

الجمهورية الجزائرية الديمقراطية الشعبية
وزارة التعليم العالي والبحث العلمي
جامعة قاصدي مرباح ورقلة
كلية التكنولوجيات الحديثة للمعلومات والاتصال
قسم الالكترونك والاتصال



مذكرة لنيل شهادة ماستر أكاديمي
تخصص انظمة اتصالات

من طرف الطالبة: سارة بن شحيمة

تحت عنوان

اختيار الميزات لاكتشاف مرض باركنسون باستخدام خوارزمية الذئب الرمادي الثنائية (BGWO)

نوقشت يوم 29/05/2025 أمام اللجنة المكونة من:

الرئيس	نجلاء بالطيب	أستاذ محاضر ب	جامعة ورقلة
المناقش	علية براك	أستاذ محاضر ب	جامعة ورقلة
المؤطر	فلة شريف	أستاذ ت.ع	جامعة ورقلة
مساعد المؤطر	حذيفة ديدة	أستاذ مستخلف	جامعة ورقلة

----- { دفعة 2025 } -----

ملخص

يعد اكتشاف مرض باركنسون من التحديات الطبية المهمة نظراً لصعوبة تشخيصه في المراحل المبكرة. مع التقدم في تقنيات الذكاء الاصطناعي، برز التعلم العميق كأداة فعالة، خاصة الشبكة العصبية الالتفافية، لما تقدمه من أداء جيد في تحليل الصور. تقدم هذه الدراسة نظاماً يعتمد على التعلم العميق لاكتشاف مرض باركنسون بشكل دقيق. لتصنيف المرض بناء على البيانات الطبية (مثل الرسم) تم استخدام شبكتين عميقتين هما: ALEXNET، RESNET50، ولتعزيز أداء التصنيف وتقليل عدد الخصائص تم دمج عملية اختيار الميزات في النظام. تم الاعتماد على خوارزمية الذئب الرمادي الثنائية لاختيار الميزات الأكثر تأثيراً. وفي الختام تظهر النتائج ان الجمع بين BGWO والشبكة العصبية الالتفافية يوفر نظاماً فعالاً لاكتشاف مرض باركنسون، مع تحسين ملحوظ في الأداء ودقة التشخيص، مما يعزز إمكانية استخدام هذا النهج في تطبيقات الرعاية الصحية الذكية.

كلمات مفتاحية: مرض باركنسون، الذكاء الاصطناعي، التعلم العميق، الشبكة العصبية الالتفافية، التصنيف، ALEXNET، RESNET50، اختيار الميزات، خوارزمية الذئب الرمادي الثنائية.

Abstract

The detection of Parkinson's disease is one of the important medical challenges due to the difficulty of its diagnosis in the early stages. With the advancements in artificial intelligence technologies, deep learning has emerged as an effective tool, especially the convolutional neural network, for its good performance in image analysis. This study presents a system based on deep learning for the accurate detection of Parkinson's disease. For disease classification based on medical data such as drawings, we employed two deep learning networks AlexNet and ResNet50. To enhance classification performance and reduce the number of features, a feature selection process was integrated into the system. The Binary Grey Wolf Optimizer algorithm was relied upon for the selection of the most influential features. In conclusion, the results show that the combination of BGWO and the convolutional neural network provides an effective system for the detection of Parkinson's disease, with a notable improvement in performance and diagnostic accuracy, which enhances the possibility of using this approach in smart healthcare applications.

Keywords: Parkinson's disease, Artificial Intelligence, Deep Learning, Convolutional Neural Network, Classification, AlexNet, ResNet50, Feature Selection, Binary Grey Wolf Optimizer.

Résumé

La détection de la maladie de Parkinson est l'un des défis médicaux importants en raison de la difficulté de son diagnostic aux stades précoces. Avec les progrès des technologies d'intelligence artificielle, l'apprentissage profond est apparu comme un outil efficace, en particulier le réseau neuronal convolutif, pour sa bonne performance dans l'analyse d'images. Cette étude présente un système basé sur l'apprentissage profond pour la détection précise de la maladie de Parkinson. Pour la classification de la maladie sur la base de données médicales telles que le dessin a été utilisé deux réseaux profonds qui sont : ALEXNET, RESNET50, et pour améliorer les performances de classification et réduire le nombre de caractéristiques, un processus de sélection de caractéristiques a été intégré dans le système. L'algorithme du loup gris binaire a été utilisé pour la sélection des caractéristiques les plus influentes. En conclusion, les résultats montrent que la combinaison de BGWO et du réseau neuronal convolutif fournit un système efficace pour la détection de la maladie de Parkinson, avec une amélioration notable des performances et de la précision du diagnostic, ce qui renforce la possibilité d'utiliser cette approche dans les applications de soins de santé intelligents. Cela met en évidence le potentiel de cette approche dans les applications de santé intelligentes.

Mots-clés : *Maladie de Parkinson, Intelligence Artificielle, Apprentissage Profond, Réseau de Neurones Convolutif, Classification, AlexNet, ResNet50, Sélection de Caractéristiques, Algorithme du Loup Gris Binaire.*

إهداء

بداية الحمد لله حباً وشكراً وامتنان على البدء والختام (وَأَخِرُ دَعْوَاهُمْ أَنْ
الْحَمْدُ لِلَّهِ رَبِّ الْعَالَمِينَ). من قال انا لها "نالها" وانا لها إن أبت رُغماً عنها
أتيتُ بها. لم تكن رحلة قصيرة ولا ينبغي لها أن تكون، لم يكن الحلم
قريباً ولا الطريق كان مخفوفاً بالتسهيلات لكنني فعلتها ونلتها
إلى الذي زين أسمى بأجمل الألقاب، من دعمني بلا حدود وأعطاني بلا
مقابل، إلى من علمني أن الدنيا كفاح وسلاحها العلم والمعرفة، إلى من
غرس في روحي مكارم الأخلاق داعمي الأول في مسيرتي ملاذي بعد
الله الى فخري واعتزازي (والدي) إلى من جعل الله الجنة تحت أقدامها
واحتضني قلبها قبل يدها وسهلت لي الشدائد بدعائها إلى القلب الحنون
والشمعة التي كانت لي في الليالي المظلمات سر قوتي ونجاحي ومصباح
دربي الى وهج حياتي (والدي) إلى سندي وعزوتي بعد الله ثم أبي الى
قوتي وظهر اخوتي (بشير وعبد الرحمان) الى توأم روحي وحيدتي اختي
الغالية امال واخيراً الشكر موصل لنفسي على الصبر والتي كانت اهلاً
للمصاعب ها انا اختم كل ما مررت به الحمد لله من قبل ومن بعد
راجية من الله تعالى ان ينفعي بما علمني وان يعلمني ما أجهل ويجعله
حجة لي لا على وأخيراً الحمد لله. وجميع من وسعتم ذاكرتي ولم تسعهم
مذكرتي.

شكر و عرفان

بسم الله الرحمن الرحيم الحمد لله نعمده وهو المستحق للحمد والثناء،
ونستعين به في السراء والضراء، وتوكل عليه في جميع امورنا، ونصلي
ونسلم على خير الخلق سيدنا وحبينا محمد عليه أفضل الصلاة والسلام.
نتقدم بأسمى عبارات الشكر والتقدير الى كل من اوقد لنا مشعل الحياة،
وحملنا على سفينة الحياة، الى كل من صرنا بفضلها نكتب ونقرأ، الى
كل من علمنا علما به ننتفع وأدباً به نرتفع، بدءاً من معلتي في المرحلة
الابتدائية وصولاً الى استاذتنا في التعليم العالي. تحية عطرة وشكر خاص
للدكتورة المشرفة شريف فلة التي افادتني بنصائحها وتوجيهاتها، والتي
كان لها الفضل بعد الله في إتمام هذا العمل. وللأستاذ ديدة حذيفة
الذي كان عوناً لي. وتحية طيبة الى اللجنة الموقرة، كل باسمه ومقامه،
التي تكرمت بمناقشة هذه المذكرة وفي الختام، نشكر كل من ساهم في
مساعدتنا لإنجاز هذا العمل، من قريب أو بعيد. والسلام عليكم ورحمة
الله تعالى وبركاته.

قائمة الاختصارات و المصطلحات و الرموز¹

Parkinson's disease	مرض باركنسون
Neurons	الخلايا العصبية
substantia nigra	المادة السوداء
Neurodegenerative disease	مرض تنكسي عصبي
coeruleus locus	اللوزة الدماغية
artificial intelligence	الذكاء الاصطناعي
machine learning	تعلم الآلة
deep learning	التعلم العميق
artificial neural networks	الشبكات العصبية الاصطناعية
supervised learning	التعلم تحت الإشراف
Unsupervised Learning	التعلم غير المشرف عليه
Semi-supervised learning	التعلم شبه المشرف عليه
Reinforcement learning	التعلم المعزز
Front-fed single-layer networks	الشبكات أحادية الطبقة أمامية التغذية
Multilayer front-fed networks	الشبكات متعددة الطبقات أمامية التغذية
Recursive Networks	الشبكات العودية
convolutional neural network	الشبكة العصبية الالتفافية
optimization	التحسين
Meta-heuristics	الخوارزميات الفوق استكشافية
Gray Wolf Optimizer	محسن الذئب الرمادي
Binary gray wolf optimization model	نموذج تحسين الذئب الرمادي الثنائي
classification	التصنيف
Feature Selection	اختيار الميزات
Accuracy	الدقة
Error Rate	معدل الخطأ

Number of Selected Features	عدد الميزات المختارة
Confusion Matrix	مصفوفة الالتباس
sensitivity	حساسية
specficity	تحديد
precision	الدقة
curve ROC	المنطقة ROC
Learning Rate	معدل التعلم
PD	مرض باركنسون
SPECT	التصوير المقطعي بالإصدار البوزيتروني الوحيد
PET	التصوير المقطعي بالإصدار البوزيتروني
MRI	التصوير بالرنين المغناطيسي
ReLU	وحدة الاستجابة الخطية المصححة
GWO	خوارزمية الذئب الرمادي
BGWO	خوارزمية الذئب الرمادي الثنائية
TP	الإيجابي الحقيقي
FP	موجب خاطئ
TN	السلبية الحقيقية
FN	خطأ سلبي
Acc	دقة التصنيف
Err	نسبة الخطأ
SN	حساسية
SP	تحديد
P	الدقة
ROC	منحنى خصائص تشغيل المتلقي
AUC	المنطقة تحت المنحنى
PRC	منحنى الاسترجاع الدقيق

