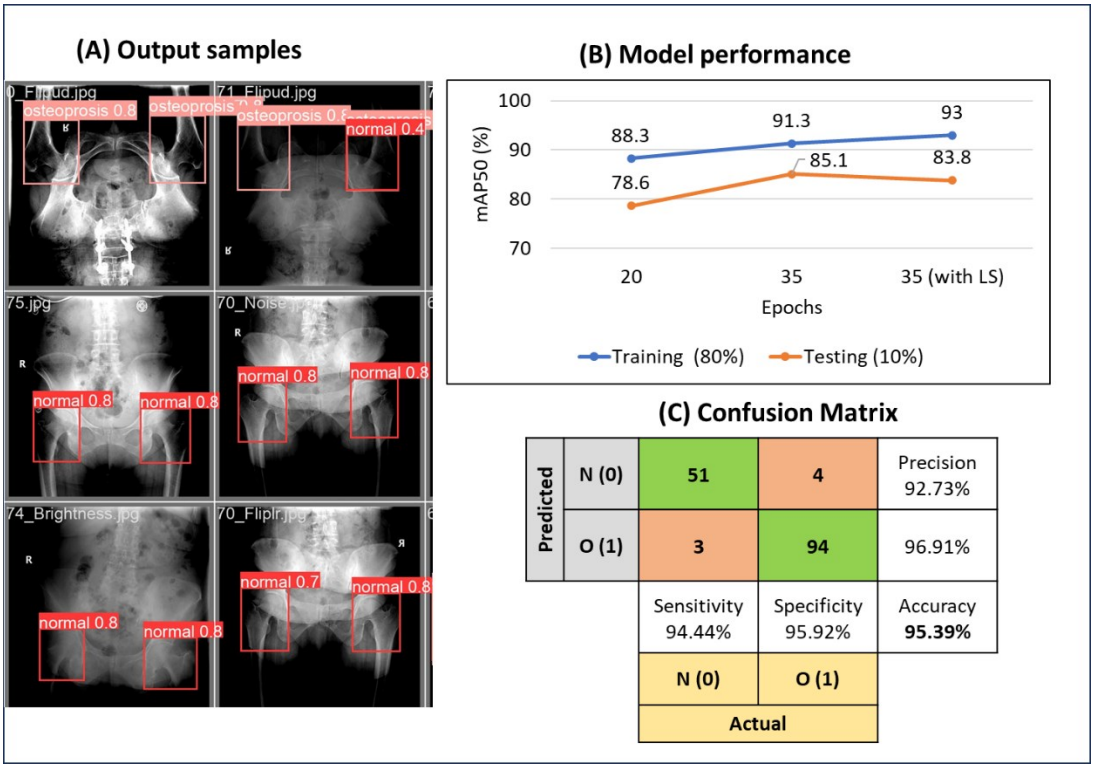
تُعرض نتائج تصنيف بيانات التصوير بالأشعة السينية عالية الدقة للكشف عن هشاشة العظام في الشكل (14.6). أولاً، يوضح الشكل((A) 14.6) عينات اختبار نموذج YOLOv9 المطبق على صور الأشعة السينية عالية الدقة، مما يسلط الضوء على قدرة النموذج على تصنيف المناطق ذات الأهمية بشكل صحيح إلى فئات مثل "هشاشة العظام" أو "طبيعية". تتضمن هذه الأمثلة تقنيات زيادة البيانات مختلفة، مثل التقليب وتعديلات السطوع، مما يشير إلى قوة النموذج عبر اختلافات الإدخال المختلفة.

يصور الشكل ((B) 14.6) أداء التدريب والاختبار لنموذج YOLOv9 عبر تكرارات epochs تدريب مختلفة. عند 20 تكرار، تبلغ دقة التدريب والاختبار 88.3٪ و78.6٪ على التوالي. ومع تقدم التدريب إلى 35 تكرار، يتحسن mAP50 (متوسط الدقة المتوسطة عند التقاطع على اتحاد 0.50) بشكل كبير، حيث يصل إلى 91.3٪ للتدريب و85.1٪ للاختبار.

إن دمج تنعيم العلامات (LS) عند 35 تكرار يعزز تعميم النموذج بشكل أكبر، مع تحسن دقة تدريب mAP50 إلى 93% مع الحفاظ على دقة اختبار مقبولة بنسبة 83.8%.

يُقدم الشكل ((c) 14.6) مصفوفة الإرباك التي تلخص أداء الاختبار لأفضل نموذج. الذي حقق دقة 95.39%، مع حساسية 94.44% وخصوصية 95.92%. ويصنف بشكل صحيح 51 حالة من أصل 54 حالة طبيعية و94 حالة من أصل 98 حالة هشاشة عظام، مما يشير إلى مستوى عالٍ من الإحكام (92.73%) والتذكر (96.91%).

بناء نموذج لتقييم هشاشة العظام لمفصل الورك باستخدام الذكاء الاصطناعي، سويقات.



