



الجمهورية العربية السورية

جامعة البعث

كلية الهندسة المعلوماتية

قسم هندسة البرمجيات ونظم المعلومات

تطبيق الذكاء التجميعي في صنع القرار

دراسة أعدت لنيل درجة الدكتوراه في كلية الهندسة المعلوماتية باختصاص هندسة البرمجيات

ونظم المعلومات

إعداد

م. نهله سعيد سعد الدين

إشراف

د. يسر السيد سليمان الأتاسي

أستاذ في كلية الهندسة المعلوماتية بجامعة البعث

حمص 2022 م - 1443 هـ

تطبيق الذكاء التجميعي في صنع القرار

الملخص

تزداد أهمية الخوارزميات في اتخاذ القرار، وقد تعزز أيضاً القرار البشري وتدعمه. ولوحظ أنه مع توفر المزيد من البيانات، فإن الزيادة في استخدام خوارزميات التعلم الآلي يوفر فرصة لاتخاذ قرارات أفضل - من خلال الجمع بين ذكاء الإنسان والآلة بطريقة ذكية.

أجرينا دراسة للذكاء التجميعي وأدواته وآلية تطبيقه في مجال صنع القرار عموماً وصنع القرار الطبي (في الجانب التشخيصي في تصنيف الصور) خصوصاً من خلال تطوير نماذج برمجية للمساعدة في عملية صنع القرار الطبي. وتم العمل في هذا البحث دراسة على تطبيق صنع القرار باستخدام التعلم التجميعي، كما عملنا على تسليط الضوء على صنع القرار في المجال الطبي بهدف مساعدة الأطباء عموماً في صنع القرار المناسب للحالة المدروسة.

عملنا من خلال البحث على إجراء العمل على بيانات حقيقية (عينة البيانات MURA للصور الشعاعية) بحيث يعتبر التصوير الشعاعي تقنية مهمة للمجتمع الطبي للكشف عن التشوهات، كما أن تفسير الصور يستغرق وقتاً طويلاً وهو معرض للخطأ من قبل أخصائيي الأشعة الذين يتعرضون للعوامل الخارجية بما في ذلك التعب المحتمل الناتج عن العمل لساعات طويلة أو الإرهاق أو التفكير بأمور الحياة الأخرى.

قمنا بالعمل على تطوير نموذجي تعلم لتصنيف الصور الشعاعية بالاعتماد على التعلم العميق من خلال تطبيق مرحلتين، هما: التعلم بالنقل والتعلم التجميعي لتصنيف الصور الشعاعية تمت أول مرحلة (التعلم بالنقل) من خلال نقل مجموعة من الشبكات العصبونية التلافيفية العميقة المختارة بين مجموعة شبكات متوفرة تمت دراستها وملائمتها لحالة الدراسة التي قمنا باختيارها. قدمت أول مرحلة نتائج جيدة جداً من حيث تحسين دقة التصنيف وتحسين أداء النماذج المختارة، وقد وصل تحسين الدقة في بعض الحالات من 82% إلى 88%. في المرحلة الثانية وهي تطبيق التعلم التجميعي، تم تطوير نموذجين تجميعيين وتقييم أدائهما على عينة البيانات، وقمتم بالفعل تحسين دقة التصنيف بنسبة 2% تقريباً في كلا النموذجين. وهذا ما يؤكد فعالية النماذج المقترحة في تحسين عملية تصنيف الصور الشعاعية.

الكلمات المفتاحية: صنع القرار - ذكاء تجميعي - تعلم عميق - التعلم بالنقل - صنع قرار - تعلم آلة - تصنيف صور - MURA - صور شعاعية - DenseNet - شبكة عصبونية تلافيفية - التعلم التجميعي.



جامعة البعث

كلية الهندسة المعلوماتية

الرقم: ٦٩٩ / ٢
التاريخ: ٢٠٢٢ / ٥ / ١٦

بيان بإجراء التعديلات العلمية واللغوية

قامت الطالبة نغمه سعيد سعد الدين بتصحيح الملاحظات التي وردت في متن أطروحة الدكتوراه والتي أشار إليها الدكتور أعضاء لجنة الحكم خلال مناقشة الأطروحة.

رئيساً للجنة الحكم ومشرفاً	عضواً	عضواً	عضواً	عضواً
أ.د. يسر الأناسي	د. أسماء شعار	د. محمد ملحم	أ.د. مريم الساعدي	أ.د. رانيا لطفي

رئيس قسم هندسة الترميمات ونظم المعلومات

د. ايمن حويقص

5	فهرس الأشكال
9	فهرس الجداول
1	الإنتاج العلمي (SCIENTIFIC PRODUCTION)
1	الفصل الأول: الإطار العام للبحث
1-1	1-1 مقدمة
2-1	2-1 مشكلة البحث
3-1	3-1 الهدف من البحث
4-1	4-1 خطة البحث
5-1	5-1 مخطط الأطروحة
7	الفصل الثاني: الدراسات المرجعية
1-2	1-2 دراسات ذات صلة بالذكاء التجميعي
2-2	2-2 دراسات ذات صلة بالتعلم بالنقل
3-2	3-2 دراسات ذات صلة بالتعلم التجميعي
4-2	4-2 دراسة مرجعية حول الاستخدام الحالي للخوارزميات والتعلم الآلي في صنع القرار
5-2	5-2 دراسات ذات صلة بالبيانات
6-2	6-2 خاتمة
16	الفصل الثالث: الذكاء التجميعي
1-3	1-3 مقدمة
2-3	2-3 ما هو الذكاء التجميعي؟
3-3	3-3 أمثلة على منصات وأنظمة ذكاء تجميعي

18.....	Sermo 1-3-3
18.....	ClickWorkers 2-3-3
19.....	Ethelo 3-3-3
20.....	Loomio 4-3-3
21.....	HeroX 5-3-3
21.....	Premise 6-3-3
23.....	Owkin 7-3-3
23	4-3 مبادئ الذكاء التجميعي
23.....	1-4-3 الانفتاح
23.....	2-4-3 التناظر
24.....	3-4-3 المشاركة
24.....	4-4-3 التصرف بشكل عام
24	5-3 تصنيف الذكاء التجميعي
26	6-3 قواعد الذكاء التجميعي
27	7-3 خاتمة
29.....	الفصل الرابع: عملية صنع القرار
29	1-4 مقدمة
30	2-4 عملية صنع القرار وصنع القرار الآلي
31	3-4 أهمية عملية صنع القرار
33	4-4 أنواع القرارات
33	5-4 نماذج صنع القرار
37	6-4 خاتمة
39.....	الفصل الخامس: الخوارزميات والنماذج المستخدمة

1-5	مقدمة	39
2-5	الشبكات العصبونية التلافيفية (CONVOLUTIONAL NEURAL NETWORKS)	39
3-5	DENSENET (الشبكات التلافيفية المتصلة بكثافة DENSELY CONNECTED CONVOLUTIONAL NETWORKS)	41
4-5	شبكة RESIDUAL NETWORKS (RESNET)	49
5-5	شبكة INCEPTIONV3	52
6-5	شبكة VGG16	55
7-5	التعلم بالنقل (TRANSFER LEARNING)	57
1-7-5	طريقة النموذج المدرب مسبقاً	58
2-7-5	طرق التعلم بالنقل	59
3-7-5	الاستراتيجيات المعتمدة في التعلم بالنقل	59
8-5	مقارنة التعلم التقليدي بالتعلم بالنقل	62
9-5	التعلم التجميعي (ENSEMBLE LEARNING)	63
1-9-5	خوارزميات تعلم المجموعات شائعة الاستخدام	63
2-9-5	أهمية نموذج التعلم التجميعي	67
10-5	خاتمة	68
70	الفصل السادس: الإطار العملي	
70	(عينة البيانات المستخدمة وتجهيزها)	
1-6	مقدمة	70
2-6	صنع القرار الطبي	70
3-6	عينة البيانات (مسابقة MURA)	71
5-6	تحليل إحصائي لعينة البيانات	74
6-6	المعالجة المسبقة للبيانات	79

80	7-6 خاتمة
83	الفصل السابع: الإطار العملي (الطرق المقترحة والنماذج المستخدمة)
83	1-7 مقدمة
83	2-7 الإطار المقترح ومراحل تطبيقه
84	1-2-7 تطبيق التعلم بالنقل
109	2-2-7 تطبيق طريقة التعلم التجميعي (Ensemble Method)
118	3-7 خاتمة
120	الفصل الثامن: النتائج والتوصيات
120	1-8 النتائج
123	2-8 التوصيات والأعمال المستقبلية
124	جدول المصطلحات
126	جدول الاختصارات المستخدمة
127	المراجع العلمية

فهرس الأشكال

- الشكل (3-1) طريقة عمل منصة ETHELO 20
- الشكل (3-2) إدارة المهام في منصة PREMISE 22
- الشكل (4-1) خطوات نماذج اتخاذ القرار العقلاني 35
- الشكل (4-2) خطوات عملية صنع القرار الإبداعي 37
- الشكل (5-1) نظرة عامة لبنية شبكة CNN 41
- الشكل (5-2) بنى شبكات DENSENET المتوفرة 43
- الشكل (5-3) بنية شبكة DENSENET مكونة من 5 طبقات وبمعدل نمو $K=4$ بحيث تأخذ كل طبقة جميع خرائط البارامترات السابقة كدخل لها 44
- الشكل (5-4) خرائط البارامترات المتسلسلة في كل طبقة، تشير الخطوط المتصلة إلى تسلسل خرائط البارامترات السابقة وخرائط البارامترات المنتجة في الطبقة التالية حيث يشير السهم إليها كما تقدم الخطوط المتقطعة اتصال طبقات مختلفة 45
- الشكل (5-5) اتصالات أول كتلة كثيفة في DENSENET201 (معدل النمو $K = 32$) 46
- الشكل (5-6) خريطة بنية DENSENET201 المستخدمة في عملية التدريب والتقييم 47
- الشكل (5-7) كتلة عنق الزجاجة لشبكات RESNET-50/101/152 49
- الشكل (5-8) بنية الكتلة المتبقية (RESIDUAL BLOCK) 50
- الشكل (5-9) الطبقات والبارامترات في بنى RESNET المختلفة 51
- الشكل (5-10) بنية شبكة RESNET152 52
- الشكل (5-11) بنية شبكة INCEPTION-RESNET-V2 52
- الشكل (5-12) توضيح لفكرة ASYMMETRIC CONVOLUTION 54

- الشكل (5-13) توضيح لفكرة AUXILIARY CLASSIFIER 54
- الشكل (5-14) هيكل شبكة INCEPTIONV3 الكامل 55
- الشكل (5-15) خريطة بنية شبكة INCEPTIONV3 بشكل تفصيلي 55
- الشكل (5-16) بنية شبكة VGG16 57
- الشكل (5-17) توضيح تطبيق استخراج الميزات على شبكة عصبونية تلافيفية، بحيث يتم تبديل المصنفات بينما يتم الاحتفاظ بنفس القاعدة التلافيفية [55] 60
- الشكل (5-18) مقارنة استخراج الميزات بالضبط الدقيق 61
- الشكل (5-19) مقارنة التعلم التقليدي بالتعلم العميق 63
- الشكل (5-20) شكل توضيحي لعمل خوارزميات BAGGING 64
- الشكل (5-21) شكل توضيحي لعمل خوارزميات BOOSTING 65
- الشكل (5-22) توضيح التعميم المكّس 66
- الشكل (5-23) مدى انتشار استخدام الشبكات والنماذج المستخدمة في البحث (من بداية 2015 وحتى تاريخ إعداد هذا البحث) 68
- الشكل (6-1) طريقة تقسيم عينة البيانات المدروسة 73
- الشكل (6-2) مجموعة من حالات الدراسة في عينة البيانات المستخدمة في البحث 74
- الشكل (6-3) مخطط إحصائي يمثل عدد المرضى في كل فئة من الفئات السبعة المحددة في نوعي عينة البيانات (التدريب الاختبار) 75
- الشكل (6-4) توزيع أعداد الدراسات في كل دراسة (على مستوى المريض) 76
- الشكل (6-5) توزيع التصنيف في البيانات لكل أنواع الدراسة 78

الشكل (6-6) مثال على نتيجة تطبيق تحويلات المعالجة المسبقة للبيانات على صورة من عينة البيانات	79
(DATA AUGMENTATION).....	
الشكل (7-6) مخططات إحصائية لعينة الدراسة (عدد الدراسات وعدد الصور في كل من بيانات التدريب وبيانات الاختبار)	80
الشكل (8-6) عدد الأوراق البحثية المعتمدة على عينة البيانات MURA	81
الشكل (1-7) شبكة $N \times N$ المستخدمة لتفسير نتائج المقيمين	89
الشكل (2-7) معالج TPUV2 المتوفر في GOOGLE COLAB	91
الشكل (2-7) نتائج تدريب وتقييم النموذج DENSENET201 على عينة البيانات لكل أنواع الدراسة	95
(1- الكوع 2- الاصبع 3- الساعد 4- اليد 5- العضد 6- الكتف 7- المعصم).....	95
الشكل (3-7) نتائج تدريب وتقييم النموذج DENSENET121 على عينة البيانات لكل أنواع الدراسة	99
(1- الكوع 2- الاصبع 3- الساعد 4- اليد 5- العضد 6- الكتف 7- المعصم).....	99
نلاحظ من المخططات عموماً أن دقة التدريب استمرت في التصاعد واقتربت من الدقة المثالية أثناء الاستمرار في التدريب إلى 115 دورة (عدد الدورات الذي تم اختياره للتدريب)، وبالتفصيل:	99
الشكل (4-7) نتائج تدريب وتقييم النموذج VGG16 على عينة البيانات لكل أنواع الدراسة	103
(1- الكوع 2- الاصبع 3- الساعد 4- اليد 5- العضد 6- الكتف 7- المعصم).....	103
الشكل (5-7) توضيح لقيم معدل التعلم (LEARNING RATE) خلال العمل على كل النماذج المدروسة	106
الشكل (6-7) مقارنة نتائج التدريب لأنواع الشبكات الثلاثة على كل أنواع الدراسة من ناحية مقياس الدقة	107

الشكل (7-7) مقارنة نتائج الاختبار لأنواع الشبكات الثلاثة على كل أنواع الدراسة من ناحية مقياس الدقة	108
الشكل (8-7) مخطط توضيحي لنتائج مقياسي الدقة وكابا لحالة دراسة الكوع لشبكة INCEPTIONRESNETV2	109
الشكل (9-7) توضيح لنموذج التجميع بالتكديس على شبكات RESNET و INCEPTIONV3 ...	110
الشكل (10-7) خطوات تطبيق التجميع بالتكديس على عينة البيانات	111
الشكل (11-7) توضيح لنموذج التجميع بالتكديس على شبكات DENSENET و VGG16	113
الشكل (12-7) ترتيب النماذج من حيث دقة التصنيف الفردي	115
الشكل (13-7) ترتيب النماذج من حيث دقة التصنيف التجميعي	116
الشكل (14-7) النموذج التجميعي الثاني المقترح والمبني على كل من INCEPTIONRESNETV2 و RESNET152V2	117
الشكل (15-7) نتائج تدريب واختبار للنموذج التجميعي الثاني من (INCEPTIONRESNETV2, RESNET152V2) على عينة البيانات لحالة الدراسة HUMERUS	118

فهرس الجداول

جدول (1-7) مقارنة نتائج تقييم نموذج DENSENET201 على عينة البيانات مع نتائج الورقة البحثية المذكورة.....	92
جدول (2-7) زمن تدريب نموذج DENSENET201 على عينة البيانات لكل نوع من أنواع الدراسة 95	
جدول (3-7) مقارنة نتائج تقييم نموذج DENSENET121 على عينة البيانات مع نتائج الورقة البحثية المذكورة.....	96
جدول (4-7) زمن تدريب نموذج DENSENET121 على عينة البيانات لكل نوع من أنواع الدراسة.....	100
جدول (5-7) مقارنة نتائج تقييم نموذج VGG16 على عينة البيانات مع نتائج الورقة البحثية المذكورة.....	101
جدول (6-7) زمن تدريب نموذج VGG16 على عينة البيانات لكل نوع من أنواع الدراسة.....	104
جدول (7-7) نتائج مقارنة أداء شبكتي DENSENET المدروسة مع شبكة VGG16 من ناحية دقة التصنيف.....	105
جدول (5-7) نتائج مقارنة أداء الشبكات الثلاث المدروسة من ناحية دقة التصنيف.....	107
جدول (6-7) نتائج مقارنة أداء الشبكات الثلاث المدروسة من ناحية مقياس كايا.....	108
جدول (7-7) نتائج تطبيق التعلم التجميعي (التكديس) لنماذج RESNET على نوع العضد (من ناحية دقة التصنيف).....	112
جدول (8-7) نتائج تطبيق التعلم التجميعي (التكديس) لنماذج DENSENET و VGG16 على نوع العضد (من ناحية دقة التصنيف).....	114
جدول (9-7) ترتيب النماذج من ناحية دقة التصنيف.....	115

الإنتاج العلمي (Scientific production)

تم نشر ورقة بحثية أولى (بحث داخلي) بعنوان: **تطبيق التعلم بالنقل في تصنيف الصور في مجلة جامعة البعث** في المجلد رقم 43 لعام 2021 بإشراف الدكتورة يسر السيد سليمان الأتاسي.

AL Baath University
Journal of Al Baath University



جامعة البعث
مجلة جامعة البعث

قبول نشر بحث
طالب دراسات عليا

الرقم: ١٦٤٦

التاريخ: ٨ / ١٠ / ٢٠٢١

طالب الدراسات العليا: نهله سعد الدين
كلية: الهندسة المعلوماتية – جامعة: البعث
نود إعلامكم بقبول بحثكم الموسوم:

تطبيق التعلم بالنقل في تصنيف الصور

لنشر في مجلة جامعة البعث بالمجلد 43 لعام 2021
بعد أن تم تحكيمه من قبل مختصين.

نشكر لكم هذه المساهمة الطيبة ونتطلع إلى استمرار تواصلكم مع مجلتنا ومدها بما لديكم من جديد
والاطلاع على الأبحاث المنشورة في المجلة على موقع المجلة والرابط المدونين في أسفل الصفحة.

موقع الجامعة www.albaath-univ.edu.sy والرابط magazine@albaath-univ.edu.sy

رئيس تحرير مجلة جامعة البعث للعلوم الطبية
والهندسية والاساسية والتطبيقية

أ.د. درغام سلوم
١٠ - ٨ - ٢٠٢١

Journal of AL Baath University – Syria – Homs
Est. 1983
P.O. Box: 77 – Fax: ++963 31 2138071
Tel: ++963 31 9910 (1180 1132)
magazine@albaath-univ.edu.sy

مجلة جامعة البعث – سورية – حمص
تأسست عام 1983
ص.ب.: 77 فاكس: ++963 31 2138071
هاتف: ++963 31 9910 (1180 1132)
www.albaath-univ.edu.sy

كما تم نشر ورقة بحثية ثانية (بحث خارجي) بعنوان: تطبيق التعلم بالنقل باستخدام شبكة DenseNet121 في تصنيف الصور الشعاعية في المجلة العربية للعلوم ونشر الأبحاث في العدد الرابع - المجلد الخامس من مجلة العلوم الهندسية وتكنولوجيا المعلومات - لعام 2021 وبإشراف الدكتورة يسر السيد سليمان الأتاسي.



Date: 11 / 07 / 2021

التاريخ: 02 / ذو الحجة / 1442هـ

سعادة الباحثة المهندسة / نهله سعيد الدين "حفظها الله"
سعادة الدكتورة المهندسة / يسر محمد مروان الأتاسي "حفظها الله"
قسم هندسة البرمجيات ونظم المعلومات - كلية الهندسة المعلوماتية - جامعة البعث - سوريا
السلام عليكم ورحمة الله وبركاته

الموضوع / قبول نشر بحث علمي محكم

تهديكم هيئة تحرير " المجلة العربية للعلوم ونشر الأبحاث " أطيب التحيات،
وتود إبلاغكم بقبول نشر البحث المقدم بعنوان:
تطبيق التعلم بالنقل باستخدام شبكة DenseNet121 في تصنيف الصور الشعاعية
حيث تم التحكيم حسب الأصول وأجيز البحث للنشر في العدد الرابع - المجلد الخامس من مجلة
العلوم الهندسية وتكنولوجيا المعلومات والذي سيصدر في 30 ديسمبر 2021 م إن شاء الله تعالى.
وسيحمل البحث معرف الوثيقة الرقمي: DOI: 10.26389/AJSRP.L060521
وتفضلوا بقبول فائق التقدير والاحترام

رئيس التحرير
أ.د. م. يسر محمد مروان الأتاسي



مدير التحرير
د. عادل إبراهيم أحمد

National Research Centre - Gaza - Palestine
Tel: 00970 - 569831045
Fax: 00970-08-282-4157
DOI: dx.doi.org/10.26389/AJSRP.2015-499

المركز القومي للبحوث - غزة - فلسطين
ص ب: 5340 - غزة - فلسطين
الموقع الإلكتروني: www.AJSRP.com
البريد الإلكتروني: info@ajsrp.com

كما وتم نشر ورقة بحثية ثالثة (بحث داخلي) بعنوان: تطبيق التعلم الجماعي في صنع القرار الطبي في مجلة جامعة البعث في المجلد رقم 43 لعام 2021 بإشراف الدكتورة يسر السيد سليمان الأتاسي.

AL Baath University
Journal of Al Baath University

جامعة البعث
مجلة جامعة البعث

قبول نشر بحث
طالب دراسات عليا

الترقيم: ٢٩٤١
التاريخ: 2021 / ١٠ / ٥

طالب الدراسات العليا: نهله سعيد سعد الدين
الدكتورة المشرفة: يسر السيد سليمان الأتاسي
كلية: الهندسة المعلوماتية - جامعة: البعث
نود إعلامكم بقبول بحثكم الموسوم:

تطبيق التعلم الجماعي في صنع القرار الطبي

لنشر في مجلة جامعة البعث بالمجلد 43 لعام 2021
بعد أن تم تحكيمه من قبل مختصين.

نشكر لكم هذه المساهمة الطبية ونتطلع إلى استمرار تواصلكم مع مجلتنا ومدها بما لديكم من جديد
والاطلاع على الأبحاث المنشورة في المجلة على موقع المجلة والرابط المدونين في أسفل الصفحة.

موقع الجامعة www.albaath-univ.edu.sy والرابط magazine@albaath-univ.edu.sy

رئيس تحرير مجلة جامعة البعث للعلوم الطبية
والهندسية والأساسية والتطبيقية / تكليفاً

أ.د. هائل الطالب

Journal of AL Baath University – Syria – Homs
Est. 1983
P.O. Box: 77 – Fax: ++963 31 2138071
Tel: ++963 31 9910 (1180 1132)
magazine@albaath-univ.edu.sy

مجلة جامعة البعث – سورية – حمص
تأسست عام 1983
ص.ب.: 77 فاكس: ++963 31 2138071
هاتف: ++963 31 9910 (1180 1132)
www.albaathuniv.edu.sy

الفصل الأول: الإطار العام للبحث

1-1 مقدمة

عملية صنع القرار هي عملية جمع بيانات وتحليلها والعمل عليها لاتخاذ قرار (البحث عن الحل الأفضل بين مجموعة حلول مطروحة) مع مجموعة من الأشخاص عن طريق المفاضلة بينها، خاصة في مجال الأعمال التجارية والعلمية والطبية، بحيث تعتبر هذه المجالات هي مجالات عملية لمهارات صنع القرار.

عند محاولة صنع قرار جيد بعد جمع البيانات وتحليلها، يجب على صانع القرار وزن الإيجابيات والسلبيات لكل الخيارات الممكنة والنظر في جميع البدائل. وكي تكون عملية صنع القرار فعّالة، يجب أن يكون صانع القرار قادراً على التنبؤ بنتيجة كل خيار، مستنداً إلى كل الشروط والخواص المتوفرة ويحدد بعدها الخيار الأفضل لهذا الوضع بالذات.

بظهور وانتشار الانترنت بشكل هائل في المجتمعات، انتقلت عملية صنع القرار لتكون قراراً جماعياً ولم تعد قراراً فردياً يتخذه قائد العمل أو المجموعة، فظهر ما يسمى بصنع القرار ضمن المجموعات (أو صنع القرار التجمياعي). تطور الأمر ليتوسع خارج المجموعات الصغيرة ليشمل مجموعة مجموعات، حيث يتم تشكيل مجموعة من مجموعات صغيرة محدودة الحجم تتواصل فيما بينها بآليات معينة لينتج بالنهاية قرار تجمياعي وتتحول عملية صنع القرار من الفرد إلى الجماعة.

كما ظهر مفهوم الذكاء التجمياعي ليعرّف على أنه ظاهرة في علم الاجتماع ينتج فيها ذكاء مشترك أو تجمياعي نتيجةً لتعاون أو منافسة العديد من الأفراد [1].

بتعاريف أخرى يُعتبر شكلاً من أشكال الشبكات التي ظهرت نتيجة تطور تكنولوجيا الاتصالات والتي مكّنت المستخدمين من توليد المحتوى الخاص بهم وزيادة التفاعل بينهم. كما تم تعريفها في دراسات Woolly على أنها مجموعات تعمل معاً على مهام مختلفة [2].

عملنا من خلال البحث على تعزيز الرسالة القائلة إن "صنع القرار يتناسب مع قوة الخيارات المتاحة لاتخاذ القرار النهائي". فتم العمل على تقييم المشاركين في صنع القرار لضمان قوة الخيار الذي سيقدمه كل مشارك في المجموعة.

1-2 مشكلة البحث

بدأ الحديث عن الذكاء التجمعي لفترة من الزمن، إلا أنه لم يتم تطبيقه إلا في الآونة الأخيرة، بحيث مكّنت تقنيات الاتصال الحديثة عدد كبير من الناس وبجميع أنحاء العالم أن تعمل مع بعضها وبطرق جديدة. نرى نجاحات لأنظمة كثيرة موجودة مثل Google و Wikipedia والتي تعتمد في أساسها على مبدأ الذكاء التجمعي. وقد شجّع هذا الأمر على أهمية استغلال الذكاء التجمعي بأنظمة مشابهة معقدة، كما شجعنا على استغلاله أيضاً في مجال البحث. وتعتبر عملية صناعة القرار من المجالات التي تحتاج هكذا مبدأ في تطبيقها من الناحية العملية.

مدفوعاً بكميات متزايدة باستمرار من البيانات والتقدم الحاصل في الذكاء الصناعي وتخصصاته المختلفة، يتم تفويض صنع القرار بشكل متزايد إلى الآلة، بحيث ساهمت خوارزميات تعلم الآلة والتعلم العميق مؤخراً بشكل كبير في تصنيف البيانات كما ساهمت أيضاً في تحسين العمل في عدة مجالات. صنع القرار الآلي بواسطة تقنيات الذكاء الصناعي هو أحد أهم مجالات العمل حديثاً.

من جانب آخر، يعتبر عمل أخصائي الأشعة في تصنيف الصور الشعاعية من الأعمال المهمة جداً في المجال الطبي بسبب ما يترتب على نتائج التشخيص والتصنيف من أمور تتعلق بالمرضى لاحقاً.

وبالرغم من أن شبكات CNN العميقة قد استخدمت على نطاق واسع في مجالات واسعة منها التحليل والتشخيص الطبي، إلا أنه لا تزال هناك بعض المشكلات التي يتعين حلها في الاستخدام العملي، ومن المشاكل العملية: الحجم المحدود لبيانات التدريب والتي تعتبر مشكلة عامة في مجالات التعلم بالآلة والتعلم العميق.

تظهر نماذج التعلم العميق في التصوير الطبي الشيء الذي لا تزال تقتصر إليه هذه النماذج بشكل كبير وهو القدرة على تعميم النتائج على البيانات الواقعية غير المرئية (ظروف الحياة الواقعية التي تختلف عادةً عن تلك التي نواجهها أثناء التدريب)، لذلك عندما نريد تطبيق نموذج عملياً، من المحتمل أن نفشل.

كما أنه غالباً ما تكون بيانات التدريب المتوفرة محدودة، وهذا يقيد أداء النماذج العميقة، كونه مرتبط بعدد عينة البيانات المتوفرة، لذلك يبقى الحل الوحيد هو العثور على المزيد من البيانات. إلا أنه ليس من الممكن دائماً العثور على البيانات التي نريدها بالضبط (وهي حالة شائعة جداً)، لهذا نلجأ للتفكير في التعلم بالنقل كأفضل حل.

تم تطبيق التعلم بالنقل الذي تم تقديمه لتبني المصنفات المدربة لفئات أخرى لتصنيف فئات معينة في البحث للتغلب على مشكلة محدودية حجم البيانات والاستفادة من مجموعة من النماذج التي تم تدريبها مسبقاً. وتم دراسة دوره وتأثيره على عينة البيانات المستخدمة في بحثنا هذا.

"سيكون تعلم النقل هو المحرك التالي لنجاح التعلم بالآلة" هذا ما ذكره Andrew Ng، في برنامج NeurIPS التعليمي [3].

لا يحل التعلم بالنقل لوحده المشاكل التي تعاني منها مسألة تصنيف الصور باستخدام التعلم الآلي والتعلم العميق، لذلك وللعمل على تحسين دقة التصنيف وتحسين أداء النماذج كان العمل في البحث على خطوة ثانية وهي الاستفادة من التعلم التجميعي وكان الهدف هو إظهار قوة التعلم التجميعي في سياق مهام صنع القرار الطبي عموماً وتصنيف الصور الطبية خصوصاً. ففي دراستنا هذه، تم إجراء التصنيف على صور الأشعة السينية لعظام الطرف العلوي الطبيعية وغير الطبيعية في مجموعة بيانات MURA.

1-3 الهدف من البحث

نهدف من دراستنا إلى تطبيق الذكاء التجميعي وتقنياته في عملية صنع القرار، حيث يمكن الربط بين مجموعات الأشخاص والمعلومات والأجهزة بطريقة تؤدي بالنتيجة إلى سلوك أكثر ذكاءً وحل المسائل العلمية بفعالية أكبر. وتعتبر مسائل صنع القرار من المسائل العلمية الصعبة والمعقدة.

وبوجود القاعدة القائلة إنه كلما ارتفع الذكاء التجميعي، كلما زادت الإمكانات التجميعية وبالتالي الوصول لنتائج أفضل، فأصبح من المهم تحويل المعرفة والقوة من الفرد إلى المجموعة والتعاون فيما بينها.

تعد تقنية التصوير الشعاعي تقنية مهمة جداً في المجتمع الطبي للكشف عن الأمراض والتشوهات التي من الممكن وجودها، إلا أن تفسير هذه الصور قد يستغرق وقتاً طويلاً كما أنه معرض للخطأ من قبل أخصائيي الأشعة الذين يتعرضون للعوامل العملية الخارجية (مثل التعب الناتج عن العمل لساعات طويلة، أو الإرهاق، أو التفكير بأمور الحياة الأخرى). ولمساعدة أخصائيي الأشعة في اتخاذ قرارهم النهائي في عملية التشخيص، قمنا بالعمل على تطوير نموذجي تصنيف بمساعدة تقنيات التعلم العميق لتصنيف الصور الشعاعية على أساس المناطق التي من المحتمل أن تكون غير طبيعية والتي يوفرها اختصاصيو الأشعة لعينة الدراسة.

لذلك كان الهدف هو تقديم إطار تشخيص (تم العمل على بناء نموذجين تجميعيين في الدراسة) ذو دقة تصنيف عالية بحيث يساعد الأطباء في تشخيص الصور الشعاعية في مرحلة مبكرة من رحلة العلاج من خلال تحسين أداء خوارزميات التعلم الآلي باستخدام نماذج التجميع المقترحة.

كما يهدف البحث إلى تطبيق التعلم بالنقل على مجموعة نماذج متوفرة للباحثين والاستفادة من تلك النماذج في العمل على تحسين دقة التصنيف، والتغلب على مشكلة أساسية في مجال التعلم الآلي والتعلم العميق وهي قلة البيانات المتوفرة.

كما تناولنا في الدراسة تفاصيل بنية النماذج النهائية المقترحة، وآلية تطبيقها، إضافةً إلى النتائج والملاحظات التي حصلنا عليها بعد تنفيذ هذه الدراسة.

في النهاية لا بد من القول إن التصنيف التلقائي باستخدام التعلم التجميعي العميق يمكن أن يساعد أخصائي الأشعة في التشخيص الصحيح في الأشعة السينية أو أن يدعم قراراتهم. وبالتالي، فإن هذا التشخيص السريع بمساعدة الكمبيوتر يمكن أن يساعد في إنقاذ الأرواح البشرية وتقليل التأثير الاجتماعي والاقتصادي على المجتمع.

1-4 خطة البحث

1. جمع المعطيات المتعلقة بالبحث من المراجع والاطلاع على الدراسات السابقة المتعلقة بكل من مجالي البحث (الذكاء التجميعي، صنع القرار)، كما تم الاطلاع على الدراسات المتعلقة بعينة البيانات المدروسة.

2. دراسة الذكاء التجميعي

- ما هو الذكاء التجميعي
- مبادئ الذكاء التجميعي
- أسس وتقنيات الذكاء التجميعي
- منصات الذكاء التجميعي الموجودة حالياً

3. دراسة عملية صنع القرار والتحليلات المتعلقة بعملية صنع القرار

- مبادئ صنع القرار
- نماذج صنع القرار
- مجموعة أسس وتقنيات، وخوارزميات هذا المجال

4. الدراسة التحليلية والتجريبية

- صنع القرار المعتمد على النماذج
- إدارة المعرفة والذكاء التعاوني والتجميحي
- تطبيق نماذج التعلم العميق المتوفرة وتقييم أدائها
- دراسة عملية من خلال تطوير الإطار المقترح بتطبيق التعلم بالنقل وتطبيق التعلم التجميحي
- تطبيق التعلم بالنقل على 6 نماذج عصبونية متوفرة وملائمتها لحالة الدراسة وتقييم أدائها
- اقتراح نموذجين للتعلم التجميحي مبنيين من النماذج المنقولة
- تطبيق النموذجين المقترحين على عينة البيانات المدروسة
- تقييم أداء النماذج ومقارنة أدائها

1-5 مخطط الأطروحة

يتضمن البحث سبعة فصول، هي:

- الفصل الأول:** الإطار العام للبحث، مقدمة، ومشكلة البحث، وأهدافه.
- الفصل الثاني:** يعرض هذا الفصل أهم وأحدث الدراسات المرجعية المتعلقة بمجال البحث.
- الفصل الثالث:** يقدم هذا الفصل دراسة لأهم خوارزميات ومنصات الذكاء التجميحي.
- الفصل الرابع:** يقدم الفصل دراسة لعملية صنع القرار كما يستعرض بعض أهم النماذج المتوفرة وخصائصها ومجالات تطبيقها.
- الفصل الخامس:** يختص هذا الفصل بدراسة النماذج والخوارزميات المستخدمة في البحث.
- الفصل السادس:** يعرض هذا الفصل عينة البيانات المدروسة التي تم العمل عليها خلال البحث.
- الفصل السابع:** تم في هذا الفصل الاستفادة من الدراسة المقدمة في الفصول السابقة من خلال تطبيق نقل التعلم كخطوة أولى وتقييم أدائها، وبناء نموذجين تجميحيين وتطبيق النماذج المقترحة على عينة البيانات المدروسة كما ويقدم شرح عن الإطار العملي للدراسة.
- الفصل الثامن:** يقدم هذا الفصل النتائج التي تم التوصل إليها بعد الانتهاء من البحث، كما يقدم مجموعة من التوصيات، والأعمال المستقبلية المقترحة للمتابعة فيها.
- تم إنهاء البحث بقائمة من المصطلحات والاختصارات والمراجع العلمية المستخدمة.

الفصل الثاني: الدراسات المرجعية

1-2 دراسات ذات صلة بالذكاء التجمياعي

تصف مجموعة كبيرة من الأعمال البحثية الذكاء التجمياعي ولكن من وجهات نظر مختلفة، فتستكشف بعض الدراسات الذكاء التجمياعي من منظور ظهوره في المجتمعات الحيوانية، مثل مستعمرات النمل وأسراب النحل وأسراب الأسماك وغيرها من النماذج المعروفة والمستخدمه في كثير من خوارزميات البحث والجدولة الشهيرة (ذكاء السرب)، فقد ألهمت الملاحظات التي تم إجراؤها على هذه المجتمعات بعض الخوارزميات الأكثر شهرة لحل المشكلات الحسابية المعقدة وتحسينها.

في سياق الذكاء التجمياعي البشري ركزت الدراسات على ظهور هذا النوع من الذكاء في مجتمعات المصادر المفتوحة (وكمثال عنها Stackoverflow, Source Forge) من خلال استكشاف تأثير مفاهيمه على مشاكل محددة قد يواجهها مجتمع المستخدمين، وتمت الإشارة إلى أن المستخدمين في هذه المجتمعات مدفوعون بأهداف شخصية.

كما حاول الباحثون الاستفادة من إمكانيات الذكاء التجمياعي في مجال الاستجابة للطوارئ، وفي هذا السياق، تم اقتراح تسخير CI من خلال التعهيد الجماعي (Crowdsourcing) بحيث يتم تحديد الموقع حيث حدثت الكارثة بسرعة، وبالتالي يمكن أن يحل مشكلة رئيسية في المجال المذكور.

قام باحثون آخرون [2] بدراسة إمكانيات الذكاء التجمياعي في مجال مختلف، وهو مجال تطبيق القانون. فتم اقتراح تطبيق WikiCrimes، وهو تطبيق تعاوني مخصص لتسجيل الأحداث الإجرامية والبحث فيها (تم تسجيل 285064 جريمة في الموقع أثناء العمل في دراستنا هذه). وهناك ملاحظة مهمة تم ذكرها في هذه الدراسة وهي الحاجة إلى المفاضلة بين مشاركة المستخدم ومصادقية المعلومات في أنظمة المشاركة الضخمة التي تسعى إلى الاستفادة من الذكاء التجمياعي العام.