المحتويات

قائمة الاختصارات و المصطلحات و الرموز

قائمة الأشكال

قائمة الجداول

1 مقدمة عامة

2 1 نظرة عامة حول مرض باركنسون والذكاء الاصطناعي

2 1.1 مقدمة

2 2.1 نظرة عامة حول مرض باركنسون

3 1.2.1 تاريخ مرض باركنسون

3 2.2.1 الفيزيولوجيا المرضية لمرض باركنسون

4 3.1 أعراض المرض

5 1.3.1 الأعراض الحركية

5 2.3.1 الأعراض الغير حركية

5 4.1 طرق تشخيص المرض

5 1.4.1 تقنية التصوير

6 2.4.1 التقييم السريري

6 3.4.1 اختبارات المؤشرات الحيوية

7 4.4.1 التشخيص من خلال الخط

7 5.1 الذكاء الاصطناعي

8 1.5.1 تعلم الآلة

8 2.5.1 التعلم العميق

10 6.1 طبقات الشبكة العصبية الالتفافية

10 1.6.1 الطبقة الخطية أو المتصلة بالكامل

10	التنشيط أو الاخطية في الشبكات العصبية	2.6.1
11	الالتفاف المكاني	3.6.1
12	التجمع المكاني	4.6.1
12	طبقة التسطيح	5.6.1
13	أشهر الشبكات العصبية الالتفافية	7.1
13	ALEXNET	1.7.1
15	GoogleNet	2.7.1
15	ResNet50	3.7.1
17	VGGNet	4.7.1
17	الذكاء الاصطناعي ومرض باركنسون	8.1
17	الخاتمة	9.1
18	اختيار الميزات باستخدام طرق التحسين	2
18	مقدمة	1.2
18	اختيار الميزات	2.2
19	آلية عمل اختيار الميزات	1.2.2
20	صياغة دالة الهدف في مشكلة اختيار الميزات	2.2.2
22	التحسين	3.2
23	طرق التحسن	1.3.2
23	الخوارزميات الفوق استدلالية	2.3.2
23	محسن الذئب الرمادي	4.2
26	نموذج تحسين الذئب الرمادي الثنائي 2	5.2
26	مقاييس التقييم لمهمة التصنيف	6.2
27	مصفوفة الالتباس	1.6.2
28	منطقة خصائص تشغيل المتلقي (ROC)	2.6.2
28	منطقة منحنى الاسترجاع الدقيق (PRC)	3.6.2
29	الخاتمة	7.2
30	نتائج المحاكاة ومناقشتها	3
30	المقدمة	1.3
30	قاعدة البيانات	2.3
31	الطريقة المقترحة	3.3
31	استخراج الميزات العميقة	1.3.3

32	دمج الميزات العميقة	2.3.3
32	اختيار الميزات أثناء التدريب	3.3.3
32	تقييم النتائج	4.3.3
32	خوارزميات التحسين	5.3.3
33	النتائج المتحصل عليها	4.3
33	نتائج بدون استخدام اختيار الميزات BGWO	1.4.3
40	نتائج بعد استخدام خوارزمية تحسين الذئب الرمادي الشائبة لاختيار الميزات	2.4.3
44	مقارنة بين استخدام خوارزمية BGWO وبدونها	5.3
44	الخاتمة	6.3

قائمة الأشكال

3	الربط بين خليتين عصبيتين	1.1
4	تمثيل اللوزة الدماغية والمادة السوداء	2.1
4	اعراض مرض باركنسون	3.1
6	دماغ لشخص مريض وشخص غير مريض بمرض باركنسون بالرنين المغناطيسي	4.1
7	كتابة شخص مريض وشخص غير مريض	5.1
7	الذكاء الاصطناعي	6.1
9	تمثيل لرسم موضع للشبكة العصبية	7.1
10	هندسة الشبكات العصبية الالتفافية	8.1
11	دالة التفعيل ReLU	9.1
12	طريقة تكوين قيم خريطة الميزات ، المثال يظهر مجال استقبالي واحد مضروب في مرشح	10.1
12	التجميع الأقصى	11.1
13	التسطيح	12.1
14	مخططاً يوضح بنية AlexNet	13.1
15	مقارنة بين وحدات Inception بدون ومع تقنية تقليل الأبعاد باستخدام مرشحات الالتفاف 1x1	14.1
16	مخططاً يوضح بنية ResNet-50	15.1
17	مخططاً يوضح بنية VGG-16	16.1
19	عملية اختيار الميزات	1.2
20	آلية عمل عملية اختيار الميزات	2.2
24	التسلسل الهرمي لتصنيفات الذئب في خوارزمية الذئب الرمادي ومخطط لآلية الصيد	3.2
25	محاكاة سلوك محاصرة الفريسة في خوارزمية الذئب الرمادي في الفضاء الثنائي	4.2
26	محاكاة سلوك محاصرة الفريسة في خوارزمية الذئب الرمادي في ثلاثي الأبعاد	5.2
27	مصفوفة الالتباس	6.2
28	منحنى ROC	7.2
29	منحنى الاسترجاع الدقيق PRC	8.2

30	الصور للبيانات المستخدمة	1.3
31	الاطار العام للطريقة المقترحة	2.3
34	الاعمدة البيانية لكل من مقاييس الدقة (ACC) ، الحساسية (SN) والتحديد (SP). لنموذج Alexnet	3.3
35	دقة التدريب وخسارة الاختبار خلال عملية التعلم لنموذج AlexNet	4.3
35	مصفوفة الالتباس	5.3
36	منحنى خصائص التشغيل التلقائي لنموذج Alexnet	6.3
38	الاعمدة البيانية لكل من مقاييس الأداء (ACC،SN،SP) لنموذج Resnet-50	7.3
38	دقة التدريب وخسارة الاختبار خلال عملية التعلم لنموذج ResNet-50	8.3
39	مصفوفة الالتباس	9.3
39	منحنى خصائص التشغيل التلقائي لنموذج Resnet-50	10.3
41	الاعمدة البيانية لمقياس الأداء (ACC) لنموذج Alexnet	11.3
	12.3 (أ)، (ب) مصفوفة الالتباس ومنحنى خصائص التشغيل التلقائي لخوارزمية BGWO و(ج)، (د)	
41	مصفوفة الالتباس ومنحنى خصائص التشغيل التلقائي بدون خوارزمية لنموذج Alexnet	
43	الاعمدة البيانية لمقياس الأداء (ACC) لنموذج Resnet-50	13.3
	14.3: (أ)، (ب) مصفوفة الالتباس ومنحنى خصائص التشغيل التلقائي لخوارزمية BGWO و(ج)، (د)	
43	مصفوفة الالتباس ومنحنى خصائص التشغيل التلقائي بدون خوارزمية لنموذج Resnet-50	

قائمة الجداول

33	نتائج تقييم نموذج AlexNet مع مُحسِّن Adam	1.3
34	نتائج تقييم نموذج AlexNet مع مُحسِّن RmsProp عبر ثلاثة مُعدَّلات تعلُّم	2.3
34	نتائج تقييم نموذج AlexNet مع مُحسِّن Sgdm عبر ثلاثة مُعدَّلات تعلُّم	3.3
37	نتائج تقييم نموذج Resnet-50 مع مُحسِّن Adam عبر ثلاثة مُعدَّلات تعلُّم	4.3
37	نتائج تقييم نموذج Resnet-50 مع مُحسِّن RmsProp عبر ثلاثة مُعدَّلات تعلُّم	5.3
37	نتائج تقييم نموذج Resnet-50 مع مُحسِّن Sgdm عبر ثلاثة مُعدَّلات تعلُّم	6.3
40	نتائج تقييم أداء نموذج AlexNet قبل وبعد تطبيق خوارزمية BGWO	7.3
42	نتائج دقة نموذج Alexnet مع وبدون تضمين ميزة BGWO عند تقليل حجم الميزات لنموذج Alexnet	8.3
42	نتائج تقييم أداء نموذج ResNet-50 قبل وبعد تطبيق خوارزمية BGWO	9.3
10.3	نتائج دقة نموذج Resnet-50 مع وبدون تضمين ميزة BGWO عند تقليل حجم الميزات لنموذج	
44	Resnet-50	

مقدمة عامة

في ظل التطور المتسارع للتقنيات الحديثة، أصبح الذكاء الاصطناعي (AI) أداة رئيسية لدعم وتحسين قطاعات متنوعة، خاصة الرعاية الصحية. يهدف الذكاء الاصطناعي إلى محاكاة القدرات العقلية البشرية، مما يتيح تطوير أنظمة لتشخيص الأمراض بدقة وسرعة. ويبرز التعلم العميق كفرع واعد للذكاء الاصطناعي، لقدرته على معالجة البيانات الضخمة واستخلاص الأنماط، خاصة في تصنيف الصور والإشارات الحيوية.

يُعد مرض باركنسون من الاضطرابات العصبية الشائعة التي تؤثر تدريجياً على الجهاز الحركي. ويشكل التشخيص المبكر والدقيق تحدياً نظراً لتشابه أعراضه مع أمراض أخرى. لذا، تبرز الحاجة إلى نماذج ذكية لتحسين دقة التشخيص بناءً على بيانات طبية مثل إشارات الصوت أو الكتابة. يُعد اختيار الميزات خطوة حاسمة لبناء نموذج فعال، حيث يقلل من الخصائص غير الضرورية ويحسن أداء التصنيف. تُستخدم خوارزميات التحسين مثل خوارزمية الذئب الرمادي، التي تحاكي سلوك الصيد لدى الذئاب، لكفاءتها في البحث عن الحلول المثلى. ولزيادة الفعالية، يتم استخدام نسخ محسنة مثل الخوارزمية الذئب الرمادي الثنائية، المتوافقة مع طبيعة اختيار الميزات الثنائية.

تهدف هذه الدراسة إلى استخدام خوارزمية الذئب الرمادي الثنائية لاختيار الميزات المؤثرة في الكشف عن مرض باركنسون، ثم استخدام نماذج تصنيف تعتمد على الذكاء الاصطناعي لتحليل البيانات المختارة وتحقيق نتائج دقيقة. ولتحقيق هذا الهدف، قُنا بتقسيم هذا العمل إلى ثلاثة فصول:

الفصل الأول: ويتناول مفاهيم حول مرض باركنسون والشبكة العصبية.

الفصل الثاني: وهو مخصص لدراسة طرق التحسين وبالأخص خوارزمية الذئب الرمادي وطرق اختيار الميزات.

الفصل الثالث: والذي يتناول الجانب التطبيقي من المذكرة اين سنقوم بعرض ومناقشة النتائج المتحصل عليها في هذه الدراسة.

الفصل 1

نظرة عامة حول مرض باركنسون والذكاء الاصطناعي

1.1 مقدمة

يُعتبر مرض باركنسون من الأمراض العصبية المزمنة التي تؤثر على الملايين حول العالم، ويتسبب في تدهور تدريجي للقدرات الحركية والوظائف العصبية نتيجة لنقص مادة الدوبامين في الدماغ. هذا المرض لا يزال يشكل تحدياً طبياً كبيراً من حيث التشخيص المبكر والمتابعة الفعالة، خاصةً في مراحله الأولية التي قد تتشابه أعراضها مع أمراض أخرى [1]. في المقابل، شهد العالم في العقود الأخيرة تطوراً هائلاً في مجال الذكاء الاصطناعي، وهو فرع من علوم الحاسوب يهتم بتطوير أنظمة ذكية قادرة على محاكاة القدرات البشرية كالتفكير والتعلم والتحليل. وقد أثار هذا التطور اهتمام الباحثين في مختلف المجالات، خاصة القطاع الصحي، لما يوفره من إمكانيات كبيرة في دعم القرارات الطبية وتحليل البيانات المعقدة. يهدف هذا الفصل إلى تقديم نظرة عامة تجمع بين الأساسيات الطبية لمرض باركنسون والمفاهيم العامة للذكاء الاصطناعي، تمهيداً لفهم العلاقة المتنامية بينهما في الفصول اللاحقة.