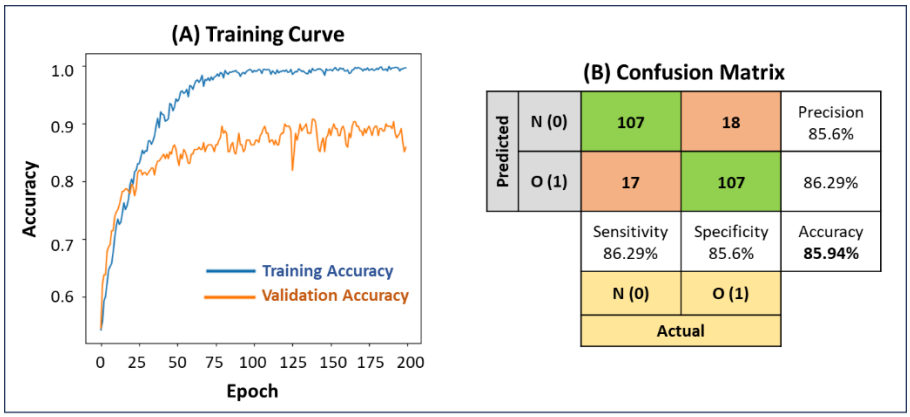
الشكل(14.6) نتائج الكشف عن هشاشة العظام باستخدام YOLOv9 على بيانات التصوير بالأشعة السينية. (A) عينات من اختبار نموذج YOLOv9 تُظهر التصنيف الدقيق للمناطق إلى "هشاشة عظام" و"طبيعية"، بما في ذلك المتانة عبر الصور المعززة مع التقليب وتعديلات السطوع. (B) أداء النموذج عبر تكرارات التدريب، مما يدل على تحسن دقة التدريب والاختبار من 20 تكرار إلى 35 تكرار. دمج تنعيم العلامات (LS) في 35 تكرار. (C) مصفوفة الإرباك التي تلخص نتائج التصنيف لـ YOLOv9.

6.6 نتائج النموذج الهجين

هنا، تم تناول نتائج دمج السجلات السريرية مع صور الأشعة السينية لتصنيف البيانات السورية (D1). يوضح الشكل (15.6(A)) منحنيات دقة التدريب والتحقق على مدى 200 تكرار. تتحسن دقة التدريب بشكل متزايد، وتقترب من 100%، بينما تستقر دقة التحقق حول 86% بعد 100 تكرار. يشير هذا إلى أن النموذج يتعلم بشكل فعال من مجموعة البيانات الهجينة ولكنه قد يتناسب بشكل مفرط مع بيانات التدريب، حيث تزداد الفجوة بين دقة التدريب والتحقق بعد التقارب.

بينما إنّ مصفوفة دقة النموذج موضحة في الشكل(15.6(B)). تعرض أداء اختبار النموذج على مجموعة بيانات الاختبار حيث يحقق النموذج دقة إجمالية تبلغ 85.94%، ويصنف بشكل صحيح 107 حالات في كل من فئتي "طبيعية" (N) و"هشاشة العظام" (O). ومع ذلك، هناك 18 نتيجة إيجابية كاذبة (حالات طبيعية تم

تصنيفها بشكل خاطئ على أنها هشاشة عظام) و17 نتيجة سلبية كاذبة (حالات هشاشة العظام تم تصنيفها بشكل خاطئ على أنها طبيعية). تبلغ الحساسية (التذكر) 86.29%، مما يشير إلى قدرة النموذج على تحديد حالات هشاشة العظام بشكل صحيح، في حين تبلغ الخصوصية 85.6%، مما يعكس قدرته على التمييز بين الحالات الطبيعية. تبلغ الدقة لكلا الفئتين 85.6% للحالات الطبيعية و86.29% لهشاشة العظام، مما يسلط الضوء على الأداء المتوازن في كلتا الفئتين.



الشكل(15.6) نتائج دمج السجلات السريرية مع صور الأشعة السينية لتصنيف البيانات السورية (D1).(A) منحنى دقة التحقق(اللون البرتقالي)، ومنحني دقة التدريب(اللون الأزرق).(B) مصفوفة الإرباك لأداء اختبار النموذج.

7.6 المناقشة والمقارنة مع الدراسات السابقة

تسلط المقارنة الضوء على أداء العمل المقترح في سياق الدراسات الحالية من الجدول (7.6) حقق Yamamoto وآخرون [19] دقة بنسبة 88.50٪ من خلال الجمع بين صور الأشعة السينية للورك البسيطة والخصائص السريرية باستخدام مصنفات متقدمة مثل EfficientNet b3، مما يدل على قيمة دمج الخصائص المتعددة. وبالمثل، ركز Yang وآخرون [6] على البيانات السريرية وحدها، محققين قيم AUROC تتراوح من 82.1٪ إلى 84.3٪ لنماذج الرجال و76.7٪ إلى 81.1٪ لنماذج النساء. على الرغم من فعالية هذا النهج، إلا أنه يفتقر إلى مكون التصوير الذي يمكن أن يعزز دقة التشخيص بشكل أكبر. Jang وآخرون. [14] حقق دقة