اقترحت الدراسة [4] أن المفاهيم المستمدة من الذكاء التجمياعي يمكن أن تكون مفيدة في مجال هندسة المتطلبات. ولتحقيق هذه المهمة، تم اقتراح منهجية لمواجهة تحديات تحليل المتطلبات المسبقة للأنظمة الكبيرة والمعقدة من خلال ثلاث خطوات رئيسية، وهي: العلامات التعاونية، وتطوير الأنطولوجيا، واتخاذ القرار التجمياعي.

قدمت الدراسات البحثية المذكورة أعلاه نتائج مهمة في استخدام مفاهيم الذكاء التجمياعي لحل المشكلات المختلفة، أو في نمذجة الذكاء من وجهة نظر مفاهيمية أكثر. ومع ذلك، فهم لا يركزون على تصميم وتحسين

نظام CI، والتي من خلالها سيتمكن الذكاء التجميعي من الظهور بطريقة منهجية تسهل عمل المصممين في تحديد الحالات التي يمكن تحويلها إلى أنظمة CI فعالة، بالإضافة إلى تمكينهم من تصميم أنظمة CI وتنفيذها وتحسينها بحيث يتم محاولة زيادة الفوائد المجتمعية والفردية. نقدم في القسم الآتي أمثلة عن أنظمة ومنصات ذكاء تجميعي مختلفة.

2-2 دراسات ذات صلة بالتعلم بالنقل

تتطلب شبكات CNN العميقة عادةً كميات كبيرة من البيانات المصنفة لغرض التدريب لتجنب فرط التلاؤم، لذلك يتم تطبيق التعلم بالنقل - وهي طريقة فعالة لحالات ندرة البيانات - على نطاق واسع باستخدام بنى كلاسيكية مدربة مسبقاً على ImageNet.

تم تطبيق التعلم بالنقل لتصنيف شذوذ الدماغ الآلي باستخدام صور MR في [5]، بحيث تم اقتراح نهج يستخدم التعلم العميق بالنقل لتصنيف صور الرنين المغناطيسي للدماغ الطبيعية وغير الطبيعية تلقائياً. وتم استخدام نموذج ResNet34 المبني على الشبكة العصبونية التلافيفية (CNN) كنموذج التعلم العميق. كما تم استخدام تقنيات التعلم العميق الحالية مثل زيادة البيانات، ومكتشف معدل التعلم الأمثل والضبط الدقيق لتدريب النموذج. وقد حقق النموذج المقترح دقة تصنيف بنسبة اقتربت من 100% على 613 صورة بالرنين المغناطيسي.

كما تم العمل على تصنيف أورام الدماغ باستخدام ميزات CNN العميقة عن طريق التعلم بالنقل في [6]، بحيث تم العمل على مشكلة تصنيف من ثلاث فئات للتمييز بين الأورام الدبقية والورم السحائي وأورام الغدة النخامية، والتي تشكل ثلاثة أنواع بارزة من أورام المخ. تبنى نظام التصنيف المقترح مفهوم التعلم بالنقل وتم استخدام شبكة GoogLeNet المدربة مسبقاً لاستخراج الميزات من صور التصوير بالرنين المغناطيسي للدماغ. سجل النموذج المقترح متوسط دقة تصنيف بنسبة 98%. وتمت الإشارة في هذه الدراسة إلى أهمية التعلم بالنقل كأسلوب مفيد عندما يكون توافر الصور الطبية محدوداً.

في الدراسة [7] قام الباحثون بتطبيق التعلم بالنقل العميق لتصنيف الصور المقطعية بالموجات فوق الصوتية، وتكونت الدراسة من تطبيق نماذج التعلم بالنقل V3 Inception و MobileNet و NasNet و Ameobanet على صور التصوير المقطعي بالموجات فوق الصوتية (USCT) لتصنيفها إلى ثلاث فئات. ووصلت دقة الاختبار إلى 96% مع مدة زمنية قصيرة.

على هذا النحو، هناك العديد من المهام والمسائل المميزة لاعتماد التعلم بالنقل في مجالات مختلفة بما في ذلك الكشف عن المرض وتشخيصه. فقد قام الباحثون في [8] بنقل شبكة CNN العميقة المكونة من تسع طبقات

والتي تم تدريبها مسبقاً على مجموعة كبيرة من بيانات تصوير الثدي بالأشعة السينية ولكنها حسّنت دقة الكشف عن الكتلة في التحليل المقطعي للثدي الرقمي (DBT) بشكل كبير من 0.80 إلى 0.91.

وفي محاولة أخرى، قام بنيامين وآخرون بتحسين دقة تصنيف الورم الشعاعي للثدي من 0.81 إلى 0.86 بعد تطبيق التعلم بالنقل [9].

طبّقنا في دراستنا أحدث شبكات CNN ومنها شبكات DenseNet وشبكات ResNet وكذلك Inception واعتمدناها في بحثنا كمصنّفات ذات نتائج مرضية بشكل جيد، والتي تزيل الإجراءات الأولية مثل التجزئة في أنظمة التشخيص التقليدية. لتحديد ما إذا كان يجب تجميد الشبكات الأساسية أم لا في هذه المشكلة، استخدمنا طريقة للتعلم بالنقل، كما تحقّقنا من نتائج دراستنا من خلال مقارنة دقة النتائج التي حصلنا عليها بأحدث الأعمال التي تمت في نفس المجال وتوصلنا إلى استنتاج مفاده أن طريقتنا تعمل بشكل أفضل بينها جميعاً على عينة البيانات المدروسة.

2-3 دراسات ذات صلة بالتعلم التجميعي

في [10]، تم اقتراح مخطط تدريب مشترك قائم على مجموعة التصوير فيما يتعلق بمشاكل التصنيف الثنائي. الأساس في الخوارزمية المقترحة هو بناء متعلم مجموعة يختار من بين خمس مصنّفات مختلفة، بناءً على وظيفة موضوعية جديدة تقيس فعالية أي زوج من المصنّفات لكل مجموعة بيانات، تعمل بموجب نظام التصويت. يتم التحقق من فعالية الآلية المقترحة لاختيار المشاركين في المجموعة من خلال العديد من التجارب - من خلال مخطط التدريب الذاتي المعروف - ومخطط التدريب المشترك، حيث تم تطبيق الأزواج العشرة المختلفة من الخوارزميات في نفس متعلم التصوير والمصنّفات الفردية الخمسة، على عدد كبير من مجموعات البيانات المعيارية عبر خمس قيم نسبية معنونة منفصلة. تم تأكيد النتائج التي تم الحصول عليها فيما يتعلق بمقياسين تصنيفيين معروفين إحصائياً.

تم ملاحظة أن عدداً كبيراً من القرارات التي تم تصنيفها بشكل خاطئ في البداية بناءً على التنبؤات الفردية تم إرجاعها نحو التسمية الصحيحة. بينما في الوقت نفسه، لم تتأثر العديد من الحالات التي يختلف فيها المشتركان حول التسمية الثنائية. يحدث هذا لأن قيمة ثقة كبيرة وصحيحة مقترنة بقيمة أصغر غير صحيحة تظل كما هي في ظل نظام التصويت المقترح.

تم في النهاية اقتراح تطبيق اعتماد مراحل معالجة مسبقة أكثر تخصصاً موجهة نحو مشاكل أكثر تحديداً لتعزيز أداء الاستراتيجية المقترحة في هذه الورقة، ومع ذلك فقد سجلت الخوارزمية المقترحة أداءً قوياً ودقيقاً. كما

أوصت الدراسة بإمكانية استخدام الشبكات العصبونية العميقة (DNNs) [11] لتعزيز أداء التنبؤ، مع تغذية إما بالبيانات الأولية أو أنواع عامة أخرى من مجموعات البيانات. فقد أثبتت شبكات الذاكرة طويلة المدى (LSTM) فعاليتها بدرجة كافية عند دمجها مع طرق (SSL (Semi Supervised Learning لبناء أنظمة دعم القرار الطبي [12].

في الدراستين [13] [14] ، تم اقتراح خوارزمية هجينة للتعليم الآلي تتكون من أشجار القرار والشبكات العصبونية التي يمكنها تصنيف البيانات بكفاءة وفعالية كبيرة. كان هيكل الخوارزمية الهجينة معتمداً على شجرة قرار ثنائية بحيث كل عقدة في الشجرة عبارة عن شبكة عصبونية مدربة على تصنيف فئة معينة من المخرجات باستخدام التصنيف الثنائي. البيانات التي تم استخدامها في الدراستين لتدريب واختبار قدرة الخوارزمية كانت مجموعة بيانات لصيانة طائرة بوينج 737 التابعة لإدارة الطيران الفيدرالية (FAA (Federal Aviation Administration والتي تكونت من 137236 سجلاً مميزاً يتكون كل منها من 72 بارامتر. تم العمل بذلك عن طريق تصنيف التناقض أو سبب الحادث فيما إذا كان الحادث قد وقع أثناء عمليات الصيانة المجدولة أم لا ثم تصنيف التفاصيل المحددة المتعلقة بالحادث. أشارت النتائج إلى أن الخوارزمية الهجينة قادرة على تصنيف الحوادث بشكل فعال بدقة عالية. أشارت الدراستان أيضاً إلى قابلية تطبيق الخوارزمية في سيناريوهات العالم الحقيقي بحيث عرضت فوائد الجمع بين أشجار القرار والشبكات العصبونية بدلاً من استخدامها بشكل فردي كونها أعطت تنبؤ أكثر دقة عند مقارنتها باستخدام نموذج عصبي واحد فقط للتنبؤات.

كما تم اقتراح نموذج هجين أيضاً في الدراسة [15] بحيث تم دمج نموذج الانتروبي الأقصى، وآلة نقل الدعم (Support Vector Machine)، ونافذة بايز لتلخيص نص متعدد المستندات لتحسين دقة التصنيف.

اقترح الباحثون في الدراسة [16] أيضاً نموذجاً هجيناً للتعليم الآلي للمشكلات متعددة التصنيف. تتكون الطريقة من مصنف شجرة القرار C4.5 ونهج واحد مقابل الكل. تم عرض فعالية الطريقة الهجينة على مجموعات البيانات مفتوحة المصدر لتجزئة الصور والأمراض الجلدية والتصوير اللمفاوي.

في الدراسة [17] جمعت شبكة عصبونية مع خوارزمية جينية لزيادة أداء الشبكات العصبونية وتم تطبيق الطريقة الهجينة على مجموعة بيانات أمراض القلب.

2-4 دراسة مرجعية حول الاستخدام الحالي للخوارزميات والتعلم الآلي في صنع القرار

في طريقة المجموعة، تم دمج الشبكة العصبونية (MLP (Multi-Layer Perceptron مع AdaBoost و Bagging و Dagging و MultiBoost و Rotation Forest و Random SubSpace [18].

كما تم تطوير نموذج تنبؤي هجين آخر بواسطة Chen et al, وفي هذه الطريقة، تم دمج مجموعات K-mean مع شجرة قرار J48 لتشخيص مرض السكري من النوع 2 [19].

كما استخدمت دراسة أخرى مبنية على التنبؤ أسلوب التعلم التجميعي. اقترح المؤلفون نهج التعلم التجميعي المكون من طبقتين (TLEL) بناءً على أشجار القرار [20]. تستخدم الطبقة الخارجية نماذج Random Forest مختلفة للتدريب بينما الطبقة الداخلية عبارة عن تكامل لشجرة القرار والتعبئة لبناء نموذج Random Forest.

استخدمت دراسة أخرى [21] التعلم التجميعي من أجل أداء تنبؤي أفضل للحياة المتبقية (RUL (Remaining Useful Life)) لمحركات الطائرات واستخدمت عدة طرق مثل المتعلمين الأساسيين المتعددين، بما في ذلك الغابات العشوائية ((RFs (Random Forests)) والشبكات العصبونية العودية (RNN (Recurrent Neural Network))، نظام الاستدلال الضبابي القائم على الشبكة التكيفية (ANFIS (Adaptive Network Based Fuzzy Inference System)) كما استخدمت الطريقة أيضاً تحسين سرب الجسيمات ((PSO (Particle swarm optimization)) والتحسين التربيعي المتسلسل (SQP (Sequential Quadratic Optimization)) لتحقيق أفضل مزيج من الأوزان لاستخدامها في المتعلمين الأساسيين.

كما كان هناك امتداد للدراسة السابقة واستُخدم في الدراسة البيان غير الدوري الموجه (DAG (Directed non-periodic Graph)) المهجن بذاكرة طويلة المدى ((LSTM (Long short-term memory)) وشبكة عصبونية تلافيفية ((CNN (Convolutional Neural Network)) للتنبؤ بـ RUL. وقد تم اختبار الطريقة باستخدام مجموعة بيانات توفرها وكالة ناسا.

بالإضافة لتطبيقات الذكاء الصناعي في علم الأمراض، فإن خوارزميات ML (Machine Learning) لها تطبيقات تنبؤية وتشخيصية في تخصصات طبية متعددة، مثل الأشعة، والأمراض الجلدية، وطب العيون، وأمراض القلب ومن المتوقع أن يؤثر الذكاء الصناعي على كل جانب من جوانب الرعاية الصحية.

كما تم دراسة إمكانية قيام الذكاء الصناعي بتشخيص المرضى المصابين بالالتهاب الرئوي COVID-19 باستخدام صور الصدر الشعاعية ((CXR (Chest X-ray Radiograph)) وحدها. وتم ذلك باستخدام Microsoft Custom Vision، وهي منصة تعلم آلية متاحة [22].

تتعدد تطبيقات الذكاء الصناعي في تفسير الصور الشعاعية بأنواعها المختلفة، وقد تمت كتابة مؤلفات كثيرة حول هذا الموضوع. باستخدام خوارزميات التعلم العميق. للذكاء الصناعي عدة أدوار محتملة لزيادة تفسير الأشعة التقليدية. يتضمن ذلك إمكانية الفحص والفرز وزيادة سرعة التشخيص. كما يمكن أن يوفر "رأي ثاني"

سريع لأخصائي الأشعة لدعم التفسير النهائي. وفي المناطق التي تعاني من نقص حاد في أطباء الأشعة، يمكن استخدام الذكاء الصناعي في تقديم التشخيص النهائي.

في COVID-19، ثبت أن دراسات التصوير مرتبطة بشدة المرض، ويمكن أن يساعد الذكاء الصناعي في مراقبة مسار المرض أثناء تقدمه ويحتل أن يحدد المرضى المعرضين لخطر أكبر. وبالتالي يمكن للتفسير اكتشاف وتوجيه فرز وعلاج المرضى الذين لديهم شكوك عالية في الإصابة بفيروس COVID-19 ولكن النتائج الأولية لـ PCR (Polymerase Chain Reaction) سلبية، أو في الحالات التي يكون فيها توافر الاختبار محدوداً أو تتأخر النتائج. هناك العديد من الفوائد المحتملة إذا كان اختبار التشخيص السريع بسيطاً مثل CXR قادراً على التأثير بشكل موثوق في احتواء ومنع انتشار العدوى في وقت مبكر من مساره.

استخدام الذكاء الصناعي لفحص وتشخيص حالات الطوارئ الصحية الناشئة مثل COVID-19 لديه القدرة على تغيير طريقة التعامل مع الرعاية الطبية بشكل كبير في المستقبل. ومع تقدم تقنيات الذكاء الصناعي بسرعة مذهلة، أصبحت الحاجة إلى تنظيم يضمن الجودة والمنفعة والأمان لأنظمة دعم القرار الطبية القائمة على الذكاء الصناعي أكثر إلحاحاً. نقدم من خلال دراستنا نافذة صغيرة على إمكانية تغيير الذكاء الصناعي بشكل كبير لممارسة الطب (في مجال التشخيص خصوصاً).

2-5 دراسات ذات صلة بالبيانات

تم تقديم مجموعة بيانات MURA لأول مرة في مؤتمر "التصوير الطبي مع التعلم العميق" الذي عقد في أمستردام عام 2018، وتم إتاحة مجموعة البيانات هذه للدراسات الأكاديمية في مسابقة تسمى "Bone X-Ray Deep Learning Competition" من قبل مجموعة Machine Learning في جامعة ستانفورد كواحدة من أكبر مجموعات بيانات الصور الشعاعية.

هناك دراسات كثيرة تم إجراؤها ونشرها باستخدام مجموعة البيانات بأكملها أو جزء منها. هذه الدراسات كانت كما يلي:

تم تحقيق متوسط دقة بنسبة 62.04% في إجراء الكشف عن الكسور باستخدام نموذج CNN العميق المقترح بعد أن تم وسم وتمييز الكسور من قبل الأطباء على صور الأشعة السينية للذراع في مجموعة بيانات MURA بواسطة Guan وآخرون [23].

كما أجرى كل من Wang و Shao تصنيف باستخدام مجموعة بيانات MURA بالكامل، بحيث تم تطوير طريقة من مرحلتين، وكانت أعلى دقة تم تحقيقها في صور عظم العضد بنسبة 88.5% لنموذج SENet154، بينما تم تحقيق أعلى دقة لنموذج DenseNet201 على صور العضد بنسبة 90.94% [24].

في التصنيف الذي أجراه Cheng وآخرون باستخدام مجموعة بيانات تحتوي على صور عظم الورك ومجموعة بيانات MURA بأكملها، كانت أعلى دقة تم تحقيقها هي 86.53% لصور عظم العضد [25].

تم تحقيق دقة تصنيف بواسطة Pelka وآخرون الذين قاموا باستخدام مجموعة بيانات MURA أيضاً بالكامل 79.85% مع نموذج InceptionV3 [26].

كما قام Harini بتصنيف صور الإصبع والمعصم والكتف في مجموعة بيانات MURA باستخدام خمس طرق مختلفة للتعلم العميق المبنية على أساس CNN، كانت أعلى دقة 56.30% في بيانات المعصم باستخدام DenseNet169 [27].

في تصنيف النوع الذي قام به Pradhan وآخرون باستخدام مجموعة بيانات MURA بالكامل، تم تحقيق دقة 91.37% مع نموذج CNN العميق المقترح [28].

كانت درجة الدقة في التصنيف الذي أجراه Varma وآخرون 88% على مجموعة بيانات الأشعة (LERA) التي تحتوي على بيانات القدم والركبة والكاحل والورك لنموذج ImageNet و DenseNet169 مُدرَّب مسبقاً مع MURA [29].

تم استخدام نموذجي ResNet18 و GoogLeNet من قبل Storey للكشف عن الشذوذ في عظام الرسغ [30].

وأخيراً، تم الحصول على أعلى دقة بنسبة 81.98% مع نموذج SqueezeNet لاكتشاف التشوهات العظمية الهيكلية التي قام بها Dias [31].

6-2 خاتمة

عرضنا في هذا الفصل عدداً من الدراسات المرجعية الحديثة التي اعتمدت على الذكاء التجميعي في تطوير عدد من الأطر والأنظمة، كما قدمنا دراسات مرجعية عن التعلم بالنقل واستخداماته، وفي النهاية أوردنا مجموعة دراسات تمت حول عينة البيانات المستخدمة في البحث.

الفصل الثالث: الذكاء التجمياعي

3-1 مقدمة

طالما كان الذكاء التجمياعي (Collective Intelligence) موجوداً لدى البشر فقد كانت تتعاون قبائل الصيادين، والأمم على مدى العصور. كما تتعامل الشركات الحديثة بشكل جماعي بدرجات متفاوتة من الذكاء. ومن بعض المنظورات، يمكن أيضاً اعتبار مجموعات من البكتيريا أو النحل أو القردة على أنها تتصرف بذكاء جماعي.

لكن هذه الظاهرة القديمة تحدث الآن بأشكال جديدة حديثة ومتطورة. مع التقنيات الجديدة - خاصة الإنترنت - فيمكن لعدد هائل من الناس في جميع أنحاء العالم أن يعملوا معاً بطرق لم تكن ممكنة من قبل في تاريخ البشرية. وبالتالي، من المهم أكثر من أي وقت مضى أن نفهم الذكاء التجمياعي حتى نتمكن من استكشاف هذه الإمكانيات الجديدة والاستفادة منها.

يعتبر الذكاء التجمياعي أحد أكبر التحديات في مختلف المجالات، ويستند إلى مفهوم أن مجموعات كبيرة من الأفراد المتعاونين يمكن أن تنتج ذكاءً وحلولاً أعلى مرتبةً أو أن تعمل ككيان واحد.

قد يظهر الذكاء التجمياعي في أشكال مختلفة بما في ذلك المتطوعون الذين يتعاونون لتحقيق هدف مشترك من شأنه أن يفيد مجتمعهم، مثلاً مجموعات كبيرة من الأفراد الذين يتعاونون أو يتنافسون من أجل إيجاد أفضل حل لمشكلة ما.

وبالتالي يمكن أن نلاحظ أن الذكاء التجمياعي قد يتواجد بشكل عام حتى دون استخدام التكنولوجيا. ومع ذلك، فإن الوسائل التكنولوجية، ساعدت المجتمعات البشرية على تطوير قدراتها الجماعية بطريقة غير مسبوقة، وهنا يأتي دور أنظمة الذكاء التجمياعي بشكل خاص، فهي تعمل على دمج المعرفة والخبرة الموجودة في أذهان الأفراد، من خلال العمل الآلي على المعلومات والقرارات المثلى التي ستؤدي إلى مصلحة المجتمع بأكمله. وبالتالي، من خلال الجمع بين أفضل جوانب الذكاء البشري والآلي، سيتم تسهيل ظهور الذكاء التجمياعي للمجتمع.

3-2 ما هو الذكاء التجمياعي؟

يمكننا الحديث عن الذكاء التجمياعي من جانبين: الأول هو جانب حياتي اجتماعي والثاني وهو الجانب البحثي (ما تم العمل عليه ضمن البحث).

في الجانب الأول، يشير الذكاء التجمياعي إلى قدرة مجموعة أو فريق على أداء مجموعة متنوعة من المهام وحل المشكلات المتنوعة. وقد تم الاعتماد على الذكاء التجمياعي للتنبؤ باستمرار بالأداء المستقبلي للمجموعات والفرق [2].

الفرق الأساسي بين الذكاء الفردي والذكاء التجمياعي هو البعد الاجتماعي وقدرة المجموعات على تحقيق وحدة الهدف والعمل والفكر، ويبدو عملياً أن هذا الجانب الاجتماعي ليس له تأثير على الذكاء التجمياعي أي أنه لا يحتاج الناس إلى أن يكونوا "أصدقاء" للعمل معاً بشكل جيد.

التعريف العملي للذكاء التجمياعي هو: مجموعات من الأفراد يقومون بأشياء جماعية تبدو ذكية. كان المفهوم موجوداً منذ القدم ولكن ما هو مختلف الآن هو التقنيات الحديثة، وبالتالي يمكن تعريفه من خلال كيفية توصيل الناس والحواسيب بحيث يتصرفون بشكل جماعي بشكل أكثر ذكاءً من أي فرد سبق له القيام به من قبل.

والفكرة عن الذكاء الجماعي هي أن الأفراد لديهم حل فردي للمشاكل. ومع ذلك، قد يكون من المثير للاهتمام معرفة مدى إمكانية تطبيق الأفكار عند وجود العديد من الحلول. وقد تم تحليل الدوافع التي قد تدفع الأفراد للمشاركة في أنظمة تُعتبر أنظمة ذكاء تجمياعي ويمكن تلخيصها بالأسباب الآتية:

- هناك جائزة أو فائدة من المشاركة
- المشاركون بدافع جوهري أو معنوي
- المشاركون لديهم الكثير من وقت الفراغ
- المشاركون غير خبراء في هذا المجال وبالتالي يسعون إلى زيادة خبرتهم من خلال التجريب والتواصل مع مجموعة كبيرة قد يكون جزء كبير منها خبير فعلاً

أما في المجال البحثي فإن الذكاء التجمياعي (CI) هو مجال بحثي ناشئ يسعى إلى دمج الذكاء البشري والآلة، بهدف تحقيق نتائج لا يمكن الوصول إليها من قبل أي منها بمفرده. قد تختلف أنظمة CI اختلافاً كبيراً في طبيعتها، فهناك مثلاً الأنظمة التعاونية، مثل مجتمعات تطوير البرمجيات مفتوحة المصدر، والأنظمة التنافسية، مثل شركات حل المشكلات التي تستفيد من المنافسة بين فرق المستخدمين المشاركة لتحديد حلول لمشاكل البحث والتطوير المختلفة.

في ضوء ما ذكرنا، نجد في الوقت الحاضر عملاً على إنشاء أنظمة CI تحقق الرؤية المطلوبة. وتتضمن الأمثلة الناجحة للأنظمة الحالية التي تحاول رفع مستوى الذكاء التجمياعي لمستخدميها المشاركين ما يلي:

- ويكيبيديا، وهي موسوعة مجانية شارك في تحريرها مستخدمو الويب وفقاً لمعرفتهم الفردية.

- شركات ومنصات حل المشكلات التي تحاول العثور على أفضل فكرة أو حل مشكلة من خلال منافسة أعداد كبيرة من مستخدمي الويب (مثل منصة Kaggle)
- جوجل، محرك البحث الشهير الذي يستخدم المدخلات المعرفية لمستخدميه لتقديم نتائج دقيقة لأسئلة البحث الخاصة بهم.

3-3 أمثلة على منصات وأنظمة ذكاء تجميعي

Sermo 1-3-3

أول مثال نقدمه كنظام ذكاء تجميعي هو Sermo وهو عبارة عن شبكة تواصل اجتماعي خاصة للأطباء مفتوحة لأطباء الطب والأطباء المرخصين في الولايات المتحدة، و149 دولة أخرى في جميع أنحاء أوروبا وأمريكا الشمالية والجنوبية وأفريقيا وتضم هذه الشبكة حسب الإحصائيات التي قمنا بها أثناء إعداد هذه الدراسة 800 ألف مشارك. وتعرّف هذه الشبكة بأنها المنصة الاجتماعية رقم 1 عالمياً للأطباء فقط. لمناقشة الحالات السريرية، وإجراء الاستطلاعات، والوصول إلى قاعدة بيانات تصنيف الأدوية. وفي دراسات حديثة تضمنت استطلاعاً لهذه الشبكة شمل 350 طبيباً، كشف 74% منهم أن رأيهم في الطب عن بعد (telemedicine) قد تغير وأن 76% منهم يخططون لمواصلة استخدام التطبيق عن بعد في المستقبل، خصوصاً بعد انتشار فايروس كورونا مؤخراً [32].

ClickWorkers 2-3-3

بقدر ما زادت قوة الحوسبة الحديثة، لا يزال هناك العديد من الأشياء التي لا يمكن لغير البشر القيام بها. مثلاً إذا كنت بحاجة إلى كميات من البيانات غير المهيكلة، مثل النصوص أو الصور أو مقاطع الفيديو، فيمكن لهذا المشروع مساعدتك في ذلك.

ClickWorkers هو مشروع يتم من خلاله استخدام معرفة الجماهير (Crowd) للحصول على الخبرة وتوافر مئات الآلاف من ClickWorkers لتقديم مشاريع سريعة وفعالة للشركات. فهو يساعد على إنجاز المهام التي لا تستطيع أجهزة الكمبيوتر معالجتها، ولن تتم معالجتها (لأن تكلفة البرمجة أو المعدات مرتفعة للغاية) أو تلك التي لا يمكنك القيام بها لأنك لا تملك الموارد البشرية الكافية لإكمال المشروع في الوقت المحدد وضمن الميزانية المحددة.

كانت بداية المشروع عام 2005 لينمو ويتطور حتى الآن ويضم مجتمع ClickWorkers حتى تاريخ إعداد الدراسة أكثر من 2.8 مليون شخص من 136 دولة حول العالم، وأوكل إلى كل واحد من المستخدمين المسجلين حسب مهاراتهم بتقديم وظائف صغيرة مناسبة. ويعمل عمال النقر على أساس العمل الحر ويتلقون أجراً ثابتاً لكل وظيفة مكتملة بشكل صحيح.

وبالتالي يمكن الاستفادة واستخدام هذه القوة العاملة المذهلة لإكمال المشاريع الكبيرة بسرعة وبتكلفة زهيدة وبأعلى جودة ممكنة. وكأمثلة على مهام يوفرها ClickWorkers:

بيانات تدريب الذكاء الصناعي، إنشاء النصوص (كتابة نصوص بسيطة أو تحريرها)، تقديم محتوى فريد، تحسين محرك البحث، تعيين الكلمات الرئيسية وتصنيفها، الدراسات الاستقصائية، ويتم إنشاء البيانات باستخدام ClickWorkers-App (لنظامي Android و iOS) لتمكين ClickWorkers من إنشاء وجمع وتقييم والتحقق من مجموعات بيانات الصوت والفيديو والصور بسهولة ونقلها من أي مكان في العالم [33].

كما يوجد العديد من المنصات المتخصصة بمجال صنع القرار، نذكر منها ما يلي:

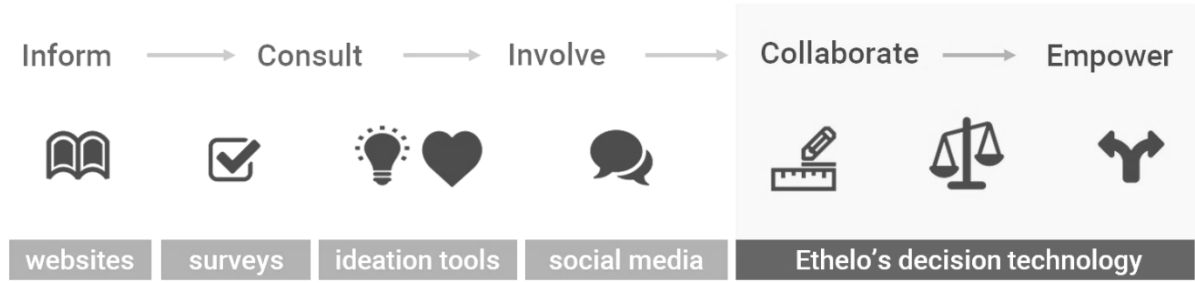
Ethelo 3-3-3

عبارة عن منصة ويب مصممة لمساعدة المجموعات من أي حجم في العثور على قرارات ذكية بسرعة وعدل من خلال التركيز على الذكاء التجميعي، وهي مدعومة بخوارزمية فريدة مصممة لتركيز الذكاء التجميعي للمجموعات. ويشق قادة الحكومات المحلية في جميع أنحاء أمريكا الشمالية في Ethelo للمساعدة في الوصول إلى المزيد من الأشخاص واتخاذ قرارات أفضل تحصل على دعم واسع. يتم العمل في هذه المنصة على اتخاذ قرارات أفضل من خلال إنشاء خطة عمل واضحة المعالم. بحيث تتجه معظم المنظمات إلى التكنولوجيا لتغيير طريقة اتخاذ القرارات. تبني صناع التغيير التكنولوجيا لحلول المصادر الجماعية للتحديات العالمية. وبالمثل، تحولت الجهات السياسية الفاعلة إلى سياسة التمهيد الجماعي من أجل مشاركة أعمق للمواطنين.

تم إنشاء Ethelo لتحسين عملية صنع القرار على أساس أصحاب المصلحة (Stakeholders) باستخدام الوصول والقوة الحسابية للإنترنت. وفي جوهرها، تعتمد Ethelo على نظرية العقد الاجتماعي الحديثة وبحوث العلوم السلوكية حول أهمية العدالة في صنع القرار التجميعي.

"مزيج من الخوارزمية القوية لاتخاذ القرار وواجهة الوسائط الاجتماعية لتوفير مجموعة غنية من المعلومات النوعية. ممتاز لأي متطلبات اتخاذ قرار تجميعي" هذا ما قاله فريق تقييم الحكومة الكندية عن Ethelo.

نبين في الشكل (1-3) طريقة العمل في منصة Ethelo:



الشكل (1-3) طريقة عمل منصة Ethelo

منصة Ethelo قادرة على نمذجة قرارات معقدة للغاية ويمكن تهيئتها لتعكس القضايا والخيارات الرئيسية، بالإضافة إلى المعايير والقيود والعلاقات المتبادلة بين الخيارات وعوامل القرار الأخرى.

المستخدمون المدعوون للمشاركة في حل مشكلة ما يقومون بزيارة المنصة للتعرف على القرار، ويمكن لكل مشارك مناقشة الخيارات مع المشاركين الآخرين وإضافة الأفكار الخاصة به، كما لديهم القدرة على تحديد النتيجة المفضلة لديهم من خلال تقييم الخيارات مقابل معيار واحد أو أكثر، وموازنة الأولويات وإجراء المفاضلات. ويتلقى كل منهم تعليقات في الوقت الفعلي من المنصة أثناء قيامهم بتطوير الحلول التي تلي قيود التصميم المالية واللوجستية [34].

Loomio 4-3-3

هي منصة تساعد مجموعات الأشخاص على اتخاذ القرارات معاً بحيث تسهل على أي شخص المشاركة في القرارات التي تؤثر عليه من خلال خدمة ويب مصممة لمساعدة المجموعات في عمليات صنع القرار التعاونية التي تركز على الإجماع، حيث يمكن للمستخدمين بدء المناقشات وطرح المقترحات. ومع تقدم المناقشات لبدء اقتراح، تتلقى المجموعة تعليقات من خلال مخطط دائري قابل للتحديث أو تصورات بيانات أخرى.

تم بناء هذه المنصة بدايةً من قبل مجموعة صغيرة من المطورين وقد تم إنجاز معظم العمل بواسطة هذه المجموعة الأساسية ولكن أكثر من 70 مساهماً من جميع أنحاء العالم شاركوا أحياناً بمساهمة صغيرة. وفي عام 2014 تم تطوير Loomio 1.0 بحيث تدعم واجهة الويب فيه الوصول عبر الهاتف المحمول واعتباراً من عام 2016، زاد انتشار استخدام Loomio وقد وصل عدد المجموعات التي تعتمد على هذه المنصة حتى تاريخ العمل على البحث 6883 في 66 دولة [35].

HeroX 5-3-3

هي منصة تعهيد جماعي بشبكة ابتكار عالمية تضم أكثر من 2 مليون شخص يحل المشكلات، بحيث تساعد المؤسسات على حل أي تحدٍ في أي مجال من خلال استخدام قوة الجمهور مع نظام سهل الاستخدام. تجعل HeroX تنفيذ التعهيد الجماعي بسيطاً وسهلاً، وحصلت على معدل نجاح 90٪، و30 مليون دولار في التحديات التي تم حلها حتى الآن، تضم 167 ألف محلل في أكثر من 180 دولة للمساعدة في دفع الابتكار المفتوح للمؤسسات [36].

آلية العمل على منصة HeroX تعتمد على أن تنتشر المنظمات الراعية أو الأفراد العمل أو الحلول التي يسعون إليها، وإضافة إرشادات وجائزة. ثم يقوم المحللون باختيار مشاركتهم بأنفسهم وتقديم أعمالهم. وتختار المنظمة الراعية أفضل المشاركات وتمنح الجائزة. وحتى الآن، نجح HeroX في حل آلاف التحديات بنجاح للمنظمات العالمية مثل NASA و Harvard Innovation Lab و NBC وغيرها.

Premise 6-3-3

مع بداية ثورة البيانات، أصبحت مصادر البيانات العننية ذات قيمة متزايدة. ويعد العمل على بيانات حقيقية أو ملاحظات مباشرة أمراً بالغ الأهمية في مجال التعلم الآلي، فهو يزود بالذكاء الدقيق، وفي الوقت المناسب، والقابل للتنفيذ الذي نحتاجه.

Premise هي منصة بيانات وتحليلات تمكّن صانعي القرار من الحصول على معلومات في الوقت الفعلي وقابلة للتنفيذ في الوقت الفعلي. من خلال الجمع بين قوة شبكة عالمية من المساهمين على أرض الواقع وعلوم البيانات الرائدة في الصناعة والتعلم الآلي [37].

تتم معالجة جميع المساهمات، سواء كانت مصممة لالتقاط المشاعر البشرية أو المراقبة المباشرة، بواسطة طبقات متعددة من التعلم الآلي للتحقق من صحة النتائج قبل التحليل (التحقق الجغرافي، التحقق من الهوية، دقة الصورة، موضوع الصورة، مكافحة الاحتيال).

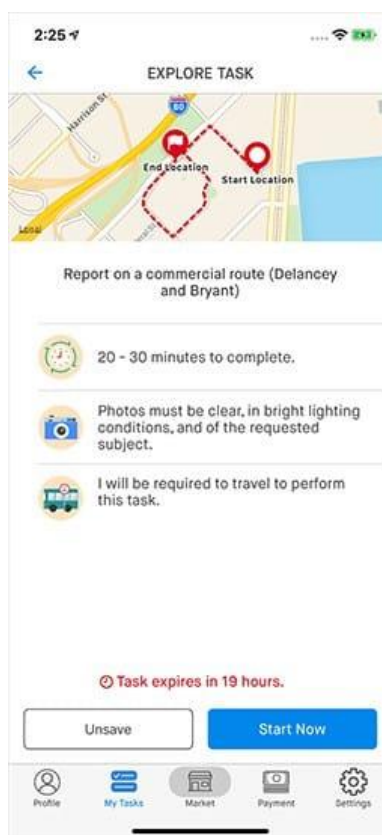
تعمل أبحاث السوق الرشيقة Agile على تقصير دورات صنع القرار، بحيث يقوم محرك القرار المدفوع بالذكاء الصناعي بأتمتة الاختبار السريع والتكرار وإطلاق المهام والاستطلاعات الجديدة، مما يقلل بشكل كبير من الوقت لجمع البيانات وجمع الرؤى القابلة للتنفيذ.

تمتلك Premise مئات الآلاف من الأشخاص الحقيقيين الذين يقومون بالتعهد الجماعي للبيانات في جميع أنحاء العالم مما يتيح الوصول إلى عالم جديد تماماً من البيانات، بحيث تقوم بجمع المعلومات عبر شبكة من المواطنين المحليين.

يتم توفير البيانات بسرعة وكفاءة وفعالية من خلال أربع خطوات:

1- الإعداد (Configure) عن طريق تحويل الأسئلة بسرعة إلى مهام.