2.1 نظرة عامة حول مرض باركنسون

مرض باركنسون هو اضطراب عصبي تدريجي يحدث بسبب تدمير الخلايا العصبية في جزء من الدماغ يُعرف بالمادة السوداء، وهو المسؤول عن إنتاج مادة الدوبامين التي تساعد على تنسيق الحركة. مع نقص الدوبامين، تبدأ أعراض مثل الرجفان، وبطء الحركة، وتيبس العضلات، وفقدان التوازن [1].


يعد باركنسون ثاني أكثر الأمراض العصبية التنكسية انتشاراً بعد الزهايمر، ويصيب بشكل أكبر كبار السن، حي يؤثر على أكثر من 1% من الأشخاص الذين تزيد أعمارهم عن 55 عاماً، وأكثر من 3% من الأشخاص الذين تزيد أعمارهم عن 75 عاماً [2]. عند موت خلايا المادة السوداء في الدماغ ينتج عن ذلك نقص في الدوبامين. عادةً ينتج التحكم في الحركة عن توازن دقيق بين كميات الدوبامين والأسيتيل كولين (وهو ناقل كيميائي آخر). وبالتالي، إذا اختل هذا التوازن تحدث رعشات وفقدان التنسيق. وعلى العكس، قد يؤدي فرط الدوبامين الى ظهور أعراض مرتبطة بالفصام [1].

1.2.1 تاريخ مرض باركنسون

بدأت أول دراسة منهجية حول مرض باركنسون على يد الطبيب البريطاني جيمس باركنسون عام 1817، حيث افترض حينها أن منشأ المرض يقع في النخاع الشوكي. وفي عام 1877، قام شاركو (Charcot) بتسمية المرض باسم "باركنسون" تكريماً لمكتشفه، بينما قدم بريسو (Brissaud) عام 1892 إعادة تعريف للمرض ساعدت على توسيع فهمه. ثم جاء تريتيكوف (Tretiakoff) عام 1919 ليكتشف وجود أجسام ضمن المادة السوداء تفتقر إلى الصباغ، وهو ما قدم أدلة جديدة حول آليات المرض [3]. أما فيما يتعلق بالدوبامين، فقد بدأ اكتشافه عام 1911 من خلال تخليقه مخبرياً، إلا أن دوره الحيوي لم يتضح إلا في الخمسينيات، عندما لوحظ انخفاض مستوياته لدى المرضى الذين يتناولون مادة ريزيربين (Reserpine) مما رجح ارتباطه المباشر بمرض باركنسون. وفي عام 1961، بدأ استخدام L-dopa في العلاج عن طريق الحقن الوريدي، وتلاه استخدامه فوياً في عام 1962، ليصبح لاحقاً العلاج الأساسي للمرض. وقد توجت الجهود العلمية في هذا المجال بمنح أرفيد كارلسون (Arvid-Carlsson) جائزة نوبل في الطب عام 2000، تقديراً لاكتشافه أهمية الدوبامين كناقل عصبي أساسي في الدماغ [3].

2.2.1 الفيزيولوجيا المرضية لمرض باركنسون


يُعد اضطراب نظام الدوبامين إحدى السمات البارزة لهذا المرض. حيث يعاني الدماغ في بعض أجزائه من نقص مادة الدوبامين، وهو ناقل عصبي يعمل كمرسل كيميائي بين خليتين عصبيتين (لاحظ الشكل 1.1). يتم تصنيع المادة في نهايات المحاور العصبية ويتم إطلاقه في الفجوة التشابكية استجابةً للإشارات العصبية. ومع ذلك، فإن التغيرات الطارئة في الدماغ لا تقتصر على نظام الدوبامين فقط، بل تشمل أيضاً أنظمة أخرى من الناقلات العصبية، وعلى سبيل المثال الأدرينالين [1].



شكل 1.1: الربط بين خليتين عصبيتين

شهد فهم الفيزيولوجيا المرضية لمرض باركنسون تقدماً كبيرة بعد اكتشاف العديد من الجينات المرتبطة بأنواع نادرة من المرض. خلال تطور المرض، تتأثر عدة مناطق في الدماغ، حيث تبدأ أولاً بإصابة منطقة التلال الشمية واللوزة الدماغية (الشكل 2.1)، والتي تقوم بعمل اضطرابات في النوم، وكل هذا يكون في المراحل المبكرة. لاحقاً، تتعرض

المناطق المسؤولة عن تنظيم الحركة، مثل المادة السوداء الموجودة في الجزء العلوي من جذع الدماغ، للضرر، مما يؤدي إلى ظهور الأعراض الحركية المميزة للمرض. ومع استقرار تطور المرض، قد تصل الأضرار إلى الهياكل القشرية [1].



شكل 2.1: تمثيل اللوزة الدماغية والمادة السوداء

3.1 أعراض المرض

تحدث أعراض مرض باركنسون (PD) بسبب انخفاض مستوى الناقل الكيميائي الدوبامين، الذي يتيح إرسال الإشارات إلى أجزاء الدماغ المسؤولة عن تنسيق الحركة، وذلك نتيجة موت الخلايا العصبية المنتجة للدوبامين. ومع فقدان هذه الخلايا، تصبح هذه الأجزاء من الدماغ غير قادرة على العمل بشكل طبيعي، مما يؤدي إلى ظهور أعراض المرض [4]. قد تظهر العلامات المبكرة خفيفة وقد تزداد سوءاً بمرور الوقت. عادةً، تبدأ الأعراض في جانب واحد من الجسم وتميل إلى أن تكون أكثر وضوحاً في ذلك الجانب. يبين الشكل (3.1) العلامات والأعراض الشائعة لمرض باركنسون حيث يشمل أعراض حركية وأخرى غير حركية. وسوف نتحدث عن بعضها في ما يلي: [5]



شكل 3.1: أعراض مرض باركنسون

1.3.1 الأعراض الحركية

تتمثل الأعراض الحركية في:

- الرعاش: هو اهتزاز يبدأ عادة في اليدين أو الأصابع. قد تقوم بفرك إبهامك وسبابتك معاً ذهاباً وإياباً، وهو ما يُعرف برعاش لف الحبوب. قد ترتجف يدك عندما تكون في حالة راحة أو عندما تكون تحت الضغط.
- بطء الحركة: قد يؤدي مرض باركنسون إلى تباطؤ حركتك، مما يجعل المهام البسيطة أكثر صعوبة. قد يكون من الصعب النهوض من الكرسي أو الاستحمام أو ارتداء الملابس. قد تقل تعابير وجهك، وقد تجد صعوبة في الرمش.
- تصلب العضلات: قد تشعر بتصلب في أي جزء من جسمك. قد تكون العضلات مشدودة ومؤلمة، وقد تصبح حركات ذراعك قصيرة ومهتزة.
- سوء في الوضعية والتوازن: قد تصبح وضعيتك منحنية، وقد تواجه صعوبة في التوازن أو تسقط.
- فقدان الحركات التلقائية: قد تقل قدرتك على أداء بعض الحركات التي تقوم بها عادة دون تفكير، مثل الرمش، أو الابتسام، أو التأرجح بذراعيك أثناء المشي.
- تغيرات في الكلام: قد تتحدث بصوت منخفض أو بسرعة، أو تتلعثم، أو تتردد قبل التحدث. قد يكون صوتك مسطحاً أو أحادي النغمة، بدون الأنماط الطبيعية للكلام.
- تغيرات في الكتابة: قد تجد صعوبة في الكتابة، وقد تبدو كتابتك ضيقة وصغيرة.

2.3.1 الأعراض الغير حركية

تتمثل الاعراض الغير حركية في الاكتئاب، القلق، الإمساك، ومشاكل في النوم. وقد تتضمن أيضاً التصرف بناءً على الأحلام، الحاجة المتكررة للتبول، صعوبة في الشم، مشاكل في التفكير والذاكرة، والشعور بالإرهاق الشديد.


4.1 طرق تشخيص المرض

يمثل تشخيص اضطرابات مرض باركنسون تحدياً كبيراً في المجال الطبي، حيث تصل نسبة الأخطاء في تشخيصه الى حوالي 24 % . ومع زيادة أعداد كبار السن، تبرز الحاجة الى تشخيص دقيق وسريع لهذه الاضطرابات لضمان التدخل العلاجي في الوقت المناسب [6] ، ومن بين طرق التشخيص تتعرف على التالي:

1.4.1 تقنية التصوير

على الرغم من أن تقنيات التصوير العصبي لا توفر تشخيصاً قاطعاً لمرض باركنسون بمفردها، فإنها تُعد أدوات مساعدة قيمة في دعم التشخيص السريري واستبعاد الاضطرابات الأخرى المشابهة. من بين هذه التقنيات، تُعد DaTscan الأكثر

استخداماً، حيث تعتمد على حقن مادة IoflupaneI-123 وهي نظير مشع يُستخدم في التصوير المقطعي المحوسب بإصدار الفوتون الأحادي (SPECT). تساعد هذه التقنية في تصوير نشاط ناقلات الدوبامين في العقد القاعدية، والتي تظهر غالباً بمستوى منخفض لدى مرضى باركنسون. وتعد DaTscan مفيدة بشكل خاص عندما يكون التشخيص السريري غير مؤكد أو للتمييز بين داء باركنسون ومتلازمات الشلل الرعاشي الأخرى [7]. بالإضافة إلى ذلك، تُستخدم تقنيات أخرى مثل التصوير المقطعي بالإصدار البوزيتروني (PET) لتقييم وظيفة الدوبامين من خلال متبعتات إشعاعية مختلفة، مما يوفر صورة دقيقة لنشاط النواقل العصبية في الدماغ. كما يمكن لتقنية الرنين المغناطيسي (MRI) أن تساعد في استبعاد الأسباب الأخرى للأعراض، مثل السكتات الدماغية أو الأورام، وللكشف عن التغيرات البنيوية المرتبطة باضطرابات الحركة. (كما هو موضح في الشكل (4.1)).



شخص غير مريض بمرض باركنسون

شخص مريض بمرض باركنسون

شكل 4.1: دماغ لشخص مريض وشخص غير مريض بمرض باركنسون بالرنين المغناطيسي

2.4.1 التقييم السريري


يعد التقييم السريري الشامل الطريقة الرئيسية لتشخيص مرض باركنسون، ويتم بواسطة طبيب أعصاب متخصص في اضطرابات الحركة. يشمل هذا التقييم جمع تاريخ طبي مفصل وإجراء فحص عصبي شامل. يقوم الطبيب بالبحث عن الأعراض الحركية الأساسية مثل بطء الحركة، الرعاش أثناء الراحة، التصلب، وعدم الاستقرار الوضعي. لتأكيد تشخيص مرض باركنسون، يجب أن يظهر لدى المريض على الأقل عرضين من هذه الأعراض. إضافة إلى ذلك، يمكن أن تدعم بعض الأعراض غير الحركية مثل ضعف حاسة الشم، واضطراب سلوك النوم في مرحلة حركة العين السريعة، والاضطرابات اللاإرادية في تشخيص المرض [8].