81.2٪ مع VGG16 على صور الأشعة السينية للورك البسيطة، مما يؤكد على إمكانيات ميزات التصوير للتصنيف. تم تنفيذ العمل المقترح بشكل مماثل لبعض النماذج القائمة على التصوير، مثل دقة YOLOv9 بنسبة 95.39٪ لتصنيف الأشعة السينية، وهو ما يشبه Twinprai et al. [16]، الذي حقق 95٪ باستخدام نماذج تعتمد على YOLO. ومع ذلك، حقق النموذج الهجين الذي يجمع بين المؤشرات الحيوية السريرية والخصائص العميقة المستخرجة عبر ResNet50 دقة 85.94%، وهو ما لا يتجاوز الأساليب الهجينة الأخرى، مثل Kim et al. [18]، الذي أبلغ عن AUROC بنسبة 95٪ من خلال دمج الخصائص العميقة والنسيجية والسريرية. وبالمثل، Yamamoto et al[20] حقق AUROC بنسبة 87.1٪ من خلال الجمع بين الأشعة السينية والبيانات السريرية، متفوقاً قليلاً على المكون الهجين لهذه الدراسة. قد تفسر عدة عوامل هذه الاختلافات في الأداء، حيثُ استخدمت دراسات مثل Kim et al. [18] وYamamoto et al. [20] مجموعات بيانات أكبر، مما ساهم على الأرجح في قوة نماذجهم. بالإضافة إلى ذلك، ركز العمل [29] على مجموعات ديموغرافية محددة، مثل جنس واحد أو نطاق عمري ضيق، مما أدى إلى تحسين أداء النموذج لفئة سكانية معينة.

على النقيض من ذلك، في المرحلة الثانية تدمج هذه الدراسة مجموعات البيانات السورية والهندية السريرية، مما قد يؤثر على قابلية التعميم ولكنه يعزز قابلية تطبيق النموذج عبر مجموعات سكانية متنوعة. في حين أن هذا يقدم تحديات إضافية في التعميم عبر مجموعات البيانات، فإنه يسلط الضوء أيضاً على أهمية تطوير نماذج يمكنها الأداء الجيد عبر سياقات ديموغرافية وإكلينيكية مختلفة. Wu وآخرون. [12] أظهر أيضاً قيم AUROC أعلى (87.2٪) مع البيانات السريرية باستخدام نماذج التعلم الآلي المتقدمة.

يتميز هذا البحث بمحاولته ربط البيانات السريرية والتصويرية من مجموعات سكانية مختلفة، كما يتضح من دمجه لمجموعات البيانات السورية والهندية، وتحقيق دقة 90.58٪ للبيانات السريرية المجمعة والتأكيد على تحديات التعميم عبر مجموعات البيانات. بالمقارنة مع نماذج مثل AlexNet و VGG16 في Wani و Arora [60] و Feng et al. [15]، يظل النهج الهجين تنافسياً في تطبيقه المحدد ولكنه يسلط الضوء على إمكانية التحسين في التعامل مع أنماط البيانات المتنوعة وتحقيق دقة تشخيصية أعلى.

الجدول (7.6): مقارنة الدراسات المرجعية مع الدراسة الحالية.

رقم الدراسة	اسم الباحث والعام والبلد	الهدف	المصنف	الدقة %	الخصائص المستخدمة	العينة	الجنس والعمر
الدراسة الأولى	Yang 2021 Taiwan	تطوير نماذج تشخيصية للتنبؤ بهشاشة العظام ومقارنة أداء هذه النماذج مع (OSTA)	Five ML algorithms و (ANN) و (SVM) و (RF) و (KNN) و (LoR)	حصلت النماذج على (AUROC) من 82.1% - 84.3% في الرجال. و76.7%- 81.1% في النساء. و73% - 76%. في OSTA	16 ميزة إدخال للرجال و19 ميزة إدخال للنساء (نماذج منفصلة)	5982 مشاركاً كان 3053 (51.0٪) من الرجال و2929 (49.0٪) من النساء.	نساء ورجال بعمر 50 وأكبر
الدراسة الثانية	Inui 2023 Japan	بناء نماذج تشخيصية للتنبؤ بهشاشة العظام من بيانات اختبار الدم	Five ML algorithms (DT) (LoR) (GB) (RF) lightGBM	أظهر lightGBM أعلى الدرجات AUC تبلغ 83%	24 ميزة إدخال للنساء.	2541 امرأة	نساء فقط بمتوسط عمر (73.5 ± 9.2 سنة). أكبر من 64
الدراسة الثالثة	Wu 2023 China	تطوير نماذج للتنبؤ بهشاشة العظام لدى المرضى المصابين بداء	XGBoost, LR, LightGBM, RF, AdaBoost, GNB,	تم اختيار نموذج XGBoost كنموذج تنبؤ نهائي مع AUROC يبلغ	31 ميزة إدخال	433 مشاركاً	نساء ورجال