2- التجميع (Collect)، يتم توزيع مهام شبكة المساهمين في سوق مهام Premise وإدارتها في الوقت الفعلي.



الشكل (2-3) إدارة المهام في منصة Premise

3- مراقبة الجودة (Quality Control): تتم معالجة نتائج المساهمين من خلال مجموعة من عمليات مراقبة الجودة اليدوية والآلية وعمليات الكشف عن الاحتيال.

4- العرض (Visualize): بمجرد التحقق من البيانات، يصبح الوصول إليها متاحاً في لوحة المعلومات.

Owkin 7-3-3

شبكة عالمية من المراكز الطبية الأكاديمية الرائدة (الباحثين الأكاديميين والمستشفيات)، يمكن من خلالها الوصول إلى بيانات المرضى عالية الجودة على مستوى البحث والخبرة السريرية المتطورة.

تمتلك Owkin كتالوجاً يضم أكثر من 70 نموذجاً تم إنشاؤها باستخدام بيانات شبكة Owkin Data Alliance العامة. هذه النماذج متاحة للباحثين الطبيين وشركاء علوم الحياة من خلال حلول Owkin AI Drug Development Solutions. تختلف هذه النماذج عن نماذج الصندوق الأسود التقليدية لأنها مبنية باستخدام الذكاء الصناعي القابل للتفسير، ويتكون الكتالوج من ثلاثة أنواع من النماذج: إثراء البيانات، وتوقع النتائج، وتحديد هوية المرضى الذين قد يستفيدون من علاج معين [38].

3-4 مبادئ الذكاء التجميعي

كما ذكرنا سابقاً فإن الذكاء التجميعي هو نتيجة لسلوك تجميعي يتم تصنيفه على أنه تعاون جماعي يقوم على أربعة مبادئ أساسية، هي:

الانفتاح (Openness)، والتناظر (Peering)، والمشاركة (Sharing)، والتصرف بشكل عام (Acting Globally) [39].

3-4-1 الانفتاح

يشير إلى أن جميع المشاركين سيعملون في المشروع دون التفكير بطريقة "هذه الفكرة لي"، بحيث تحتل الملكية الفكرية مقعداً خلفياً في المشاركة المفتوحة وانتشار الأفكار مع المجموعة.

3-4-2 التناظر

يشير التناظر إلى أن المشاريع سيتم فتحها أفقياً ما يخلق أساساً للمساواة يمكن للناس من خلاله دعم الأفكار وتطوير مشروع في هذا الاتجاه بمفردهم، دون الحاجة إلى موافقة من التسلسل الهرمي. يتم تعزيز هذا بشكل عام من خلال مبدأ التناظر القائل بأن مثل هذه المشاريع الأفقية ستكون مفتوحة أيضاً لمساهمات الأقران. يمكن أن يكون التنظيم الذاتي الناتج أكثر فعالية وكفاءة في تحقيق النتائج المرجوة لأنه يتيح لجميع المساهمين المساواة والحرية فيما يتعلق بتحقيق أهداف المشروع.

3-4-3 المشاركة

يعتبر هذا المبدأ مضمون إلى حد ما في مبدأ الانفتاح، بحيث أنه يوضح الحاجة إلى مشاركة الملكية الفكرية مع الآخرين في المجموعة. حيث يتم تشجيع الأقران على مشاركة جميع تطوراتهم مرة أخرى إلى المجموعة. تعد المشاركة أمراً ضرورياً لأنها تسمح بالتبادل السلس للأفكار والنقد الذي يعزز الإنتاجية.

4-4-3 التصرف بشكل عام

تأسس هذا المبدأ بسبب تقدم تقنيات الاتصالات التي تسمح للمنظمات بالوصول عبر شبكة المتعاونين بالكامل وإشراك الجميع. يتغلب هذا المفهوم على الحواجز مثل حدود الأقسام والفروع في محاولة لالتقاط واستخدام الأفكار الجديدة والمواهب الجديدة والأسواق الجديدة.

3-5 تصنيف الذكاء التجمياعي

لا يلزم وجود أنظمة الذكاء التجمياعي في شبكة الويب العالمية فقط، وإنما في أي موقف تتجمع فيه مجموعات كبيرة من الأشخاص، وتتصرف بشكل فردي ولكنها تشترك في بعض الأهداف المشتركة، يمكن أن تتحول - من خلال الاستخدام المناسب للتكنولوجيا - إلى نظام CI، وبالتالي، قد نحدد نظام الذكاء التجمياعي على أنه نظام يحوي مجموعة كبيرة من الأفراد الذين يعملون من أجل أهدافهم الفردية، ولكن أعمالهم الجماعية قد تؤدي إلى ذكاء عالي المستوى ولصالح المجتمع.

يمكن تصنيف أنظمة CI ضمن مجموعتين:

1- أنظمة CI السلبية:

يتصرف الأفراد في هذا النوع كما يفعلون عادةً من دون وجود النظام. ومع ذلك، قد يقدم سلوكهم وأفعالهم خصائص محددة يمكن أن يستخدمها نظام CI لتزويد كل واحد منهم بإرشادات وتلميحات وتنسيق معين بحيث يتم تحقيق هدفهم المشترك بسهولة أكبر. يمكن استخدام أنظمة CI السلبية في أي حالة حيث يبدو أن مجموعات كبيرة من الأشخاص تظهر بالفعل عقلاً جماعياً أو سلوكاً شبيهاً بالسرب، حيث يعمل كل مستخدم بشكل فردي ولكن جميع المستخدمين يتشاركون عدداً معيناً من الأهداف المشتركة. لا يشكل هذا السلوك الجماعي ذكاءً تجميعياً في حد ذاته، لأنه يفتقر إلى الوعي والقصد. ومع ذلك، من خلال استخدام التكنولوجيا، يمكن ملاحظة

سلوك الجماهير ثم نمذجتها في نظام CI السلبي الذي سيوفر تلميحات محددة لأفراد معينين بحيث يتم تسهيل أهدافهم المجتمعية والفردية.

كمثال على نظام CI السلبي في مجال تنسيق شبكة المركبات على الشكل التالي: حالة طرق المدن الكبيرة، حيث تتحرك أعداد كبيرة من المركبات على أساس يومي. يقوم السائقون بمجموعة بسيطة من الإجراءات، على سبيل المثال اتباع السيارة التي أمامك، أسرع، بالإضافة إلى التصرف الفردي، على سبيل المثال قد يسرع بعض السائقين فجأة، في حين أن البعض الآخر أكثر سلاسة، قد يفضل بعض السائقين ترك مسافة طويلة بين مركبتهم والسيارات الأخرى، بينما قد يترك البعض الآخر مسافة أقصر. تخيل الحالة عندما تضطر السيارة إلى إبطاء سرعتها بشكل ملحوظ. ثم سيناريو محتمل هو أن المركبات التي تتبعها سوف تتعطل أيضاً، مما يقلل المسافات بينها وينتهي بها الأمر في نهاية المطاف إلى ازدحام مروري، والذي لن يتم حله لفترة طويلة. يمثل هذا السيناريو سلوكاً يشبه السرب ويمكن تحويله إلى نظام CI سلبي باستخدام التكنولوجيا إما على شكل نقاط ثابتة أو على شكل اتصال مخصص بين المركبات. من خلال هذا المزيج من سلوك الحشد مع التكنولوجيا، يمكن تسهيل ظهور القدرات الجماعية من خلال تطبيق نظام ذكاء تجميعي من أجل زيادة الفوائد الفردية والمجتمعية. يمكن لهذا النظام عرض شبكة المركبات على أنها شبكة مخصصة، حيث تتلقى كل مركبة معلومات من المركبات القريبة. يمكن للمعرفة المحيطة التي يتم إنشاؤها بعد ذلك إبلاغ المركبات بالظروف التي يكونون على وشك تلبيتها وتقديم المشورة للسائقين لإجراء تغييرات في السرعة أو الاتجاه بحيث يتم تجنب حركة المرور أو الاصطدامات.

2- أنظمة CI النشطة:

في هذا النوع لا يكون سلوك الجماهير موجود مسبقاً وإنما يتم إنشاؤه وتنسيقه من خلال طلبات نظام محدد. يمكن تقسيم هذا النوع من الأنظمة إلى الفئات التالية:

1. تعاوني: يتعاون الأفراد مع بعضهم البعض من أجل الوصول إلى أهداف المجتمع والأفراد.
2. تنافسي: في هذا النوع يطلق النظام منافسة بين المستخدمين حتى يمكن الوصول إلى أفضل حل.
3. هجين: يجمع هذا النوع بين أنواع الأنظمة التعاونية والتنافسية، من خلال المنافسة بين مجموعات المستخدمين المتعاونين.

من الأمثلة على نظام CI النشاط ذو الطبيعة التعاونية:

- ويكيبيديا: لم يكن سلوك المستخدم موجوداً قبل إنشاء النظام، وإنما تم إنشاؤه وتشغيله من خلاله، بحيث يتعاون المستخدمون ويبنون على مساهمات بعضهم البعض، من أجل إنشاء مقالات موسوعية. وتعد ويكيبيديا واحدة من أكثر الأمثلة نجاحاً لأنظمة CI في الوقت الحالي.
- مجتمعات تطوير البرمجيات مفتوحة المصدر: يقوم المستخدمون في هذه المجتمعات بالوصول إلى الكود المصدري (Source Code) لمشروع البرنامج وتحريره وتحميل مساهماتهم. تقلل هذه العملية تدريجياً من عدد الأخطاء في المشروع وتحسن جودته، من حيث الميزات المدعومة، وتحديد أخطاء الكود، وموثوقية الكود وما إلى ذلك. يقرر معظم المستخدمين المشاركة لإضافة وظيفة غير موجودة يحتاجون إليها، أو لمعالجة خطأ، أو لتخصيص البرنامج بشكل عام لاحتياجاتهم الخاصة.

من الأمثلة على نظام CI النشاط ذو الطبيعة التنافسية:

شركات حل المشكلات التي تعمل كوسيط بين أصحاب المشكلات الموزعين في جميع أنحاء العالم، والذين يعملون كمشتريين، وحالي المشكلات المحتملين، الذين يعملون كبائعين. بحيث يسعى هذا النوع من الشركات إلى إيجاد الحل الأمثل للمشكلات التي وضعها العملاء من خلال المنافسة بين مستخدمي الويب. ثم يتم مكافأة الحلول الفائزة، التي يختارها العميل، على أساس مالي متفق عليه مسبقاً. على سبيل المثال:

- يستخدم Innocentive مساهمات أعداد كبيرة من المستخدمين للحصول على أفضل حل للبحث والتطوير والمشكلات الصناعية.
- ويسعى BootB للعثور على أفضل الأفكار التسويقية.
- وتعمل DesignBay على المنافسة بين مستخدمي الويب للعثور على أفضل تصميم جرافيك لعملائها.

مجموعة إجراءات المستخدم المحتملة في هذه الأمثلة هي مساهمة أفكارهم وحلولهم في تبادل الأفكار والحلول التي ساهموا بها، ومن المعروف أن الهدف الفردي الذي يسعى إليه المستخدمون هو المكافأة المالية المعلن عنها.

3-6 قواعد الذكاء التجميعي

هناك ثلاثة قواعد للذكاء التجميعي، وهي:

1. قاعدة اتباع الأغلبية follow-the-plurality rule

2. قاعدة اتباع الأكثر ثقة follow-the- most-confident rule

3. قاعدة اتباع الأقدم follow-the-most-senior rule

3-7 خاتمة

قدمنا في هذا الفصل دراسة شاملة تقريباً للذكاء التجميعي، بحيث قمنا بدراسة ما هو الذكاء التجميعي، كما عرضنا عدداً من الأمثلة على منصات وأنظمة معتمدة على هذا النوع من الذكاء. قمنا في نهاية الفصل بعرض مبادئ وتصنيفات الذكاء التجميعي. نقدم في الفصل الرابع دراسة عن عملية صنع القرار.

الفصل الرابع: عملية صنع القرار

4-1 مقدمة

بعد الحديث عن موضوع الذكاء التجميعي في الفصل السابق، نأتي على القسم الثاني من البحث، وهو عملية صنع القرار.

لنلاحظ أنه مع توفر المزيد من البيانات، فإن الزيادة في استخدام خوارزميات التعلم الآلي ستسمح للمؤسسات بالنظر في نطاق أوسع بكثير من مجموعات البيانات أو المدخلات مما كان ممكناً في السابق. وهذا ما يوفر فرصة لاتخاذ قرارات أفضل - من خلال الجمع بين ذكاء الإنسان والآلة بطريقة ذكية.

تجدر الإشارة إلى أن مدى الاستخدام المستقبلي للخوارزميات في صنع القرار يختلف حسب مجال تطبيقها، إلا أن المشكلة الأساسية هي الافتراض أن الخوارزميات قريبة من الكمال، أو ستحل محل البشر تماماً في جميع عمليات صنع القرار.

تزداد أهمية الخوارزميات في اتخاذ القرار، وقد تعزز أيضاً القرار البشري وتدعمه. فقد استخدمت تقنيات تعلم الآلة الخوارزميات التقليدية، مثل (SVM (Support Vector Machine، وNaïve Bayes، و KNNs (K-nearest neighbors) والغابة العشوائية بشكل متكرر [40]. قدم التعلم الآلي نتائج مهمة في المجال الطبي [41].

حالة الجهاز العضلي الهيكلي هي حالة يحدث فيها الألم والإصابة في العضلات والعظام نتيجة حالات معينة، وأكثر الأجزاء التي تتأثر بهذه الحالة هي المفاصل والعضلات. ووفقاً لتقرير منظمة الصحة العالمية [42]، تسببت حالات الجهاز العضلي الهيكلي في حدوث إعاقات في جميع أنحاء العالم. ووفقاً للإحصائيات فإن واحداً من كل ثلاثة أشخاص يعاني من حالة عضلية هيكلية مؤلمة ومعيقة. وتعتبر مهمة شاقة أن تختار دراسة معينة في مجموعة البيانات بشكل طبيعي أو غير طبيعي: أي يمكن لأي شخص يتم اختياره بشكل طبيعي من خلال هذا الإجراء تخطي المزيد من التشخيص والإجراءات الطبية. كشف الشذوذ في التصوير له تطبيقات في الطب. بحيث، سيحصل المريض الذي يحصل على تقرير غير طبيعي على التشخيص والعلاج بالأولوية الأولى ويمكن إخراج المرضى الذين حصلوا على تقرير طبيعي. كما يمكن أن يساعد الكشف الآلي عن الشذوذ من خلال الخوارزميات الفعالة الأطباء على العمل بكفاءة عالية وبمستويات أعلى من التركيز. تساعد تقنيات التعلم الآلي في تخطي الطرق التقليدية للتشخيص اليدوي وتشخيص بيانات التصوير الطبي باستخدام خوارزميات متكاملة فردية أو متعددة [43].

نعرض في هذه الفصل دراسة حول نماذج صنع القرار المتوفرة ومدى ملاءمتها لأنواع المشكلات العامة التي نراها في الواقع، كما نحاول تسليط الضوء على صنع القرار في المجال الطبي بهدف مساعدة الأطباء عموماً في صنع القرار المناسب للحالة المدروسة. ونعمل أيضاً توضيح ما إذا كان يمكن إجراء عملية صنع القرار باستخدام الخوارزميات بطريقة شفافة ومسؤولة، وكيف يمكن ذلك.

4-2 عملية صنع القرار وصنع القرار الآلي

يشير مصطلح صنع القرار عموماً إلى عملية جمع البيانات وتحليلها وتصنيفها لاتخاذ قرار مناسب (اتخاذ القرار هو عملية اختيار الخيار بين مسارات العمل البديلة أو الخيارات المتاحة - والتي قد تشمل أيضاً عدم اتخاذ أي إجراء). يستخدم الأفراد في جميع المؤسسات المعلومات التي يجمعونها لاتخاذ مجموعة واسعة من القرارات، وقد تؤثر هذه القرارات على حياة الآخرين وتغير مسار العمل. مثلاً، أدت القرارات التي اتخذها التنفيذيون والشركات الاستشارية لشركة Enron في النهاية إلى خسارة 60 مليار دولار للمستثمرين، وآلاف الموظفين من دون وظائف، وخسارة جميع صناديق التقاعد للموظفين.

ويمكن تعريف عملية صنع القرار الآلي بعدة طرق. وبشكل محدد، يمكن وصفها بأنها "قرارات بالوسائل التكنولوجية دون مشاركة بشرية" (European Commission 2018) [44]. كما يمكن النظر إليها على نطاق أوسع على أنها العملية التي يتم من خلالها معالجة الكمية المتزايدة باستمرار من البيانات الشخصية - وتنوعها - من خلال الخوارزميات، والتي تُستخدم بعد ذلك لاتخاذ قرارات (تعتمد على البيانات) " (نيويل وماربيلي (2015) [45].

عرضنا في هذه الدراسة في السيناريوهات التي يتم فيها اتخاذ القرارات بواسطة الذكاء الصناعي والخوارزميات. وميزنا هنا بين المستويات المختلفة لتأثير القرار ونستكشف مجموعة من السيناريوهات التي قد تكون فيها التأثيرات بسيطة مثل إصدار الأخبار أو توصيات الصحة واللياقة البدنية، إلى تأثيرات كبيرة مثل إصدار الأحكام الجنائية في القطاع القضائي أو اتخاذ قرارات العلاج في مجال الصحة. عملنا أيضاً من خلال البحث على مقارنة نفس القرارات عندما يتخذها خبير بشري مع تلك القرارات التي يتخذها الذكاء الصناعي.

يمكن تصور صانع القرار الآلي على أنه خوارزمية أو نظام توصية اعتماداً على كيفية تأطيره وتقديمه لمستخدم النظام أو موضوع القرار. وفقاً لذلك، يمكن أن يكون نظام صنع القرار النهائي أشكلاً تتراوح من أنظمة دعم القرار التي تقدم توصيات لصانعي القرار البشريين و / أو تحفز مستخدمي هذه الأنظمة في اتجاه معين (وهي الحالة التي عملنا عليها في دراستنا)، إلى عمليات صنع القرار المؤتمتة بالكامل التي تتخذ القرارات نيابة عن

المؤسسات أو المنظمات دون مشاركة بشرية. وبالتالي يعتمد صانعو القرار البشريون بدرجات مختلفة على أنظمة دعم القرار الآلية عند اتخاذ القرارات التي تتعلق إما بأنفسهم أو بالآخرين.

4-3 أهمية عملية صنع القرار

صنع القرارات وظيفة ضرورية للغاية لأي شخص ولأي مجموعة ولأي مجتمع بشكل عام. فبدون القرارات، لا يحدث شيء فعلياً، كما تتحكم القرارات في مصائرنا كأفراد مستقلين أو كأفراد داخل مجموعات (مؤسسة أو شركة أو المجتمع ككل).

نحن نتخذ قرارات كل يوم. هذا جزء من عملنا وحياتنا، وفي معظم الأوقات تسير الأمور في نصابها الصحيح مع تلك القرارات. فإذا كنا بحاجة إلى اتخاذ قرارات كبيرة وطويلة الأمد سيكون لها تأثير على ما نفعله في المستقبل، فسيكون من الجيد أن يكون لدينا نوع من نموذج صنع القرار الذي يساعدنا ويوفر أساساً ثابتاً للقرار الذي يجب أن نتخذه.

القرارات مهمة، لكن نلاحظ أنه نادراً ما يتم الاهتمام بكيفية صنع القرار. فبدلاً من اختيار نموذج اتخاذ القرار الصحيح للموقف المطروح، إما أن نتراجع عن القواعد أو نقرر ببساطة بأنفسنا بمعزل عن الآخرين. إلا أن رد الفعل السريع يمكن أن يكون له عواقب سلبية اقتصادياً وثقافياً وشخصياً وصحياً داخل المجتمع أو المؤسسات. قرارات قرارات، هذا هو واقع الحياة، هل أنا أتخذ القرار الصحيح؟، هل هذا هو الخيار الأفضل؟، هل أندم على ذلك؟

تُوفّر خوارزميات لكل أنواع المشكلات التي من الممكن أن تحدث في العالم يتيح لنا القول إن هناك خوارزمية لذلك (لصنع القرار) أيضاً. وفعلياً عندما نتخذ أي قرار في حياتنا، فإننا نريد أفضل نتيجة بأقل قدر من الأسف. كما نعلم فإن الخوارزميات تستخدم منذ سنوات كثيرة، إلا أن التوافر المتزايد للبيانات وإمكانية الوصول إلى أجهزة الكمبيوتر ذات قوة المعالجة الكبيرة، أثر في تطوير خوارزميات جديدة للمساعدة في التنبؤ بالسلوك وأتمتة القرارات. وأدى ذلك إلى تمكين اتخاذ قرارات أكثر كفاءة في الحكومات والشركات والهيئات والمؤسسات عموماً. عند اتخاذ قرار ما من الممكن أن يكون لدينا خيارات متعددة للاختيار بينها، فأياً منها يجب أن نختاره حتى يكون لدينا أكبر فرصة لاختيار الخيار الأفضل؟

يمكن أن تستند القرارات الخوارزمية على أنظمة عادية تستخدم آليات تسجيل بسيطة، أو تحديد الكلمات الرئيسية، أو استخراج اللغة الطبيعية. وقد يتم توضيح القواعد مباشرة من قبل المبرمجين، أو تكون ديناميكية ومرنة بناءً على التعلم الآلي للبيانات.

تتم مواجهة هذه الحالة في عدة حالات، مثلاً في عملية التوظيف لاختيار المرشح المناسب والأفضل بين المرشحين المتقدمين، أو اختيار منزل بين عدة خيارات متاحة أو.... الخ، هذه العملية مقسمة إلى مرحلتين،

مرحلة الاستكشاف ومرحلة الاختيار. أولاً يجب استكشاف عدد محدد من الخيارات لإنشاء خط الأساس الذي سيتم اعتماده كمعيار تفاضل بين الخيارات، ثم اختيار الخيار الأول الذي يتجاوز خط الأساس الذي تم تحديده. كما أنه في السنوات الأخيرة، تركزت الدراسات حول فرص استخدام خوارزميات التعلم الآلي في صنع القرار. وكما نعلم التعلم الآلي هو نوع من الذكاء الصناعي الذي يزود أجهزة الحاسوب بالقدرة على الوصول للنتائج تلقائياً عند تلقيها بيانات جديدة، دون أن تكون مبرمجة بشكل صريح على تلك البيانات. وهناك العديد من الأمثلة على الاستخدام الحالي والمستقبلي لخوارزميات التعلم الآلي في صنع القرار، نذكر في هذا السياق:

- في المجال المالي: يتم استخدام التعلم الآلي لأتمتة قرارات التداول واكتشاف فرص الاستثمار للعملاء بشكل سريع.

- في المجال التعليمي: يتم استخدام التعلم الآلي لتقييم أداء التدريس في المدارس. كما يمكن استخدام التعلم الآلي لدعم كفاءة التعلم عن طريق اختيار تقييمات وموارد تعلم أخرى للطلاب.

- في المجال الطبي: اكتسب التشخيص المعتمد على التعلم الآلي اهتماماً في السنوات الأخيرة، ويرجع ذلك إلى نتائج استدلالها الأسرع وقدرتها على أداء المهام المعقدة، والتي تتطلب خبرة وتجربة متخصصة. يتم استخدام التعلم الآلي لتحسين دقة تشخيص الأمراض المختلفة من خلال اكتشاف الأنماط، كما يمكن استخدام التعلم الآلي للتنبؤ بالاستجابة لمسارات علاج معينة، ما يتيح اتخاذ قرارات أكثر فائدة حول خيارات العلاج المخصصة.

حاولنا من خلال الدراسة توضيح طرق دعم المجموعات -عموماً- في صنع القرار ومساعدتها على أن تصبح أكثر وعياً بعملية صنع القرار الخاصة بهم.

تلعب الخوارزميات دوراً قوياً بشكل متزايد في مجالات كثيرة جداً، بحيث تؤدي مهام مختلفة وبشكل أسرع من البشر، على سبيل المثال تحليل البيانات الكبيرة، وتقوم تلك الخوارزميات باتخاذ القرارات لتكون أكثر دقة وحيادية.

أصبح الذكاء الصناعي منتشراً في معظم جوانب صنع القرار في العالم. كما يتزايد استخدام الخوارزميات بسرعة بسبب توفر كميات كبيرة من البيانات وتحليلها من قبل الحكومات والشركات والمؤسسات عموماً للاستفادة منها في عمليات صنع القرار العام. نقدم في هذه الدراسة توضيح للأنواع المختلفة من الخوارزميات المستخدمة في صنع القرار. يعتمد استخدام الخوارزميات في صنع القرار على نوع الخوارزمية؛ كما أن سياق عمل الخوارزمية سيكون ضرورياً أيضاً.

يمكن لعملية صنع القرار باستخدام الخوارزميات القضاء على التحيز أو التمييز في عملية صنع القرار، وذلك يعتمد على جودة وتمثيل البيانات الأساسية التي تستخدمها الخوارزمية، بحيث تتأثر جودة البيانات بعدد من العوامل التي تشمل دقة التوقيت والتفصيل وجودة البيانات الوصفية ... الخ.

تجدر بنا الإشارة أيضاً إلى أن هناك مخاوف إضافية بشأن الاستبعاد أو التحيز اللاواعي الذي يمكن أن يحدث في هذه الأنظمة، والتهديد بـ "التزوير"، حيث يتم تزوير البيانات عمداً دون علم متلقي البيانات الذي سيعمل عليها من خلال الخوارزميات ويبني نتائجه عليها.

عملنا في هذه الدراسة أيضاً على توضيح ما إذا كان نظام الذكاء الصناعي يمكن أن يعمل كصانع قرار أساسي، أو كمساعد وداعم مهم لصانع القرار البشري، بحيث إن الجمع بين أساليب الذكاء الصناعي في دعم القرار يمكن من استخدام كميات كبيرة من البيانات لإنتاج معلومات صنع القرار ذات الصلة بالمجال المدروس. كما نعمل في هذا البحث على توضيح كيف يمكن دمج منهجيات الذكاء الصناعي المختلفة في أنظمة صنع القرار.

4-4 أنواع القرارات

قرارات مبرمجة: هناك قرارات بسيطة واعتيادية مثل ماذا ترتدي، وماذا تأكل، والطريق الذي تسلكه وأنت تذهب من وإلى المنزل. ربما لا تقضي الكثير من الوقت في هذه القرارات ويسمى هذا النوع من القرارات المباشرة بالقرارات المبرمجة، وهي قرارات تحدث بشكل متكرر بما يكفي لتطوير استجابة آلية لها. تسمى الاستجابة الآلية التي نستخدمها لاتخاذ هذه القرارات بقاعدة القرار.

قرارات غير مبرمجة: تتطلب القرارات الفريدة والمهمة التفكير الواعي وجمع المعلومات والنظر بعناية في البدائل، وتسمى هذه القرارات قرارات غير المبرمجة.

يعد اتخاذ القرارات الاستراتيجية والتكتيكية والتشغيلية جزءاً من وظيفة التخطيط في نموذج P-O-L-C (التخطيط / Planning - التنظيم / Organizing - القيادة / Leading - التحكم / Controlling). فيتم

تصنيف صنع القرار إلى ثلاث فئات بناءً على المستوى الذي تحدث فيه:

القرارات الإستراتيجية: وهي تحدد مسار التنظيم.

القرارات التكتيكية: هي قرارات حول كيفية إنجاز الأمور.

القرارات التشغيلية: هي القرارات التي يتخذها الموظفون كل يوم لإدارة المؤسسات.

4-5 نماذج صنع القرار

من المهم تحديد نوع نموذج اتخاذ القرار الذي نتبعه عادةً. ويجب أن نسأل أنفسنا مثلاً:

- هل النموذج الذي نستخدمه أكثر فعالية؟
 - هل نميل إلى التصرف بطريقة مهينة مسبقاً أو مجهزة؟
- يمكن تصنيف نماذج صنع القرار إلى مجموعات رئيسية ومجموعة أخرى تفصيلية أكثر، المجموعات الرئيسية هي:

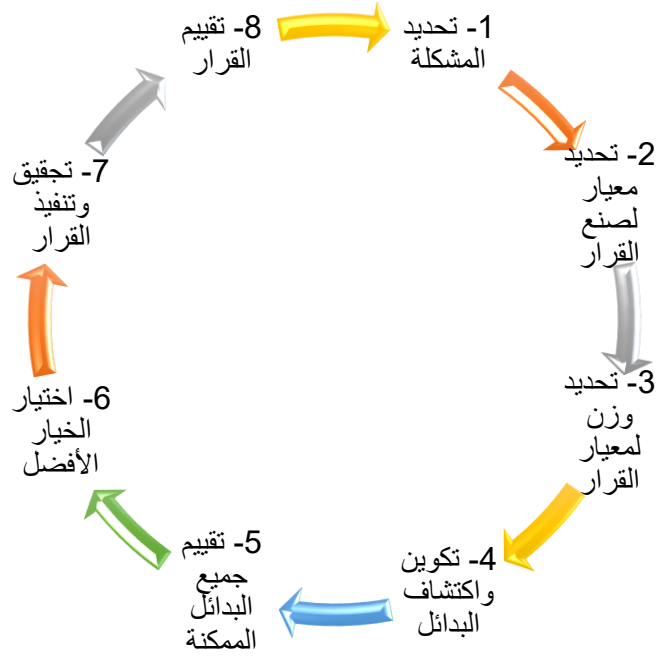
1) مجموعة نماذج صنع القرار العقلاني والمنطقي / Rational/Logical Decision Making Models

في هذه المجموعة يكون الميل لجمع الحقائق، وفحص المواقف بدقة، واتخاذ قرارات منطقية بناءً على المعرفة المتوفرة حول موضوع معين حيث سيتم إجراء أكبر قدر من البحث ولن يتم ترك شيء للصدفة. وهذه الطريقة التي يوصى بها لاتخاذ القرار للأمور الإدارية [46].

وتتصف نماذج اتخاذ القرار العقلاني سلسلة من الخطوات (نعرضها في الشكل (4-1)) التي يجب على صانع القرار مراعاتها إذا كان الهدف هو زيادة جودة النتائج. أي أنه إذا كنا نريد التأكد من أننا نتخذ الخيار الأفضل، فإن اتباع الخطوات الرسمية لنموذج اتخاذ القرار العقلاني قد يكون منطقياً.

* ميزات هذا النموذج:

1. المشاكل واضحة
2. الأهداف واضحة
3. تتفق المجموعة على المعايير والأوزان
4. جميع البدائل معروفة
5. يمكن توقع جميع العواقب
6. صنع القرار عقلاني



الشكل (1-4) خطوات نماذج اتخاذ القرار العقلاني

2) مجموعة نماذج صنع قرارات "جيدة بما فيه الكفاية" / Making "Good Enough" Decisions Models

في هذا النموذج يقتصر الأفراد في خياراتهم على مجموعة يمكن التحكم فيها ويختارون البديل الأفضل دون إجراء بحث شامل عن البدائل. يعد الميل إلى الإرضاء جزءاً من العقلانية المحدودة، والذي يشير إلى قبول البديل الأول الذي يلبي الحد الأدنى من المعايير المطلوبة ويشبه الإرضاء اتخاذ القرار العقلاني، لكنه يختلف في ذلك بدلاً من اختيار الخيار الأفضل وتعظيم النتيجة المحتملة، يوفر صانع القرار الوقت والجهد من خلال قبول البديل الأول الذي يلبي الحد الأدنى [47].

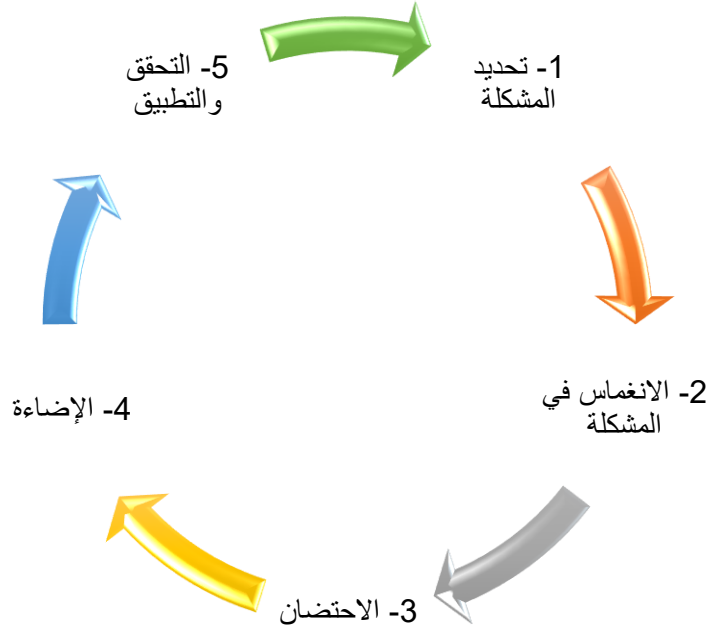
3) مجموعة نماذج صنع القرار البديهية / Intuitive Decision Making Models

لا ينطوي هذا النوع على استخدام الإحصائيات والبيانات وإنما على الإحساس، وعلى الرغم من أن هذه الطريقة ليست سيئة بالضرورة، إلا أنها قد تؤدي إلى كارثة أحياناً، حيث لا ينبغي أن يكون الحدس هو العامل الوحيد في عملية صنع القرار، ومن الأفضل استخدام الخبرات السابقة والإحصاءات معاً لاتخاذ القرار الصحيح [47]. كما يشير إلى التوصل إلى قرارات دون التفكير المنطقي. وفقاً للدراسات فقد قال 89% بالمائة من المدراء الذين شملهم الاستطلاع باستخدام الحدس لاتخاذ القرارات في بعض الأحيان، وقال 59% إنهم استخدموا الحدس كثيراً. عندما ندرك أن المدراء يحتاجون إلى اتخاذ قرارات في ظل الظروف الصعبة مع ضغوط الوقت والقيود

وقدر كبير من عدم اليقين والنتائج المرئية للغاية وذات المخاطر العالية، وفي ظل الظروف المتغيرة، فمن المنطقي أنه لن يكون لديهم الوقت الكافي فعلياً للعمل على جميع خطوات نموذج اتخاذ القرار العقلاني. وجدت الأبحاث حول قرارات الحياة أو الموت التي يتخذها رؤساء الإطفاء والطيارون والأطباء والممرضات أن هؤلاء الخبراء لا يختارون من بين قائمة بدائل مدروسة أي إنهم لا يقررون بين خيارين أو ثلاثة ويختارون الخيار الأفضل. بل إنهم يعتبرون خياراً واحداً فقط في كل مرة. يقوم الخبراء الذين يتخذون القرارات بفحص البيئة بحثاً عن إشارات للتعرف على الأنماط. بمجرد التعرف على النمط، يمكنهم لعب مسار محتمل للعمل حتى نتائجه بناءً على خبرتهم السابقة. بسبب التدريب والخبرة والمعرفة، فإن صانعي القرار لديهم فكرة عن مدى نجاح حل معين. إذا مروا بالنموذج العقلي ووجدوا أن الحل لن ينجح، فإنهم يغيرون الحل ويعيدون اختباره قبل وضعه في التنفيذ. إذا لم يتم اعتباره حلاً عملياً، فسيتم استبعاده كخيار ويتم اختبار فكرة جديدة حتى يتم العثور على حل عملي. بمجرد تحديد مسار عمل قابل للتطبيق، يضع صانع القرار الحل موضع التنفيذ. النقطة الأساسية هي أنه يتم النظر في خيار واحد فقط في كل مرة. لذلك يمكننا القول إن المبتدئين غير قادرين على اتخاذ قرارات فعالة بهذه الطريقة لأنه ليس لديهم خبرة سابقة كافية للاستفادة منها.

4) مجموعة نماذج اتخاذ قرارات إبداعية / Creative Decision Making Models

الإبداع هو توليد أفكار جديدة وخيالية. مع المنافسة الشديدة بين المؤسسات، يتم تشجيع الأفراد ليكونوا مبدعين في القرارات التي تتراوح من خفض التكاليف إلى إنشاء طرق جديدة لممارسة الأعمال. تشبه الخطوات الخمس لاتخاذ القرار الإبداعي نماذج اتخاذ القرار السابقة في بعض النواحي الأساسية، بحيث تشمل جميع النماذج خطوة تحديد المشكلة، وهي الخطوة التي تصبح فيها الحاجة إلى حل المشكلات واضحة. كما يقال: "إذا لم تدرك أن لديك مشكلة، فمن المستحيل حلها". الانغماس هو الخطوة التي يفكر فيها صانع القرار في المشكلة بوعي ويقوم بجمع المعلومات. ويعد أساس النجاح في صنع القرار الإبداعي هو امتلاك واكتساب الخبرة في المجال الذي تتم دراسته. ثم تحدث الحضانة، وفيها يترك الشخص المشكلة ولا يفكر فيها لفترة. وفي هذا الوقت، يعمل الدماغ بالفعل على حل المشكلة دون وعي، ثم تأتي الاستنارة عندما يصبح حل المشكلة واضحاً. وفي النهاية مرحلة التحقق والتطبيق عندما يتحقق صانع القرار من جدوى الحل وينفذ القرار [47]. ونبين في الشكل (4-2) تسلسل خطوات هذا النموذج.



الشكل (2-4) خطوات عملية صنع القرار الإبداعي

5) مجموعة نماذج اتخاذ القرار المسبقة / Predisposed Decision Making Models

في هذا النوع سيتم اتخاذ القرار سريعاً بناءً على التفضيلات الشخصية والآراء وسيتم البحث للعثور على البيانات التي تدعم ما يراد القيام به [47] .

4-6 خاتمة

عرضنا في هذا الفصل دراسة عن عملية صنع القرار عموماً وصنع القرار الطبي خصوصاً، كما بينّا أهمية عملية صنع القرار لما لها من تأثيرات واسعة في مختلف جوانب الحياة. كما قمنا بتقديم دراسة لأنواع القرارات التي يتم التعامل معها. وعرضنا أيضاً مجموعة من نماذج صنع القرار المتوفرة وميزاتها ومجالات استخدامها. ندرس في الفصل الخامس الخوارزميات والنماذج والتقنيات التي تم العمل عليها في البحث، كما نقدم ميزات استخدامها.