3.4.1 اختبارات المؤشرات الحيوية

لقد أصبحت اختبارات المؤشرات الحيوية الحديثة تكتسب أهمية متزايدة في تشخيص مرض باركنسون. من بين الاختبارات المتاحة تجارياً، يوجد اختبار البروتين α -synuclein في السائل النخاعي، وخزعة الجلد للكشف عن α -synuclein الفسفوري. لا تزال هذه الاختبارات قيد التقييم لتحديد فائدتها في الممارسة السريرية. بالإضافة إلى ذلك، يجري الباحثون دراسات لتحديد المؤشرات الحيوية في الدم التي قد تساعد في التشخيص المبكر للمرض [9][10]

4.4.1 التشخيص من خلال الخط

لقد أصبح الفحص من خلال خط يد المريض أداة مساعدة في تشخيص الامراض العصبية والحركية بما في ذلك مرض باركنسون. حيث يمكن استعماله للكشف المبكر عن مرض وتشخيصه ذاتيا في مراحله الاولى (انظر الشكل 5.1) [6]




شكل 5.1: كتابة شخص مريض وشخص غير مريض

5.1 الذكاء الاصطناعي

الذكاء الاصطناعي هو مجال علمي يتعلق بإنشاء أجهزة كمبيوتر وآلات يمكنها التفكير والتعلم والتصرف بطرق تتطلب عادة ذكاء بشرياً أو تتضمن بيانات يتجاوز حجمها ما يمكن للبشر تحليله [11]. ويتكون من عدة فروع ، من أبرزها كما هو موضح في الشكل 6.1:

- تعلم الآلة: وهو أحد الفروع الرئيسية، ويعني تمكين الأنظمة من التعلم من البيانات وتحسين أدائها دون أن تتم برمجتها بشكل صريح لكل مهمة.
- التعلم العميق: أحد فروع تعلم الآلة يستخدم طبقات متعددة من الشبكات العصبية لحل مشكلات معقدة.



شكل 6.1: الذكاء الاصطناعي

1.5.1 تعلم الآلة

يُعد تعلم الآلة فرعاً من فروع الذكاء الاصطناعي، ويتضمن في نطاقه التعلم العميق. يعتمد هذا المجال على تحليل البيانات السابقة لاستخلاص الأنماط والمعارف بهدف التنبؤ بالبيانات المستقبلية، مما يساهم في التحكم الآلي بالعمليات وتحسين الأداء بمرور الوقت. ينقسم التعلم الآلي إلى أربعة أنواع رئيسية:


1. التعلم تحت الإشراف: يتم فيه استخدام بيانات مُعلّمة (أي أن المخرجات معروفة مسبقاً) لتدريب النموذج.
 2. التعلم غير المُشرف عليه: يُستخدم عندما لا تكون هناك مخرجات محددة، ويهدف لاكتشاف البنى أو الأنماط في البيانات.
 3. التعلم شبه المُشرف عليه: يجمع بين النوعين السابقين، ويُستخدم عندما تكون هناك كمية قليلة من البيانات المُعلّمة وكميات كبيرة من البيانات غير المُعلّمة.
 4. التعلم المعزز: يعتمد على مبدأ المكافأة والعقوبة، حيث يتعلم النموذج من التجربة لتحسين قراراته بمرور الوقت.
- لكل نوع من هذه الأنواع استخداماته الخاصة ويتم اختياره حسب طبيعة المشكلة وحالة الاستخدام المناسبة [12].

2.5.1 التعلم العميق

التعلم العميق هو منهجية تعلم آلي تعتمد على الشبكات العصبية الاصطناعية وتُستخدم في مجالات متعددة مثل التعرف على الكلام، والرؤية الحاسوبية، وتحليل البيانات الضخمة [13]. وهو كذلك نهج حديث نسبياً لتدريب الشبكات العصبية متعددة الطبقات. يضم مجموعة من الخوارزميات القادرة على تدريب نماذج عصبية معقدة. ويعتبر النموذج عميق عندما يحتوي على أكثر من طبقتين مخفيتين [14].

الشبكات العصبية الاصطناعية

يبين الشكل (7.1) الشبكة العصبية والتي هي مستوحاة من طريقة عمل الدماغ البشري، وتُستخدم في تحليل الأنماط والتعرف على الصور والصوت وغيرها تُعرف الشبكة العصبية بأنها رسم بياني موجه يتكون من عدة عقد مترابطة عبر روابط، حيث يتم تمرير المجموع الموزون لمخرجات العقدة كمدخلات إلى العقدة التالية. وقد استُوحى هذا النموذج من تركيب الدماغ البشري [15].




شكل 7.1: تمثيل لرسم موضح للشبكة العصبية

تُعد الشبكات العصبية إحدى خوارزميات التعلم الآلي الخاضع للإشراف ، وتستخدم بشكل أساسي في مهام التصنيف . يمكن تصنيف الشبكات العصبية إلى عدة أنواع بناءً على بنية الشبكة، [15]. ومن بين هذه الأنواع ما يلي:

1. الشبكات أحادية الطبقة أمامية التغذية: تُعد أبسط أنواع الشبكات العصبية، حيث تتألف من طبقة إدخال متصلة مباشرة بطبقة إخراج، دون وجود أي طبقات مخفية بينهما.
2. الشبكات متعددة الطبقات أمامية التغذية: يتميز هذا النوع بوجود طبقة واحدة على الأقل مخفية بين طبقتي الإدخال والإخراج، مما يجعله أكثر قدرة على معالجة البيانات المعقدة.
3. الشبكات العودية: يختلف هذا النوع عن الشبكات أمامية التغذية بوجود اتصالات راجعة ، حيث يمكن إعادة تغذية مخرجات بعض العقد إلى العقد الأخرى داخل الشبكة، مما يمكنها من معالجة البيانات المتسلسلة مثل النصوص والإشارات الزمنية [15].

الشبكة العصبية الالتفافية

تُعد الشبكة العصبية الالتفافية نوعاً من الشبكات العصبية العميقة التي تُستخدم في التعلم الآلي . ومن أبرز مجالات استخدامها الرؤية الحاسوبية ، معالجة اللغة الطبيعية ، وتحليل المعلومات المرئية في الصور. [16]. تتكون الشبكات الالتفافية بشكل عام من طبقة دخول، و طبقتي التفاضل و تجميع تليهما طبقة تفعيل، إضافة إلى طبقة تسطيح، و طبقة ربط كامل (الشكل 8.1).



شكل 8.1: هندسة الشبكات العصبية الالتفافية

6.1 طبقات الشبكة العصبية الالتفافية

1.6.1 الطبقة الخطية أو المتصلة بالكامل

يمكن اعتبار الطبقة الخطية على أنها دالة تقوم بتطبيق تحويل خطي على إدخال متجهي ذي بُعد I وتنتج متجهاً ذا بُعد O .

$$(1.1) \quad y = Ax + b$$

$$(1.2) \quad y_i = \sum_{j=1}^I A_{i,j} x_j + b_i$$

يتم تحفيز الطبقة الخطية من خلال الوحدة الحسابية الأساسية في الدماغ المسماة العصبون. يمكن العثور على ما يقارب 86 مليار عصبون في الجهاز العصبي البشري، وهي متصلة بحوالي عشرة قوة خمسة عشر تشابك عصبي. يتلقى كل عصبون إشارات الإدخال من التغصنات أو الاغصان الخاصة به وينتج إشارة خرج على طول المحور العصبي. تُبسّط الطبقة الخطية هذه العملية بربط عدة عصبونات بنفس المدخلات. عادةً، تُستخدم دالة تنشيط مثل السيجمويد لإضافة لخطية، لكن هنا نفترض أن دالة التنشيط هي دالة الهوية التي تُنتج قيمة حقيقية مباشرةً. [16]

2.6.1 التنشيط أو اللاخطية في الشبكات العصبية

إن قدرة الشبكات العصبية على تقريب الدوال المختلفة، خاصة الدوال غير المحدبة، تعتمد بشكل كبير على دالة التنشيط غير الخطية. تقوم كل دالة تنشيط بإجراء عمليات رياضية معينة على كل عنصر من عناصر متجه الإدخال. هناك ثلاث دوال رئيسية مستخدمة هنا:

1. الدالة السينية: تحول القيم إلى النطاق $[0,1]$ ، ولكنها تعاني من تشبع التدرج، مما يضعف تحديث الأوزان

$$(1.3) \quad y = \sigma(x) = \frac{1}{1 + e^{-x}}$$


2. ظل التمام الزائدي: ينقل القيم إلى نطاق $[-1, 1]$ ، مما يؤدي إلى استقرار التدريب، ولكن مع نفس مشكلة التشبع.

$$(1.4) \quad y = 2\sigma(x) - 1$$

3. وحدة الاستجابة الخطية المصححة: تتيح تمرير القيم الموجبة كما هي وتحويل القيم السالبة إلى 0، مما يسرع التدريب ويمنع تلاشي التدرج، لكنها قد تفقد بعض المعلومات السالبة (انظر الشكل 9.1).

$$(1.5) \quad y = \max(0, x)$$

وتعد من أكثر دوال استخداما وذلك بسبب بساطتها وفعاليتها في تحسين أداء الشبكة العصبية والمسماة بالريلو ReLU.




شكل 9.1: دالة التنفيل ReLU

3.6.1 الالتفاف المكاني

لا تتناسب الشبكات العصبية التقليدية، التي تتكون فقط من طبقات خطية وطبقات تنفيل، بشكل جيد مع معالجة الصور الكاملة. وبسبب هذا تستغل طبقات الالتفاف المكاني من العلاقات المكانية بين وحدات البكسل في الصورة، حيث يفترض أن البكسلات المجاورة يجب أن تحتفظ بنفس الخصائص بغض النظر عن موقعها. لذا، تتعلم طبقة الالتفاف مجموعة من [16] المرشحات $F = f_1, \dots, f_{N_k}$ يتم تطبيقها على الصورة المدخلة x لإنتاج خرائط ميزات ثنائية الأبعاد:

$$(1.6) \quad z_k = f_k * x$$

حيث $*$ هو معامل الالتفاف. وعلى عكس الطبقات الخطية، تتم مشاركة الأوزان عبر الصورة، مما يقلل من عدد المعاملات ويسمح للشبكة بتعلم التكافؤ المكاني. يمكن اعتبار الطبقات المتصلة بالكامل حالة خاصة من التلايف بحجم مرشح $1 \times 1 \times 1$. يتم تعريف الطبقات الالتفافية من خلال عدد المرشحات وخصائصها (عدد القنوات والعرض والارتفاع)، بالإضافة إلى معاملات التلايف مثل الحشو والخطوة. [16] كما هو موضح في الشكل 10.1 يعد الناتج "4" قيمة واحدة فقط في خريطة الميزات.