			87.2% ودقة 80%.	MLP, SVM, KNN,	السكري من النوع الثاني.		
الدراسة الرابعة	Jang 2021 Korea	تشخيص هشاشة العظام من التصوير الشعاعي البسيط للورك.	الدقة 81.2% AUC 86.7%	VGG16	صور أشعة بسيطة للورك	1012	نساء فقط بعمر 55 سنة
الدراسة الخامسة	Feng 2024 Taiwan	تفسير صور الأشعة السينية البسيطة باستخدام الذكاء الاصطناعي	U-Net ++U-Net ResNet50 VGG16 DenseNet121	++U-Net لتجزئة الصور VGG16 للتصنيف بدقة 74%	صورة أشعة بسيطة للورك	134	نساء في سن اليأس ورجال مسنين
الدراسة السادسة	Twinprai 2022 Thailand	تقييم دقة تشخيص وحساسية نموذج الذكاء الاصطناعي للكشف عن كسور الورك.	YOLO	YOLOv4-tiny الدقة 95% الحساسية 96.2% خصوصية 94.6%	صور أشعة بسيطة للورك والحوض	1000	نساء ورجال بعمر 18 سنة وأكبر
الدراسة السابعة	Kim 2022 Korea	المقارنة بين نماذج مختلفة لتشخيص هشاشة العظام	MLP: multilayer perceptron	95% AUC	10 سمات عميقة. 16 سمة نسيجية. 3 سمات سريرية.	4924	نساء ورجال بمتوسط عمر 62 عاماً
الدراسة الثامنة	Yamamoto 2020 Japan	أهمية إضافة المتغيرات السريرية إلى نماذج التشخيص باستخدام صور	ResNet18، ResNet34، GoogleNet EfficientNet b3	EfficientNet b3 بدقة 88.5%	صور أشعة بسيطة للورك و4 سمات سريرية.	1131	نساء ورجال بعمر 60 عاماً وأكبر

				EfficientNet .b4	الأشعة السينية.		
الدراسة التاسعة	Yamamoto 2021 Japan	قياس مدى تأثير إضافة المتغيرات السريرية في تصنيف هشاشة العظام	ResNet18) و34 و50 و101 و152).	ResNet34 حجم التأثير AUC %87.1	صور أشعة بسيطة للورك و3 سمات سريرية.	1699	نساء ورجال بعمر 60 عاماً وأكبر
الدراسة الحالية	2025 سوريا	بناء نموذج لتقييم هشاشة العظام	YOLOv9 SVM, RF (ResNet50).	حقق (YOLOv9) دقة 95.39% % 90.58 (combined clinical data) 85.94% (hybrid).	صور أشعة بسيطة للورك و9 سمات سريرية	439 عينة سريرية و111 صورة	نساء ورجال بمتوسط عمر 51



الفصل السابع

الاستنتاجات والآفاق المستقبلية



1.7 الاستنتاجات

يُقدم هذه البحث إطاراً شاملاً لتشخيص هشاشة العظام يجمع بين المؤشرات الحيوية السريرية والميزات العميقة المستخرجة من صور الأشعة السينية. وتوضح النتائج الرئيسية أن:

- ❖ حقق YOLOv9 دقة عالية بنسبة 95.39٪ لتصنيف صور الأشعة السينية، حيثُ تمَّكن من الكشف عن المنطقة ذات الاهتمام والتصنيف في مرحلة واحدة، تكمن أهمية استخدام هذا النموذج بأنه من خلال صورة أشعة سينية بسيطة واحدة يمكن أن نساعد في الكشف عن هشاشة العظام، كما يمكن أن يكون الإدخال إلى النموذج عبارة عن صورة تحتوي مفصل واحد أو صورة كاملة للحوض.
- ❖ حققت خوارزميات SVM دقة وصلت إلى 87.34% لتصنيف البيانات السريرية، وهي دقة جيدة مقارنة مع العديد من الدراسات التي تناولت فكرة تصنيف هشاشة العظام من خلال بيانات سريرية مختلفة.
- ❖ بينما النموذج الهجين، الذي يدمج السمات المستخرجة من ResNet50 مع البيانات السريرية والمصنفة باستخدام Perceptron متعدد الطبقات (MLP)، حقق دقة بنسبة 85.94٪. ومع ذلك، لم يتفوق النموذج الهجين على النماذج المتكاملة المتقدمة الأخرى، مثل Yamamoto وآخرون [20]، الذين حققوا دقة بنسبة 88.5٪ من خلال الجمع بين السمات العميقة والسريرية.
- ❖ وعلى الرغم من ذلك، فإن النهج الهجين في هذه الدراسة يوضح بفعالية أهمية الجمع بين العوامل البنيوية (التصوير) والجهازية (السريرية) في تشخيص هشاشة العظام.
- ❖ كما قيمت الدراسة قابلية تعميم النماذج عبر السكان من خلال الجمع بين البيانات السريرية من مجتمعات مختلفة. حيثُ أظهرت النماذج المدربة على مجموعة بيانات واحدة واختبارها على مجموعة أخرى انخفاضاً كبيراً في الأداء، مع انخفاض الدقة بنسبة 10–15٪، مما يعكس تحدي نقل النماذج بين مجموعات سكانية متنوعة.
- ❖ أدى الجمع بين مجموعات البيانات السورية والهندية في نموذج موحد إلى تحسين الأداء، وتحقيق دقة بنسبة 90.58 ٪ والتأكيد على الحاجة إلى معالجة الاختلافات الخاصة بالسكان في البيانات السريرية.