الفصل الخامس: الخوارزميات والنماذج المستخدمة

5-1 مقدمة

يتحدث الفصل الخامس عن شبكات التعلم الآلي والتعلم العميق والنماذج المستخدمة في البحث، حيث تم تطبيق عدد من النماذج باستخدام تقنية التعلم بالنقل المتوفرة من خلال تدريب نموذج لكل منها كما تم مقارنة أداء النماذج الفردية وأخصائي الأشعة (والذين تم أيضاً إعطاؤهم الصور وقاموا بتصنيفها يدوياً، حيث قام 6 من أخصائيي الأشعة بالعمل على ذلك وفقاً للورقة البحثية الخاصة بالبيانات المنشورة) [48].

تم تطبيق عدة أنواع من نماذج الشبكات التلافيفية المطورة حديثاً للاستفادة من ميزات وأدائها في تصنيف الصور الطبية الخاصة بالبحث.

حيث تم تطبيق ثلاثة من نماذج ResNet المتوفرة حتى تاريخ إعداد هذا البحث من خلال تدريب نموذج لكل منها ثم مقارنة أداء هذه النماذج.

نماذج شبكات الـ DenseNet التي قمنا بالعمل عليها نموذجين، وهما: DenseNet121 وDenseNet201.

نماذج شبكات الـ ResNet التي طبقنا العمل عليها أثناء الدراسة هي ثلاثة نماذج، وهي ResNet152V2, InceptionV3, InceptionResNetV2.

كما عملنا أيضاً على نموذج VGG16، وبالتالي كان العمل على 6 نماذج خلال البحث، وقد تم العمل على هذه النماذج بالتحديد كونها الأحدث حتى تاريخ إعداد البحث، وبالتالي الأكثر كفاءة في التصنيف.

5-2 الشبكات العصبونية التلافيفية (Convolutional Neural Networks)

على الرغم من أن شبكات CNN العميقة قد استخدمت على نطاق واسع في المجالات التي لا تشمل فقط التحليل والتشخيص الطبي [49]، فإنه لا تزال هناك بعض المشكلات التي يتعين حلها في الاستخدام العملي لكل مشكلة.

أشار جيسون أيضاً في الدراسة [50] أن الطبقات السفلية في شبكات CNN العميقة وخاصة الطبقة الأولى تتعلم بعض الميزات العامة المشابهة لفلاتر Gabor أو نقاط الألوان، لكن الطبقات العليا تتعلم المزيد من الميزات المحددة فيما يتعلق بمجموعة البيانات.

أحد العوائق الرئيسية لاستخدام شبكات CNN لتصنيف الصور عملياً هو الحجم المطلوب للبيانات اللازمة للتدريب بدقة، حيث عادةً ما تكون آلاف الصور مطلوبة. وهذه المشكلة تحد من استخدام شبكات CNN في تصنيف الصور في المجال الطبي. عملنا في بحثنا على التغلب على مشكلة حجم مجموعة البيانات باستخدام نقل التعلم. حيث تم تقديم التعلم بالنقل للتغلب على تحدي حجم مجموعة البيانات من خلال تدريب النماذج المدروسة على مجموعة بيانات غير طبية كبيرة، ثم ضبط الأوزان على مجموعة البيانات الطبية الخاصة بالبحث.

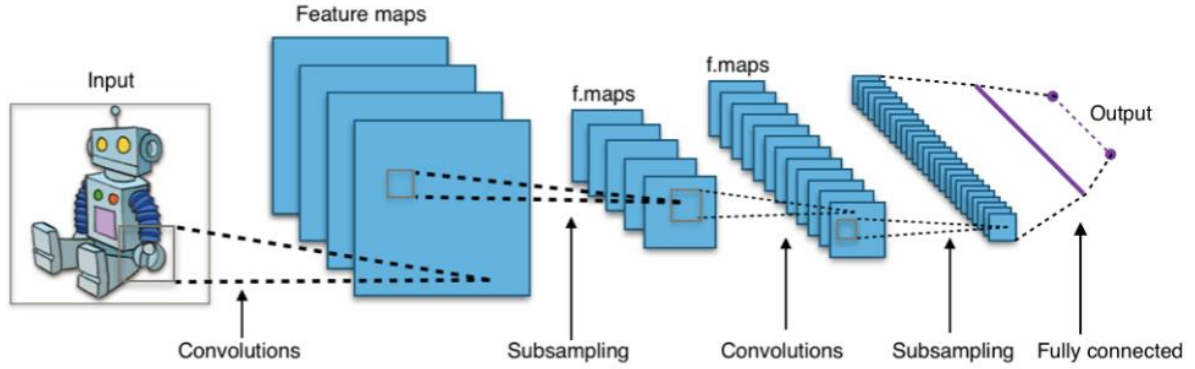
التعلم الانتقالي (أو التعلم بالنقل)، الذي تم تقديمه لتبني المصنفات المدربة لفئات أخرى لتصنيف فئات معينة، تبين أنه طريقة فعالة لحل مثل هذه الحالات. ولهذا قمنا بالعمل على تطبيقه ودراسة دوره في عينة البيانات المستخدمة في بحثنا هذا.

هناك طريقتان لتحويل الشبكات المتوفرة إلى شبكات موجهة للمشاكل. الإجراء الأول لطريقتي للتعلم بالنقل هو نفسه وهو نسخ أول n من الطبقات السفلية من الشبكات الأساسية إلى الشبكات المستهدفة بينما تتم تهيئة البارامترات (Parameters) في الطبقات المتبقية من الشبكات المستهدفة بشكل عشوائي. الفرق بين الطريقتين هو في الإجراء الثاني وهو أن إحدهما تترك البارامترات في الطبقات المنسوخة مجمدة بينما تقوم الأخرى بضبط البارامترات عند تدريب الشبكات المستهدفة. يُقترح تقنية التجميد عندما يكون حجم مجموعة البيانات المستهدفة صغيراً بينما تكون أعداد البارامترات كبيرة وإلا يجب اعتماد الضبط الدقيق عندما تكون مجموعة البيانات الكبيرة مصحوبة بعدد صغير من البارامترات [51].

في التعلم بالنقل، يتم تطبيق معرفة نموذج التعلم الآلي الذي تم تدريبه بالفعل على مشكلة مختلفة ولكنها ذات صلة. على سبيل المثال، إذا قمنا بتدريب المصنف البسيط للتنبؤ فيما إذا كانت الصورة تحتوي على حقيبة ظهر، فيمكننا استخدام المعرفة التي اكتسبها النموذج أثناء تدريبه للتعرف على أشياء أخرى مثل النظارات،

أي أننا نحاول بشكل أساسي استغلال ما تم تعلمه في مهمة A لتحسين التعميم في مهمة أخرى B بحيث نقوم بنقل الأوزان التي تعلمتها الشبكة في "المهمة A" إلى "المهمة B" الجديدة.

أصبح هذا النوع من النموذج ذو المرحلتين شائعاً للغاية في العديد من التطبيقات العملية، وخاصة في التصوير الطبي. بحيث تم ضبط البنى القياسية المصممة لـ ImageNet مع الأوزان المقابلة مسبقاً للتدريب بدقة على المهام الطبية التي تتنوع من تفسير الأشعة السينية للصدر وتحديد أمراض العيون، إلى الاكتشاف المبكر لمرض الزهايمر.



الشكل (5-1) نظرة عامة لبنية شبكة CNN

DenseNet 3-5 (الشبكات التلافيفية المتصلة بكثافة) (Densely connected convolutional networks)

أظهرت الدراسات الحديثة [52] أن الشبكات التلافيفية يمكن أن تكون أعمق بكثير وأكثر دقة وكفاءة للتدريب إذا كانت تحتوي على اتصالات أقصر بين الطبقات القريبة من المدخلات وتلك القريبة من المخرجات. نقدم الشبكة التلافيفية الكثيفة (DenseNet)، التي تربط كل طبقة بكل طبقة أخرى بطريقة التغذية إلى الأمام. في حين أن الشبكات التلافيفية التقليدية ذات الطبقات L لها وصلات بعدد $L - 1$ واحدة بين كل طبقة وطبقتها اللاحقة - تحتوي هذه الشبكة على اتصالات مباشرة $(L + 1) / 2$. لكل طبقة، تُستخدم خرائط البارامترات لجميع الطبقات السابقة كمدخلات، وتُستخدم خرائط البارامترات الخاصة بها كمدخلات في جميع الطبقات اللاحقة.

تتمتع DenseNets بالعديد من المزايا:

- تقوي انتشار الميزات
- تشجع على إعادة استخدام الميزات
- تقلل عدد البارامترات بشكل كبير

نقوم بتقييم هذه الشبكة من خلال اعتماد تقنية التعلم بالنقل لنوعين من شبكات DenseNet هما شبكة DenseNet121 وشبكة DenseNet201 مدربتان مسبقاً على عينة البيانات ImageNet الشهيرة ونقلهما لتقوموا بالعمل على عينة البيانات الخاصة بالدراسة.

يظهر في الشكل الآتي بنى شبكات DenseNet الأربعة المتوفرة حتى تاريخ العمل على البحث، وهي DenseNet121 و DenseNet169 و DenseNet201 و DenseNet264 (تم العمل خلال الدراسة على نوعين منها وهي DenseNet121 و DenseNet201).

لم يتم العمل على DenseNet169 بسبب استخدامها بكثرة في العديد من الدراسات المرجعية التي تمت دراستها، وبالتالي نتائجها كانت متوفرة ولا داعي لتكرار العمل.

كما لم يتم العمل على DenseNet264 لعدم توفر نموذج مدرب مسبقاً (حتى تاريخ إعداد البحث) على عينة البيانات ImageNet ليتم نقل التعلم منه والاستفادة منه في البحث.


Layers	Output Size	DenseNet-121	DenseNet-169	DenseNet-201	DenseNet-264
Convolution	112×112	7×7 conv, stride 2			
Pooling	56×56	3×3 max pool, stride 2			
Dense Block (1)	56×56	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer (1)	56×56	1×1 conv			
Dense Block (2)	28×28	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer (2)	28×28	1×1 conv			
Dense Block (3)	14×14	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 64$
Transition Layer (3)	14×14	2×2 average pool, stride 2			
Dense Block (4)	7×7	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$
Transition Layer (4)	7×7	1×1 conv			
Dense Block (5)	7×7	2×2 average pool, stride 2			
Transition Layer (5)	7×7	1×1 conv			
Classification Layer	1×1	7×7 global average pool			
		1000D fully-connected, softmax			

الشكل (5-2) بنى شبكات DenseNet المتوفرة

من بين جميع شبكات CNN العميقة المقترحة حديثاً، كانت DenseNet معروفة بالأداء الرائع في المهام المعيارية للتعرف على الأشياء التنافسية مثل ImageNet و CIFAR-100 [52]. ويعود ظهور شبكات CNN العميقة إلى عام 2012. في عام 2012، فازت شبكة ذات بنية جديدة تسمى AlexNet، وهي المحاولة الأولى لحل تحدي تصنيف الصور على نطاق واسع بواسطة شبكة CNN العميقة، بالمركز الأول والثاني في مهمة التصنيف. قد يكون عمق AlexNet، الذي يتكون فقط من خمس طبقات تلافيفية وثلاث طبقات متصلة

تماماً، قليلاً جداً مقارنةً بعمق شبكات CNN العميقة الحديثة المصممة في السنوات الأخيرة، ولكنها أشارت إلى مستقبل واعد لشبكات CNN العميقة والذي تم إثباته من خلال النمو الهائل في عدد نماذج لشبكات CNN عميقة جديدة.

الشكل الآتي يوضح بنية شبكة DenseNet مكونة من 5 طبقات:




الشكل (3-5) بنية شبكة DenseNet مكونة من 5 طبقات وبمعدل نمو $k=4$ بحيث تأخذ كل طبقة جميع خرائط البارامترات السابقة كدخل لها

بالنسبة للشبكات المطورة حديثاً، تبين أن العديد من الاتصالات المختصرة هي طرق فعالة للتغلب على المشكلات المحتملة مثل انحدار التدرج (Gradient Descent) عند تدريب شبكات CNN العميقة. في البحث [53]، حلت وحدة البداية المحسنة المكونة من فرع مختصر وعدد قليل من الفروع العميقة مشكلة تلاشي / انفجار التدرجات عندما تتعمق الشبكات. لتسهيل عملية تدريب الشبكات العميقة، تم تصميم الشبكات المسماة شبكات الطرق السريعة (High Ways Networks) للسماح بتدفق المعلومات التي تنتجها الطبقات السابقة إلى الطبقات اللاحقة دون فقدان المعلومات. تم تحقيق نفس الهدف ولكن باستخدام أسلوب التعلم المتبقي في [54]. في حين أن الاستفادة من البنى العميقة والواسعة يمكن أن تكون تقنيات مفيدة لتحسين أداء شبكات CNN العميقة، فإن DenseNet تدرك هدف التدريب السهل وكفاءة البارامترات من خلال إعادة استخدام الميزات، والتي تُدخل خرائط الميزات المتسلسلة التي تنتجها جميع الطبقات السابقة في الطبقة اللاحقة. بهذه الطريقة، يُسمح للطبقات العميقة في الشبكات بالوصول إلى جميع خرائط البارامترات التي تنتجها الطبقات السابقة وبالتالي إعادة استخدام الميزات.

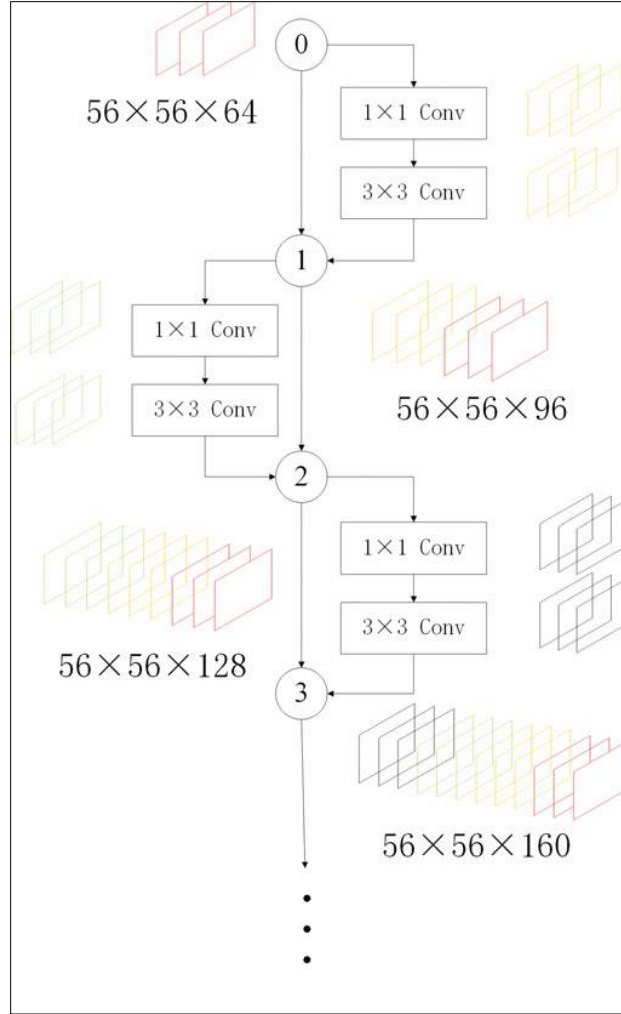
في شبكات CNN التقليدية العميقة، كانت الطبقات التلافيفية متنوعة عموماً بطبقات تصغير الحجم تقلل عرض خرائط البارامترات وارتفاعها إلى نصفها. وبالتالي، فإن تسلسل خرائط البارامترات قبل طبقات العينات السفلية وبعدها سيكون مشكلة بسبب الأحجام المختلفة. لحل هذه المشكلة، تم تصميم الكتل الكثيفة بمهارة متنوعة بطبقات تأخذ العينات السفلية بينما ترتبط الطبقات في الكتل الكثيفة بشكل كامل. ونتيجة لذلك، ظلت أحجام خرائط البارامترات في الكتل الكثيفة دون تغيير بينما تم تخفيضها إلى النصف بعد أخذ العينات للأسفل. لذلك، بالنسبة للكتلة الكثيفة ذات الطبقات L ، يكون العدد الإجمالي للتوصيلات المباشرة بين الطبقات هو $L(L + 1) / 2$.

إذا لم تكن هناك قيود على النمو الخطي في عدد خرائط الميزات، فإن كلفة الحساب الضخمة ستكون كبيرة جداً. لذلك تم تصميم معدل النمو k للتحكم في عدد خرائط البارامترات المنتجة في كل طبقة. ونتيجة لذلك، فإن العدد الإجمالي لخرائط البارامترات في الطبقة l من كتلة كثيفة هو $k_0 + (l - 1) * k$ ، حيث k_0 هو عدد القنوات في طبقة الإدخال.

لتقليل تعقيد الحساب، تم إدخال طبقات عنق الزجاجة (Bottleneck Structure) عن طريق استخدام التقاف 1×1 قبل كل التقاف 3×3 . إلى جانب طبقات عنق الزجاجة، تعمل الطبقات المسماة طبقات الانتقال على التحكم في عدد خرائط ميزات الخرج في عمق معين للشبكات وبالتالي تحسين ضغط الشبكات بأكملها. يوضح الشكل (4-5) عملية ربط وإنتاج خرائط ميزات جديدة في أول كتلة كثيفة من DenseNet201. نظراً لأن الطبقة الانتقالية تظهر عموماً بعد كتلة كثيفة بعمق محدد، فلا توجد طبقة انتقالية بعد الكتلة الكثيفة الأولى.

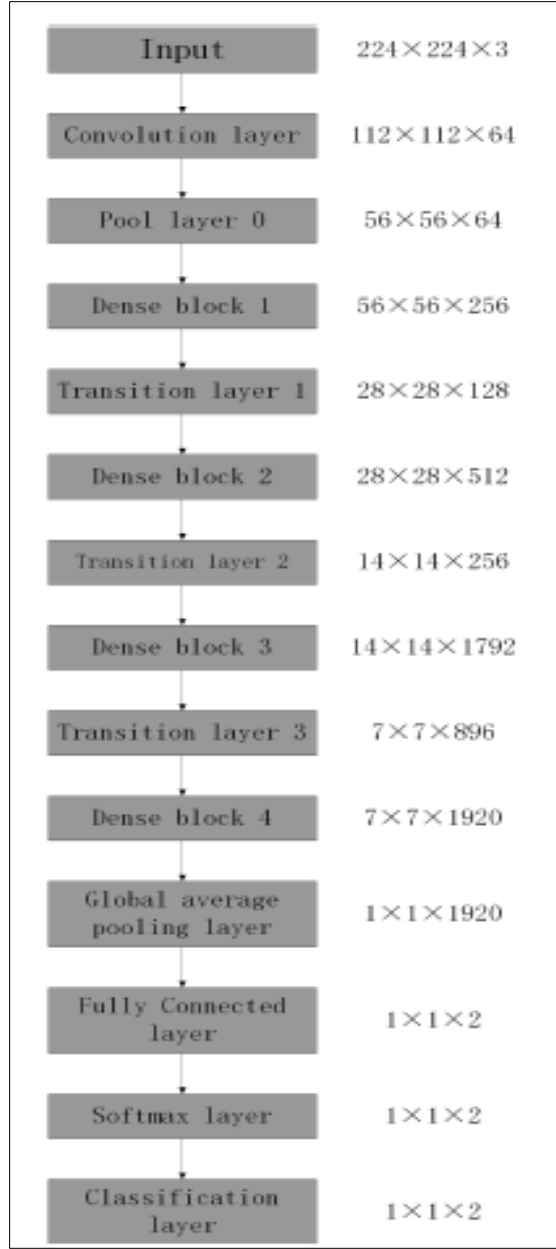


الشكل (4-5) خرائط البارامترات المتسلسلة في كل طبقة، تشير الخطوط المتصلة إلى تسلسل خرائط البارامترات السابقة وخرائط البارامترات المنتجة في الطبقة التالية حيث يشير السهم إليها كما تقدم الخطوط المتقطعة اتصال طبقات مختلفة



الشكل (5-5) اتصالات أول كتلة كثيفة في DenseNet201 (معدل النمو $k = 32$)

تم إنتاج الخرائط المميزة حديثاً في كل طبقة.



الشكل (5-6) خريطة بنية DenseNet201 المستخدمة في عملية التدريب والتقييم

Dense Block (الكتلة الكثيفة): هي وحدة مستخدمة في الشبكات العصبونية التلافيفية التي تربط جميع الطبقات (بأحجام خرائط ميزات متطابقة) مع بعضها البعض مباشرة. تم اقتراحها في الأصل كجزء من بنية DenseNet.

تتكون الكتلة الكثيفة من كتل التفاضل متعددة، كل منها يستخدم نفس عدد قنوات الإخراج. ومع ذلك، في الانتشار الأمامي، نقوم بربط المدخلات والمخرجات لكل كتلة التفاضل على بُعد القناة.

للحفاظ على طبيعة التغذية الأمامية، تحصل كل طبقة على مدخلات إضافية من كل الطبقات السابقة وتكرر خرائط الميزات الخاصة بها إلى كل الطبقات اللاحقة.

وبالتالي، تحتوي الطبقة l على l مدخل، تتكون من خرائط الميزات لجميع الكتل التلافيفية السابقة. يتم تمرير خرائط الميزات الخاصة بها إلى جميع الطبقات اللاحقة $l+1$.

Transition Layer (طبقة النقل): نظراً لأن كل كتلة كثيفة ستزيد من عدد القنوات، فإن إضافة الكثير منها سيؤدي إلى نموذج معقد للغاية. بالتالي يتم استخدام طبقة نقل للتحكم في مدى تعقيد النموذج ما يقلل من عدد القنوات باستخدام طبقة تلافيفية 1×1 وتقليل ارتفاع وعرض طبقة التجميع المتوسطة بخطوة (stride) 2، مما يقلل بشكل أكبر من تعقيد النموذج.

بشكل أبسط، يمكن القول إن طبقات الانتقال (الالتفاف + التجميع) هي طريقة لاختزال التمثيلات المحسوبة بواسطة Blocks Dense ببطء حتى النهاية. وتتكون طبقة النقل من الأجزاء الآتية:


Batch Normalization

1×1 Convolution

Average pooling

Bottleneck Structure (عنق الزجاجة): في تصميم نماذج CNN التقليدية، هناك دائماً مفاضلة بين الأبعاد وعدد القنوات. في حين أن الدقة المكانية العالية ضرورية للحفاظ على المعلومات المحلية التفصيلية، فإن عدداً كبيراً من القنوات ينتج مسافات عالية الأبعاد ومعرفة تمثيلات أكثر تعقيداً. يتم تحديد تعقيد طبقة تلافيفية واحدة بواسطة ناتج هذين العاملين. للحفاظ على تعقيد مقبول، يتم تقليل الأبعاد المكانية عن طريق التجميع الأعظمي (max pooling) أو الالتفاف السريع (stride convolution) بينما يتم زيادة عدد القنوات. كما ترتبط البكسلات المجاورة في مدخلات كل طبقات تلافيفية، بطريقة مماثلة لمجال الصورة، خاصة عندما تكون الدقة المكانية عالية. في حين أن تقليل الدقة عن طريق أخذ عينات فرعية بسيطة سيؤدي بوضوح إلى فقدان المعلومات، فإن مثل هذا الارتباط يمثل تكراراً كبيراً يمكن الاستفادة منه.

بنية "عنق الزجاجة" المكانية تقلل من مقدار الحساب دون تقليل الدقة المكانية أو عدد القنوات من خلال استغلال التكرار المكاني للمدخلات. بالنظر إلى بيانات الإدخال ثلاثية الأبعاد، نطبق أولاً التفافاً واحداً داخل القناة لكل قناة إدخال. يتم لف kernel k مع كل قناة إدخال بخطوة k ، بحيث يتم تقليل بُعد الإخراج إلى $R_k^{\frac{h}{k} \times \frac{w}{k} \times n}$. ثم يتم تطبيق طبقة الإسقاط الخطي. أخيراً، نجري تفكيك $k \times k$ داخل القناة باستخدام خطوة k لاستعادة الدقة المكانية.



الشكل (5-7) كتلة عنق الزجاجة لشبكات ResNet-50/101/152.

4-5 شبكة (ResNet) Residual Networks

بعد أول بنية قائمة على CNN (AlexNet) والتي فازت بمسابقة ImageNet 2012، تستخدم كل بنية فائزة لاحقة المزيد من الطبقات في شبكة عصبونية عميقة لتقليل معدل الخطأ، ويعمل هذا مع عدد أقل من الطبقات، ولكن عندما نزيد عدد الطبقات، توجد مشكلة شائعة في التعلم العميق مرتبطة بما يسمى Vanishing/Exploding gradient. يؤدي هذا إلى أن يصبح التدرج / gradient 0 أو كبيراً جداً. وبالتالي عندما نزيد عدد الطبقات، يزداد أيضاً معدل خطأ التدريب والاختبار.


تم تقديم ResNet والتي اقترحها باحثون في Microsoft Research في عام 2015، كبنية جديدة تسمى الشبكة المتبقية (Residual Network).

الكتلة المتبقية (Residual Block):

من أجل حل مشكلة الانحدار المتلاشي / المتفجر (vanishing/exploding gradient)، قدمت هذه البنية مفهوماً جديداً يسمى الشبكة المتبقية. في هذه الشبكة يتم استخدام تقنية تسمى تخطي الاتصالات. يتخطى الاتصال من خلال تخطي التدريب من عدة طبقات ويتصل مباشرة بطبقة الخرج.

النهج المستخدم في هذه الشبكة هو أنه بدلاً من أن تتعلم الطبقات التعيين الأساسي (mapping)، يتم السماح للشبكة بتناسب التعيين المتبقي.

لذلك، بدلاً من قول $H(x)$ ، التعيين الأولي، تقوم الشبكة بما يلي $F(x) := H(x) - x$ والذي يعطي H $x + F(x) = H(x)$. والشكل (8-5) يوضح بنية الكتلة المتبقية (Residual Block)



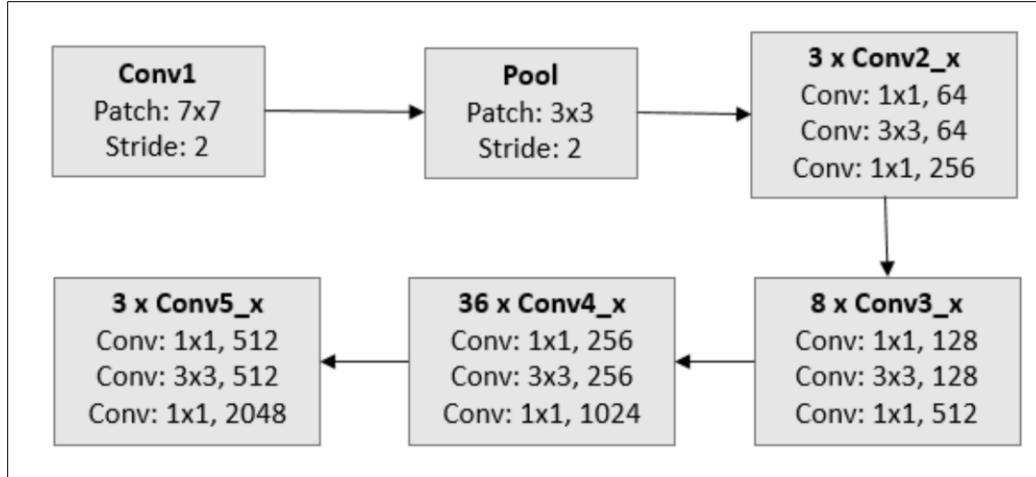
الشكل (8-5) بنية الكتلة المتبقية (Residual Block)

بنية الشبكة:

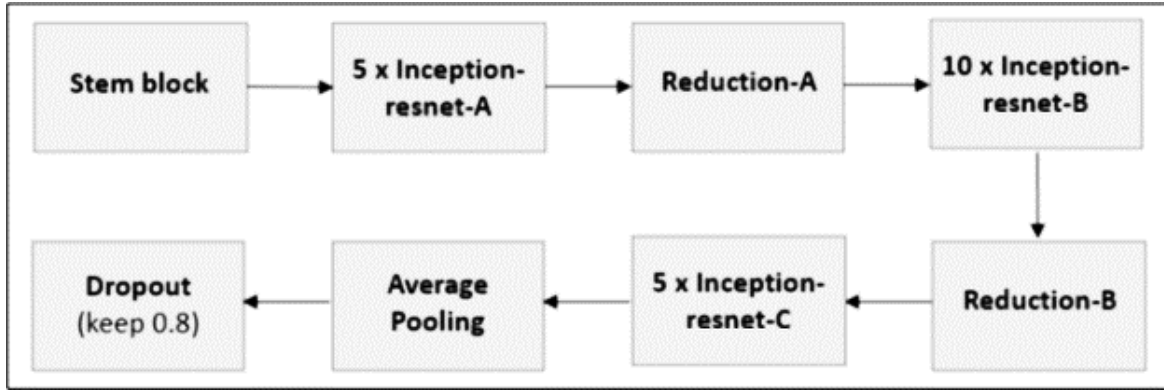
تستخدم هذه الشبكة بنية شبكة عادية مكونة من عدد من الطبقات مستوحاة من VGG-19 حيث يتم إضافة اتصال الاختصار (shortcut connection) بحيث تقوم اتصالات الاختصار هذه بتحويل البنية إلى شبكة متبقية.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
		3×3 max pool, stride 2				
conv2_x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10 ⁹	3.6×10 ⁹	3.8×10 ⁹	7.6×10 ⁹	11.3×10 ⁹

الشكل (5-9) الطبقات والبارامترات في بني ResNet المختلفة



الشكل (10-5) بنية شبكة Resnet152



الشكل (11-5) بنية شبكة Inception-Resnet-v2

5-5 شبكة InceptionV3

هي بنية شبكة عصبونية تلافيفية من عائلة Inception للمساعدة في تحليل الصور واكتشاف الأشياء تقوم بإجراء العديد من التحسينات بما في ذلك استخدام Label Smoothing و Factorized 7 x 7 convolutions، واستخدام مصنف إضافي (auxiliary) لنشر معلومات Label للشبكة (مع استخدام batch normalization للطبقات).

كانت شبكة Inception معقدة ولكن استخدمت الكثير من التقنيات لتحسين الأداء من حيث السرعة والدقة. وقد أدى تطورها المستمر إلى إنشاء عدة إصدارات من الشبكة. الإصدارات الشائعة هي كما يلي:

- Inception v1

- Inception v2 and Inception v3
- Inception-ResNet


بحيث كان كل إصدار هو تحسين تزايدى مقارنة بالإصدار السابق (اعتمدنا في بحثنا على Inception V3 و Inception-ResNet).

وقد بدأت هذه الشبكة كوحدة نمطية (module) لـ Googlenet. وتعتبر الإصدار الثالث من Google Inception Convolutional Neural Network، والتي تم تقديمها في الأصل أثناء تحدي التعرف على ImageNet وكان القصد من تصميم Inceptionv3 السماح لشبكات أعمق مع الحفاظ على عدد البارامترات من النمو بشكل كبير جداً، فهي تحتوي على أقل من 25 مليون بارامتر، مقارنة بـ 60 مليوناً لشبكة AlexNet. تساعد Inception على تصنيف الكائنات وقد أعيد استخدام بنية Inceptionv3 في العديد من التطبيقات المختلفة، وغالباً ما تستخدم مُدرّبة مسبقاً على عينة البيانات الشهيرة ImageNet وأحد هذه الاستخدامات هو التشخيص الطبي.

بنية شبكة InceptionV3:

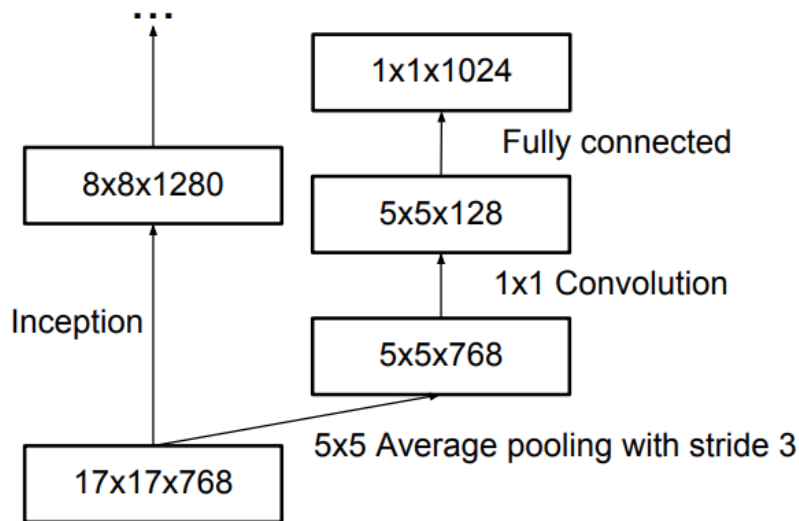
يتم بناء بنية شبكة Inception v3 تدريجياً، خطوة بخطوة بالشكل الآتي:

- 1- Factorized Convolutions: تقلل هذه المرحلة من عدد البارامترات المتضمنة في الشبكة.
- 2- Smaller convolutions: استبدال تلافيف أكبر مع تلافيف أصغر مما يؤدي إلى تدريب أسرع.
- 3- Asymmetric convolutions: يمكن استبدال الالتفاف 3×3 باللتفاف 3×1 متبوعاً باللتفاف 1×3 . إذا تم استبدال التفاف 3×3 باللتفاف 2×2 ، فسيكون عدد البارامترات أعلى قليلاً من الالتفاف غير المتماثل المقترح.




الشكل (5-12) توضيح لفكرة Asymmetric convolution

4- Auxiliary classifier: هو عبارة عن شبكة CNN صغيرة يتم إدخالها بين الطبقات أثناء التدريب ، وتضاف الخسارة فيها إلى خسارة الشبكة الرئيسية. في GoogLeNet، تم استخدام المصنفات المساعدة لشبكة أعمق، بينما في Inception v3، يعمل هذا المصنف كمنظم (regularizer).

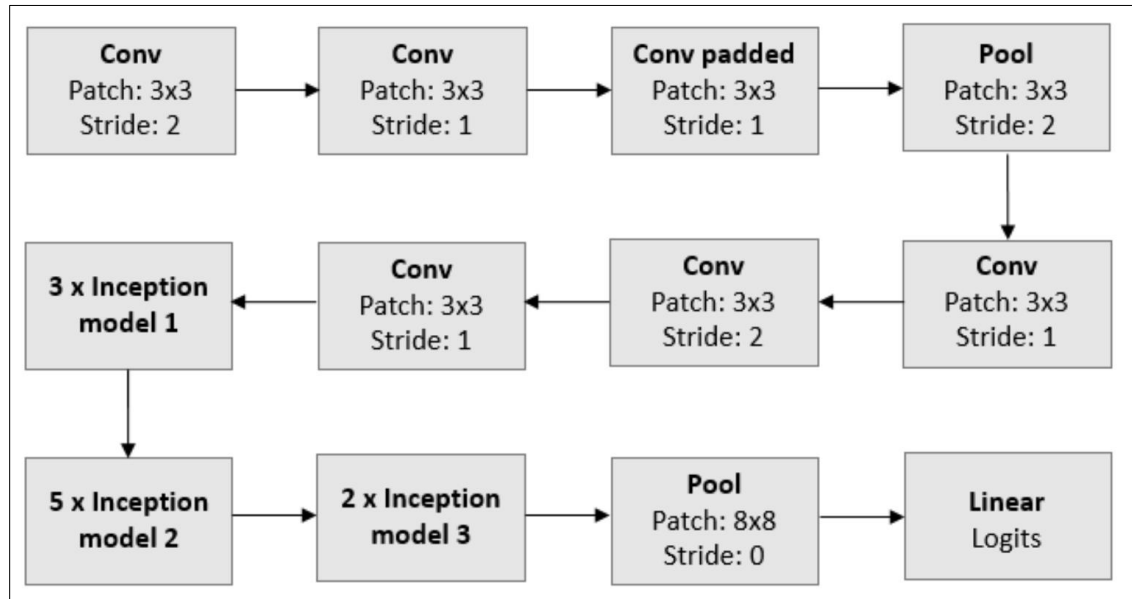


الشكل (5-13) توضيح لفكرة Auxiliary classifier

5- Grid size reduction: عادة ما يتم ذلك عن طريق عمليات التجميع (pooling). يتم دمج جميع المفاهيم المذكورة أعلاه في الهيكل النهائي الآتي:



الشكل (5-14) هيكل شبكة InceptionV3 الكامل



الشكل (5-15) خريطة بنية شبكة InceptionV3 بشكل تفصيلي

6-5 شبكة VGG16

تسمى أيضًا OxfordNet، وهي عبارة عن بنية شبكة عصبونية التلافيفية سميت باسم مجموعة الهندسة المرئية (Visual Geometry Group) من أكسفورد، التي طورتها، تم استخدامها للفوز بمسابقة ILSVR (ImageNet Large Scale Visual Recognition Challenge) في جامعة أكسفورد في عام 2014

في مقالة بعنوان "شبكات عميقة للغاية للتعرف على الصور على نطاق واسع". وتعتبر واحدة من تصميمات نماذج الرؤية الحاسوبية المميزة، بحيث حقق النموذج 92.7% من أعلى 5 اختبارات دقة على مجموعة بيانات ImageNet التي تحتوي على 14 مليون صورة تنتمي إلى 1000 تصنيف/فئة.