شكل 10.1: طريقة تكوين قيم خريطة الميزات ، المثال يظهر مجال استقبالي واحد مضروب في مرشح

4.6.1 التجمع المكاني

بعد إنشاء الطبقات التلافيفية وتطبيق دوال التنفيع عليها كدالة ReLU يتم استخدام أسلوب يسمى بالتجمع المكاني يطلق عليه أيضاً عملية الاختزال أو جمع العينات .
التجمع المكاني في الشبكات العصبية الالتفافية ، تُستخدم طبقة التجمع عادةً لتصبح غير حساسة للتغيرات الصغيرة في الصورة المدخلة ولتقليل البُعد (مثل العرض والارتفاع) لخريطة الميزة:

$$(1.7) \quad p_R = P_{iR}(z_i)$$

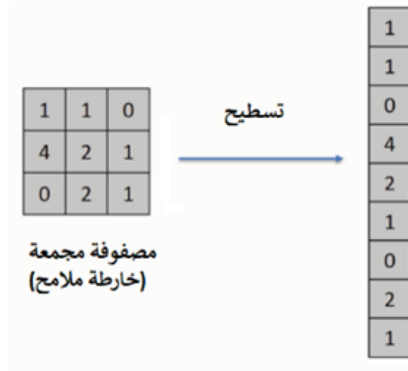
حيث P هي دالة التجمع المطبقة على منطقة البكسل R. نظراً لأن التدرجات تتركز في مكان واحد أثناء التكاثر العكسي، [16] يُفضّل التجمع الأقصى لمنع إلغاء العناصر السالبة ولتقليل ضوضاء التنشيط والتدرج عبر الشبكة كما هو موضح في الشكل 11.1. طبقة التجمع المكاني هي دالة التجمع المستخدمة. أبعاد المنطقة التي يتم تطبيق التجمع عليها (العرض والارتفاع).



شكل 11.1: التجمع الأقصى

5.6.1 طبقة التسطيح

يمثل الشكل 12.1 التسطيح والذي يتمثل في تحويل كل مصفوفة مجمعة (و تسمى أيضاً خارطة ملامح) ناتجة عن عمليات الالتفاف و التجمع في الأخير إلى سلسلة خطية عددها هو عدد خانات المصفوفة السابقة.



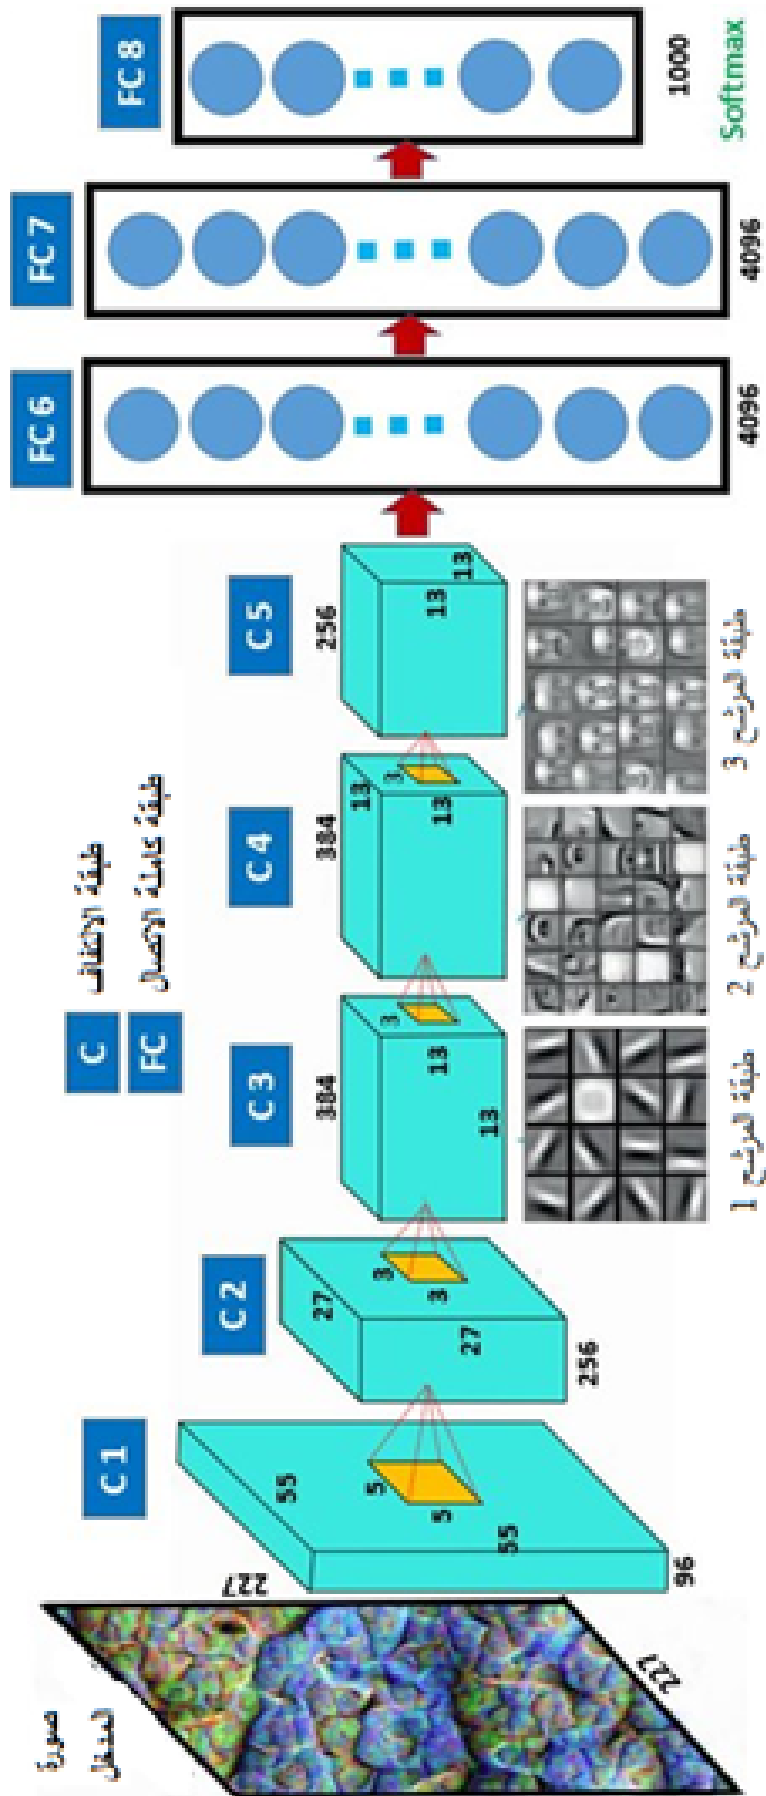
شكل 12.1: التسطيح

7.1 أشهر الشبكات العصبية الالتفافية

لقد أصبحت الشبكات العصبية الالتفافية العنصر الأساسي للعديد من المهمات رؤية الحاسوب وذلك لقدرتها على تعلم التدرجات الهرمية المكانية للميزات من الصور المدخلة تلقائياً. نتطرق فيما يلي إلى أشهر الشبكات العصبية الالتفافية:

1.7.1 ALEXNET


كان أول تطبيق للشبكات الالتفافية وتم استخدامه لقراءة الرموز البريدية والأرقام ، اما ALEXNET فقد مثل نقطة تحول رئيسية في مجال الرؤية الحاسوبية، حيث كان أول نموذج للشبكة العصبية الالتفافية يُحقق نتائج مذهلة في مسابقة ImageNet لعام 2012. تميزت AlexNet ببنية مشابهة إلى حد ما لـ LeNet، لكنها كانت أعمق وأكثر تعقيداً، حيث احتوت على عدد أكبر من الطبقات الالتفافية المكسدة، واستخدمت تقنيات حديثة نسبياً في ذلك الوقت مثل ReLU للتفعيل، و Dropout لتقليل الإفراط في التعلم، و acceleration GPU لتسريع التدريب. تتكون من 8 طبقات رئيسية: 5 طبقات التفاف و 3 طبقات مرتبطة بالكامل (الشكل 13.1). [17]



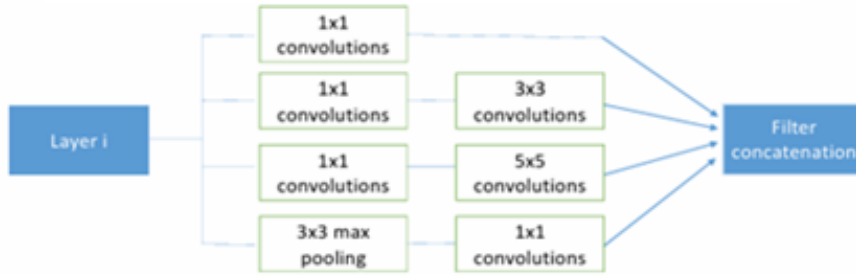
شكل 13.1: مخططاً يوضح بنية AlexNet

GoogleNet 2.7.1

المسمى كذلك باسم Inception-v1 ، هو بنية الشبكة العصبية الالتفافية التي طورها google سنة 2014، تعتمد بنية GoogleNet على مفهوم Inception (الشكل 14.1) وهي عبارة عن مزيج من الطبقات الالتفافية والتجمعية المصممة لاستخراج الميزات على نطاقات مختلفة. [18]



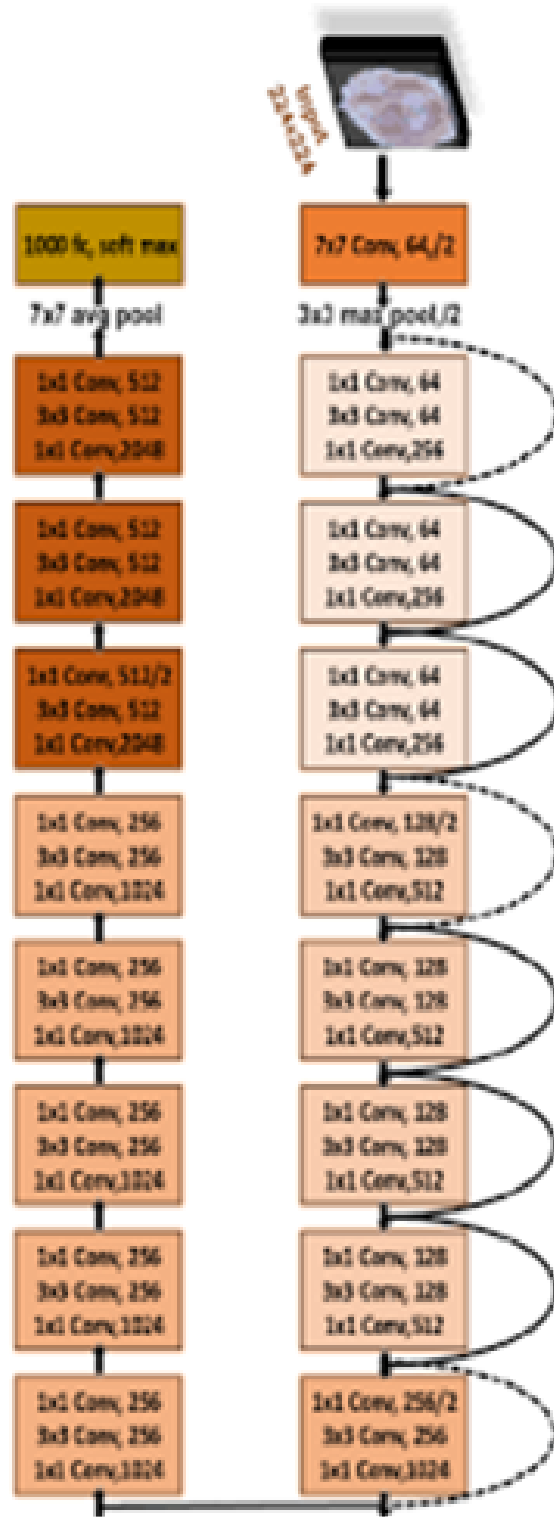
(a) وحدة Inception بدون استخدام تقنية مرشح الالتفاف 1x1 لتقليل الأبعاد