- ❖ كما أكَّد هذا الجانب من الدراسة على أهمية القدرة على التعميم في نماذج التعلم الآلي للرعاية الصحية، حيث يمكن أن تنحاز خوارزميات الذكاء الصنعي حسب المجموعة السكانية بالتالي يؤثر بشكل كبير على الأداء في التطبيقات في العالم الحقيقي.
- ❖ تُسلط هذه النتائج الضوء على فعالية دمج البيانات المتعددة وتؤكد على إمكانية معالجة التحيزات الخاصة بالسكان لتحسين الأداء التشخيصي من خلال زيادة عدد البيانات والاختبار على عدة مناطق في العالم للحصول على نموذج معمم.

2.7 الآفاق المستقبلية

بما أن هذه الدراسة تستخدم خصائص مختلفة لتشخيص هشاشة العظام، وتحاول الجمع بين البيانات السريرية من مجموعات البيانات السورية والهندية، سلطت الدراسة الضوء على تحديات التعميم عبر مجموعات البيانات، مؤكدة على أهمية معالجة الاختلافات الخاصة بالسكان في البيانات السريرية. وبالمقارنة بالأدبيات الحالية، أظهر الإطار أداءً تنافسيا في تصنيف التصوير وقدم رؤى قيمة في دمج البيانات المتعددة وتقييم النماذج عبر مجتمعات متنوعة. ومع ذلك، كشفت الدراسة أيضاً عن قيود:

- زيادة حجم قاعدة البيانات التي تعتبر صغيرة جداً مقارنة بالدراسات المرجعية.
- استخدام أحد تقنيات الـ Ensembles لدمج عدة نماذج أو خوارزميات للحصول على توقعات أفضل وأكثر دقة.
- ينبغي أن يركز العمل المستقبلي على تعزيز قابلية تعميم النموذج من خلال تقنيات نقل التعلم، والتحقق من صحته على مجموعات بيانات أكبر وأكثر تنوعاً، واستكشاف وسائط بيانات إضافية.
- استخدمنا MLP في النموذج الهجين لأنه بسيط وسريع التنفيذ، ويعتبر نقطة بداية جيدة لدمج نوعين مختلفين من البيانات، العمل في المستقبل على نماذج أكثر تطوراً.
- يمهد هذا الإطار الطريق لتطوير أنظمة ذكاء اصطناعي قوية ومتعددة الخصائص يمكنها تحسين نتائج التشخيص ومعالجة تحديات تطبيقات الرعاية الصحية المتنوعة.

المراجع

[1]. Pouresmaeili, F., Kamalidehghan, B., Kamarehei, M., & Goh, Y. M. (2018). A comprehensive overview on osteoporosis and its risk factors. *Therapeutics and clinical risk management*, 2029-2049.

[2]. Koh, L. K., Sedrine, W. B., Torralba, T. P., Kung, A., Fujiwara, S., Chan, S. P., Huang, Q. R., Rajatanavin, R., Tsai, K. S., Park, H. M., Reginster, J. Y., & Osteoporosis Self-Assessment Tool for Asians (OSTA) Research Group (2001). A simple tool to identify asian women at increased risk of osteoporosis. *Osteoporosis Int*, *12*(8), 699–705. https://doi.org/10.1007/s001980170070

[3]. van Oostwaard, M. (2018). Osteoporosis and the nature of fragility fracture: an overview. *Fragility fracture nursing: holistic care and management of the orthogeriatric patient*, 1-13.

[4]. Sözen, T., Özışık, L., & Başaran, N. Ç. (2016). An overview and management of osteoporosis. *European journal of rheumatology*, *4*(1), 46.

[5]. Kanis, J. A., Johnell, O., Oden, A., Johansson, H., & McCloskey, E. (2008). FRAX and the assessment of fracture probability in men and women from the UK. *Osteoporosis Int*, *19*(4), 385–397. https://doi.org/10.1007/s00198-007-0543-5

[6]. Ou Yang.-Y.; Lai, C.-C.; Tsou, M.-T.; Hwang, L.-C. Development of Machine Learning Models for Prediction of Osteoporosis from Clinical Health Examination Data. Int. J. Environ. Res. Public Health **2021**, 18, 7635.

[7]. Inui, A.; Nishimoto, H.; Mifune, Y.; Yoshikawa, T.; Shinohara, I.; Furukawa, T.; Kato, T.; Tanaka, S.; Kusunose, M.; Kuroda, R. Screening for Osteoporosis from Blood Test Data in Elderly Women Using a Machine Learning Approach. Bioengineering 2023, 10, 277.

[8]. Zhang, Y. Y., Xie, N., Sun, X. D., Nice, E. C., Liou, Y. C., Huang, C., ... & Shen, Z. (2024). Insights and implications of sexual dimorphism in osteoporosis. *Bone research*, *12*(1), 8.