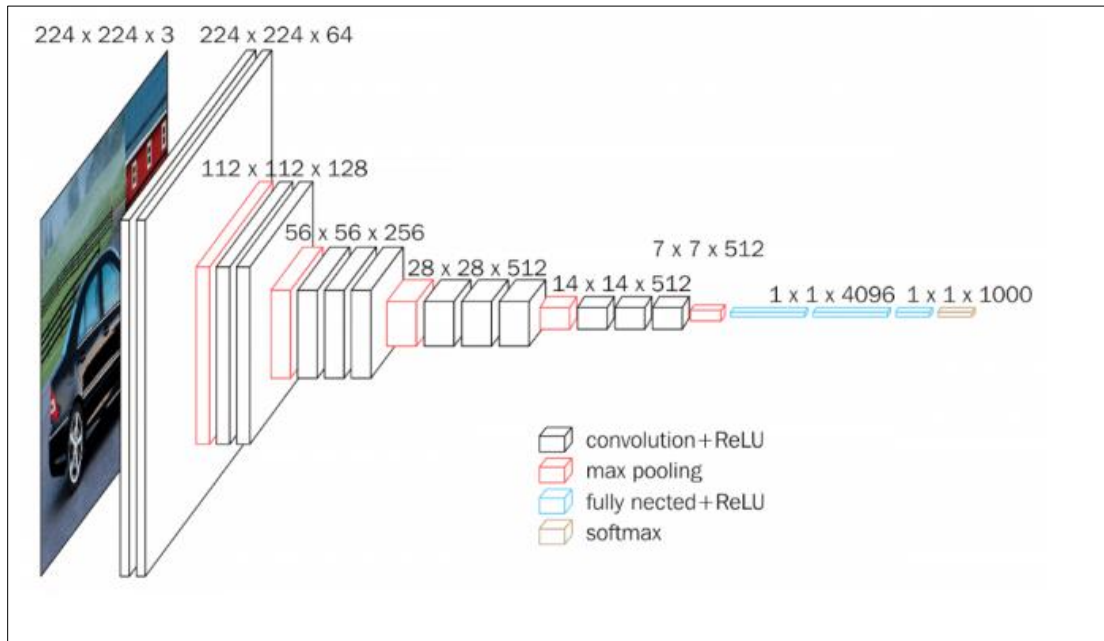
يشير الرقم 16 في VGG16 إلى أن الشبكة تحتوي على 16 طبقة لها أوزان ولديها حوالي 138 مليون بارامتر تقريباً. كما يتوفر نسخة أخرى منها VGG19 بـ 19 طبقة.

يقوم النموذج بتحميل مجموعة من الأوزان المدربة مسبقاً على مجموعة البيانات الشهيرة ImageNet.


حجم الإدخال الافتراضي لطراز VGG16 هو 224×224 بكسل مع 3 قنوات لصورة RGB. يحتوي النموذج على طبقات التلافيف بفلتر 3×3 مع خطوة (stride) 1 وطبقة maxpool بفلتر 2×2 بخطوة 2.

ما يميز VGG16 هو ببساطتها فبدلاً من وجود عدد كبير من البارامترات الفائقة، تم التركيز على وجود طبقات التلافيف 3×3 مكسدة مع خطوة 1 وتم استخدام نفس الحشو/ Padding دائماً. كما يتم التعامل مع تقليل الحجم عن طريق التجميع الأقصى 2×2 . في النهاية يحتوي على (FC(Fully Connected) 2 (طبقتين متصلتين بالكامل) تحتوي كل منهما على 4096 عقدة، متبوعةً بـ softmax للإخراج.

في عام 2014، تم اعتبار 16 و 19 شبكة طبقة عميقة جداً (على الرغم من أن لدينا الآن بنى شبكات تصل لأعماق كبيرة جداً).



(أ) بنية شبكة VGG16 بالشكل الكامل



(ب) خريطة بنية شبكة VGG16 بالشكل المفصل

الشكل (5-16) بنية شبكة VGG16

7-5 التعلم بالنقل (Transfer Learning)

قد تستغرق نماذج الشبكة العصبونية التلافيفية العميقة أياماً أو حتى أسابيع للتدريب على مجموعات بيانات كبيرة جداً. وتتمثل إحدى طرق اختصار هذه العملية في إعادة استخدام أوزان النموذج من النماذج المدربة

مسبقاً التي تم تطويرها لمجموعات البيانات المعيارية، مثل مهام التعرف على الصور ImageNet. يمكن تنزيل النماذج الأفضل أداءً واستخدامها مباشرةً، أو دمجها في نموذج جديد لحل مشكلات الرؤية الحاسوبية.

يشير مصطلح التعلم بالنقل إلى تأثير المعرفة المكتسبة من قبل الشبكة العصبونية المدربة مسبقاً على مجموعة بيانات معينة (كبيرة عادةً) متاحة لحل المشكلات الجديدة التي تتوفر لها عينة تدريب قليلة، ودمج المعرفة الحالية (المسبقة) مع المعرفة الجديدة المستفادة من العينة القليلة من مجموعة البيانات الخاصة بالمسألة. وبالتالي، يتم استخدام التعلم بالنقل بشكل كبير، غالباً مع تقنيات أخرى مثل زيادة عينة البيانات المدروسة، من أجل معالجة مشكلة نقص بيانات التدريب.

يعمل التعلم الانتقالي فقط في التعلم العميق إذا كانت ميزات النموذج التي تم تعلمها من المهمة الأولى عامة. في التعلم بالنقل، نقوم أولاً بتدريب شبكة أساسية على مجموعة بيانات أساسية ومهمة، ثم نقوم بإعادة توظيف الميزات المكتسبة، أو نقلها، إلى الشبكة الهدف ليتم تدريبها على مجموعة بيانات ومهمة هدف. ستتم هذه العملية إذا كانت الميزات عامة، ما يعني أنها مناسبة لكل من المهام الأساسية والهدف، بدلاً من المهمة المحددة للمهمة الأساسية.

5-7-1 طريقة النموذج المدرب مسبقاً

1- تحديد النموذج المصدر: يتم اختيار نموذج مصدر مدرب مسبقاً من النماذج المتاحة بحيث تطلق العديد من المؤسسات البحثية نماذج على مجموعات بيانات كبيرة وصعبة يمكن تضمينها في مجموعة النماذج المرشحة للاختيار من بينها.

2- إعادة استخدام النموذج: يمكن استخدام النموذج الذي تم تدريبه مسبقاً كنقطة انطلاق لنموذج في مهمة ثانية. قد يشمل ذلك استخدام النموذج بالكامل أو أجزاء منه، اعتماداً على تقنية النمذجة المستخدمة.

3- ضبط النموذج: قد يحتاج النموذج إلى تكيفه أو تعديله على بيانات الإدخال والإخراج المتاحة للمهمة الهدف.

ولكن يمكن أن يتساءل الباحثون هنا ما مقدار المساعدة التي يمكن أن يساعدها التعلم بالنقل فعلياً، قمنا بالإجابة على هذا السؤال فيما يتعلق بتصنيف مجموعة البيانات الخاصة بالصور الشعاعية الطبية التي ذكرناها في بند عينة البيانات المدروسة.

يعتبر التعلم بالنقل تحسين، اختصار لتوفير الوقت أو الحصول على أداء أفضل. وبشكل عام، ليس من الواضح أنه ستكون هناك فائدة من استخدام التعلم بالنقل في المجال إلا بعد تطوير النموذج وتقييمه.

5-7-2 طرق التعلم بالنقل

تبين أن التعلم عن طريق النقل هو وسيلة فعالة لتقديم الشبكات ذات الأداء الجيد في التصنيف لحل مشاكل التصنيف العملية بشرط محدودية حجم البيانات ومع ذلك، فإن شبكات CNN العميقة الحديثة مصممة بشكل عام للتعرف على الأشياء على نطاق واسع.

لذلك، في الخطوة الأولى من التعلم بالنقل، يجب استبدال الطبقة المتصلة بالكامل التي تحتوي على n خلية عصبونية بطبقة تحوي عدد محدد من الخلايا العصبونية لتلبية احتياجات التصنيف المحددة (الخاصة بدراستنا هنا).

يعتمد ما إذا كان ينبغي تطبيق تقنية التجميد أو الضبط الدقيق على عدد البارامترات التي سيتم تدريبها وعلى حجم البيانات المتاحة للدراسة.

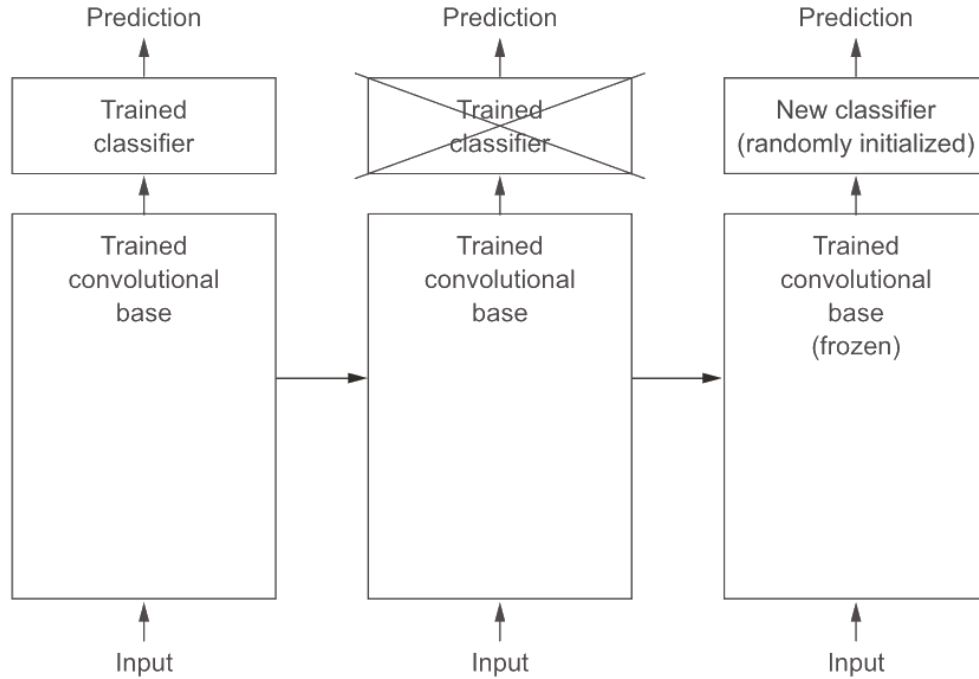
للتمييز بين الأداء المختلف لهاتين التقنيتين، استخدمنا كلتا الطريقتين عند نقل الشبكات الأساسية بسبب غموض حجم البيانات وكذلك عدد البارامترات التي سيتم تدريبها. بالنظر إلى التصنيف الثنائي في حالتنا، فقد استبدلنا جميع الطبقات المتصلة بالكامل في الشبكات الأساسية بخلية عصبونية واحدة. لذلك، تم إعادة تدريب ثلاث طبقات عليا فقط، بما في ذلك الطبقة المتصلة بالكامل، وطبقة softmax، وطبقة التصنيف عندما قمنا بتجميد الطبقات التي تسبق الطبقة المتصلة بالكامل أثناء إعادة تدريب الشبكات بأكملها من خلال عدد صغير من الفترات لضبط البارامترات في حالة الدقة.

5-7-3 الاستراتيجيات المعتمدة في التعلم بالنقل

تتم معالجة مهمة تصنيف الصور الموضحة سابقاً من خلال تبني الطريقتين الشائعتين اللتين يتم استخدامهما بشكل شائع عند تطبيق التعلم بالنقل باستخدام شبكات CNN المدربة مسبقاً، وهما استخراج الميزات والضبط الدقيق.

1- استخراج الميزات / Feature Extraction

يتكون استخراج الميزات أساساً من أخذ القاعدة التلافيفية لشبكة مُدَرَّبَة مسبقاً، وتشغيل البيانات المستهدفة من خلالها وتدريب مُصنّف جديد على الناتج (أي الاستفادة من الشبكة أو النموذج المُدَرَّب مسبقاً والاستفادة من الميزات منها في تدريب شبكة أو نموذج جديد لمسألة تصنيف جديدة)، كما هو موضح في الشكل الآتي:



الشكل (5-17) توضيح تطبيق استخراج الميزات على شبكة عصبونية تلافيفية، بحيث يتم تبديل المصنفات بينما يتم الاحتفاظ بنفس القاعدة التلافيفية [55]

ملاحظة: تعني كلمة "مجمد" في كتلة المصنف الجديد أن الأوزان لم يتم تحديثها أثناء التدريب.

يمكن أن يكون المصنف المكس أعلى القاعدة التلافيفية إما مجموعة من الطبقات المتصلة بالكامل أو مجرد طبقة تجميع global واحدة، يتبعها طبقة كثيفة مع تابع تنشيط softmax.

اعتماداً على ما ورد في الدراسات السابقة عموماً فإنه لا توجد قاعدة محددة بشأن نوع المصنف الذي يجب اعتماده، ولكن كما تم وصفه في [56]، يؤدي استخدام طبقة Global Pooling واحدة بشكل عام إلى تقليل التخصيص وذلك نظراً لعدم وجود بارامترات للتحسين في هذه الطبقة.

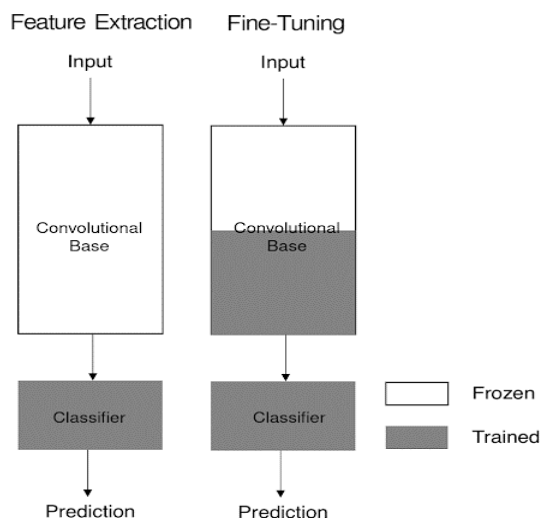
وبالتالي، ولأن مجموعات التدريب المستخدمة في التجارب صغيرة نسبياً، فإن المصنّف المختار يتكون فقط من طبقة تجميع متوسط global واحدة يتم تغذية المخرجات مباشرة في طبقة تنشيط softmax والتي تنتج الاحتمالات لكل فئة من فئات التصنيف المدروسة.

يتم تحديث أوزان المصنفات العليا فقط أثناء التدريب، بينما يتم "تجميد" أوزان القاعدة التلافيفية وبالتالي الاحتفاظ بها دون تغيير. بهذه الطريقة، يتعلم المصنّف الضعيف كيفية تصنيف الصور إلى فئتين من التمثيلات الجاهزة التي تعلمها مسبقاً نموذج المصدر لمجالها. وإذا كان المصدر والمجال الهدف متشابهين، فمن المحتمل أن تكون هذه التمثيلات مفيدة للمصنّف ويمكن أن تؤدي المعرفة المنقولة بالتالي إلى تحسين أدائها بمجرد تدريبها.

2- الضبط الدقيق / Fine Tuning:

يمكن النظر إلى التكوين المثالي أو الضبط الدقيق على أنه خطوة مختلفة على عكس استخراج الميزات التي تتكون من إعادة تدريب اختياري لبعض الطبقات العليا للقاعدة التلافيفية المستخدمة سابقاً لاستخراج الميزات. وبهذه الطريقة، يتم تعديل التمثيلات الأكثر تجريداً للنموذج المصدر التي تعلمتها طبقاته الأخيرة بشكل طفيف لجعلها أكثر صلة بالمشكلة الهدف (أو المشكلة المدروسة).

يمكن تحقيق ذلك من خلال إلغاء تجميد بعض الطبقات العليا للقاعدة التلافيفية، والحفاظ على تجميد جميع طبقاتها الأخرى وتدريب القاعدة الالتفافية بشكل مشترك باستخدام المصنّف نفسه المستخدم سابقاً لاستخراج الميزات، كما هو موضح في الشكل أدناه.



الشكل (5-18) مقارنة استخراج الميزات بالضبط الدقيق

من المهم الإشارة إلى أنه وفقاً لـ [55]، لا يمكن ضبط الطبقات العليا لقاعدة تلافيفية مُدربة مسبقاً إلا إذا كان المصنّف الموجود فوقها قد تم تدريبه مسبقاً بالفعل. والسبب هو أنه إذا لم يكن المصنّف مدرباً بالفعل، فسيتم تهيئة أوزانه بشكل عشوائي. نتيجة لذلك، ستكون إشارة الخطأ التي تنتشر عبر الشبكة أثناء التدريب كبيرة جداً وسيتم تحديث الأوزان غير المجمدة لتعطيل التمثيلات المجردة التي تعلمتها القاعدة التلافيفية سابقاً.

ولأسباب مشابهة، يوصى أيضاً بإجراء الضبط الدقيق باستخدام معدل تعلم أقل من المعدل المستخدم لاستخراج الميزات.

والجدير بالذكر أن السبب وراء إلغاء تجميد الطبقات العليا فقط هو أن الطبقات السفلية تشير إلى ميزات عامة مستقلة عن المشكلة، بينما تشير الطبقات العليا إلى الميزات المعتمدة على المشكلة والتي ترتبط بشكل أكبر بالمجال المحدد والذي تم تدريب الشبكة في الأصل من أجله. وبالتالي، فإن الميزات التي تعلمتها الطبقات الأولى مناسبة بشكل عام لمعالجة مجموعة واسعة من المجالات، في حين أن الميزات التي تعلمتها الطبقات العليا تحتاج إلى تعديل لكل مجال محدد [50].

5-8 مقارنة التعلم التقليدي بالتعلم بالنقل

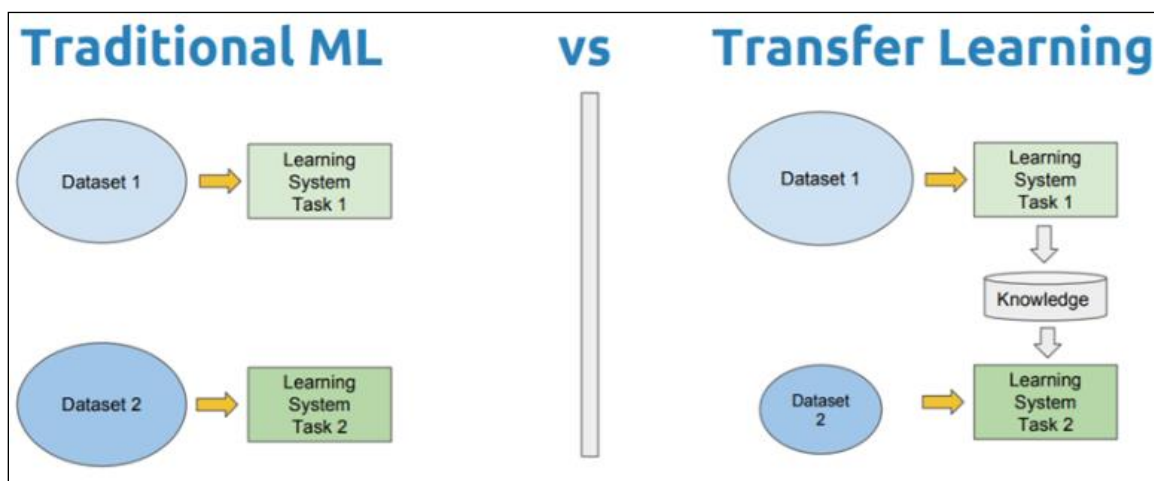
تتعرف خوارزميات التعلم الآلي التقليدية على الأنماط في البيانات وتقوم بالتنبؤات للبيانات الجديدة. يتم تصميم خوارزميات تعلم الآلة التقليدية لتعلم مهام محددة، وبالتالي يجب إعادة بناء النماذج من الصفر لمهام جديدة وتدريبه وهذا يتطلب الوقت والمال. أي أن النماذج تعمل بمعزل عن غيرها، فعند إعطائها مجموعة بيانات، فإنها تتعلم كيفية أداء مهمة محددة، إلا أنها عند تكليفها بحل مشكلة جديدة، لا يمكنها اللجوء إلى أي معرفة مكتسبة مسبقاً. وإنما تحتاج هذه الخوارزميات التقليدية إلى مجموعة بيانات ثانية لبدء عملية تعلم جديدة. كما تتطلب أيضاً معظم خوارزميات التعلم الآلي كميات هائلة من البيانات. فغالباً ما تحتاج نماذج التعلم العميق إلى ملايين نقاط البيانات لتوليد نتائج مرضية.

وبالرغم أن التعلم العميق تلقى تقديراً كبيراً في مجال الذكاء الصناعي، إلا أنه يعاني من ناحية البيانات الضخمة والمتطلبات الزمنية.

ظهر حديثاً التعلم بالنقل والذي يعمل على تحسين التعلم في مهمة جديدة من خلال نقل المعرفة من مهمة ذات صلة تم تعلمها بالفعل مسبقاً، مثلاً يمكن تدريب الخوارزمية التي تعلمت كيفية التعرف على الكلاب على التعرف على القطط بسهولة عن طريق نقل بعض المفاهيم المجردة. ففي التعلم بالنقل، يعتمد تعلم المهام الجديدة على المهام التي تم تعلمها مسبقاً، بحيث يمكن للخوارزمية تخزين المعرفة والوصول إليها لاحقاً وبالتالي يمكننا القول إن النموذج عام وليس محدد مثل النماذج التقليدية.

بالتالي يزيد التعلم بالنقل من سرعة التعلم مع وجود عدد أقل من الأشياء الجديدة التي يجب تعلمها، وتكون الخوارزمية أسرع في إنتاج مخرجات عالية الجودة. كما أنه يقلل من كمية البيانات المطلوبة. في التعلم التقليدي كما أشرنا سابقاً، يمكن للخوارزمية أن تتعلم فقط عندما يتم تزويدها ببيانات تدريب كافية، وأحياناً ملايين نقاط

البيانات. وقد لا تكون هذه البيانات متاحة على الإطلاق أو قد تكون مكلفة للغاية لإنشاء النموذج والتحضير له.



الشكل (5-19) مقارنة التعلم التقليدي بالتعلم العميق

9-5 التعلم التجميعي (Ensemble Learning)


التعلم التجميعي أو التعلم القائم على المجموعات أو تعلم أنظمة التصنيف المتعددة وبتعريف هذا التعلم فهو مفهوم استخدام نماذج عصبونية أو نماذج تدريب متعددة معاً لإنشاء خوارزمية أكثر دقة من الخوارزمية الأصلية التي تعمل بمفردها. ويعتبر أحد الحلول الملاءمة لبناء نماذج تصنيف قوية ودقيقة [57]. فبدلاً من استخدام خوارزمية واحدة لبناء نموذج، يتم استخدام طرق المجموعات بشكل واسع لبناء مجموعة من المصنفات والجمع بينها، سواء كانت هذه المصنفات ضعيفة أو قوية، وتسمى هذه المجموعة مجموعة المتعلمين الأساسيين. تتعلق النقاط الأساسية لفعالية طريقة التجميع بالاختيار الدقيق لكل من المتعلمين الأساسيين [58] وطريقة الدمج لإنتاج النتيجة النهائية. ومن طرق الدمج الشهيرة وشائعة الاستخدام، نذكر:

- حساب المتوسط (البسيط أو الموزون)
- التصويت (الأغلبية، الإجماع، التعددية، أو حتى الأصوات الموزونة)

9-5-1 خوارزميات تعلم المجموعات شائعة الاستخدام

Bagging/ التعبئة:

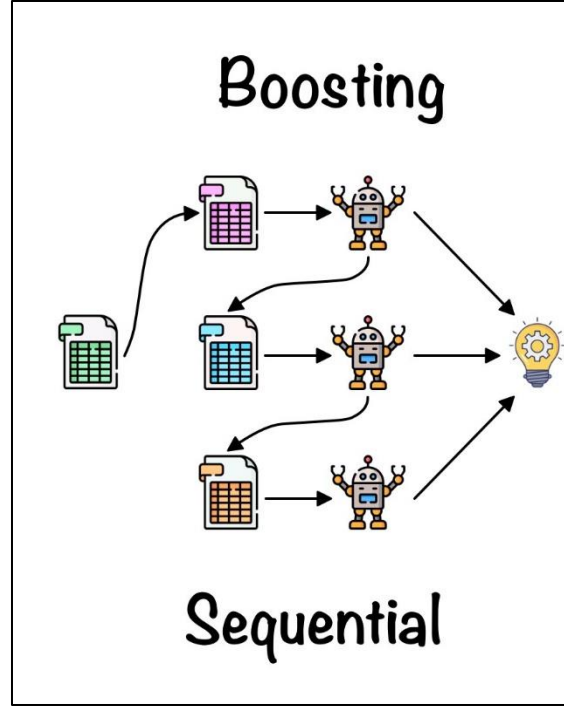
هي واحدة من أقدم الخوارزميات المبنية على المجموعات وأكثرها سهولة وربما أبسطها، مع أداء جيد (Breiman 1996)[59]. يتم الحصول على تنوع المصنفات في التعبئة باستخدام نسخ متماثلة لبيانات التدريب. بحيث يتم الحصول على مجموعات فرعية مختلفة من بيانات التدريب بشكل عشوائي (مع الاستبدال) من مجموعة بيانات التدريب بأكملها. يتم استخدام كل مجموعة فرعية من بيانات التدريب لتدريب مصنف مختلف من نفس النوع. يتم بعد ذلك دمج المصنفات الفردية عن طريق التصويت بالأغلبية البسيطة لقراراتهم. بالنسبة لأي حالة، فإن التصنيف الذي يختاره أكبر عدد من المصنفات هو قرار المجموعة.



الشكل (5-20) شكل توضيحي لعمل خوارزميات Bagging

Boosting / التعزيز :

يتم إنشاء مجموعة من المصنفات من خلال إعادة تجميع البيانات، والتي يتم دمجها بعد ذلك عن طريق التصويت بالأغلبية. بحيث يتم توجيه عملية إعادة التشكيل بشكل استراتيجي لتوفير بيانات التدريب الأكثر إفادة لكل مصنف متتالي. كل تكرار للتعزيز يقوم بإنشاء ثلاث مصنفات ضعيفة: المصنف الأول C_1 يتم تدريبه بمجموعة فرعية عشوائية من بيانات التدريب المتاحة. يتم اختيار المجموعة الفرعية لبيانات التدريب للمصنف الثاني C_2 على أنها المجموعة الفرعية الأكثر فائدة، بالاعتماد على C_1 . بحيث يتم تدريب C_2 على بيانات التدريب التي تم تصنيف نصفها فقط بشكل صحيح بواسطة C_1 ، والنصف الآخر مصنف بشكل خاطئ. يتم تدريب المصنف الثالث C_3 مع الحالات التي يختلف عليها C_1 و C_2 . وفي النهاية يتم الجمع بين المصنفات الثلاثة من خلال تصويت الأغلبية الثلاثة.



الشكل (5-21) شكل توضيحي لعمل خوارزميات Boosting

:AdaBoost

يمكن القول إن AdaBoost (Adaptive Boosting) هي من أكثر الخوارزميات القائمة على المجموعات شهرةً ولها العديد من الأنواع، مثل AdaBoost.M1 لمسائل التصنيف، AdaBoost.M2 للمصنفات الضعيفة، AdaBoost.R لمشاكل regression.

Stacked Generalization / التعميم المكسب:

في التعميم المكسب Wolpert (أو التكديس)، يتم تدريب مجموعة من المصنفات أولاً باستخدام عينات من بيانات التدريب، وإنشاء مصنفات المستوى الأول، والتي تُستخدم مخرجاتها بعد ذلك لتدريب مصنفات الطبقة الثانية (Wolpert 1992)[60]. الفكرة الأساسية هي معرفة ما إذا تم تعلم بيانات التدريب بشكل صحيح. على سبيل المثال، إذا تعلم مصنف معين بشكل غير صحيح منطقة معينة من مساحة الميزة، وبالتالي أخطأ باستمرار في تصنيف الحالات القادمة من تلك المنطقة، فقد يكون مصنف المستوى الثاني قادراً على تعلم هذا السلوك بالتعاون مع السلوكيات المكتسبة للمصنفات الأخرى، وبالتالي يمكنه تصحيح مثل هذا التدريب غير المناسب. يتم تقسيم مجموعة بيانات التدريب بأكملها إلى T كتلة، ويتم تدريب كل مصنف من المستوى الأول بدايةً على مجموعة مختلفة من $T-1$ كتلة من بيانات التدريب. ثم يتم تقييم كل مصنف على الكتلة T (الاختبار

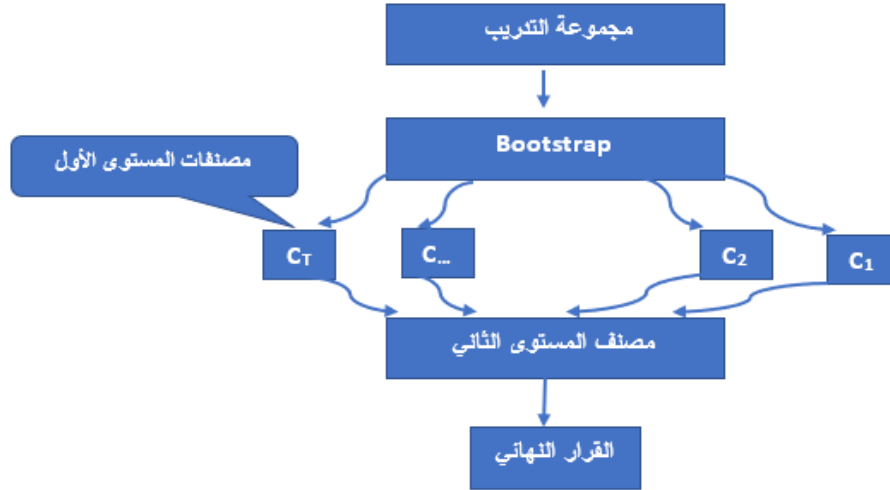
(الزائف)، ولا يتم رؤيته أثناء التدريب. تشكل مخرجات هذه المصنفات على كتل التدريب الزائفة مع الـ Labels الصحيحة الفعلية لتلك الكتل مجموعة بيانات التدريب لمصنف المستوى الثاني.

يمكننا تخيل إجراء التكديس على أنه يحتوي على مستويين، هما:

- المستوى الأول: بيانات هذا المستوى هي بيانات دخل مجموعة التدريب التي يتم بناء مستوى التنبؤ الأول من خلالها.

- المستوى الثاني: بيانات المستوى الثاني تأخذ مخرجات نماذج المستوى الأول كمدخلات، ويقوم النموذج الوحيد في هذا المستوى (أو المتعلم الفوقي / meta-learner) بتعلم عمل تنبؤات من هذه البيانات.

نوضح في الشكل الآتي آلية عمل التعميم المكّس:



الشكل (5-22) توضيح التعميم المكّس

Stacked Generalization Ensemble / مجموعة التعميم المكّس:

المجمّع هو نموذج يحسب المتوسط للتنبؤات من عدة نماذج مدربة، ويتمثل أحد قيود هذا النهج هو أن كل نموذج يساهم بنفس المقدار في تنبؤ المجموعة، بغض النظر عن مدى جودة أداء النموذج.

أحد أشكال هذا النهج يُطلق عليه اسم مجموعة المتوسط الموزون (Weighted Average Ensemble) يقوم بوزن مساهمة كل عضو في المجموعة من خلال الثقة أو الأداء المتوقع للنموذج على عينة بيانات محددة. وهذا يسمح للنماذج ذات الأداء الجيد بالمساهمة أكثر من النماذج ذات الأداء الأقل. يوفر نموذج مجموعة المتوسط الموزون تحسناً على نموذج مجموعة المتوسط العادي.

التحسين الآخر الذي يمكن تقديمه لهذا النهج هو استبدال نموذج المجموع الموزون الخطي (مثل الانحدار الخطي) المستخدم لدمج تنبؤات النماذج الفرعية بخوارزمية تعلم. وهذا النهج يسمى التعميم المكّس (التكديس).

في التكديس، تأخذ خوارزمية التعلم مخرجات النماذج الفرعية كمدخلات وتحاول تعلم أفضل طريقة تجمع بين تنبؤات الإدخال للحصول على تنبؤ خرج أفضل ما يمكن.

5-9-2 أهمية نموذج التعلم التجميعي

يكون عادةً نموذج التعلم التجميعي أكثر تعقيداً من استخدام نموذج واحد للتعلم الآلي، وقد يتطلب هذا أسلوباً أكثر تعقيداً لإعداد النموذج، وموارد حسابية أكثر لتدريب النموذج، ومع ذلك، يمكن القول إنه لدينا سببان لاستخدام خوارزميات تعلم المجموعات، وهما:

متانة أفضل: تقدم العديد من خوارزميات التعلم الآلي تنبؤات مختلفة في كل مرة يتم فيها تدريب النموذج على نفس البيانات أو حتى على بيانات مختلفة قليلاً. يشار إلى هذا باسم التباين في التنبؤات أو استقرار النموذج. يمكن أن تعطي خوارزميات التعلم التجميعي تنبؤات أكثر استقراراً من نموذج واحد.

تنبؤات أفضل: هناك بعض المجالات ومهام التنبؤ يكون الأداء التنبؤي هو الأكثر أهمية من أي شيء آخر. وهذا هو الحال بشكل خاص في التعلم الآلي التنافسي حيث تكون المهارة التنبؤية هي النتيجة الوحيدة التي يتم أخذها في الاعتبار وهذا ما توفره خوارزميات التعلم التجميعي فهي توفر مهارة تنبؤية أفضل من استخدام نموذج واحد.

تُستخدم المجموعات بشكل شائع لتثبيت التنبؤات التي قدمتها نماذج التعلم العميق بالنظر إلى كل من الطبيعة العشوائية لبنية النموذج التي تمت تهيئتها باستخدام أوزان عشوائية.


يشير تنوع المجموعة إلى الاختلافات في التنبؤات أو أخطاء التنبؤ التي تحدثها النماذج التي تساهم في المجموعة. ومن الناحية المثالية، سيكون كل عضو في المجموعة مستقلاً، ما يعني أنه سيقدم تنبؤات بطريقة مختلفة تماماً عن جميع أعضاء المجموعة الآخرين إلا أن هذا غير ممكن لأن لدينا مجموعة بيانات تدريب واحدة فقط.

تشير طرق التجميع إلى الطريقة المحددة التي يتم بها استخدام الخرج من كل عضو في المجموعة لإجراء التنبؤ النهائي. يمكن أن يتضمن ذلك استخدام طريقة إحصائية بسيطة كوسيلة للتصويت، على الرغم من أنه قد يتضمن وزن التنبؤات بمهارة النموذج المساهم أو حتى استخدام نموذج آخر لمعرفة أفضل طريقة للجمع بين التنبؤات.

10-5 خاتمة

قدمنا في هذا الفصل دراسة للنماذج المستخدمة في بحثنا، حيث قمنا بدراسة خطوات عمل كل نموذج مع ميزات ومساوئه.

ونعرض في نهاية هذا الفصل مخططاً يوضح مدى انتشار استخدام بعض الشبكات والنماذج المستخدمة في البحث (من بداية 2015 وحتى تاريخ إعداد هذا البحث)، ويظهر الاهتمام المتزايد بشبكات ResNet في السنوات الأخيرة:



الشكل (5-23) مدى انتشار استخدام الشبكات والنماذج المستخدمة في البحث (من بداية 2015 وحتى تاريخ إعداد هذا البحث)

الفصل السادس: الإطار العملي

(عينة البيانات المستخدمة وتجهيزها)

1-6 مقدمة

حسب الاحصائيات الأخيرة المتوفرة في مجال الحالات المتعلقة بمجال بحثنا (الصور الشعاعية) فإن أمراض العضلات والعظام تؤثر على أكثر من 1.7 مليار شخص في جميع أنحاء العالم، وهي السبب الأكثر شيوعاً للألم والإعاقة الشديدة وطويلة الأجل، بحيث تزداد 30 مليون زيارة لقسم الطوارئ سنوياً وتزايد بسبب هذا النوع من الحالات [42][48].

مهمة الكشف عن المرض، أو بمعنى آخر تحديد ما إذا كانت دراسة التصوير الشعاعي طبيعية أو غير طبيعية، هي عملية صعبة ومهمة بحيث تعتبر دراسة تفسر على أنها تستبعد المرض بشكل طبيعي ويمكن أن تلغي حاجة المرضى للخضوع لمزيد من الإجراءات التشخيصية أو التدخلات.

2-6 صنع القرار الطبي

قمنا في بحثنا بتطبيق صنع القرار في المجال الطبي التشخيصي لصور الأشعة، تتمثل المهمة الحاسمة لأخصائي الأشعة في تحديد ما إذا كانت الدراسة (الحالة المدروسة) غير طبيعية. أما إذا كانت الدراسة طبيعية، يكون المريض خالياً من المرض ولا يتعين عليه الخضوع لمزيد من الإجراءات التشخيصية، ولكن إذا لم يكن الأمر كذلك، فقد يحتاج المريض إلى مزيد من التقييم إذا تم اكتشاف حالة غير طبيعية. ويعد اكتشاف الشذوذ العضلي الهيكلي مهماً بشكل خاص لأن الحالات العضلية الهيكلية هي السبب الأكثر شيوعاً للإعاقة والألم الشديد طويل الأمد، حيث يتأثر أكثر من 1.7 مليار شخص في جميع أنحاء العالم بأكثر من 30 مليون زيارة سنوية للطوارئ [42].

توفير طريقة آلية للكشف عن الشذوذ في الأشعة السينية للعظام لها تطبيقات سريرية مهمة. أولاً، يمكن استخدامها لتحديد أولويات قائمة العمل. وفي هذا السياق، يمكن إعطاء الأولوية للحالات التي تعتبر غير طبيعية بحيث يحصل المريض ذو الحالة الأشد خطورة على الرعاية أولاً. ثانياً، يمكن أن تساعد في مكافحة إجهاد أخصائي الأشعة. يقرأ أطباء الأشعة في جميع أنحاء العالم عدداً كبيراً من الحالات مع المزيد من الصور لكل حالة، وتتفاقم المشاكل في المجتمعات التي تعاني من نقص الكوادر المختصة. كما يمكن أن يؤثر التعب على دقة التشخيص، كما يتضح من نتائج دراسة تم إجراؤها وجدت أن هناك انخفاضاً ذا دلالة إحصائية في

اكتشاف الكسور في نهاية يوم العمل مقارنة ببداية يوم العمل [61]. يمكن للأداة التي يمكنها توضيح الخلل في الصورة أن تلفت انتباه أخصائي الأشعة، مما قد يقلل الأخطاء ويسرع تفسير الصور ويساعد في توحيد جودة التشخيص.