شكل 14.1: مقارنة بين وحدات Inception بدون ومع تقنية تقليل الأبعاد باستخدام مرشحات الالتفاف 1x1

ResNet50 3.7.1

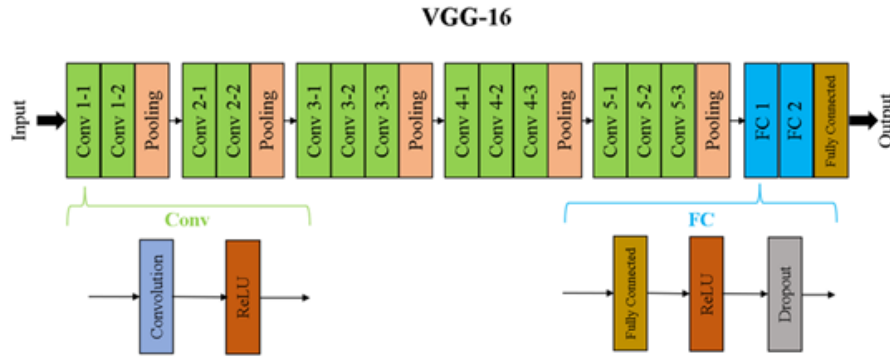
قدمت ResNet، التي طورها كامينغ هي من Microsoft "تخطي الهوية" لمعالجة مشكلة التدرج المتلاشي". أدى هذا الابتكار إلى إنشاء نموذج ResNet، الذي فاز بتحدي ILSVRC 2015 مع تحسن كبير في الأداء، مما قلل من نسبة الخطأ الخمسة الأوائل إلى 3.6 بالمئة متجاوزاً الأداء على مستوى الإنسان في نفس مجموعة البيانات. وضع هذا الإنجاز معايير جديدة في مهام التصنيف والكشف . على الرغم من كونه أعمق 8 مرات من VGGNets (22 طبقة) مع 152 طبقة، إلا أن ResNet لديها تعقيد أقل من VGGNets (16/19). يتم تنظيم بنية ResNet-50 (الشكل 15.1) في سلسلة من المراحل، تتكون كل منها من مزيج من الطبقات التلافيفية، وتطبيع الدفعة، ووظائف التنشيط (ReLU)، وطبقات التجميع، تليها بالكامل طبقات متصلة في النهاية. [19]



شكل 15.1: مخططاً يوضح بنية ResNet-50

VGGNet 4.7.1

يحتوي VGGNet (الشكل 16.1) أفضل نموذج نهائي للشبكة على 16 طبقة من الالتفاف والاتصال الكامل، ويتميز بهيكل متجانس للغاية يستخدم فقط التفافات 3×3 وتجميعات 2×2 من البداية إلى النهاية. احدى عيوب VGGNet هي أنها مكلفة من حيث الحسابات، كما أنها تستهلك كمية كبيرة من الذاكرة والمعاملات (140 مليون). معظم هذه المعاملات توجد في أول طبقة متصلة بالكامل، وقد تم اكتشاف لاحقاً أن إزالة هذه الطبقات لا يؤثر على الأداء، مما أدى إلى تقليل عدد المعاملات اللازمة بشكل كبير [17].



شكل 16.1: مخططاً يوضح بنية VGG-16

8.1 الذكاء الاصطناعي ومرض باركنسون

يُعد الذكاء الاصطناعي أداة واعدة في الكشف المبكر عن مرض باركنسون، تعتمد تقنيات الذكاء الاصطناعي على تحليل كميات ضخمة من البيانات الطبية والسلوكية للمريض بهدف استخراج أنماط دقيقة قد يصعب على الأطباء ملاحظتها في المراحل الأولى من المرض. تُستخدم خوارزميات التعلم الآلي والتعلم العميق لتحليل رسومات اليد، وأنماط المشي، وتسجيلات الصوت، وحتى صور الدماغ، مما يُمكن من التمييز بين الحالات السليمة والمصابة بدرجة عالية من الدقة. هذه الأدوات لا تُساعد فقط في التشخيص المبكر، بل تتيح أيضاً تتبع تطور المرض وتخصيص العلاجات بشكل أدق، مما يسهم في تحسين جودة حياة المرضى وتقليل العبء على الأنظمة الصحية.

9.1 الخاتمة

في هذا الفصل، تطرقنا في البداية الى مرض باركنسون حيث تعرفنا عليه من الناحية العلمية وعن أسبابه وشرحناه بطريقة مفصلة نوعاً ما، أي اعراض هذا المرض وكيفية تشخيصه. بعد ذلك قمنا بالتعرف على التعلم العميق والتعلم الآلي وفصلنا في الشبكة العصبية الالتفافية.

الفصل 2

اختيار الميزات باستخدام طرق التحسين

1.2 مقدمة

في مشكلات التصنيف أو التنبؤ، غالباً ما تحتوي مجموعات البيانات على عدد كبير من الميزات، إلا أن وجود عدد كبير من الميزات لا يعني بالضرورة تحسين أداء النموذج؛ إذ أن بعض هذه الميزات قد لا تكون ذات صلة، أو مكررة، أو حتى ذات تأثير سلبي، مما يؤدي إلى زيادة تعقيد النموذج وتقليل دقته وفعاليته. من هذا المنطلق، برزت خوارزميات التحسين كأدوات فعالة لاختيار مجموعة فرعية مثلى من الميزات التي تُحقق:

• أعلى دقة ممكنة في التصنيف،

• أقل عدد ممكن من الميزات،

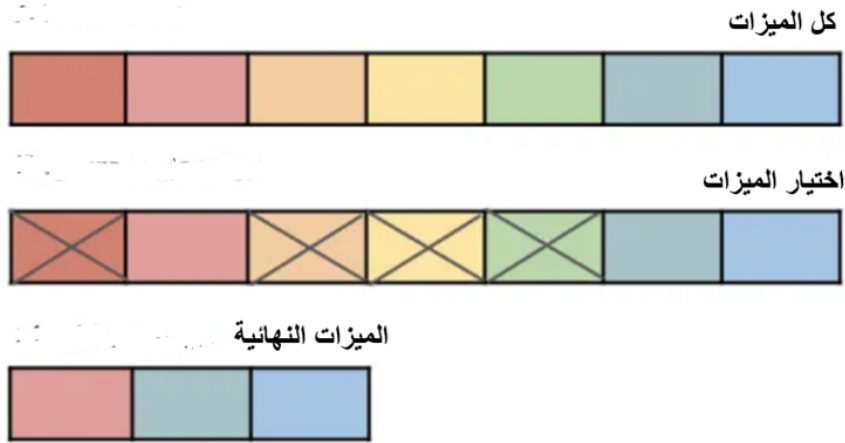
• وأفضل قدرة على التعميم على بيانات جديدة.

في هذا الفصل، سوف نتناول مفهوم اختيار الميزات ودوره الجوهري في بناء نماذج تعلم أكثر كفاءة ودقة. كما سنسلط الضوء على استخدام خوارزميات التحسين الذكية، التي أثبتت قدرتها العالية على معالجة هذه المشكلة. على وجه الخصوص، سنناقش كيفية تحويل مسألة اختيار الميزات إلى مسألة تحسين، يتم فيها تطبيق خوارزميات مستوحاة من سلوك الطبيعة، مثل خوارزمية الذئب الرمادي، مع تحليل مراحل عملها وكيفية تمثيل الحلول داخلها.

2.2 اختيار الميزات

اختيار الميزات هو عملية تهدف إلى انتقاء الميزات الأكثر صلة من بين مجموعة الميزات الكاملة، أو تحديد مجموعة فرعية مثالية منها. وتُستخدم في هذه العملية معايير تقييم محددة تساعد على تحديد تلك المجموعة المثالية. في حالة البيانات عالية الأبعاد - حيث يكون عدد العينات أقل بكثير من عدد الميزات - تصبح عملية اختيار الميزات تحدياً كبيراً، إذ تُعد من المسائل المعقدة التي تتدرج ضمن فئة المشاكل الصعبة. فعند وجود مجموعة بيانات تحتوي على N ميزة، فإن عدد المجموعات الفرعية الممكنة من الميزات يبلغ 2^N ، مما يزيد من تعقيد عملية البحث عن الحل الأمثل. [20]. يتعلق اختيار الميزات بالتعامل

مع الميزات التي قد تكون غير ملائمة أو غير مرتبطة أو غير ضرورية. وتعتبر هذه العملية ضرورية لاستخراج أفضل الميزات من مجموعات البيانات (كما هو موضح في الشكل 1.2). يُعتبر اختيار الميزات من أبرز التحديات في مجال تعلم الآلة، ويمكن تطبيقه في مجالات متعددة.



شكل 1.2: عملية اختيار الميزات

1.2.2 آلية عمل اختيار الميزات

نفرض وجود مجموعة بيانات نسميها S تحتوي على d عدداً من الميزات. طريقة عمل اختيار الميزات تهدف الى اختيار الميزات ذات الصلة من بين الميزات d . مجموعة البيانات $S: f_1, f_2, f_3, \dots, f_d$ الهدف هو اختيار أفضل مجموعة فرعية من الميزات من المجموعة S . نقوم باستخراج المجموعة الفرعية $D = f_1, f_2, f_3, \dots, f_n$ حيث ان $n < d$ ، و ملاحظة أن هناك 5 مكونات رئيسية لعملية اختيار الميزات، وهي:

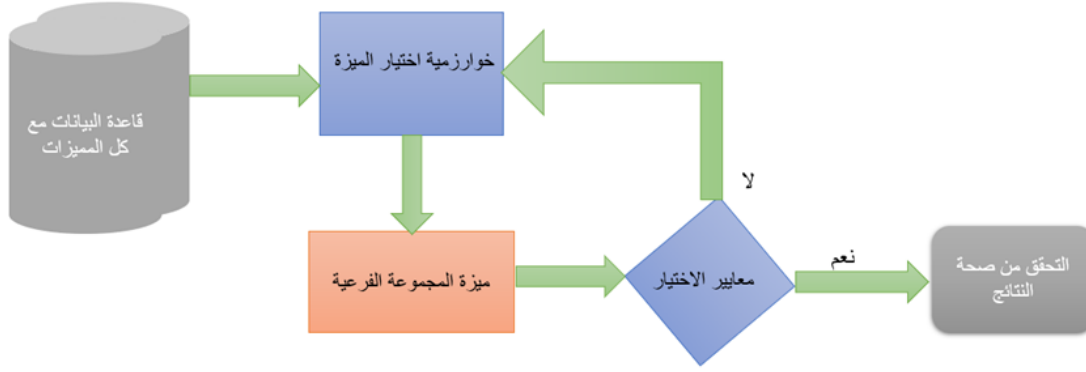
- مجموعة البيانات الأصلية

- اختيار مجموعة فرعية من الميزات

- تقييم المجموعة الفرعية

- معيار الاختيار

- التحقق النهائي [21]