[9]. Kanis, J. A., McCloskey, E. V., Johansson, H., Oden, A., Melton III, L. J., & Khaltaev, N. (2008). A reference standard for the description of osteoporosis. *Bone*, *42*(3), 467-475.

[10]. https://viso.ai/computer-vision/intersection-over-union-iou/ (accessed on 20 September 2024).

[11]. Ng, A., & Ma, T. (2023). *CS229: Machine Learning – Lecture Notes*. Stanford University. Retrieved from https://cs229.stanford.edu/main_notes.pdf

[12]. Wu, X., Zhai, F., Chang, A., Wei, J., Guo, Y., & Zhang, J. (2023). Development of Machine Learning Models for Predicting Osteoporosis in Patients with Type 2 Diabetes Mellitus-A Preliminary Study. *Diabetes, metabolic syndrome and obesity : targets and therapy*, *16*, 1987–2003.

[13]. Morgan, S. L., & Prater, G. L. (2017). Quality in dual-energy X-ray absorptiometry scans. *Bone*, *104*, 13-28.

[14]. Jang R, Ho Choi J, Kim N, Suk Chang J, Yoon5 P, Kim C. (2021). Prediction of osteoporosis from simple hip radiography using deep learning algorithm. Scientific Reports. 11. 19997.

[15]. Feng, S.-W.; Lin, S.-Y.; Chiang, Y.-H.; Lu, M.-H.; Chao, Y.-H. 2024. Deep Learning-Based Hip X-ray Image Analysis for Predicting Osteoporosis. *Applied Sciences* 14, no. 1: 133.

[16]. Twinprai, N., Boonrod, A., Boonrod, A., Chindaprasirt, J., Sirithanaphol, W., Chindaprasirt, P., & Twinprai, P. (2022). Artificial intelligence (AI) vs. human in hip fracture detection. *Heliyon*, *8*(11), e11266.

[17]. Messina, C., Albano, D., Gitto, S., Tofanelli, L., Bazzocchi, A., Ulivieri, F. M., ... & Sconfienza, L. M. (2020). Body composition with dual energy X-ray absorptiometry: from basics to new tools. *Quantitative imaging in medicine and surgery*, *10*(8), 1457.

[18]. Kim, S., Kim, B. R., Chae, H. D., Lee, J., Ye, S. J., Kim, D. H., Hong, S. H., Choi, J. Y., & Yoo, H. J. (2022). Deep Radiomics-based Approach to the Diagnosis of Osteoporosis Using Hip Radiographs. *Radiology. Artificial intelligence*, *4*(4), e210212.

[19]. Yamamoto, N., Sukegawa, S., Kitamura, A., Goto, R., Noda, T., Nakano, K., Takabatake, K., Kawai, H., Nagatsuka, H., Kawasaki, K., Furuki, Y., & Ozaki, T. (2020). Deep Learning for Osteoporosis Classification Using Hip Radiographs and Patient Clinical Covariates. *Biomolecules*, *10*(11), 1534.