يواجه منهج التعلم الآلي لهذه المشكلة تحديين:

التحدي الأول هو البيانات: فمن أجل إنشاء نموذج يمكنه اكتشاف وتحديد مكان الشذوذ في الأشعة السينية للعظام بدقة عالية، يحتاج النموذج إلى التدريب على مجموعة كبيرة من الصور الشعاعية للعضلات الهيكلية، والتي يصعب الحصول عليها.

التحدي الثاني هو إيجاد منهج التعلم الآلي المناسب الذي يمكنه تصنيف البيانات بدقة عالية (مجال عملنا كان على هذا التحدي لتوفير النهج المناسب والذي توصلنا إليه لتصنيف الحالات المدروسة).

تم الاستفادة من خوارزميات الذكاء الصناعي والتعلم الآلي والتعلم العميق في إنشاء نموذج تشخيصي تم تدريبه على مجموعة واسعة من الصور والحالات للحصول على قرارات تشخيصية.

نتحدث أيضاً عن نظام دعم القرار السريري ((CDSS (Clinical Decision Support System) ويُعرف بأنه نظام لتكنولوجيا المعلومات للرعاية الصحية يتم تصميمه لأخذ المدخلات من مصادر سريرية مختلفة لتزويد الطبيب بالدعم في صنع القرار. كما تم تعريفه على أنه نظام معرفة نشط يستخدم عناصر متعددة من بيانات المريض لتوليد مشورة خاصة بكل حالة. ويتكون CDSS النموذجي من:

- قاعدة المعرفة: تحتوي على قواعد لربط البيانات المجمعة (قواعد if-then).
- محرك الاستدلال: يجمع القواعد من قاعدة المعرفة مع قواعد المريض.

ويوجد نوع آخر من CDSS لا يستخدم قاعدة معرفية ولكنه يعتمد على AI / ML للتعلم من التجارب السابقة والعثور على الأنماط في البيانات السريرية دون الحاجة إلى كتابة القواعد أو تقديم مدخلات الخبراء.

نقترح هنا نموذجاً لنظام صنع قرار طبي تشخيصي باستخدام بيانات سريرية للمرضى في العالم الحقيقي بهدف مساعدة الأطباء والمتدربين وتشجيعهم في تشخيصهم. بالإضافة إلى ذلك، يمكن للأطباء الذين يعملون في مواقع نائية استخدام النظام المقترح من أجل الحكم بشكل أكثر دقة على تشخيص معين.

3-6 عينة البيانات (مسابقة MURA)

نشرت مجموعة التعلم الآلي في جامعة ستانفورد ورقة بحثية [48] تتعلق بمشكلة تصنيف الصور الشعاعية الطبية وقدمت واحدة من أكبر مجموعة بيانات صور شعاعية عامة في العالم تسمى MURA. MURA هي

اختصار للتصوير الشعاعي العضلي الهيكلي (Musculoskeletal Radiographs). استخدمت مجموعة ML بجامعة ستانفورد خوارزمية DenseNet169 لتدريب شبكة عصبونية عميقة يمكنها الكشف عن التشوهات في الصور الشعاعية بدقة أقرب إلى كبار أطباء الأشعة.

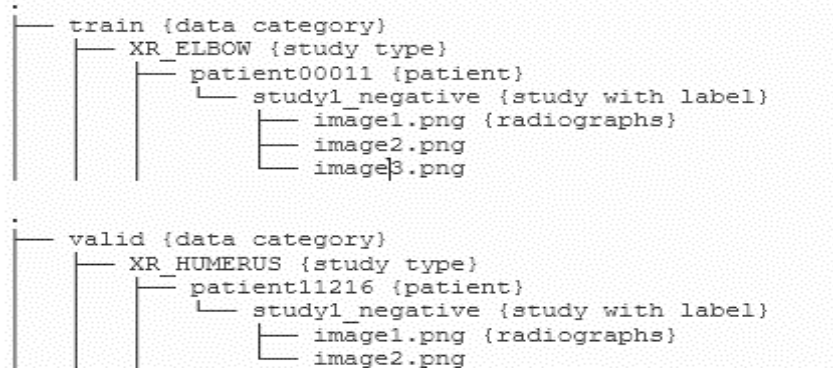
وكان الهدف من مسابقة MURA هو تصنيف كل دراسة إلى طبيعية أو غير طبيعية (تنبؤات ثنائية)، وليس كل صورة. وكان أفضل أداء في جامعة ستانفورد.

نعمل من خلال دراستنا على عينة البيانات هذه MURA Dataset، وهي مجموعة بيانات كبيرة للكشف عن التشوهات في التصوير الشعاعي العضلي الهيكلي تتألف من 14863 دراسة (وتحتوي كل دراسة على واحد أو أكثر من المشاهدات (الصور)) من 12173 مريضاً، بإجمالي 40,561 صورة شعاعية متعددة الرؤية. تحتوي مجموعة البيانات على 9,045 دراسة طبيعية و5818 دراسات شعاعية عضلية هيكلية غير طبيعية [48].

ينتمي كل منها إلى واحد من سبعة أنواع من الدراسات التصويرية للأطراف العلوية: الكوع، الإصبع، الساعد، العضد، الكتف والمعصم واليد. تم تصنيف كل دراسة يدوياً على أنها طبيعية أو غير طبيعية من قبل أطباء الأشعة المعتمدين من مستشفى ستانفورد بين 2001 و2012.

وفي الدراسة التي قدمتها جامعة ستانفورد تم تقسيم مجموعة البيانات إلى ثلاث مجموعات: مجموعة التدريب (11184 مريض، 13457 دراسة، 36808 صورة)، مجموعة التحقق (783 مريض، 1199 دراسة، 3197 صورة)، ومجموعة الاختبار (206 مريض، 207 دراسة، 556 صورة). كما أنه لا يوجد تداخل في المرضى بين أي من المجموعات.


أما في أغلب الدراسات التي تمت على نفس عينة البيانات فإنها تنقسم الصور إلى 36808 صورة تدريبية و3197 صورة للتحقق منها. بحيث تأتي عينة البيانات كمجموعة بيانات منقسمة إلى مجموعتين: مجموعة التدريب ومجموعة الاختبار في مجلدات منفصلة. كل مجموعة من مجموعات البيانات (التدريب الاختبار) لها مجلدات فرعية (كما في الشكل (6-1))



الشكل (1-6) طريقة تقسيم عينة البيانات المدروسة

كما نرى من الشكل أنه يتم تقسيم البيانات ضمن المجموعتين المذكورتين سابقاً (في مجلد منفصل لكل مجموعة منها)، كما أنه يوجد مجلد خاص بكل فئة من الفئات السبعة والمذكورة أيضاً، ضمن كل فئة يوجد مجلد خاص لكل مريض (حالة دراسة مستقلة) ويتم تحديد حالة الدراسة مع وضع الـ label أو التصنيف لها، بحيث أن التصنيفين المحددين هما positive و negative، وضمن المجلد الخاص بحالة الدراسة هناك مجموعة من المشاهدات (الصور).

كما نقدم بعض الأمثلة في الشكل الآتي.



إحدى الدراسات لحالة دراسة مع صور متنوعة (Abnormal - الصورة من جهة اليمين وحالة Normal - الصورة من جهة اليسار) لعظم الكوع




إحدى الدراسات لحالة دراسة مع صور متنوعة (Abnormal - الصورة من جهة اليمين وحالة Normal - الصورة من جهة اليسار) لعظم الأصابع

الشكل (2-6) مجموعة من حالات الدراسة في عينة البيانات المستخدمة في البحث

5-6 تحليل إحصائي لعينة البيانات

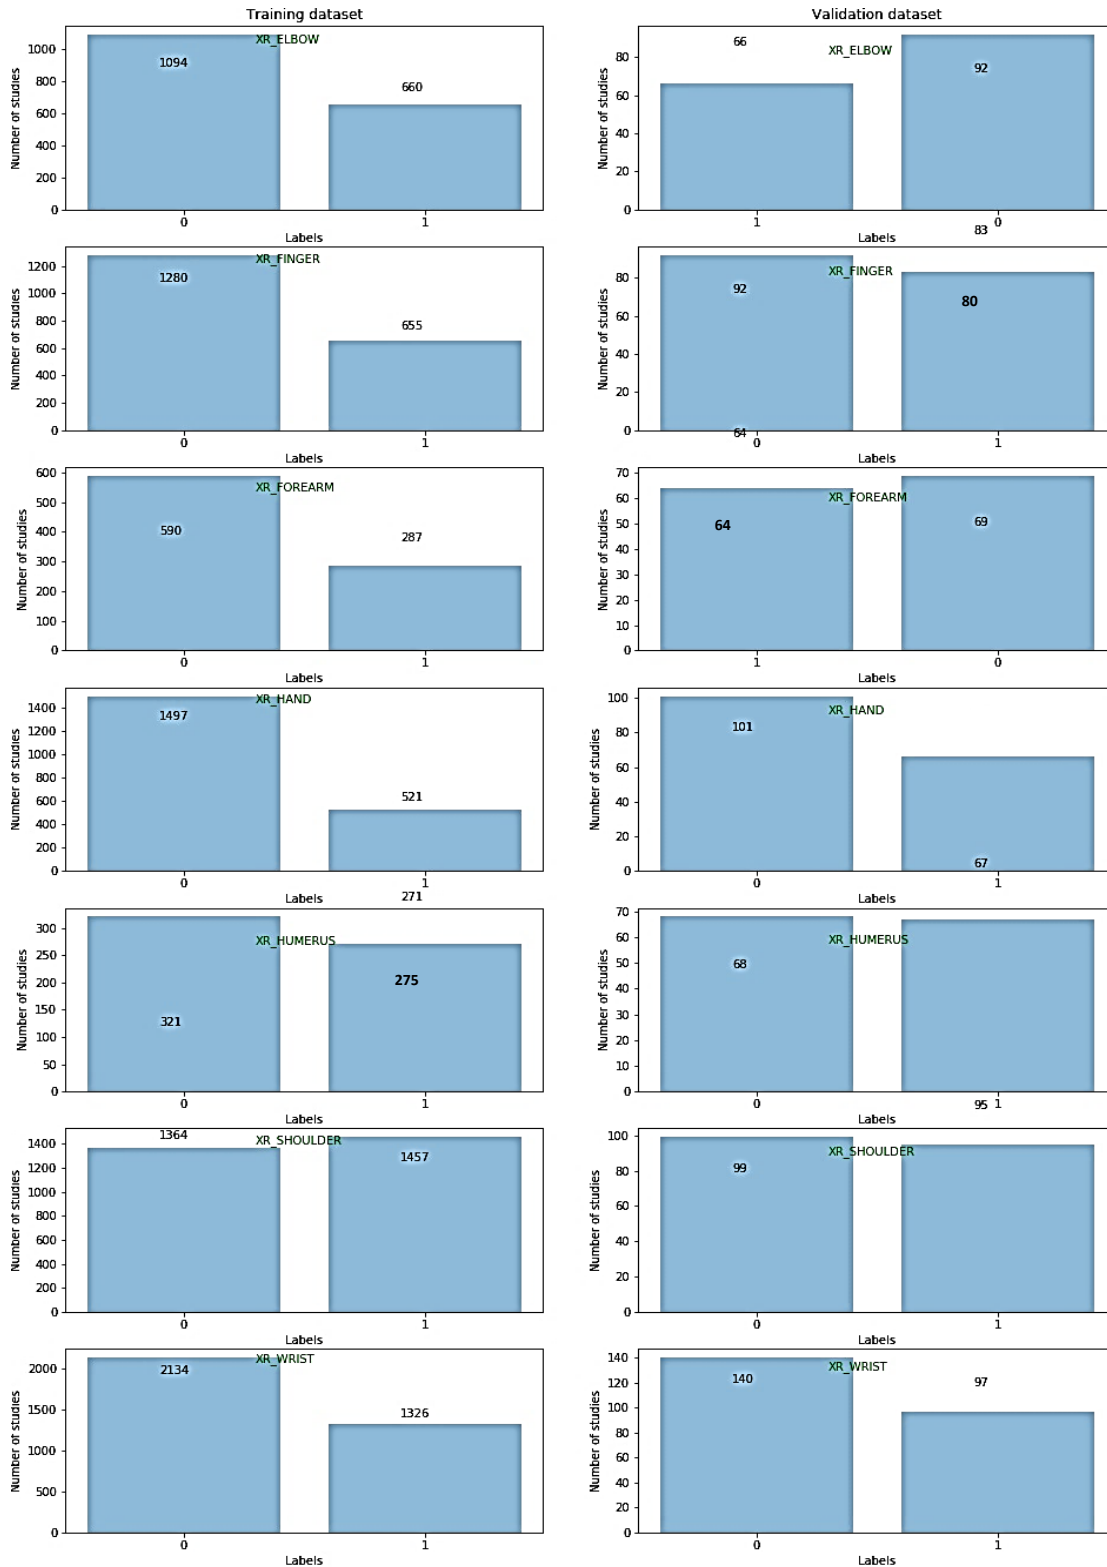
للتحقق من أنواع التشوهات الموجودة في مجموعة البيانات، تمت مراجعة تقارير أخصائي الأشعة لتمييز 100 دراسة غير طبيعية يدوياً مع اكتشاف الشذوذ: بحيث تم تصنيف 53 دراسة بالكسور، و48 دراسة مع الأجهزة، و35 دراسة مع أمراض تنكسية، و29 دراسة مع تشوهات أخرى، بما في ذلك الآفات والخلع الفرعي [48].

تم التعامل مع مجموعة البيانات من خلال إنشاء نوعين من البيانات الوصفية. واحدة تحتوي على معلومات لكل صورة مع التصنيف الخاص بها ونوع الدراسة. والأخرى تحتوي على كل نوع من أنواع الدراسة والتصنيف وعدد الصور كي يتمكن من رسم البيانات لفهم الخصائص المختلفة لها.



الشكل (3-6) مخطط إحصائي يمثل عدد المرضى في كل فئة من الفئات السبعة المحددة في نوعي عينة البيانات (التدريب الاختبار)

نرى في الشكل بيانات كل أنواع الدراسة ونلاحظ أن نوع المعصم يحتوي على أكبر عدد من البيانات مقارنة بأنواع الدراسة الأخرى ولكن لا يوجد اختلاف كبير في أحجام بيانات الاختبار بين أنواع الدراسة.

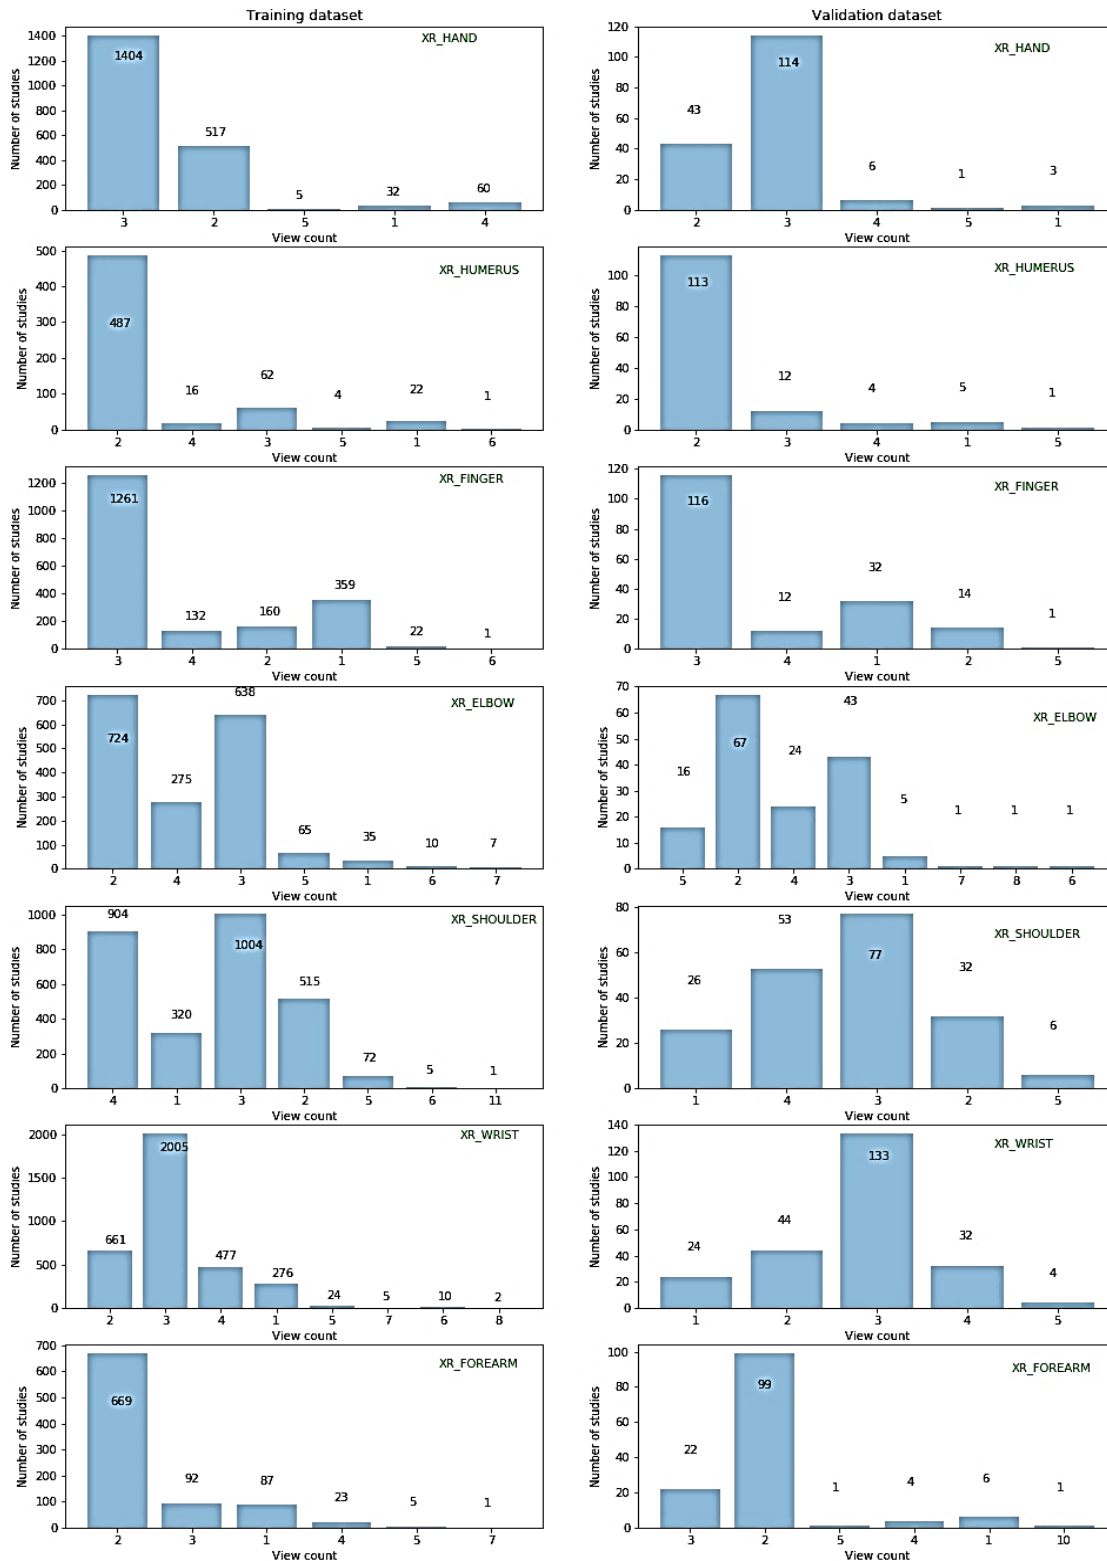


الشكل (4-6) توزيع أعداد الدراسات في كل دراسة (على مستوى المريض)

يتطلب التشخيص في بعض الأحيان دراسات متعددة عن الصور الشعاعية المختلفة. تمت ملاحظة أن أكثر من 90% من الحالات يحتاج المريض فيها إلى دراسة واحدة فقط. ومع ذلك، فمن الممكن أيضاً أن تتضمن كل دراسة صوراً شعاعية متعددة. قد يحتاج المريض إلى أخذ صور إشعاعية متعددة خلال كل دراسة اعتماداً على مدى تعقيد المشكلة.

استنتجنا من خلال دراسة عينة البيانات وتحليلها بشكل دقيق أن أنواع الدراسة "الساعد والكتف واليد والمعصم والإصبع" تحتوي على 3 صور لكل دراسة في معظم دراساتهما، كما يحتوي نوع الدراسة "الكوع" على صورتين لكل دراسة في معظم دراساتهما.

يوضح الشكل الآتي عدد الدراسات في كل نوع من الأنواع المدروسة مع عدد الصور (views) في كل دراسة.



الشكل (5-6) توزيع التصنيف في البيانات لكل أنواع الدراسة

6-6 المعالجة المسبقة للبيانات

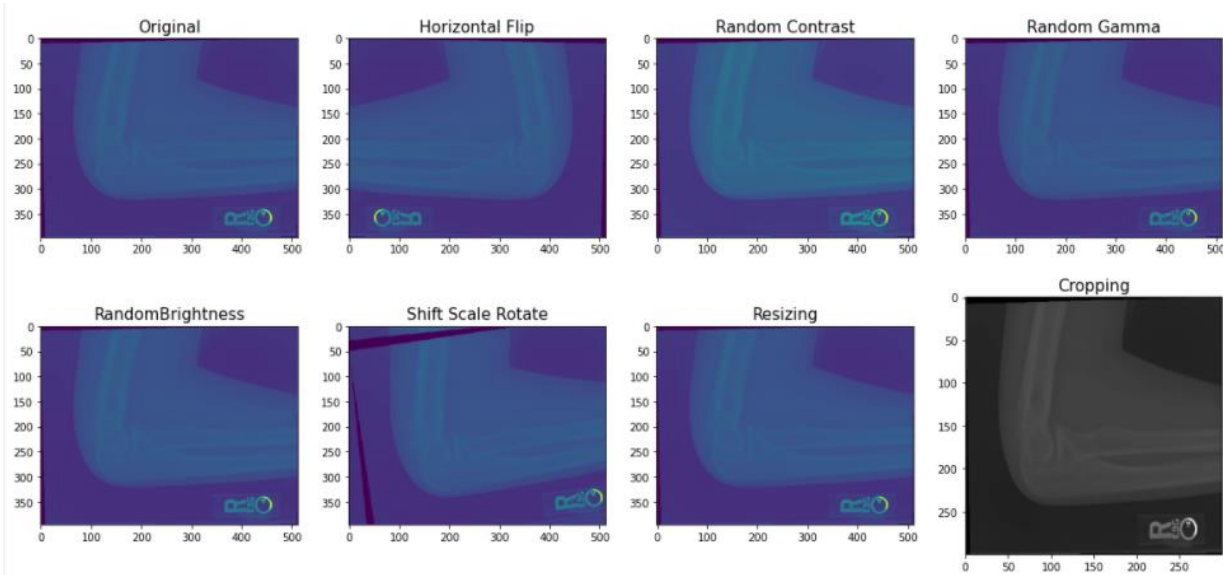
قمنا بتطبيق توسعة (Augmentation) لزيادة حجم البيانات، وتجنب فرط التلاؤم والوصول إلى نموذج أكثر عمومية.

يتم عادةً تطبيق العديد من إجراءات التعزيز مثل الدوران العشوائي، والانعكاس الأفقي، والانعكاس الرأسي.

قمنا بمعالجة كل صورة بحيث يكون لها نفس المتوسط الانحراف المعياري للصور في مجموعة التدريب ImageNet، تم استخدام صور متغيرة الحجم وتحويلها لحجم ثابت $224 \times 224 \times 3$. كما قمنا بزيادة البيانات أثناء التدريب عن طريق تطبيق بعض التحويلات باستخدام ImageDataGenerator، وما قمنا بتطبيقه فعلياً هو (Horizontal Flip, Random Contrast, Random Gamma, Random Brightness, Shift Scale Rotate, Resizing, Cropping)


كما اعتمدنا على $\text{Batch Size} = 32$ وفقاً لنتائج التجريب باستخدام عدة أحجام لـ batch وكان الأنسب بينها الحجم 32 لبعض النماذج المستخدمة في الدراسة.

يوضح الشكل الآتي مثال على نتائج التحويلات المطبقة على إحدى الصور:




الشكل (6-6) مثال على نتيجة تطبيق تحويلات المعالجة المسبقة للبيانات على صورة من عينة البيانات (Data Augmentation)

```
0    8280
1    5177
Name: Train_Label, dtype: int64
```




```
0    21935
1    14873
Name: Train_Label, dtype: int64
```




العدد الفردي (التفصيلي) لتصنيفات الصور في مجموعة التدريب - عدد التصنيفات في عينة بيانات التدريب كاملة (عدد الدراسات)

```
0    661
1    538
Name: Valid_Label, dtype: int64
```



```
0    1667
1    1530
Name: Valid_Label, dtype: int64
```




العدد الفردي لتصنيفات الصور في مجموعة الاختبار - عدد التصنيفات في مجموعة الاختبار (عدد الدراسات)

الشكل (6-7) مخططات إحصائية لعينة الدراسة (عدد الدراسات وعدد الصور في كل من بيانات التدريب وبيانات الاختبار)

7-6 خاتمة

قمنا في هذا الفصل بدراسة مفصلة وتوضيح كامل لعينة البيانات المستخدمة، كما قمنا بعرض إحصائيات للأنواع الموجودة فيها. ونعرض في نهاية الفصل عدد الأوراق البحثية المعتمدة على عينة البيانات والمنشورة خلال السنوات الأخيرة (وفقاً للإحصائيات التي يقدمها موقع paperswithcode.com).



الشكل (6-8) عدد الأوراق البحثية المعتمدة على عينة البيانات MURA

سنقوم في الفصل السابع بالاستفادة من الدراسة المقدمة في الفصول الأولى من خلال تطبيق النماذج المقترحة على عينة البيانات المدروسة كما وسنقدم شرحاً عن الإطار العملي للدراسة.

الفصل السابع: الإطار العملي (الطرق المقترحة والنماذج المستخدمة)

7-1 مقدمة

درسنا في الفصول السابقة كلاً من الذكاء التجميعي وعملية صنع القرار كل منها على حدة، كما قدمنا دراسة لمجموعة من النماذج المبنية على الشبكات العصبونية والشبكات العصبونية التلافيفية بشكل خاص، كما عرضنا أيضاً مجموعة من خوارزميات التعلم الآلي التي سيتم استخدامها في تطبيق الطرق المقترحة على المشكلة المدروسة.

تجمع مجموعة التعلم التجميعي بين العديد من المصنفات التي تستخدم خوارزميات مختلفة للحصول على تنبؤات ممتازة من خلال دمج الميزات من العديد من التصميمات العميقة في مصنف جديد.

بالعودة إلى المجال العملي للدراسة فإن توفر أداة تلقائية لتصنيف الصور يمكن أن يوفر رأياً ثانياً وذا قيمة وأهمية بالنسبة للأطباء العاملين في غرف الطوارئ في المستشفيات كما ويمكن أن يقلل من معدل الخطأ في التشخيص. في هذه الدراسة عملنا على الحصول على أفضل أداء الشبكات العصبونية التلافيفية الحديثة الحالية باستخدام تقنيات تعلم المجموعات (أو التعلم التجميعي). بحيث يتم استخدام شبكات CNN (الشبكات العصبونية التلافيفية) المختلفة لتصنيف الصور، وبدلاً من اختيار الأفضل بينها من ناحية الأداء (وفق معايير معينة)، نقوم بتجميع نتائج الشبكات من خلال تقنيات التعلم التجميعي للحصول على مصنف أكثر قوة. ونعرض في النتائج كيف يتفوق نموذج المجموعة على نتائج نماذج CNN الفردية.

7-2 الإطار المقترح ومراحل تطبيقه

لعبت مجموعات البيانات الكبيرة والعالية الجودة دوراً مهماً في دفع عجلة التقدم في مجالات التعليم العميق. كما تساعد Ensemble Learning في تحسين نتائج التعلم الآلي من خلال الجمع بين عدة نماذج لتحسين الأداء التنبؤي مقارنة بنموذج واحد.

تعمل الطريقة المقترحة على دمج نتائج نماذج التعلم الآلي والتعلم العميق التي تم العمل عليها في إطار التعلم التجميعي المقترح للحصول على نتائج جيدة في عملية التشخيص الطبي بالاستفادة من مجموعات البيانات المتوفرة.

نقترح من خلال الدراسة نموذجين لدمج النماذج المستخدمة في البحث باستخدام التعلم التجميعي. تعمل النماذج المقترحة كذلك باستخدام التعلم بالنقل، والضبط الدقيق، والضبط الفائق/ Meta جميعها في تصميم واحد. حققت نماذج التعلم التجميعي المقترحة أداءً أفضل من النماذج الفردية على مجموعة البيانات المستخدمة في البحث.

كما تم العمل في هذا الفصل على تطبيق دراسة عملية تجريبية لعدة نماذج لشبكات CNN عميقة وكبيرة من ناحية عدد الطبقات (تم شرح النماذج في الفصل الخامس). وبالاستفادة من تقنية التعلم بالنقل قمنا بتطبيق دراستنا على عينة البيانات الرسمية (تفاصيل أكثر عن عينة البيانات تم توضيحها في الفصل السادس)،

7-2-1 تطبيق التعلم بالنقل

تتكون المهمة المختارة لتجربة التعلم بالنقل من تصنيف صور شعاعية طبية لسبعة أنواع مفاصل وعظام في الجسم إلى فئتين. يرجع اختيار هذه المهمة بشكل أساسي إلى توفر هذه المجموعة من البيانات، بالإضافة إلى مجال المشكلة، وهو عام بما يكفي ليكون مناسباً للتطبيق الفعال للتعلم بالنقل مع الشبكات العصبونية المدربة مسبقاً على مجموعة بيانات ImageNet الشهيرة.

7-2-1-1 مواد وطرق البحث

قمنا بتطبيق عدد من نماذج التعلم بالنقل المتوفرة من خلال تدريب نموذج لكل منها ثم قمنا بمقارنة أداء هذه النماذج وأخصائيي الأشعة (والذي تم أيضاً إعطاؤهم الصور وقاموا بتصنيفها يدوياً، حيث قام 6 من أخصائيي الأشعة بالعمل على ذلك وفقاً للورقة البحثية الخاصة بالبيانات المنشورة) [48].

أردنا أن تحقق الطريقة المقترحة أداءً مشابهاً لأداء أطباء الأشعة، كما أردنا تحقيق تحسين في دقة التصنيف باستخدام التعلم بالنقل والتعلم التجميعي من خلال الإطار المقترح.

7-2-1-2 الإعداد التجريبي للإطار المقترح

نعرض في هذا القسم تفاصيل النتائج التجريبية للنماذج المستخدمة إضافةً إلى مناقشة التحسينات التي أدخلتها هذه النماذج، باستخدام التعلم التجميعي، ونقل التعلم، في المنهجية المقترحة.

الآلية المستخدمة في تقسيم البيانات وتوسعتها (Data Augmentation):

كما ذكرنا سابقاً عن البيانات المدروسة وتصنيفها إلى فئتين وفقاً للتسميات المقدمة من اختصاصي الأشعة. قمنا بتقسيم 80% بشكل عشوائي في مجموعة التدريب (Train Set) من مجموعة البيانات بالكامل، بينما بقي الجزء الباقي 20% في مجموعة الاختبار (Test Set). ملاحظة: السبب الذي جعلنا نحتفظ بـ 80 % من مجموعة البيانات كمجموعة تدريب هو أننا اتبعنا قاعدة الاستبعاد (Exclusion Rule)، التي تقسم 80% من مجموعة البيانات الكاملة كمجموعة تدريب بينما يتم استخدام البيانات المتبقية كمجموعة اختبار.

قاعدة الاستبعاد في تقسيم البيانات:

وفقاً لـ Andrew Ng، في Coursera MOOC on Introduction to Machine Learning، تتمثل القاعدة في تقسيم مجموعة البيانات إلى نسبة 3:1:1 (60:20:20) للتدريب والتحقق من الصحة والاختبار على التوالي. فعندما يحتوي المصنف على بارامترات يجب تعيينها، يمكن تقسيم مجموعة البيانات إلى 3 أجزاء (التدريب والتحقق والاختبار) بحيث يمكن ضبط البارامترات مع تجنب فرط التلاؤم. عند تدريب نظام التعلم على عينات البيانات، قد لا نعرف إلى أي مدى يمكنه التنبؤ بالعينات غير المرئية بشكل صحيح، لذلك يتم إجراء مفهوم التحقق (Cross Validation) لتعديل البارامترات المستخدمة للتدريب من أجل تحسين دقتها وإلغاء تأثير فرط التلاؤم على تلك البيانات. ولا ينبغي أن يتم ذلك في مجموعة الاختبار نفسها، وبالتالي علينا الفصل بين مجموعة الاختبار ومجموعة التحقق من الصحة. في الحالات التي لا ينطبق فيها التحقق، من الشائع فصل البيانات بنسبة 8:2 (80:20) للتدريب والاختبار على التوالي.

لتقدير القدرة التنبؤية الفعلية للمصنف (على سبيل المثال، الدقة/accuracy)، عادةً ما نأخذ 5 fold cross-validation. أي سيكون هناك 5 مجموعات حسابات لتقدير القوة التنبؤية للمصنف، مع كل حساب يتم استخدام قسم مختلف (20%) كمجموعة اختبار والـ 80% المتبقية كمجموعة تدريب. يتم أخذ متوسط نتيجة هذه الحسابات الخمسة كأفضل تقدير للقدرة التنبؤية للمصنف.

في بعض الأحيان، عندما تكون مجموعة البيانات كبيرة بما فيه الكفاية (مثل حالة الدراسة لدينا)، فإن إجراء التحقق من الصحة بمقدار 5 مجموعات سيستغرق وقتاً طويلاً. لذلك فمن المقبول عادةً تقسيم

مجموعة البيانات الكبيرة إلى 80% للتدريب و20% للاختبار ، ويتم أخذ النتائج في مجموعة الاختبار كتقدير لأداء المصنف عند نشره لتصنيف بيانات جديدة.

بيئة التكوين:

قمنا بتطوير جميع التجارب وتنفيذها على منصة Google Colaboratory السحابية باستخدام Keras مع TensorFlow, ومن ثم تم التعامل أيضاً مع منصة Kaggle لما تقدمه من ميزات للتعامل مع نماذج الشبكات العصبونية أيضاً وبسبب القيود التي بدأت تفرضها منصة Google Colab من حيث محدودية الموارد المتاحة وتحديد موارد الجلسة الواحدة وتقييد مدتها.

Colaboratory أو Colab اختصاراً ، هو أحد منتجات Google Research ، والذي يسمح للمطورين بكتابة وتنفيذ كود Python من خلال متصفحهم. يعد Google Colab أداة ممتازة لمهام التعلم العميق. كما يعتبر فعلياً كإصدار متخصص من Jupyter Notebook، والذي يعمل على السحابة ويوفر موارد حوسبة مجانية مثل GPUs وTPU.

هناك عدة أسباب لاختيار استخدام Google Colab بدلاً من Jupyter Notebook العادي، وأهمها:

- وجود مكتبات مثبتة مسبقاً (Keras, TensorFlow, and PyTorch مثلاً).
- يتم الحفظ على السحابة (يتم حفظ جميع دفاتر Google Colab ضمن حساب Google Drive، تماماً مثل ملفات Google Docs وGoogle Sheets).
- التعاون (وهي ميزة أخرى يقدمها Colab فإذا كان العمل مع مطورين متعددين في مشروع ما، فمن الأفضل استخدام Colab. تماماً مثل التعاون في مستند محرّر مستندات Google، كما يمكن البرمجة المشتركة مع مطورين متعددين باستخدام Colab notebooks).
- استخدام GPU وTPU مجاناً (تتيح Google Research استخدام وحدات معالجة الرسومات (GPU) و (TPU) المخصصة لمشاريع التعلم الآلي كون رفع أداء GPU وTPU يحدثان فرقاً كبيراً حتى في المشاريع الصغيرة) من حيث السرعة والأداء.

أما بالنسبة لمنصة Kaggle فهي تابعة لشركة Google LLC، وهي مجتمع عبر الإنترنت لعلماء البيانات وممارسي التعلم الآلي. يسمح Kaggle للمستخدمين بالعثور على مجموعات البيانات ونشرها، واستكشاف

النماذج وإنشائها في بيئة علم البيانات المستندة إلى الويب، والعمل مع علماء البيانات الآخرين ومهندسي التعلم الآلي، والدخول في مسابقات لحل تحديات علوم البيانات. وقد كانت بدايتها في عام 2010 من خلال تقديم مسابقات التعلم الآلي وتقدم الآن أيضاً منصة بيانات عامة وبيئة عمل قائمة على السحابة (cloud-based workbench) لعلوم البيانات وتعليم الذكاء الصناعي.

خدمات Kaggle (إضافةً إلى الخدمات التي يقدمها Colab):

- مسابقات التعلم الآلي: كانت أول منتج لشركة Kaggle، بحيث تنشر الشركات المشكلات ويتنافس المتسابقون لبناء أفضل خوارزمية، عادةً ما تكون بجوائز نقدية قيّمة.
- Kaggle Kernels: وهي بيئة عمل قائمة على السحابة لعلوم البيانات والتعلم الآلي، تسمح لعلماء البيانات بمشاركة الكود والتحليل في Python و R و R Markdown، وقد تمت مشاركة أكثر من 150 ألف نواة على Kaggle تغطي عدة مشاريع ومواضيع هامة.
- منصة لمجموعات البيانات العامة: يشارك أعضاء مجتمع Kaggle مجموعات البيانات مع بعضهم البعض. ونجد على هذه المنصة مجموعات بيانات عن كل شيء.
- Kaggle Learn: وهي منصة لتعليم الذكاء الصناعي.