شكل 2.2: آلية عمل عملية اختيار الميزات

2.2.2 صياغة دالة الهدف في مشكلة اختيار الميزات

صياغة دالة الهدف في مشكلة اختيار الميزات تهدف إلى تحقيق توازن بين شيئين رئيسيين:

- أداء النموذج
- عدد الميزات المستخدمة

1. الدوال ذات الهدف الواحد

[22] في سياق مشكلة اختيار الميزات ، عند استخدام وظائف ذات هدف واحد ، يكون التركيز على تحسين مقياس واحد فقط بدلاً من تحقيق توازن بين هدفين أو أكثر (كما في الحالة متعددة الأهداف). تركز الوظائف ذات الهدف الواحد على تحقيق مستوى مثالي لوظيفة معينة واحدة فقط، مع مراعاة القيود المفروضة. من الناحية الرياضية، يتم تمثيل مشاكل تحسين الهدف الواحد بالشكل التالي:

$$(2.1) \quad \text{Minimize/Maximize: } f(x), \quad x \in X$$

حيث تمثل $f(x)$ دالة الهدف، فإن x تشير إلى متجه الحل الذي يتكون من متغيرات القرار الدقة: الدقة تقيس مدى كفاءة خوارزمية التصنيف في التنبؤ الصحيح بفئات البيانات. يتم حساب الدقة كنسبة الحالات التي تم التنبؤ بها بشكل صحيح إلى العدد الإجمالي للحالات في مجموعة البيانات. معدل الخطأ: يُشار إليه أحياناً بمعدل الخطأ في التصنيف، وهو مكمل أساسي لمقياس الدقة. يقيس الدقة العامة لنموذج ما من حيث نسبة الحالات التي تم تصنيفها بشكل خاطئ في مجموعة البيانات.

2. الدوال متعددة الأهداف

تركز الدوال متعددة الأهداف على تحقيق الاستغلال الأمثل المستقل لكل وظيفة موضوعية. ومن ثم، يتم استخدام مبدأ [22] هيمنة باريتو لتحديد الحل الأمثل. رياضياً، يتم تمثيل مشاكل التحسين متعددة الأهداف بجثة بالشكل التالي:

$$(2.2) \quad \text{Minimize: } f_1(x), f_2(x), \dots, f_m(x), \quad x \in X$$

حيث تمثل الدوال $f_1(x), f_2(x), \dots, f_m(x)$ الأهداف المكونة من m والتي سيتم تحسينها، و X هو متجه الحل الذي يتضمن متغيرات القرار.

في إطار الدوال متعددة المتعددة، تم التعرف على الدوال مختلفة منها:

عدد الميزات المختارة (NFS): يُعتبر تحسين أداء المصنفين باستخدام أقل عدد ممكن من الميزات أحد الجوانب الأساسية في معالجة مشكلة اختيار الميزات. بناءً على ذلك، يُعد عدد الميزات المختارة هدفاً مهماً.

معدل الخطأ: معرف في القسم السابق.

تكلفة الميزات: تحدد التكاليف المرتبطة بالميزات في سياق مشكلة اختيار الميزات، مما يسهم في تقليل كل من التكاليف المرتبطة بهذه الميزات ومعدل الخطأ في خوارزميات التصنيف.

3. الدوال متعددة الأهداف المرجحة

بشكل عام، تم تصميم الخوارزميات الاستكشافية لحل مشكلات التحسين ذات الهدف الواحد، ويعتبر تكييفها لتناسب مشكلات التحسين متعددة الأهداف عملية مكلفة للغاية من حيث الحسابات ووقت التطوير. وقد قدم المؤلفون أسلوباً لتحويل مشكلة تحسين متعددة الأهداف إلى مشكلة تحسين ذات هدف واحد. تعتمد هذه الطريقة على مجموع مرجح لجميع دوال الأهداف، [22] ويمكن تعريفها رياضياً كما يلي:

$$(2.3) \quad \max / \min f(X) = f_1w_1 + f_2w_2 + \dots + f_mw_m$$

حيث:

$$w_i \geq 0, i = 1, 2, \dots, m$$

$$w_1 + w_2 + \dots + w_m = 1$$

حيث تمثل w_1, w_2, \dots, w_m أوزاناً غير سلبية للوظائف الهدف m . في إطار فئة الوظائف المتعددة الأهداف المرجحة، تم التعرف على عدة وظائف مختلفة وهي:

عدد الميزات المختارة: معرف في القسم السابق.

معدل الخطأ وعدد الميزات المختارة (معدل الخطأ و NFS): في سياق مشكلة اختيار الميزات، يُعتبر تحسين أداء المصنف وتقليل عدد الميزات أمراً ضرورياً. بناءً على ذلك، تم اقتراح دالة مرجحة متعددة الأهداف تتعلق بهذين العنصرين كما يلي:

$$(2.4) \quad F(x) = \alpha \cdot \text{Error} + \beta \cdot \frac{S}{F}$$

حيث:

• S عدد الميزات المختارة

• F العدد الإجمالي للميزات

• α و β أوزان تحدد أهمية كل مقياس

يتوافق S و F مع عدد الميزات المختارة مقارنةً بالعدد الإجمالي لخصائص مجموعة البيانات. كما تحدد القيم α و β أهمية معدل الخطأ وعدد الميزات المختارة، حيث أن α و β تتراوحان بين 0 و 1. ومع ذلك، لا يوجد اتفاق عام حول القيم المناسبة لهذه المعلمات.

دقة وعدد الخصائص المختارة (الدقة وNFS): وظيفة موضوعية مشابهة لمعدل الخطأ وNFS. الفرق هو أن الدقة هي مقياس تقنية التصنيف. في الأدبيات، تم الكشف عن وظيفتين موضوعيتين تربطان الدقة بعدد الميزات المختارة. تم تعريف النسخة الأولى على النحو التالي:

$$(2.5) \quad F(x) = \text{Accuracy} + \alpha \left(1 - \frac{S}{F}\right)$$

حيث يتطابق S و F مع عدد الميزات المختارة والعدد الإجمالي لخصائص مجموعة البيانات، ويحدد α أهمية عدد الميزات المختارة $\alpha \in [1, 0]$ وليس هناك توافق في الآراء حول قيم هذا الاعدادات. أما النسخة الثانية الموجودة فتحدد على النحو التالي:

$$(2.6) \quad F(x) = \alpha \cdot \text{Accuracy} + \beta \left(\frac{F - S}{F}\right)$$

يتوافق S و F مع عدد الميزات المختارة مقارنةً بالعدد الإجمالي لخصائص مجموعة البيانات. كما تحدد القيم α و β أهمية معدل الخطأ وعدد الميزات المختارة، حيث أن α و β تتراوحان بين 0 و 1. ومع ذلك، لا يوجد توافق في الآراء بشأن قيم هذه الاعدادات بل يتم تحديدها عادة تجريبياً حسب طبيعة المشكلة.

3.2 التحسين

عند وجود مشكلة معينة نبحث عن حل لها ومن بين هذه الحلول نتطرق الى عملية التحسين وهي عملية إيجاد الحل الأمثل، حيث يتم اختيار أفضل جزء من مجموعة عناصر المسموح بها للحصول على أفضل نتائج. ونظراً لوجود مشكلات التحسين متنوعة، كان تطوير تقنيات حلها مجالاً بحثياً مهماً منذ فترة طويلة. ويُعد التحسين من الفروع الأساسية في الرياضيات التطبيقية والتحليل العددي. فبينما يمكن حل بعض المشكلات البسيطة باستخدام الطرق التحليلية التقليدية، إلا أن العديد من مشكلات التحسين المعقدة يصعب التعامل معها عبر تلك الطرق، مما يستدعي اللجوء إلى أساليب أكثر تطوراً ومرونة. [23]

1.3.2 طرق التحسن

تعود جذور تقنيات التحسين إلى أعمال علماء كبار مثل نيوتن، بيرنولي، لاغرانج، كوشي وجيبس، حيث تم استخدام حساب التغيرات كأساس لتطوير التحليل الرياضي، فيما أصبح يُعرف لاحقاً بـ "البرمجة الرياضية". ومع ظهور الحواسيب، ازداد الطلب على معالجة مسائل التحسين المعقدة وغير الخطية، مما أدى إلى تطور ملحوظ في نظريات وتقنيات التحسين. بشكل عام، يُعد التحسين مفهوماً متأصلاً في الطبيعة، إذ إن كل قرار نتخذه بهدف حل مشكلة معينة يمثل محاولة للوصول إلى حل أمثل أو شبه أمثل. ولذلك، يمكن اعتبار مسائل التحسين بمثابة مسائل صنع قرار، حيث يكون الهدف هو إيجاد حل أفضل من الحل المتوفر حالياً. وبمعنى آخر، يسعى التحسين إلى اكتشاف الحل الأمثل الذي يُحسن أداء النظام المعني إلى أقصى درجة ممكنة. تقسم خوارزميات التحسين إلى ثلاث فئات: الخوارزميات الحتمية، التي تستغل الخصائص التحليلية للمشكلة لتوليد سلسلة من النقاط المقاربة نحو الحل العالمي الأمثل، الخوارزميات العشوائية، حيث يدمج البحث عن الحل الأمثل بشكل بناء عناصر العشوائية، وأخيراً الخوارزميات الهجينة. [23] [24] ونظراً لأن الطبيعة تمثل نظاماً متكاملًا يقدم حلولاً فعالة لمتعدد الظواهر والتحديات، فقد استلهمت منها العديد من الخوارزميات القادرة على التعامل مع المشكلات الحسابية المعقدة. من هذا المنطلق، نشأ مجال "الميتا-خوارزميات" خلال الفترة ما بين الأربعينيات والثمانينيات من القرن الماضي، وشهد تطوراً وانتشاراً واسعاً منذ بداية الألفية الجديدة وحتى اليوم.