[20]. Yamamoto, N., Sukegawa, S., Yamashita, K., Manabe, M., Nakano, K., Takabatake, K., Kawai, H., Ozaki, T., Kawasaki, K., Nagatsuka, H., Furuki, Y., & Yorifuji, T. (2021). Effect of Patient Clinical Variables in Osteoporosis Classification Using Hip X-rays in Deep Learning Analysis. *Medicina (Kaunas, Lithuania)*, *57*(8), 846.
[21]. Gatineau, G., Shevroja, E., Vendrami, C., Gonzalez-Rodriguez, E., Leslie, W. D., Lamy, O., & Hans, D. (2024). Development and reporting of artificial intelligence in osteoporosis management. *Journal of Bone and Mineral Research*, *39*(11), 1553-1573.
[22]. Si, Y., Wang, C., Guo, Y., Yin, H., & Ma, Y. (2020). Prevalence of osteoporosis in patients with type 2 diabetes mellitus in the Chinese mainland: A protocol of systematic review and meta-analysis. *Medicine*, *99*(16), e19762.
[23]. Qiu, C., Su, K., Luo, Z., Tian, Q., Zhao, L., Wu, L., ... & Shen, H. (2024). Developing and comparing deep learning and machine learning algorithms for osteoporosis risk prediction. *Frontiers in Artificial Intelligence*, *7*, 1355287.
[24]. He, Y., Lin, J., Zhu, S., Zhu, J., & Xu, Z. (2024). Deep learning in the radiologic diagnosis of osteoporosis: a literature review. *Journal of International Medical Research*, *52*(4), 03000605241244754.
[25]. Kawade, V., Naikwade, V., Bora, V., & Chhabria, S. (2023, July). A Comparative Analysis of Deep Learning Models and Conventional Approaches for Osteoporosis Detection in Hip X-Ray Images. In *2023 World Conference on Communication & Computing (WCONF)* (pp. 1-7).
[26]. Sasser PhD J. R. (2016). Aging bones: A short history of osteoporosis, by Gerald N. Grob. *Journal of women & aging*, *28*(5), 465–466.
[27]. Compston, J. E., McClung, M. R., & Leslie, W. D. (2019). Osteoporosis. *Lancet (London, England)*, *393*(10169), 364–376.
[28]. Martini, F. H., Timmons, M. J., & Tallitsch, R. B. (2015). Human Anatomy, Eighth Edition. Toronto, ON: Pearson Education Inc.
[29]. Consensus development conference: diagnosis, prophylaxis, and treatment of osteoporosis. (1993). *The American journal of medicine*, *94*(6), 646–650.
[30]. Wáng, Y. X. J., & Xiao, B. H. (2022). Estimations of bone mineral density defined osteoporosis prevalence and cutpoint T-score for defining osteoporosis among older Chinese population: a framework based on relative fragility fracture risks. *Quantitative Imaging in Medicine and Surgery*, *12*(9), 4346.
[31]. Chavda, S., Chavda, B., & Dube, R. (2022). Osteoporosis screening and fracture risk assessment tool: its scope and role in general clinical practice. *Cureus*, *14*(7).
[32]. Rozenberg, S., Bruyère, O., Bergmann, P., Cavalier, E., Gielen, E., Goemaere, S., Kaufman, J. M., Lapauw, B., Laurent, M. R., De Schepper, J., & Body, J. J. (2020). How to manage osteoporosis before the age of 50. *Maturitas*, *138*, 14–25.
[33]. Xie, Q., Chen, Y., Hu, Y., Zeng, F., Wang, P., Xu, L., Wu, J., Li, J., Zhu, J., Xiang, M., & Zeng, F. (2022). Development and validation of a machine learning-derived radiomics model for diagnosis of osteoporosis and osteopenia using quantitative computed tomography. *BMC medical imaging*, *22*(1), 140.
[34]. Rajan, R., Paul, J., Kapoor, N., Cherian, K.E. and Paul, T.V. (2020) Postmenopausal Osteoporosis—An Indian Perspective. *Current Medical Issues*, *18*, 98-104.
[35]. Tian, Y., Shu, M., Jia, Q. (2021). Artificial Neural Network. In: Daya Sagar, B., Cheng, Q., McKinley, J., Agterberg, F. (eds) Encyclopedia of Mathematical Geosciences. Encyclopedia of Earth Sciences Series. Springer, Cham.
[36]. Kühl, N., Schemmer, M., Goutier, M. *et al.* (2022). Artificial intelligence and machine learning. *Electron Markets* **32**, 2235–2244.
[37]. Sahil. (2020, December 1). *A tour of evaluation metrics for machine learning*. Analytics Vidhya. https://www.analyticsvidhya.com/blog/2020/11/a-tour-of-evaluation-metrics-for-machine-learning/(Accessed 13 Aug. 2024)
[38]. Kabir, H. (2021). Convolutional Neural Network. International Islamic University Chittagong.
[39]. Bezdan, T, & Džakula, N. B. (2019). Convolutional neural network layers and architectures.

[40].https://medium.com/@nitishkundu1993/exploring-resnet50-an-in-depth-look-at-the-model-architecture-and-code-implementation-d8d8fa67e46f. (accessed on 10 September 2024).