إعداد البارامترات:

لمقارنة أداء الطرق المختلفة للتعلم بالنقل، قمنا بتعيين نفس البارامترات لكل الطرق المستخدمة من دون مواصفات خاصة، البارامترات هي: معدل التعلم الأولي 0.0001 ويتناقص تدريجياً ليصل إلى قيمة 0.000000001، عدد الفترات القصوى هو 100 (Epochs=100) فترة لنماذج شبكات DenseNet أما لنماذج شبكات ResNet فكان عدد الفترات الأعظمي هو 43 (Epochs=43). تم الاعتماد على هذا العدد من الدورات بالنسبة لشبكات ResNet كون أداء النماذج فيها أسرع فقد تم الوصول لدقة تصنيف ممتازة بعدد دورات أقل بعد التجريب على عدد 100، 50 دورة.

كما تم التعامل مع Adam Optimizer من بين مجموعة خوارزميات التحسين المتوفرة أثناء تدريب الشبكات العصبونية، وهي: Gradient Descent, Stochastic Gradient Descent, Mini-Batch Gradient Descent, Adaptive Gradient Descent, Momentum, Nesterov Accelerated Gradient, AdaDelta, Adaptive Moment Estimation (Adam)

خوارزميات التحسين عبارة عن خوارزميات أو طرق يتم استخدامها لتغيير سمات الشبكة العصبونية مثل الأوزان ومعدل التعلم من أجل تقليل الخسارة، وبالتالي خوارزمية التحسين الصحيحة سوف تقلل من وقت التدريب بشكل كبير.

تم اختيار خوارزمية التحسين Adam Optimizer بسبب سرعتها فهي تتقارب بشكل سريع وبالتالي تقلل وقت التدريب بشكل ملحوظ، كما أنها تقوم بتصحيح تلاشي معدل التعلم والتباين العالي.

نماذج شبكات التعلم التي قمنا بالعمل عليها هي النماذج الآتية:

نماذج DenseNet هي: DenseNet121, DenseNet201

نماذج ResNet هي: Resnet152, Inception-Resnet-v2

كما عملنا أيضاً على نموذج Inception v3 ونموذج VGG16.

ويصبح مجموع النماذج ستة نماذج تم تجربتها وتقييم أدائها بشكل فردي بداية ومن ثم بشكل تجميعي وفق خوارزميات التعلم التجميعي (تم تطبيق اثنتين منها في البحث) التي تم اختيار تطبيقها على هذه النماذج وعينة البيانات المستخدمة وتقييم أدائها في النهاية.

3-1-2-7 مقاييس ومعايير تقييم النتائج

تقييم الأداء

قمنا بتقييم أداء النماذج المدروسة على مجموعة الاختبار الذي تم تعيينه لكل أنواع الدراسة ومقارنتها معاً كما تمت مقارنتها بنموذج المجموعة (القسم التالي). تم إنشاء نموذج المجموعة باستخدام النماذج الثلاثة لنوع الدراسة (العقد). تمت مقارنة الأداء باستخدام مقياس الدقة ومقياس كابتا.

- مقياس دقة التصنيف (Classification Accuracy metric)

هي نسبة عدد التنبؤات الصحيحة إلى العدد الإجمالي لعينات الإدخال.

$$Accuracy = \frac{\text{Number of Correct Predictions}}{\text{Total number of predictions made}}$$

- مقياس كوهين كابتا (Cohen's kappa statistic)

المقياس المستخدم في مسابقة MURA ليس هو الدقة الكلاسيكية، ولكن درجة kappa أو مقياس كابتا. وهو مقياس أكثر قوة من الدقة البسيطة، لأنه يأخذ في الاعتبار إمكانية حدوث الاتفاقية عن طريق الصدفة بطرحها من الاتفاقية الملاحظة.

ما هو مقياس كوهين كابا؟

يقيس كوهين كابا الاتفاق بين اثنين من المقيمين (مصنّفين) يصنف كل منهما عناصر N إلى فئات (classes) مستقلة بشكل متبادل. هناك طريقة بسيطة للتفكير في ذلك وهي أنه مقياس كمي للاعتمادية لاثنتين من المقيمين الذين يصنفون نفس الشيء، ويتم تصحيحه وفقاً لعدد المرات التي قد يتفق فيها المقيّمون عن طريق الصدفة.

تقييم كوهين كابا:

يمكن أن تكون قيمة kappa أقل من 0 (سالبة). تعني الدرجة 0 أن هناك اتفاقاً عشوائياً بين المقيمين، في حين أن الدرجة 1 تعني أن هناك اتفاقاً تاماً بين المقيمين. لذلك، فإن الدرجة الأقل من 0 تعني أن هناك اتفاقاً أقل من فرصة عشوائية.

		Rater 2	
		Correct	Incorrect
Rater 1	Correct	A	B
	Incorrect	C	D

الشكل (1-7) شبكة $N \times N$ المستخدمة لتفسير نتائج المقيمين

تقسم الشبكة في الشكل إلى الأجزاء الآتية:

- A: إجمالي عدد الحالات التي قال كلا المقيمين إنها صحيحة، أي أن المقيمين متفقون.
- B: العدد الإجمالي للحالات التي قال Rater 2 إنها غير صحيحة ، لكن Rater 1 قال إنها صحيحة. وهذه تمثل حالة خلاف.
- C: العدد الإجمالي للحالات التي قال Rater 1 إنها غير صحيحة ، لكن Rater 2 قال إنها صحيحة. وهذه تمثل أيضاً حالة خلاف.
- D: إجمالي عدد الحالات التي قال كلا المقيمين إنها غير صحيحة، أي أن المقيمين متفقون.

$$kappa_{score} = \frac{Agree - ChanceAgree}{1 - ChanceAgree}$$

صيغة مقياس كابا

4-1-2-7 سيناريوهات التجارب ومناقشة النتائج العملية

الموارد المستخدمة في Google Colab:

كان التعامل بداية في أجهزة الكمبيوتر مع وحدة المعالجة المركزية CPU، ثم GPU، والآن TPU، وذلك بسبب نمو صناعة التكنولوجيا ومحاولة إيجاد طرق جديدة لاستخدام أجهزة الكمبيوتر، ما زاد الحاجة إلى أجهزة أسرع.

الفرق بين CPU و GPU و TPU هو أن وحدة المعالجة المركزية تتعامل مع جميع المنطق والحسابات والدخل/الخرج للكمبيوتر، وهي معالج للأغراض العامة. أما GPU هو معالج إضافي لتحسين الواجهة الرسومية وتشغيل المهام المتطورة.


أما TPUs فهي معالجات قوية مصممة خصيصاً لتشغيل المشروع المصمم على إطار عمل محدد، مثل TensorFlow.

يتوفر Tesla K80 فقط في Colab من نوع GPU كما نرى.

```
[name: "/device:CPU:0"
device_type: "CPU"
memory_limit: 268435456
locality {
}
incarnation: 18391302539150292526
xla_global_id: -1, name: "/device:GPU:0"
device_type: "GPU"
memory_limit: 11320098816
locality {
  bus_id: 1
  links {
  }
}
incarnation: 1491595498639744146
physical_device_desc: "device: 0, name: Tesla K80, pci bus id: 0000:00:04.0, compute capability: 3.7"
xla_global_id: 416903419]
```

-كما يتوفر TPUv2 فقط في Colab من نوع TPU كما نرى في الشكل 2-7

```
Timestamp: 08:47:20
TPU type: TPU v2
Utilization of TPU Matrix Units (higher is better): 0.000%
```



Cloud TPU v2
180 teraflops
64 GB High Bandwidth Memory (HBM)

الشكل (2-7) معالج TPuv2 المتوفر في Google Colab

1- تطبيق نموذج DenseNet201:

التدريب:

تمت تهيئة الشبكة بأوزان من نموذج شبكة DenseNet201 تم تدريبه مسبقاً على عينة البيانات الشهيرة ImageNet، وتم تدريب الشبكة من طرف إلى طرف باستخدام Adam Optimizer مع البارامترات الافتراضية. تم تدريب الشبكات لكل نوع من أنواع الدراسة بشكل منفصل بحيث تم تطبيق نموذج التعلم بالنقل على عينة البيانات المدروسة على كل نوع بشكل مستقل (أي التطبيق على فئة المعصم بشكل مستقل، على فئة الأصابع بشكل مستقل... الخ) وبعدد مرات 100 لكل نوع من الأنواع، كما قمنا بمتابعة تدريب النموذج على عينة البيانات كاملةً دون فصل الأنواع بشكل مستقل، وقمنا بتسجيل النتائج لكل الحالات المدروسة. ونعرضها في القسم الآتي:

ملاحظات حول النتائج:

نوضح في الجدول أدناه نتائج المقارنة (من ناحية دقة التصنيف)، التي قمنا بإجرائها بين نتائج الورقة البحثية ونتائج دراستنا لتطبيق التعلم بالنقل على تصنيف الصور الشعاعية الطبية [48].

نلاحظ من الجدول أننا حصلنا على نتائج أفضل (دقة) في أغلب حالات الدراسة ضمن عينة البيانات-لاحظنا أن أفضل تحسين في قيمة الدقة كانت بالنسبة لنوع HUMERUS (العضد)، كما أننا قمنا بإجراء تدريب للنموذج على عينة البيانات كاملةً بغض النظر عن نوع الدراسة (تدريب لكل الصور في عينة البيانات)، بحيث وصلنا إلى دقة تصل 82% تقريباً وهي نسبة مقبولة نوعاً ما مقارنة بالدقة التي حصلنا عليها لكل نوع بشكل مستقل، كون بعض حالات الدراسة أعطت دقة أقل من 82% مثل حالة SHOULDER (الكتف) و FINGER (الاصبع) و HAND (اليَد) أما الأنواع الأربعة الباقية أعطت نتائج بدقة أعلى.


جدول (1-7) مقارنة نتائج تقييم نموذج DenseNet201 على عينة البيانات مع نتائج الورقة البحثية المذكورة

نوع الدراسة	دقة تصنيف نموذج DenseNet201 المنقول	دقة التصنيف في المرجع
المعصم	0.862	0.86
الكوع	0.8778	0.85
العضد	0.8819	0.82
الكتف	0.7964	0.79
إصبع اليد	0.7969	0.78
الساعد	0.8194	0.77
اليد	0.7969	0.73
الكل	0.8191	-


نلاحظ من جدول المقارنة بين النتائج التي حصلنا عليها بتطبيق التعلم بالنقل من خلال شبكة DenseNet201 والنتائج التي حصل عليها الباحثون في المرجع المعتمد لعينة البيانات أننا حصلنا على دقة أعلى في كل أنواع الدراسة وكان فرق الدقة التي حصلنا عليها في نوع العضد الأفضل بين الأنواع الأخرى فقد كان تحسين الدقة من 82% إلى 88%, كما نلاحظ التحسين الثاني والذي يعتبر تحسناً قوياً هو في نوع اليد بحيث أننا حصلنا على دقة بنسبة 79% مقابل دقة 73% كانت في نتائج المرجع, كما حصلنا على تحسين في الأنواع الأخرى ولو كان بنسبة غير عالية جداً كما في النوعين المذكورين.

قمنا أيضاً بتدريب النموذج على عينة البيانات كاملة بغض النظر عن نوع الدراسة وحصلنا على دقة تقارب 82% وهي تعتبر نسبة جيدة خاصة أنها تفوقت على بعض الحالات الخاصة المدروسة مثل الإصبع والكتف اللتين حققتا نسبة 79% تقريباً.


نوضح في الشكل الآتي نتائج تدريب نموذج DenseNet201 على عينة البيانات لكل أنواع الدراسة.




1




2




3




4



5



6



7

الشكل (7-2) نتائج تدريب وتقييم النموذج DenseNet201 على عينة البيانات لكل أنواع الدراسة

(1- الكوع 2- الاصبع 3- الساعد 4- اليد 5- العضد 6- الكتف 7- المعصم)

نلاحظ من الشكل 7-2 في نوع الدراسة (الكوع) أن دقة التدريب استمرت في التصاعد واقتربت من الدقة المثالية أثناء الاستمرار في التدريب إلى 100 دورة بحيث وصلت إلى 98% في نوع الكوع، بينما وصلت دقة الاختبار إلى 87.78%، بحيث بدأت بقيمة صغيرة 72% من ثم تصاعدت ووصلت لدقة 87.78% والتي قمنا بتسجيلها عند الدورة 75 ولم تتجاوز هذه الدقة في الدورات الباقية.

في نوع العضد لاحظنا أن دقة التدريب استمرت في التصاعد واقتربت من الدقة المثالية أثناء الاستمرار في التدريب إلى 100 دورة ووصلت إلى حوالي 97%، حيث دقة الاختبار بدأت بقيمة صغيرة 68% من ثم تصاعدت ووصلت لدقة 88% التي قمنا بتسجيلها عند أكثر من نقطة (دورة).

كما نبين في الجدول الآتي زمن التدريب لنموذج DenseNet201 لكل نوع من أنواع الدراسة:

جدول (7-2) زمن تدريب نموذج DenseNet201 على عينة البيانات لكل نوع من أنواع الدراسة	
نوع الدراسة	زمن تدريب نموذج DenseNet201 المنقول (مقدراً بالثانية) لكل دورة تدريب (Epoch)
المعصم	133
الكوع	68
العضد	20
الكتف	112
إصبع اليد	72
الساعد	29
اليد	78

2- تطبيق نموذج DenseNet121:


تم تطبيق نموذج التعلم بالنقل المقترح من خلال تدريبه كما قمنا بتخزين أوزان النموذج، فبدلاً من العمل على الأوزان العشوائية، بدأنا بالأوزان المستفادة من النموذج المدرب مسبقاً على مهمة مختلفة (مهمة تصنيف الصور في ImageNet). وكون المهمة الجديدة مختلفة عن المهمة المدربة، تم تجاهل الطبقة الأخيرة (أو حتى الأجزاء الأكبر من الشبكة مثلما تكلمنا عنها في قسم تعديل النموذج المدرب سابقاً).

تم تدريب الشبكة باستخدام Adam Optimizer مع البارامترات الافتراضية. استخدمنا حجم $batch = 8$ ومعدل التعلم 0.0001 (تم التدريب باستخدام أكثر من حجم $batch$, إلا أن حجم 8 أعطى النتائج الأفضل، كما تم العمل على معدل تعلم مختلف وكانت القيمة 0.0001 أعطت أفضل النتائج)


قمنا بتدريب الشبكات لكل أنواع الدراسة بشكل منفصل بحيث قمنا بتطبيق نموذج التعلم بالنقل على عينة البيانات المدروسة على كل نوع بشكل مستقل (أي التطبيق على فئة المعصم بشكل مستقل، على فئة الأصابع بشكل مستقل... الخ) وبعدد مرات 115 لكل الأنواع، كما قمنا بمتابعة تدريب النموذج على عينة البيانات كاملةً دون فصل الأنواع بشكل مستقل، وقمنا بتسجيل النتائج لكل الحالات المدروسة. ونعرضها في الجدول الآتي:

جدول (3-7) مقارنة نتائج تقييم نموذج DenseNet121 على عينة البيانات مع نتائج الورقة البحثية المذكورة		
نوع الدراسة	دقة تصنيف نموذج DenseNet121 المنقول	دقة التصنيف في المرجع
المعصم	0.8552	0.86
الكوع	0.8556	0.85
العضد	0.875	0.82
الكتف	0.7946	0.79
إصبع اليد	0.808	0.78
الساعد	0.8472	0.77
اليَد	0.7946	0.73
الكل	0.8207	-


نعرض في هذا القسم مخططات تعرض نتائج تدريب وتقييم النموذج على عينة البيانات لكل أنواع الدراسة:




1




2




3




4



5



6



7

الشكل (3-7) نتائج تدريب وتقييم النموذج DenseNet121 على عينة البيانات لكل أنواع الدراسة

(1- الكوع 2- الاصبع 3- الساعد 4- اليد 5- العضد 6- الكتف 7- المعصم)

نلاحظ من المخططات عموماً أن دقة التدريب استمرت في التصاعد واقتربت من الدقة المثالية أثناء الاستمرار في التدريب إلى 115 دورة (عدد الدورات الذي تم اختياره للتدريب)، وبالتفصيل:

وصلت دقة التدريب إلى 98% في نوع Elbow (الكوع) بينما وصلت دقة الاختبار إلى 85.6%، بحيث بدأت بقيمة صغيرة 72% من ثم تصاعدت ووصلت لدقة 85.6% والتي قمنا بتسجيلها عند الدورة 73 ولم تتجاوز هذه الدقة في الدورات الباقية.

وصلت دقة التدريب إلى 98% في نوع Finger (الأصابع) بينما وصلت دقة الاختبار إلى 80.8%، بحيث بدأت بقيمة صغيرة 70% من ثم تصاعدت ووصلت لدقة 80.8% والتي قمنا بتسجيلها عند الدورة 43 ولم تتجاوز هذه الدقة في الدورات الباقية.

وصلت دقة التدريب إلى 97% في نوع Forearm (الساعد) بينما وصلت دقة الاختبار إلى 84.7%، بحيث بدأت بقيمة صغيرة 67.7% من ثم تصاعدت ووصلت لدقة 84.7% والتي قمنا بتسجيلها عند الدورة 14 ولم تتجاوز هذه الدقة في الدورات الباقية.

وصلت دقة التدريب إلى 98.5% في نوع Hand (اليدين) بينما وصلت دقة الاختبار إلى 79.5%، بحيث بدأت بقيمة صغيرة 61% من ثم تصاعدت ووصلت لدقة 79.5% والتي قمنا بتسجيلها عند الدورة 53 والدورة 73 ولم تتجاوز هذه الدقة في الدورات الباقية.

وصلت دقة التدريب إلى 98.5% في نوع Humerus (عظم العضد) بينما وصلت دقة الاختبار إلى 87.5%، بحيث بدأت بقيمة صغيرة 66.3% من ثم تصاعدت ووصلت لدقة 87.5% والتي قمنا بتسجيلها عند الدورة 59 ولم تتجاوز هذه الدقة في الدورات الباقية.

وصلت دقة التدريب إلى 97.9% في نوع Shoulder (الكتف) بينما وصلت دقة الاختبار إلى 79.5%، بحيث بدأت بقيمة صغيرة 67.5% من ثم تصاعدت ووصلت لدقة 87.5% والتي قمنا بتسجيلها عند الدورة 34 ولم تتجاوز هذه الدقة في الدورات الباقية.

وصلت دقة التدريب إلى 98% في نوع Wrist بينما وصلت دقة الاختبار إلى 85.5%، بحيث بدأت بقيمة صغيرة 67.8% من ثم تصاعدت ووصلت لدقة 85.5% والتي قمنا بتسجيلها عند الدورة 108 ولم تتجاوز هذه الدقة في الدورات الباقية.

نلاحظ من هذه النتائج أن دقة التدريب تصل إلى نسبة مثالية نوعاً ما، أما نتائج الاختبار فقد كانت متراوحة بنسب معقولة في كل الأنواع المدروسة.

كما نلاحظ أننا حصلنا على أعلى دقة اختبار عند دورات مختلفة في كل نوع من الأنواع، مثلاً الدورة 73 والدورة 43 والدورة 34 والدورة 59 والدورة 108 (في حالة نوع المعصم فقط)، ما يعني أننا حصلنا على أعلى دقة قبل الوصول لعدد الدورات الأعظمي بكثير، أي أنه لا يحصل لدينا فرط تلاؤم.

كما نبين في الجدول الآتي زمن التدريب لنموذج DenseNet121 لكل نوع من أنواع الدراسة:

جدول (7-4) زمن تدريب نموذج DenseNet121 على عينة البيانات لكل نوع من أنواع الدراسة	
نوع الدراسة	زمن تدريب نموذج DenseNet121 المنقول (مقدراً بالثانية) لكل دورة تدريب (Epoch)
المعصم	155
الكوع	78
العضد	21
الكتف	117
إصبع اليد	68
الساعد	27
اليد	77


3- تطبيق نموذج VGG16:


تم تهيئة نموذج VGG16 بنفس الأوزان والبارامترات لنموذج DenseNet121 أيضاً.

لم يعطِ نموذج VGG16 أي نتائج جيدة كما نرى في الجدول الآتي:


جدول (5-7) مقارنة نتائج تقييم نموذج VGG16 على عينة البيانات مع نتائج الورقة البحثية المذكورة		
نوع الدراسة	دقة تصنيف نموذج VGG16 المنقول	دقة التصنيف في المرجع
المعصم	0.5549	0.86
الكوع / المرفق	0.5065	0.85
العضد	0.5139	0.82
الكتف	0.5089	0.79
إصبع اليد	0.62	0.78
الساعد	0.5104	0.77
الكف / اليد	0.5982	0.73
الكل	0.5546	-

نقدم في هذا القسم مخططات تعرض نتائج تدريب وتقييم النموذج على عينة البيانات لكل أنواع الدراسة (النموذج VGG16)، بغرض المقارنة بين أداء النماذج التي تم تطبيقها على نفس عينة البيانات.







2




3




4



5



6



7

الشكل (4-7) نتائج تدريب وتقييم النموذج VGG16 على عينة البيانات لكل أنواع الدراسة
(1- الكوع 2- الاصبع 3- الساعد 4- اليد 5- العضد 6- الكتف 7- المعصم)

نلاحظ من المخططات عموماً أن دقة التدريب في أغلب أنواع الدراسة لم تتقدم بشكل جيد وإنما تقدمت بشكل بطيء جداً أو تراوحت حول قيم ثابتة أثناء الاستمرار في التدريب إلى 115 دورة (عدد الدورات الذي تم اختياره للتدريب)، أما نتائج الاختبار فقد كانت غير جيدة في أغلب الأنواع المدروسة، وبالتفصيل:

وصلت دقة التدريب إلى 61% تقريباً في نوع الكوع، بينما لم تتجاوز دقة الاختبار 50.65%.

وصلت دقة التدريب إلى 63.11% في نوع الاصبع، بينما لم تتجاوز دقة الاختبار 62%.

وصلت دقة التدريب إلى 66.5% في نوع الساعد، بينما لم تتجاوز دقة الاختبار 51.4%.

وصلت دقة التدريب إلى 73.39% في نوع اليد، بينما لم تتجاوز دقة الاختبار 60%.

وصلت دقة التدريب إلى حوالي 57% في نوع العضد، بينما لم تتجاوز دقة الاختبار 51.39%.

وصلت دقة التدريب إلى 51.8% في نوع الكتف، بينما لم تتجاوز دقة الاختبار 50.9%.

وصلت دقة التدريب إلى 62.6% في نوع المعصم، بينما لم تتجاوز دقة الاختبار 55.49%.

كما نبين في الجدول الآتي زمن التدريب لنموذج DenseNet121 لكل نوع من أنواع الدراسة:

جدول (6-7) زمن تدريب نموذج VGG16 على عينة البيانات لكل نوع من أنواع الدراسة	
نوع الدراسة	زمن تدريب نموذج VGG16 المنقول (مقدراً بالثانية) لكل دورة تدريب (Epoch)
المعصم	125
الكوع	72
العضد	20
الكتف	110
إصبع اليد	66
الساعد	26
اليد	83

كما وتمت مقارنة أداء نمودجي DenseNet201 و DenseNet121 مع نموذج VGG16 من حيث دقة التصنيف في الجدول الآتي:

جدول (7-7) نتائج مقارنة أداء شبكتي DenseNet المدروسة مع شبكة VGG16 من ناحية دقة التصنيف

دقة التصنيف في المرجع	دقة التصنيف						نوع الدراسة
	VGG16		DesneNet121		DenseNet201		الشبكة المختارة
	Train	test	train	Test	Train	Test	
0.86	0.6202	0.5549	0.9236	0.8552	0.9637	0.862	المعصم
0.85	0.6084	0.5065	0.9524	0.8556	0.9595	0.8778	الكوع
0.82	0.5697	0.5139	0.9661	0.875	0.947	0.8819	العضد
0.79	0.5176	0.5089	0.9222	0.7946	0.9598	0.7964	الكتف
0.78	0.6311	0.62	0.9392	0.808	0.961	0.7969	الاصبع
0.77	0.6642	0.5104	0.962	0.8472	0.948	0.8194	الساعد
0.73	0.7339	0.5982	0.8842	0.7946	0.9581	0.7969	اليد
-		0.5546		0.8207		0.8190	الكل


حقق النموذج المنقول من شبكة DenseNet201 نتائج مرضية من ناحية دقة التصنيف، تفوقت النتائج التي حصلنا عليها من هذا النموذج على النتائج التي تمت المقارنة معها من المرجع المذكور وكذلك نتائج النموذج المبني على VGG16، ونتائج نموذج DenseNet121 في معظم أنواع الدراسة ماعدا حالي (الاصبع والساعد) واللذان تفوق فيهما نموذج DenseNet121 على النماذج الأخرى من ناحية دقة التصنيف، وهذا ما يؤكد جدوى استخدام شبكات بعمق أكبر في زيادة الدقة.

تؤكد أيضاً المقارنة مع نتائج المرجع تفوق نموذجي DenseNet المنقولين المستخدمين في الأداء على النموذج المستخدم في المرجع، جدوى استفادتنا من تطبيق التعلم بالنقل للاستفادة من النماذج المدربة مسبقاً واختصار الوقت اللازم للتدريب والحصول على النتائج المرجوة بسرعة ودقة أعلى.

نجد من خلال الجدول أيضاً أن النموذج المبني على VGG16 لم يقدم أي نتائج مرضية وذلك وفقاً للدقة التي تم الحصول عليها، ما يعني عدم ملائمة لهذا النوع من المهام (التشخيص الطبي / تصنيف الصور الطبية). لذلك يمكننا القول إنه لا يمكن الحكم على نتائج أي نموذج مدرب مسبقاً ومنقول للعمل على بيانات جديدة إلا بعد تطبيق النموذج فعلياً (ربما تعتبر هذه النقطة إحدى سلبيات التعلم بالنقل إلا أنه لا يمكن التنبؤ بالنتائج مسبقاً، دون العمل بشكل مباشر).

4- تطبيق نماذج Inceptionv3 , InceptionResnetv2 , ResNet152v2:

تمت تهيئة الشبكات بأوزان من نماذج الشبكات المختارة والتي تم تدريبها مسبقاً على عينة البيانات ImageNet وتم تدريب الشبكات باستخدام Adam Optimizer مع البارامترات الافتراضية. استخدمنا حجم $\text{batch} = 32$ ومعدل التعلم 0.0001 يتناقص تدريجياً مع مراحل التكرار (الشكل (5-7))، وقمنا بتدريب الشبكات لكل أنواع الدراسة بشكل منفصل بحيث قمنا بتطبيق نموذج الشبكة المحددة على عينة البيانات المدروسة على كل نوع بشكل مستقل (أي التطبيق على فئة المعصم بشكل مستقل، على فئة الأصابع بشكل مستقل... الخ) وبعدد مرات 43 لكل الأنواع (بسبب السرعة التي تمت ملاحظتها في الحصول على النتائج)، وقمنا بتسجيل النتائج لكل الحالات المدروسة.



الشكل (5-7) توضيح لقيم معدل التعلم (Learning Rate) خلال العمل على كل النماذج المدروسة

ملاحظات حول النتائج:

نوضح في الجداول أدناه نتائج المقارنة (من ناحية دقة التصنيف في الجدول الأول، مقياس كاتا في الجدول الثاني)، التي قمنا بإجرائها بين الشبكات الثلاث التي عملنا عليها وتم ذكرها سابقاً لتصنيف صور عينة البيانات المدروسة.


نلاحظ من الجدول الأول أننا حصلنا على أفضل دقة لأغلب (الكل ما عدا نوع المعصم) حالات الدراسة ضمن عينة البيانات من خلال نموذج الشبكة **Resnet152v2** بحيث وصلنا إلى دقة تصنيف تقريباً 88% في نوع الكوع والعضد وهي كانت الأفضل بين الأنواع الأخرى فقد وصلت دقة تصنيف نوع الكتف في هذا النموذج

حوالي 78.5% ووصلت 79% في نوع الاصبع واقتربت من 80% في تصنيف نوع الساعد وتجاوز هذه النسبة قليلاً في نوع اليد.

أما بالنسبة لنوع المعصم فقد تفوق أداء نموذج Inceptionv3 على الأنواع الأخرى بدقة اقتربت من 86%.

جدول (7-5) نتائج مقارنة أداء الشبكات الثلاث المدروسة من ناحية دقة التصنيف							
دقة التصنيف في المرجع	دقة التصنيف						نوع الدراسة
	InceptionResnetv2		Inceptionv3		Resnet152v2		الشبكة المختارة
	Train	test	train	Test	Train	Test	
0.86	0.9296	0.8562	0.9236	0.8578	0.8931	0.8562	المعصم
0.85	0.9624	0.8544	0.9524	0.8504	0.908	0.875	الكوع
0.82	0.9641	0.8546	0.9661	0.8646	0.9248	0.8681	العضد
0.79	0.9376	0.7702	0.9222	0.7831	0.8656	0.7849	الكتف
0.78	0.9292	0.7546	0.9392	0.7746	0.8978	0.7902	الاصبع
0.77	0.9782	0.7917	0.962	0.7913	0.9424	0.7986	الساعد
0.73	0.8802	0.791	0.8842	0.7909	0.8392	0.8036	اليـد

كما نعرض في الشكلين الآتيين توضيح لنتائج المقارنة من خلال مخططين توضيحين لأداء النماذج الثلاثة على كل أنواع الدراسة لكل من التدريب والاختبار.



الشكل (6-7) مقارنة نتائج التدريب لأنواع الشبكات الثلاثة على كل أنواع الدراسة من ناحية مقياس الدقة




الشكل (7-7) مقارنة نتائج الاختبار لأنواع الشبكات الثلاثة على كل أنواع الدراسة من ناحية مقياس الدقة

نعرض في الجدول التالي نتائج مقياس كبا لحالات الدراسة ضمن عينة البيانات من خلال نماذج الشبكات الثلاثة.

بحيث حصلنا على قيم جيدة تتناسب مع دقة التصنيف المعروضة في الجدول الأول. نجد من الجدول أنه بالنسبة لنوع المعصم والكوع فقد أعطت شبكة InceptionResnetv2 أعلى قيمة لمقياس كبا من ناحية الاختبار، بالنسبة للعضد كانت القيمة الأكبر لمعامل كبا لنموذج Inceptionv3 وتفوقت Resnet152v2 في باقي أنواع الدراسة بحصولها على أعلى قيم لهذا المقياس.

جدول (7-6) نتائج مقارنة أداء الشبكات الثلاث المدروسة من ناحية مقياس كابا						
kappa static						نوع الدراسة
InceptionResnetv2		Inceptionv3		Resnet152v2		
Train	test	train	Test	Train	Test	
0.9545	0.9577	0.9373	0.9207	0.896	0.8497	المعصم
0.9541	0.9488	0.9418	0.9099	0.9384	0.895	الكوع
0.99578	0.9299	0.99621	0.948	0.997	0.942	العضد
0.9997	0.85	0.9993	0.889	0.9863	0.8627	الكتف
0.9675	0.6649	0.9572	0.9598	0.9535	0.9649	الاصبع
0.9379	0.9138	0.9204	0.8894	0.9337	0.9194	الساعد
0.841	0.8191	0.8649	0.8224	0.8965	0.8826	اليد

ونعرض في الشكل الآتي قيم الدقة وقيم مقياس كابا لإحدى حالات الدراسة (الكوع) ويظهر من خلاله التناسب الذي نتج في المقياسين (مقياس الدقة ومقياس كابا للتوافق).



الشكل (7-8) مخطط توضيحي لنتائج مقياسي الدقة وكابا لحالة دراسة الكوع لشبكة

InceptionResnetv2

بعد استخدام عدة نماذج تعلم عميق لتصنيف الصور في عينة البيانات، وتقييم أدائها بشكل فردي ومقارنتها مع بعضها البعض.

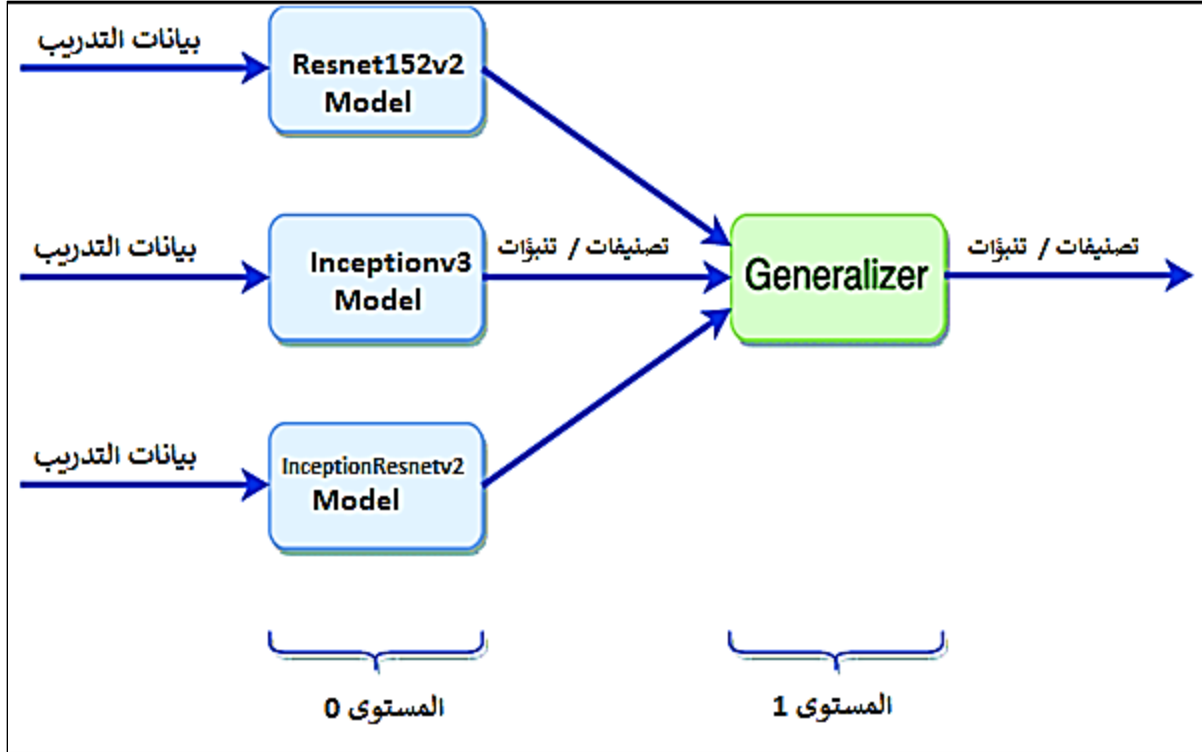
الطريقة المقترحة هي بناء نموذج المجموعة باستخدام التعلم التجميعي من النماذج المطبقة باستخدام آليتين من آليات من التعلم التجميعي (تم شرحها سابقاً) وتقييم تأثير تجميع النماذج على النتائج.

7-2-2-2 تطبيق طريقة التعلم التجميعي (Ensemble Method)

الخطوة التالية في هذه الدراسة هي تطبيق تجميع (تم شرح التعلم التجميعي وآلياته سابقاً) للنماذج الثلاثة من شبكات ResNet على واحدة فقط من حالات الدراسة وهي نوع العضد، وكذلك للنماذج من شبكات DenseNet و VGG16 على نفس حالة الدراسة من خلال:

7-2-2-2-1 نموذج التجميع الأول

طبقنا التكديس، المعروف أيضاً باسم التعميم المكس Stacked Generalization، وهو أسلوب تجميع يجمع بين عدة تصنيفات عبر meta-classifier. يتم تدريب نماذج المستوى الأساسي على مجموعة التدريب كاملة، ثم يتم تدريب النموذج Meta على الميزات (features) التي تمثل مخرجات نموذج المستوى الأساسي. غالباً ما يتكون المستوى الأساسي من خوارزميات تعليمية مختلفة.



الشكل (7-9) توضيح لنموذج التجميع بالتكديس على شبكات ResNet و InceptionV3

الخطوة الأولى هي تقسيم مجموعة التدريب إلى عدة أجزاء.

الخطوة الثانية هي تطبيق تناسب (fit) النموذج الأساسي على عدة أجزاء من مجموعة التدريب والقيام بعمل تنبؤات للجزء المتبقي من مجموعة التدريب.



الخطوة الثالثة هي تطبيق (fit) النموذج الأساسي على مجموعة بيانات التدريب بأكملها.

الخطوة الرابعة تتم باستخدام نفس النموذج، بحيث يتم عمل تنبؤات على مجموعة الاختبار.

الخطوة الخامسة هي تكرار الخطوات من 2 إلى 4 لنموذج أساسي آخر، مما يؤدي إلى مجموعة أخرى من التنبؤات لمجموعة التدريب ومجموعة الاختبار.

الخطوة السادسة تتم باستخدام التنبؤات من مجموعة التدريب كمميزات لبناء نموذج جديد.

الخطوة السابعة تكون باستخدام النموذج لعمل التنبؤات النهائية حول مجموعة التنبؤ بالاختبار.



الشكل (7-10) خطوات تطبيق التجميع بالتكديس على عينة البيانات

جدول (7-7) نتائج تطبيق التعلم التجميعي (التكديس) لنماذج ResNet على نوع العضد (من ناحية دقة التصنيف)

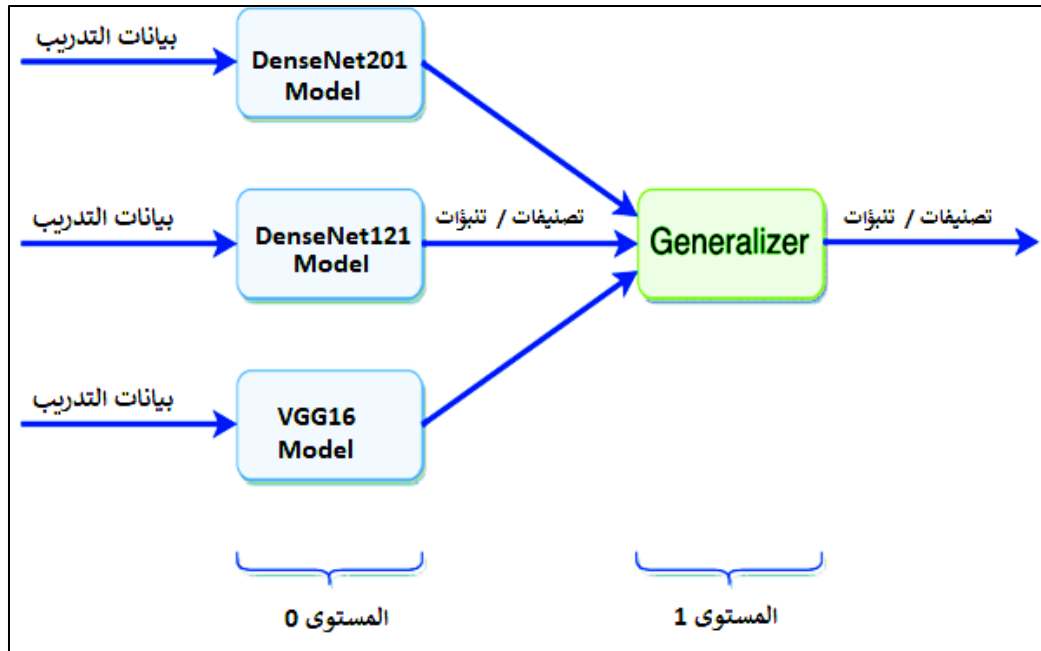
دقة التصنيف														نوع الدراسة
Avg		InceptionResnetv2				Inceptionv3				Resnet152v2				الشبكة المختارة
single		ensemble		single		Ensemble		single		Ensemble		single		
train	Test	train	Test	train	Test	train	Test	train	Test	Train	test	train	Test	
0.93593	0.85997	0.98253	0.8717	0.9661	0.8646	0.9976	0.8859	0.9169	0.8472	0.979	0.8572	0.9248	0.8681	humerus / العضد

نلاحظ من الجدول التحسن في دقة نتائج التصنيف للنماذج الثلاثة للنوع المدروس (نوع العضد HUMERUS) فقد ارتفع أداء نموذج شبكة Resnet152v2 من ناحية دقة الاختبار من 0.8681 إلى 0.8721 وكذلك بالنسبة لنماذج شبكتي Inceptionv3 و InceptionResnetv2 فقد حصلنا أيضاً على زيادة في دقة التصنيف بحوالي 2% لكل من النموذجين من ناحية دقة الاختبار، في العمود الأخير للجدول قمنا بحساب متوسط الدقة الفردية للشبكات الثلاثة ومتوسط دقتها عند تجميعها من خلال التكديس في نموذج تجميعي لتوضيح التحسين النهائي الذي تم الحصول عليه.

من خلال الفرق الواضح في الدقة النهائية والدقة بالمتوسط للنماذج المركبة الثلاثة نستنتج جدوى وفائدة أول آلية من آليات التعلم التجميعي (التكديس).

في أول تجربة وكما نلاحظ من الجدول أننا طبقنا التكديس على ثلاثة نماذج وهي النماذج المبنية على شبكات ResNet أي أننا اعتمدنا على نوع واحد من الشبكات.

طبقتنا التجميع أيضاً على النماذج الثلاثة الأخرى المستخدمة في البحث (نموذجين من شبكات DenseNet ونموذج VGG16) أيضاً على واحدة فقط من حالات الدراسة وهي نوع العضد من خلال آلية التجميع (التكديس).



الشكل (7-11) توضيح لنموذج التجميع بالتكديس على شبكات DenseNet و VGG16

ونعرض النتائج في الجدول الآتي:

جدول (7-8) نتائج تطبيق التعلم التجميعي (التكديس) لنماذج DenseNet و VGG16 على نوع العنصر (من ناحية دقة التصنيف)

دقة التصنيف														نوع الدراسة
Avg		DenseNet121				DenseNet201				VGG16				الشبكة المختارة
single		ensemble		single		Ensemble		single		Ensemble		single		
train	Test	train	Test	train	Test	train	Test	train	Test	Train	test	train	Test	
0.80696	0.75393	0.82303	0.7642	0.9093	0.8542	0.9202	0.868	0.967	0.875	0.969	0.8891	0.6031	0.5549	humerus / العنصر

نلاحظ من الجدول التحسن في دقة نتائج التصنيف للنماذج الثلاثة للنوع المدروس (نوع العنصر HUMERUS) فقد ارتفع أداء نموذج شبكة ResNet121 من ناحية دقة الاختبار من 0.8542 إلى 0.8611 وكذلك بالنسبة لنماذج شبكتي DenseNet201 و VGG16 فقد حصلنا أيضاً على زيادة في دقة التصنيف بحوالي 1% لكل من النموذجين من ناحية دقة الاختبار، في العمود الأخير للجدول قمنا بحساب متوسط الدقة الفردية للشبكات الثلاثة ومتوسط دقتها عند جمعها من خلال التكديس في نموذج تجميعي لتوضيح التحسين النهائي الذي تم الحصول عليه.


في أول تجربة وكما لاحظنا من الجدولين التحسن في دقة التصنيف بعد تطبيق التكديس على نوعي الشبكات التي استخدمناها. لاحظنا أيضاً أن أداء نماذج شبكات ResNet كان الأفضل بين جميع النماذج المستخدمة بشكل فردي وبشكل تجميعي عموماً (من خلال التكديس)، إضافةً إلى شبكة DenseNet201.

نعرض في النهاية جدول ترتيب الشبكات من ناحية دقة التصنيف للنوع المدروس من الأكثر دقة إلى الأقل (بشكل تجميعي، وبشكل فردي) ومن ناحية دقة الاختبار فقط (لم نعرض دقة التدريب).


ونلاحظ تفوق نموذج شبكة InceptionResnetv2 في النموذج التجميعي وذلك كونها تتضمن اتصالات متبقية تحل محل مرحلة سلسلة المرشح (filter concatenation stage) في بنية Inception التي تعتمد عليها InceptionResnetv2.

جدول (7-9) ترتيب النماذج من ناحية دقة التصنيف		
الترتيب	دقة النموذج بشكل فردي	دقة النموذج بشكل تجميعي
1	(0.875) DenseNet201	(0.8859) InceptionResnetv2
2	(0.8681) Resnet152v2	(0.8851) DenseNet201
3	(0.8646) InceptionResnetv2	(0.8721) Resnet152v2
4	(0.8542) DenseNet121	(0.868) DenseNet121
5	(0.8472) InceptionV3	(0.8572) InceptionV3
6	(0.5549) VGG16	(0.5639) VGG16

نوضح النتائج أيضاً من خلال الشكلين الآتيين لترتيب دقة النماذج المستخدمة من الأكثر دقةً إلى الأقل (بشكل فردي وبشكل تجميعي).



الشكل (7-12) ترتيب النماذج من حيث دقة التصنيف الفردي

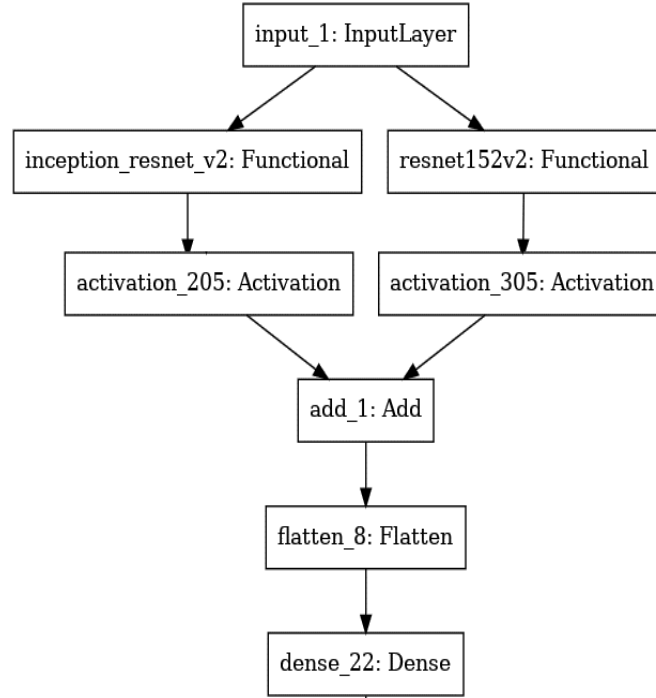


الشكل (7-13) ترتيب النماذج من حيث دقة التصنيف التجميعي

2-2-2-7 نموذج التجميع الثاني


في هذا النموذج تم اختيار أفضل نموذجين من ناحية دقة التصنيف (لم يتم العمل على نماذج أكثر لعدم توفر بيئة عمل تتلاءم مع الحجم الكبير من الطبقات الذي سيتم التعامل في تلك الحالة (قمنا بمحاولة تجريب ثلاثة نماذج إلا أنه لا يوجد أي إمكانية في أي من منصات التدريب المتاحة))، ثم تم استخراج الميزات من هذه النماذج من خلال تطبيق نهج التعلم التجميعي. بعد ذلك، ومن أجل التصنيف، قمنا بإضافة طبقة متصلة بالكامل وطبقة SoftMax وطبقة تصنيف إلى نموذج المجموعة المشترك (وهي تقنية من تقنيات التعلم بالنقل). وأخيراً قمنا باختبار أداء نموذج التعلم العميق المقترح على واحدة فقط من حالات الدراسة وهي نوع العضد (كما تم في نموذج التجميع الأول).

نعرض في الشكل الآتي النموذج المقترح:



الشكل (7-14) النموذج التجميعي الثاني المقترح والمبني على كل من InceptionResNetV2 و ResNet152V2

نلاحظ من المخطط التحسن في دقة نتائج التصنيف للنموذج المقترح على (نوع العضد) فقد حصلنا على زيادة في دقة التصنيف بحوالي 2.5% عن النماذج بشكل فردي من ناحية دقة الاختبار (وصلت الدقة إلى 0.894). كما نلاحظ أنه في النموذج المقترح فقد تقاربت دقة التدريب ودقة الاختبار من بعضهما من الدورة 17 تقريباً، أي أننا وصلنا إلى دقة جيدة بعدد دورات أقل وبالتالي أداء جيد سريع من النموذج المقترح، كما أن تقارب كل من دقة التدريب ودقة الاختبار من بعضهما يدل أن النموذج يُعمم بشكل جيد. من خلال الفرق الواضح في الدقة النهائية للنموذج المركب المقترح نستنتج جدوى وفائدة التعلم التجميعي.



الشكل (7-15) نتائج تدريب واختبار للنموذج التجميعي الثاني من (InceptionResNetV2, ResNet152V2) على عينة البيانات لحالة الدراسة Humerus

3-7 خاتمة

كان العمل في هذا الفصل على توضيح الإطار العملي للدراسة ونتائج تطبيق النماذج المستخدمة والتي تم تقديم شرح تفصيلي لها في الفصل الخامس. كما تم عرض نتائج دقة التصنيف لكل نموذج على حدا. قمنا بمقارنة أداء النماذج بشكل منفصل من حيث دقة التصنيف النهائية لأنواع الدراسة المقدمة والمتعلقة ببيانات البحث.

قمنا بعدها باقتراح تطبيق للذكاء التجميعي (التعلم التجميعي) من خلال اقتراح نموذجين للتعلم التجميعي تم بناؤهما من النماذج المستخدمة وتوضيح نتائج استخدام كل منها ومقارنة أدائهما معاً.

كان الهدف من المقارنة هو توضيح أهمية نتائج استخدام التعلم التجميعي وتوضيح إمكانية الاستفادة منه في تحسين دقة النتائج فيما يتعلق ببيانات البحث (التشخيص الطبي).

نعرض في الفصل الثامن مجموعة النتائج التي توصلنا إليها بعد إتمام هذا البحث. كما نقدم مجموعة من التوصيات والأعمال المستقبلية التي يمكن المتابعة فيها لاحقاً.

الفصل الثامن: النتائج والتوصيات

1-8 النتائج

كان الهدف من الدراسة هو السعي للوصول إلى نموذج جديد (تم تقديم نموذجين باستخدام الذكاء التجميعي) يقدم أداءً مشابهاً لأداء أطباء الأشعة ويقدم مساعدة لهم في تطبيق قراراتهم. بالنسبة للدراسات التي أجريناها، فإن نتائج النماذج الخاصة بنا من ناحية دقة التصنيف أعلى بشكل كبير من تلك النتائج الخاصة بأطباء الأشعة.

من النتائج التي تم الحصول عليها في النماذج، نجد أن معظم النماذج عملت بشكل شبه مثالي بالنسبة لعينة البيانات، أما نموذج VGG16 فقد أعطى نتائج غير جيدة في هذا النمط. يمكن الاستفادة من النموذج الذي تم تدريبه وأعطى نتائج جيدة وتخزينه ليعمل على عينات مشابهة من البيانات للاستفادة من نقل التعلم في الحصول على نتائج أفضل وبدقة أفضل وسرعة وأداء جيدين مقارنة بتدريب نموذج من الصفر.

تقنية التعلم بالنقل تعتمد على عدم بناء نموذج من الصفر، وإنما الاستفادة من النموذج المدرب مسبقاً والعمل على دراسة مدى الاستفادة منه في البيانات المدروسة، ولا يمكن التنبؤ بنتائجه قبل تطبيقه فعلياً، فقد وجدنا الفرق بين نتائج النموذج المبني على DenseNet121 والنموذج المبني على VGG16، كما يمكن تطبيق أي من النماذج الموجودة والمتاحة للبحث ودراسة مدى الاستفادة منها أيضاً وتوفير وقت الباحثين في هذا المجال لعدم البدء من الصفر في كل مهمة جديدة للتصنيف.

وضحنا من خلال الدراسة فائدة نقل التعلم لمهام التعامل مع الصور الشعاعية الطبية. ووجدنا أن ضبط النماذج التي تم اختبارها مسبقاً أعطى نتائج جيدة، كون ImageNet هي قاعدة بيانات ضخمة للصور.

تمثل الأوزان من الطبقات العميقة لهذه النماذج بالتأكيد سمات مختلفة جداً عن تلك الموجودة في الصور الحالية (الحالة المدروسة)، ومن خلال إلغاء تجميد بعض الطبقات اللاحقة، تم الاحتفاظ بجميع الميزات القابلة للتعميم الأكثر فائدة. وبالتالي العمل على تسخير القوة والعمق المتاحين من أحدث نماذج ML على تغيير وتحسين النتائج في المجال الطبي، ونؤكد أنه عندما تصبح بيانات الصور الطبية متاحة بشكل أكبر، ستكون هناك نتائج رائعة لكافة مجالات تعلم الآلة على عمليات التشخيص وغيرها.

تعاملنا مع التعلم التجميعي من خلال بناء نموذجين تجميعيين وعرضنا النتائج التي تم الحصول عليها. أعطى كل من النموذجين التجميعيين نتائج جيدة وفعالة من ناحية المقياسين اللذين تم التعامل معهما (مقياس الدقة ومقياس كابتا).

هناك العديد من التأثيرات البشرية في اتخاذ القرارات، بما في ذلك تحديد خيارات المعايير ووظائف التحسين. وبالتالي سنحتاج للخوارزميات للتفكير في طرق تدعم آليات التغذية الراجعة والتسجيل. كما تحتاج الحكومات والشركات والمؤسسات النظر في استخدام الخوارزميات في صنع القرار، والتشاور على نطاق واسع، والتأكد من وجود آليات لاكتشاف ومعالجة أي أخطاء أو عواقب غير مقصودة للقرارات المتخذة.

نسلط في توصياتنا الضوء على الحالات التي يعمل فيها نموذج صنع قرار معين بشكل جيد (الحالة الخاصة التي تمت دراستها)، ولكن هذا النموذج قد لا يعمل مع جميع الحالات وفي جميع الظروف.

من الناحية البشرية فإنه مع نمو الفريق، يصبح اتخاذ القرارات معاً أكثر صعوبة. فعندما نضيف المزيد من الأشخاص، غالباً ما يصبح الوصول إلى الإجماع بطيئاً للغاية، وتصبح التنازلات التي يتعين القيام بها مؤثرة للغاية. ولذلك، تضع بعض الفرق جميع مسؤوليات اتخاذ القرار على عاتق قائد الفريق، مما يثقل كاهلهم ويثبط عزيمة أي شخص آخر.

ولكن هناك العديد من الطرق لاتخاذ القرار معاً، أكثر بكثير من مجرد إعطاء رأي لكل فرد أو إعطاء سلطة لشخص واحد فقط.

من الناحية الآلية (العمل مع الآلة) فإن نمو الفريق يمكن أن يدعم اتخاذ القرار ولا يكون هناك معاناة كما في العامل البشري والآراء المختلفة.

يمكننا تقسيم النتائج إلى نتائج عامة، ونتائج خاصة بنقل التعلم على عينة البيانات الخاصة بالبحث، ونتائج التعلم التجميعي أيضاً.

النتائج العامة:

بعد العمل على مجموعة البيانات المذكورة وتطبيق طرق التعلم بالنقل عليها ونموذجي التعلم التجميعي المقترحين في محاولة من خلال بحثنا للحصول على نتائج أفضل، وجدنا ما يلي:

- يتطلب تدريب نموذج التعلم العميق Deep Learning باستخدام الصور الطبية العديد من الاختيارات (اختيار البارامترات الصحيحة والبارامترات الفائقة) وبدون وحدة معالجة الرسومات السريعة، يستغرق الأمر عدة أيام للحصول على نتيجة (استخدمنا منصتي Google Colab و Kaggle). يمكن اعتبار هذه النقطة هي نتيجة عامة لمعظم الدراسات المتعلقة بمجال تعلم الآلة والتعلم العميق، حيث أننا قمنا بتجريبها في هذه الدراسة ولاحظنا هذه النقطة.

- عدم وجود معرفة بمجال الصور الطبية (حالة الدراسة) ليست مشكلة في الحصول على نموذج بمستوى جيد ولكن هذه المعرفة الطبية تصبح ضرورية لإنشاء تطبيق على المستوى المهني.

أما فيما يتعلق بالنتائج الخاصة بتطبيق نقل التعلم على عينة البيانات الخاصة ببحثنا فقد تم توضيحها بالتفصيل في قسم دراسة النتائج العملية من حيث الحصول على نتائج أفضل في عدة أقسام من المجال المدروس على عينة البيانات التي تم الاعتماد عليها، والاستفادة من النماذج المدربة مسبقاً في عمليات التصنيف لمشاكل عملية جديدة لا يتوفر فيها الكم المطلوب من البيانات اللازمة لإنجاز التصنيف والحصول على نتائج مرضية. الاستفادة من التعلم بالنقل في اختصار الوقت الكبير اللازم للتدريب، والاستفادة من بنى الشبكات العميقة المتوفرة والعمل عليها لما قدمته من أداء فعال في مجال التعامل مع الصور عموماً.

أظهرت النتائج العملية التي قدمناها في الفصل السابق النتائج الجيدة أيضاً التي يقدمها التعلم التجميعي عند العمل على الاستفادة من أكثر من نموذج وبناء نماذج جديدة تستفيد من خواص النماذج الفردية وتقدم نتائج فعالة وتعطي دقة أفضل في عملية التشخيص وهو ما نحتاجه بشكل كبير عموماً وفي المجال الطبي خصوصاً بسبب النتائج التي تترتب على عملية التشخيص.

الفائدة الأولى لشبكات CNN العميقة في مهام تصنيف الصور هي أن الهندسة المعمارية العميقة الكاملة يتم تدريبها طوال الوقت، من وحدات البكسل الأولية إلى التصنيفات النهائية، مما يقلل من الحاجة إلى ابتكار مستخرج ميزة مصنوع يدوياً.

ومع ذلك، فإن أوجه القصور الرئيسية في نموذج CNN العميق هي كالتالي مع الحلول التي تم العمل على تطبيقها في بحثنا:

- هناك حاجة إلى آلة GPU قوية لتسريع عملية التدريب (وهو ما تم حله باستخدام المنصات المذكورة أعلاه).
- هناك حاجة إلى قدر كبير من عينة التدريب مع التصنيفات لتعلم الأوزان (تم العمل على حل هذه المشكلة باستخدام التعلم بالنقل الذي يستفيد من النماذج المدربة مسبقاً على عينات بيانات كبيرة وبالتالي الاستفادة من الميزات التي تم تعلمها مسبقاً).

8-2 التوصيات والأعمال المستقبلية

بناءً على النتائج التي تم التوصل إليها توصي الدراسة بالتالي:

- يمكن توسيع هذه الدراسة أيضاً لتشمل تطبيق أنواع أخرى من خوارزميات نقل التعلم على عينة البيانات ومقارنة نتائجها مع نتائج الدراسة الحالية.
- يمكن الاستفادة من النماذج المقترحة والتي تم تدريبها على عينة البيانات وحصلنا من خلالها على نتائج جيدة جداً في العمل على مجموعات بيانات أخرى والاستفادة من آلية التعلم التجميعي في تحسين النتائج والأداء والحصول على نتائج أفضل وبسرعة أكبر.
- يمكن توسيع هذا البحث ليشمل تطبيق التعلم التجميعي من خلال العمل على عدة شبكات أخرى وتكديس عدة نماذج من نماذج الشبكات المدروسة على عينة البيانات ومقارنة نتائجها مع نتائج البحث الحالي (في حال العمل على تقنية الجمع بالتكديس).
- كما يمكن توسيع البحث بطريقة أخرى وهي تطبيق طرائق التعلم التجميعي المختلفة على عينة البيانات المحددة ودراسة نتائج كل طريقة وتحديد من الأفضل بينها حسب الحالة المدروسة.

جدول المصطلحات

Collective Intelligence	الذكاء التجميعي
Crowdsourcing	التعهيد الجماعي
Telemedicine	الطب عن بعد
Crowd	ال جماهير
Stakeholders	أصحاب المصلحة
Agile	الرشيقية
Openness	الانفتاح
Peering	التناظر
Sharing	المشاركة
Acting Globally	التصرف بشكل عام
Decision Making	صنع القرار
Convolutional Neural Networks	الشبكات العصبونية التلافيفية
Parameters	البارامترات
Bottleneck Structure	عنق الزجاجة
Dense Block	الكتلة الكثيفة
Transition Layer	طبقة النقل
max pooling	التجميع الاعظمي
stride convolution	الالتفاف السريع
vanishing/exploding gradient	التدرج المتلاشي / المتفجر
Mapping	التعيين الأساسي
Residual Block	الكتلة المتبقية
shortcut connection	اتصال الاختصار
Visual Geometry Group	مجموعة الهندسة المرئية

Transfer Learning	التعلم بالنقل
Feature Extraction	استخراج الميزات
Fine Tuning	الضبط الدقيق
Ensemble Learning	التعلم التجميعي
Bagging	التعبئة
Boosting	التعزيز
Stacked Generalization	التعميم المكس
meta-learner	المتعلم الفوقي
Stacked Generalization Ensemble	مجموعة التعميم المكس
Weighted Average Ensemble	مجموعة المتوسط الموزون
Train Set	مجموعة التدريب
Test Set	مجموعة الاختبار
Cross Validation	مفهوم التحقق
Overfitting	فرط التلاؤم
Data Augmentation	زيادة البيانات / التوسعة
cloud-based workbench	بيئة عمل قائمة على السحابة
features	الميزات

جدول الاختصارات المستخدمة

Support Vector Machine	SVM
K-nearest neighbors	KNNs
Multi-Layer Perceptron	MLP
Remaining Useful Life	RUL
Random Forests	RFs
Recurrent Neural Network	RNN
Adaptive Network Based Fuzzy Inference System	ANFIS
Particle swarm optimization	PSO
Sequential Quadratic Optimization	SQP
Directed non-periodic Graph	DAG
Long short-term memory	LSTM
Convolutional Neural Network	CNN
Chest X-ray Radiograph	CXR
Polymerase Chain Reaction	PCR
Clinical Decision Support System	CDSS
Densely connected convolutional networks	DenseNet
Residual Networks	ResNet
ImageNet Large Scale Visual Recognition Challenge	ILSVR
Federal Aviation Administration	FAA
Adaptive Boosting	AdaBoost
Musculoskeletal Radiographs	MURA

المراجع العلمية

- [1] Lee J-Y, Jin C-H, 2019 - How Collective Intelligence Fosters Incremental Innovation. Journal of Open Innovation: Technology, Market, and Complexity. 5(3):53. <https://doi.org/10.3390/joitmc5030053>
- [2] Young J. K, Engel D, Woolley A. W, Lin J. Yu-T., McArthur N, Malone T. W, 2017 - What Makes a Strong Team? Using Collective Intelligence to Predict Team Performance in League of Legends. Proceedings of the 2017 ACM Conference on Computer Supported Cooperative Work and Social Computing.
- [3] NIPS 2016 tutorial: "Nuts and bolts of building AI applications using Deep Learning" by Andrew Ng, retrieved 2021.
- [4] Peng L., Paris A., Keqing H., Lai X., 2010 - From Collective Knowledge to Intelligence: Pre-Requirements Analysis of Large and Complex Systems. Proceedings of the 1st Workshop on Web 2.0 for Software Engineering.
- [5] Talo M., Baloglu U.B., Yildirim O., Acharya U. R., 2019 - Application of deep transfer learning for automated brain abnormality classification using MR images. Cognitive Systems Research.
- [6] Deepak S. Ameer P.M., 2019 - Brain tumor classification using deep CNN features via transfer learning. Department of Electronics & Communication Engineering, National Institute of Technology.
- [7] Fradi M. , Afif M. , Zahzeh H. , Bouallegue K. , Machhout M., 2020 – Transfer Deep Learning Application for Ultrasonic Computed Tomographic Image Classification. IEEE.
- [8] Samala, R.K., Heang-Ping Ch., Hadjiiski L., Helvie, M.A., Richter, C.D., Cha, K.H., 2019 - Breast Cancer Diagnosis in Digital Breast Tomosynthesis: Effects of Training Sample Size on Multi-Stage Transfer Learning Using Deep Neural Nets. IEEE transactions on medical imaging.
- [9] Benjamin Q H., Hui L., Maryellen L. G., 2016 - Digital mammographic tumor classification using transfer learning from deep convolutional neural networks. Journal of Medical Imaging.

- [10]Rokach L, Schclar A, Itach E, 2014 - Ensemble methods for multi-label classification. Expert Systems with Applications, Volume 41, Issue 16, Pages 7507-7523, ISSN 0957-4174, <https://doi.org/10.1016/j.eswa.2014.06.015>.
- [11]Feng Sh, Zhou H, Dong H, 2019 - Using deep neural network with small dataset to predict material defects. Materials & Design, Volume 162, Pages 300-310, ISSN 0264-1275, <https://doi.org/10.1016/j.matdes.2018.11.060>.
- [12]Zhang, Min et al, 2020 - Semi-Supervised Bidirectional Long Short-Term Memory and Conditional Random Fields Model for Named-Entity Recognition Using Embeddings from Language Models Representations. Entropy (Basel, Switzerland) vol. 22,2 252. 22, doi:10.3390/e22020252.
- [13]Carson J., Hollingsworth K., Datta R., Clark G. and Segev A., 2020 - A Hybrid Decision Tree-Neural Network (DT-NN) Model for Large-Scale Classification Problems. IEEE International Conference on Big Data (Big Data), 2020, pp. 4103-4111, doi: 10.1109/BigData50022.2020.9378061.
- [14]Carson J., Hollingsworth K., Datta R., Segev A., 2019 - Failing & !Falling (F&!F): Learning to Classify Accidents and Incidents in Aircraft Data. 4357-4365. 10.1109/BigData47090.2019.9005531.
- [15]Mohamed Abdel Fattah, 2014 - A hybrid machine learning model for multi-document summarization. Applied Intelligence 40, 4 (June), 592–600. DOI: <https://doi.org/10.1007/s10489-013-0490-0>.
- [16]Elshazly H., Azar A. T., El-korany A. and Hassanien A. E., 2013 - Hybrid system for lymphatic diseases diagnosis. International Conference on Advances in Computing, Communications and Informatics (ICACCI), pp. 343-347, doi: 10.1109/ICACCI.2013.6637195.
- [17]Jan Carlo T. Arroyo and Allemar Jhone P. Delima, 2022 - An Optimized Neural Network Using Genetic Algorithm for Cardiovascular Disease Prediction. Journal of Advances in Information Technology, Vol. 13, No. 1, pp. 95-99.
- [18]Pham P.T., Bui D.T., Prakash I., Dholakia M.B., 2016 - Hybrid Integration of Multilayer Perceptron Neural Networks and Machine Learning Ensembles for Landslide Susceptibility Assessment at Himalayan Area (India) using GIS. Landslide studies.

- [19] Wenqian Ch., Shuyu Ch., Hancui Z, Tianshu W., 2017 - A hybrid prediction model for type 2 diabetes using K-means and decision tree. Conference: 2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS).
- [20] Xinli Y., David L., Xin X., Jianling S., 2017 - TLEL: A two-layer ensemble learning approach for just-in-time defect prediction. Information and Software Technology.
- [21] Zhixiong L., Kai G., Dazhong W., 2018 - Degradation Modeling and Remaining Useful Life Prediction of Aircraft Engines Using Ensemble Learning. Journal of Engineering for Gas Turbines and Power 141(4).
- [22] Andrew B., Narayan A. V., Brannon Th., Rodney D., Guzman L. A. Deland, Stephen M., 2020 - Using Artificial Intelligence for COVID-19 Chest X-ray Diagnosis. Fed Pract. 2020 Sep;37(9):398-404. doi: 10.12788/fp.0045. PMID: 33029064; PMCID: PMC7535959.
- [23] Guan, B., Zhang G., Yao J., Wang X., Wang M., 2020 - Arm fracture detection in X-rays based on improved deep convolutional neural network. Computers & Electrical Engineering.
- [24] Shao Y., Wang X., 2020 - A Two Stage Method for Abnormality Diagnosis of Musculoskeletal Radiographs. Springer.
- [25] Cheng K., Iriondo C., Calivá F., Krogue J., Majumdar S., Pedoia V., 2019 - Adversarial Policy Gradient for Deep Learning Image Augmentation. Medical Image Computing and Computer Assisted Intervention – MICCAI.
- [26] Pelka O., Nensa F., Friedrich C.M., 2019 - Branding-Fusion of Meta Data and Musculoskeletal Radiographs for Multi-modal Diagnostic Recognition. IEEE.
- [27] Harini N., Ramji B., Sriram S., Sowmya V., Soman K.P., 2020 - Musculoskeletal radiographs classification using deep learning. In Deep Learning for Data Analytics: Foundations, Biomedical Applications and Challenges. Center for Computational Engineering and Networking (CEN), Amrita School of Engineering.

- [28] Pradhan N., Dhaka V.S., Chaudhary H., 2019 - Classification of Human Bones Using Deep Convolutional Neural Network. IOP Conference Series: Materials Science and Engineering.
- [29] Varma M., Lu M., Gardner R., Dunnmon J., et al, 2019 - Automated abnormality detection in lower extremity radiographs using deep learning. Nat Mach Intell.
- [30] Storey O., Wei B., Zhang L., Mtope F.R.F., 2020 - Adaptive bone abnormality detection in medical imagery using deep neural net-works. Conference: 14th International FLINS Conference (FLINS 2020).
- [31] Dias D.D.A., 2019 - Musculoskeletal Abnormality Detection on X-Ray Using Transfer Learning. Universitat Pompeu Fabra, Barcelons.
- [32] <https://www.sermo.com/>. Last visited 2021.
- [33] <https://www.clickworker.com/>. Last visited 2021.
- [34] <https://ethelo.com/>. Last visited 2021;
- [35] <https://www.loomio.com/>. Last visited 2021.
- [36] <https://www.herox.com/>. Last visited 2021.
- [37] <https://www.premise.com/>. Last visited 2021.
- [38] <https://owkin.com/>. Last visited 2021.
- [39] Tapscott, D., Williams, A.D. 2008 - Wikinomics: How Mass Collaboration Changes Everything. Wayback Machine, USA: Penguin Group.
- [40] Zerilli, J., Knott, A., Maclaurin, J., Gavaghan C., 2019 - Algorithmic Decision-Making and the Control Problem. Minds & Machines (Springer).
- [41] Christopher T., James P. B., 2020 - Applications of Machine Learning in Healthcare.
- [42] [Musculoskeletal conditions \(who.int\), 2021](#)
- [43] Simarjeet K., Jimmy S., Lewis N., Sudan J., et al, 2020 - Medical Diagnostic Systems Using Artificial Intelligence (AI) Algorithms: Principles and Perspectives. IEEE.

- [44] Gabriela B., Kristina K., 2018 - Automated decision-making.
- [45] Sue N., Marco M., 2015 - Strategic Opportunities (and Challenges) of Algorithmic Decision-Making: A Call for Action on the Long-Term Societal Effects of 'Datification'. SSRN Electronic Journal.
- [46] Uzonwanne F. 2016 - Rational Model of Decision Making. In book: Global Encyclopedia of Public Administration, Public Policy, and Governance
- [47] Gati I., Levin N., Landman-Tal S. 2019 - Decision-Making Models and Career Guidance. International Handbook of Career Guidance. Springer, Cham.
- [48] Pranav R., Jeremy I., Andrew Ng. et al, 2017 - MURA Dataset: Towards Radiologist-Level Abnormality Detection in Musculoskeletal Radiographs. 1st Conference on Medical Imaging with Deep Learning (MIDL 2018)
- [49] Sarvamangala D.R., Kulkarni R.V., 2021 - Convolutional neural networks in medical image understanding: a survey. Springer.
- [50] Jason Y., Jeff C., Bengio Y., Hod L., 2014 - How transferable are features in deep neural networks? Conference: Advances in Neural Information Processing Systems.
- [51] Grega V., Vili P., 2020 - Transfer Learning with Adaptive Fine-Tuning. IEEE.
- [52] Gao H., Zhuang L., Geoff P., Laurens M., Kilian Q. W., 2020 - Convolutional Networks with Dense Connectivity. IEEE transactions on pattern analysis and machine intelligence.
- [53] Jason B., 2019 - A Gentle Introduction to Exploding Gradients in Neural Networks. Long Short-Term Memory Networks.
- [54] Rupesh K. S., Klaus G., Jürgen S., 2015 - Highway Networks. ICML 2015 Deep Learning workshop.
- [55] Michele Z. – 2020, Transfer Learning in Image Classification: how much training data do we really need?

- [56] Yamashita R., Nishio M., Do R.K.G. et al, 2018 - Convolutional neural networks: an overview and application in radiology. Springer Open, Insights Imaging.
- [57] Pintelas, P. & Livieris, Ioanni, 2020 - Ensemble learning and their applications. MDPI ISBN: 978-3-03936-959-1
- [58] Zhou, Z.-H, 2012 - Ensemble Methods: Foundations and Algorithms (1st ed.). Chapman and Hall/CRC. <https://doi.org/10.1201/b12207>
- [59] Breiman, L, 1996 Bagging predictors. Mach Learn 24, 123–140 (1996). <https://doi.org/10.1007/BF00058655>
- [60] David H. Wolpert, 1992 - Stacked generalization. Neural Networks, Volume 5, Issue 2, Pages 241-259, ISSN 0893-6080, [https://doi.org/10.1016/S0893-6080\(05\)80023-1](https://doi.org/10.1016/S0893-6080(05)80023-1).
- [61] Hallas, P., Ellingsen, T., 2006 - Errors in fracture diagnoses in the emergency department – characteristics of patients and diurnal variation. BMC Emerg Med 6, 4. <https://doi.org/10.1186/1471-227X-6-4>.

Applying Collective Intelligence in Decision Making

ABSTRACT

Algorithms are becoming increasingly important in decision-making, and they may also enhance and support human decision-making. It was noted that as more data becomes available, the increase in the use of machine learning algorithms provides an opportunity to make better decisions - by combining human and machine intelligence in an intelligent way.

We conducted a study of collective intelligence, its tools and the mechanism of its application in the field of decision-making in general and medical decision-making (in the diagnostic aspect of image classification), especially through the development of software models to assist in the medical decision-making process. In this research, a study was conducted on the application of decision-making using associative learning, and we also worked to shed light on decision-making in the medical field with the aim of helping doctors in general in making the appropriate decision for the case studied.

Through research, we worked on real data (MURA sample data for radiographic images) so that radiography is an important technique for the medical community to detect abnormalities, and interpretation of images takes a long time and is prone to error by radiologists who are exposed to external factors including possible tiredness from working long hours, being tired, or thinking about other things in life.

We worked on developing two learning models for classifying radial images based on deep learning by applying two stages: Transfer learning and Ensemble learning to classify radiographic images. and its relevance to the study case that we have chosen. The first stage provided very good results in terms of improving the classification accuracy and improving the performance of the selected models. In some cases, the accuracy improvement reached from 82% to 88%.

In the second stage, which is the application of ensemble learning, two ensemble models were developed and their performance was evaluated on the data sample, and the classification accuracy was already improved by about 2% in both models. This confirms the effectiveness of the proposed models in improving the classification of radiological images.

Keywords: decision making – collective intelligence - deep learning - transfer learning - decision making - machine learning - image classification - MURA - radiographic images - DenseNet - convolutional neural network - ensemble learning.

**Syrian Arab Republic
Al-Baath University
Faculty of Informatics Engineering
Department of Software Engineering
and Information Systems**



Applying Collective Intelligence in Decision Making

**A thesis submitted in partial fulfillment of the requirements for the
PhD' Degree in Informatics Engineering Software Engineering and
Information Systems**

Prepared by

Eng. Nahla Saeed Saad AlDeen

Supervised by

Dr. Yosser Atassi

Homs 2022 A.D - 1443 A.H