[41]. AYENI, J. A. (2022). Convolutional Neural Network (CNN): The architecture and applications. *Applied Journal of Physical Science,* Volume 4(4), pages 42-50.
[42]. Gogul, I. and Kumar, V. S. (2017). Flower species recognition system using convolution neural networks and transfer learning, Fourth International Conference on Signal Processing, Communication and Networking (ICSCN), Chennai, India.
[43]. He, K. Zhang, X. Ren, Sh. Sun, J. (2015). Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR),PP.770-778.
[44]. Koonce, B. (2021). ResNet 50. In: Convolutional Neural Networks with Swift for Tensorflow. Apress, Berkeley, CA.
[45]. Chen, Y. –W. and Jain, L. C. (2020). Deep Learning in Healthcare Paradigms and Applications. P: 225. Cham: Switzerland. *Springer Nature.*
[46]. Shah, S., Tembhurne, J. (2023). Object detection using convolutional neural networks and transformer-based models: a review. *Journal of Electrical Systems and Inf Technol* **10**, 54.
[47]. Redmon, J. Divvala, S. Girshick, R. Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection, *In: Proceedings of the IEEE conference on computer vision and pattern recognition, pp 779–788.* Las Vegas, Nevada: USA.
[48]. Jiang, P. Ergu, D. Liu, F. Cai, Y. Ma, B. (2022). A Review of Yolo Algorithm Developments, *Procedia Computer Science,*Volume 199, PP 1066-1073, ISSN 1877-0509.
[49]. Shah, D., (2023). Intersection over Union (IoU): Definition, Calculation, Code**.** Available: *https://www.superannotate.com/blog/intersection-over-union-for-object-detection*.
[50]. Gaye B., Zhang D., Wulamu A., (2021). Improvement of Support Vector Machine Algorithm in Big Data Background. *Mathematical Problems in Engineering*. Vol. 2021.
[51]. Singh H., (2019). Understanding Random Forests. Available: https://medium.com/@harshdeepsingh_35448/understanding-random-forests-aa0ccecdbbbb
[52]. Shekar, B. H. and Dagnew, G. (2019). Grid Search-Based Hyperparameter Tuning and Classification of Microarray Cancer Data, *Second International Conference on Advanced Computational and Communication Paradigms (ICACCP)*, pp. 1-8, Gangtok, India.
[53]. Malato, G.,(2021). Hyperparameter tuning. Grid search and random search. *Online courses and lessons about data science, machine learning and artificial intelligence*. Available: https://www.yourdatateacher.com/2021/05/19/hyperparameter-tuning-grid-search-and-random-search/
[54]. Sapkota, R., et al. (2024). Yolov10 To Its Genesis: A Decadal And Comprehensive Review Of The You Only Look Once Series.DOI: 10.36227/techrxiv.171995313.38075245/v1
[55]. Imran, A., et al. (2024). Real Time American Sign Language Detection Using Yolo-v9.
[56]. An J., (2020). How to Remember all these Classification Concepts forever. Available: https://medium.com/swlh/how-to-remember-all-these-classification-concepts-forever-761c065be33
[57]. Anusha, P. V. et al. (2019). Detecting outliers in high dimensional data sets using Z-score methodology. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*. 9(1), 48–53.
[58]. Brownlee, J. (2020). How to Use StandardScaler and MinMaxScaler Transforms in Python. Available: https://www.machinelearningmastery.com/standardscaler-and-minmaxscaler-transforms-in-python/
[59]. Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, *16*, 321-357.
[60]. Wani, I. M., & Arora, S. (2023). Osteoporosis diagnosis in knee X-rays by transfer learning based on convolution neural network. *Multimedia Tools and Applications*, *82*(9), 14193-14217.
[61]. Gut, Daniel (2021), "X-ray images of the hip joints Mendeley Data, V1, doi:10.17632/zm6bxzhmfz.1"

[62]. Majeed Wani, Insha ; Arora, Sakshi (2021), “Knee X-ray Osteoporosis Database”, Mendeley Data, V2, doi: 10.17632/fxjm8fb6mw.2
[62]. Office of the Surgeon General (US). (2004). *Bone Health and Osteoporosis: A Report of the Surgeon General*.
[63]. Looker, A. C., et al. (2018). "Prevalence of Low Bone Mineral Density in Adults in the United States." *JAMA*.
[64]. Faulkner, K.G. The tale of the T-score: Review and perspective. *Osteoporos. Int.* **2004**, *16*, 347–352.
[65]. Cosman, F.; De Beur, S.J.; LeBoff, M.S.; Lewiecki, E.M.; Tanner, B.; Randall, S.; Lindsay, R. **(**2014**).** Clinician’s Guide to Prevention and Treatment of Osteoporosis. *Osteoporos. Int*, *25*, 2359
[66]. Vazan, M. (2021). Deep learning: principles, concepts and approaches.
[67].Vazan, M. (2022). Deep Learning: From Basics to Building Deep Neural Networks with Python. 10.48550/arXiv.2205.01069.
[68]. P. Lips, “Epidemiology and predictors of fractures associated with osteoporosis,” *American Journal of Medicine*, 1997.
[69]. Nguyen, K. (2015). Introduction to machine learning. *Dec*, *16*, 1-59.
[70] Burkov, A. (2019). *The hundred-page machine learning book* (Vol. 1, p. 32). Quebec City, QC,
[71]. Varma, Subir & Das, Sanjiv. (2018). Introduction to Deep Learning.

Abstract

Osteoporosis is a progressive condition characterized by reduced bone density, increasing the risk of fractures and associated health complications. Accurate diagnosis, especially across diverse populations, remains a critical challenge. This study proposes a multi-stage framework for osteoporosis detection, integrating clinical biomarkers and X-ray imaging features to improve diagnostic accuracy and assess model generalizability. In the first stage, X-ray imaging data from a Syrian dataset (D1) were classified using YOLOv9, achieving 95.39% accuracy, while clinical biomarkers were analyzed using support vector machines (SVM) and random forest (RF), resulting in accuracies of 87.34% and 84.81%, respectively. The second stage combined clinical data from Syrian (D1) and Indian (D2) datasets to evaluate cross-dataset generalizability, achieving an accuracy of 85% and revealing challenges in transferring models across populations. In the third stage, a hybrid model was developed by integrating ResNet50-extracted deep features from X-ray images with clinical biomarkers, achieving 85.94% accuracy using a Multi-Layer Perceptron (MLP). Compared to existing studies, the proposed framework demonstrates competitive performance while addressing the often-overlooked challenge of generalizability across diverse communities.

Syrian Arab Republic
Ministry of Higher Education
Damascus University
Biomedical Engineering Department

Constructing a model for assessing osteoporosis of the hip joint using artificial intelligence

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

By:

Eng. Kholoud Ahmad sweekat

Supervisor:

Prof. Eng. Rasha massoud

Prof. Eng. Mamdouh Monif

2025