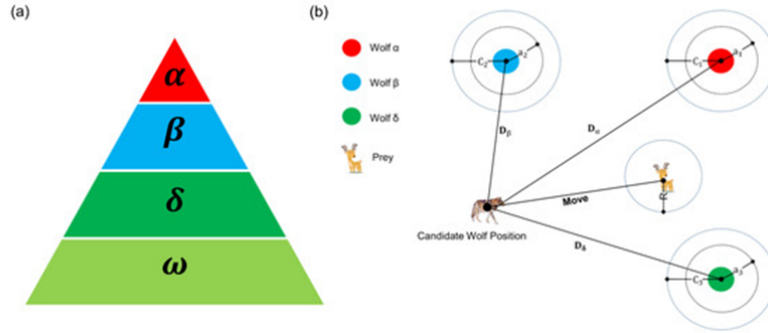
2.3.2 الخوارزميات الفوق استدلالية

الميتا-خوارزمية هي عملية توليد تكرارية تعمل على توجيه خوارزمية فرعية، من خلال دمج ذكي لمفاهيم متعددة بهدف تحقيق توازن بين الاستكشاف العالمي للفضاء الكامل للحلول، والاستغلال المحلي لتحسين الحلول المكتشفة في مناطق محددة. كما تستفيد هذه الخوارزميات من استراتيجيات التعلم لتنظيم المعلومات وتوجيه عملية البحث بشكل أكثر كفاءة نحو حلول شبه مثلى. [23] أما مصطلح الخوارزميات الاستدلالية، فهو (Heuristique) مشتق من الكلمة اليونانية القديمة *heuriskêin* التي تعني "العثور". على عكس الخوارزميات الدقيقة التي تهدف إلى إيجاد الحل الأمثل بشكل مؤكد، فإن الخوارزميات الاستدلالية تقدم حلولاً تقريبية فعالة ضمن وقت معقول، دون السعي لتحقيق دقة مطلقة. وتُعرف الميتا-خوارزميات الاستدلالية بأنها خوارزميات فائقة تعتمد على مبادئ الاستدلال، وتتميز بقدرتها على التعامل مع المشكلات المعقدة وعالية الأبعاد، حيث تقدم حلولاً مرضية حتى وإن لم تكن مثالية أو مضمونة. حظيت الخوارزميات فوق الاستدلالية بشعبية في السنوات 20 الماضية. تنقسم إلى فئتين: الخوارزميات فوق الاستدلالية القائمة على الحلول الواحد والتي تقوم بمعالجة وتحويل حل واحد أثناء البحث والخوارزميات فوق الاستدلالية القائمة على السكان والتي تقوم بتطوير مجموعة كاملة من الحلول. [25]

4.2 محسن الذئب الرمادي

محسن الذئب الرمادي (GWO) هو طريقة تحسين فوق استدلالية حديثة طورها ميرجاليلي وزملاؤه في عام 2014. عادة، تعيش الذئاب الرمادية في مجموعات تتراوح بين 5 إلى 12. يحاكي GWO فرانس الصيد والبحث التي تتميز الذئاب الرمادية في الطبيعة. في GWO، ينقسم السكان إلى ألفا وبيتا ودلتا وأوميغا (كما هو ملاحظ في الشكل 3.2). الذئب ألفا هو

القائد الرئيسي المسؤول عن صنع القرار. الذئب بيتا هو القائد الثاني الذي يساعد ألفا في اتخاذ القرار أو الأنشطة الأخرى. يُعرف ذئب دلتا بأنه القائد الثالث في المجموعة، التي تهيمن على ذئاب أوميغا. رياضياً، تسمى أفضل ثلاثة حلول في GWO ألفا (α) وبيتا (β) ودلتا (δ) على التوالي. يُفترض أن الباقي هو أوميغا (ω). في GWO، تسترشد عملية الصيد α, β, δ ، بينما تتبع ω هؤلاء القادة الثلاثة. [26]



شكل 3.2: التسلسل الهرمي لتصنيفات الذئاب في خوارزمية الذئب الرمادي ومخطط لآلية الصيد

يمكن التعبير عن سلوك الحصار للعبوة بهدف اصطياد الفريسة بالشكل التالي:

$$(2.7) \quad \vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D}$$

حيث:

• $\vec{X}_p(t)$: موقع الفريسة في التكرار t

• \vec{A} : متجه المعامل

• \vec{D} : المسافة إلى الفريسة وتُحسب كما يلي:

$$(2.8) \quad \vec{D} = \left| \vec{C} \cdot \vec{X}_p(t) - \vec{X}(t) \right|$$

تحديد المتجهات \vec{A} و \vec{C} :

$$(2.9) \quad \vec{A} = 2a \cdot r_1 - a \quad , \quad \vec{C} = 2r_2$$

حيث:

• r_1, r_2 : قيم عشوائية موزعة توزيعاً منتظماً في المجال $[0, 1]$


• a : معامل الإحاطة (encircling) الذي يتناقص خطياً من 2 إلى 0 وفقاً للمعادلة:

$$(2.10) \quad a = 2 - 2 \cdot \left(\frac{t}{T} \right)$$

حيث:

• t : عدد التكرارات الحالي

• T : العدد الأقصى للتكرارات



شكل 4.2: محاكاة سلوك محاصرة الفريسة في خوارزمية الذئب الرمادي في الفضاء الثنائي

توجه الذئب القائدة (α , β , δ) ذئب أوميغا نحو موقع الفريسة (الشكل 4.2 والشكل 5.2). يتم حساب الموقع الجديد لأي ذئب كالتالي:

$$(2.11) \quad \vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3}$$


حيث:

$$(2.12) \quad \begin{aligned} \vec{X}_1 &= \vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha \\ \vec{X}_2 &= \vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta \\ \vec{X}_3 &= \vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta \end{aligned}$$

ويتم حساب $\vec{D}_\delta, \vec{D}_\beta, \vec{D}_\alpha$ كالتالي:

$$(2.13) \quad \begin{aligned} \vec{D}_\alpha &= \left| \vec{C}_1 \cdot \vec{X}_\alpha - \vec{X} \right| \\ \vec{D}_\beta &= \left| \vec{C}_2 \cdot \vec{X}_\beta - \vec{X} \right| \\ \vec{D}_\delta &= \left| \vec{C}_3 \cdot \vec{X}_\delta - \vec{X} \right| \end{aligned}$$

حيث يتم تحديد $\vec{C}_1, \vec{C}_2, \vec{C}_3$ بنفس طريقة حساب \vec{C} المذكورة سابقاً.



شكل 5.2: محاكاة سلوك محاصرة الفريسة في خوارزمية الذئب الرمادي في ثلاثي الأبعاد

5.2 نموذج تحسين الذئب الرمادي الثنائي

بالنسبة للنهج الثاني، يُعرف باسم BGWO2، حيث يتم تحديث موقع الذئب عن طريق تحويل الموضع إلى متجه ثنائي باستخدام دالة تنشيط احتمالية. يتم ذلك كما يلي: [26]

$$(2.14) \quad X^d(t+1) = \begin{cases} 1, & \text{if } S\left(\frac{X_1^d + X_2^d + X_3^d}{3}\right) \geq r_7 \\ 0, & \text{otherwise} \end{cases}$$

حيث:

• $X^d(t+1)$: الموضع الجديد للذئب في البعد d

• r_7 : عدد عشوائي موزع توزيعاً منتظماً في الفترة $[0, 1]$

• d : بُعد مساحة البحث

• $S(x)$: الدالة السينية وتُعرف بالشكل:

$$(2.15) \quad S(x) = \frac{1}{1 + \exp(-10(x - 0.5))}$$

6.2 مقاييس التقييم لمهمة التصنيف

في مهمة التصنيف، هناك مجموعة من مقاييس التقييم تُستخدم لقياس جودة أداء النموذج. تختلف هذه المقاييس باختلاف نوع التصنيف (ثنائي، متعدد، غير متوازن). أهم المقاييس المستخدمة:

1.6.2 مصفوفة الالتباس

بالنسبة لمشاكل التصنيف الثنائية، يمكن تحديد تقييم التمييز لأفضل حل أثناء التدريب على التصنيف على أساس مصفوفة الالتباس (الشكل 6.2). يمثل صف الافقي الفئة المتوقعة، بينما يمثل العمود الفئة الفعلية. من مصفوفة الارتباك هذه، يشير (TP) و (TN) إلى عدد الحالات الموجبة والسلبية المصنفة بشكل صحيح. وفي الوقت نفسه، تشير (FN) و (FP) إلى عدد الحالات السلبية والإيجابية المصنفة بشكل خاطئ، على التوالي. [27]

	Positive	FN
Actual value	TP	FN
Negative	FP	TN
	Positive	Negative
	Predicted value	

شكل 6.2: مصفوفة الالتباس

يمكننا تحليل مصفوفة الالتباس من خلال حساب العديد من المقاييس الإحصائية المهمة لتقييم أداء نموذج التصنيف، ومنها:

• دقة التصنيف (Accuracy)

$$(2.16) \quad \text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

تمثل النسبة المئوية للتصنيفات الصحيحة. هذا المقياس مناسب فقط عندما تكون البيانات متوازنة.

• نسبة الخطأ (Error-Rate)

$$(2.17) \quad \text{Error} = \frac{FP + FN}{TP + TN + FP + FN}$$

• الحساسية (Sensitivity) أو الاسترجاع (Recall)

$$(2.18) \quad \text{SN} = \frac{TP}{TP + FN}$$

تمثل نسبة العينات الإيجابية التي تم اكتشافها بشكل صحيح. هذا المقياس مهم خصوصاً في الحالات التي نرغب فيها بتقليل عدد السلبيات الكاذبة، مثل تشخيص الأمراض.

• النوعية (Specificity)

$$(2.19) \quad \text{SP} = \frac{TN}{TN + FP}$$


• الدقة الإيجابية (Precision)

$$(2.20) \quad P = \frac{TP}{TP + FP}$$

تمثل نسبة العينات التي تم تصنيفها كموجبة وكانت فعلاً موجبة. هذا المقياس مهم عندما يكون تقليل عدد الإيجابيات الكاذبة (False Positives) أمراً أساسياً.

2.6.2 منطقة خصائص تشغيل المتلقي (ROC)

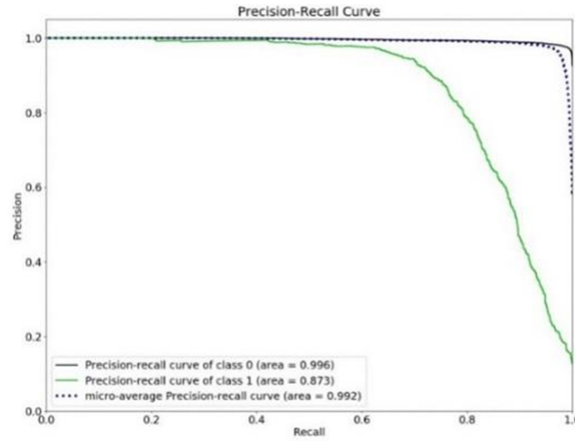
منحنى ROC (الشكل 7.2) هو رسم بياني يظهر العلاقة بين المعدل الإيجابي الحقيقي والمعدل الإيجابي الخاطئ. لكل عتبة، نقوم بحساب المعدل الإيجابي الحقيقي والمعدل الإيجابي الخاطئ، ثم نرسمها على رسم بياني واحد. كلما زاد المعدل الإيجابي الحقيقي وانخفض المعدل الإيجابي الخاطئ عمد كل عتبة، كانت النتيجة أفضل. المصنفات الأكثر كفاءة تظهر منحنيات أقرب إلى الجهة اليسرى. تُعرف المنطقة الواقعة تحت منحنى ROC بدرجة ROC AUC وهي قيمة تعكس جودة منحنى ROC. [28]



شكل 7.2: منحنى ROC

3.6.2 منطقة منحنى الاسترجاع الدقيق (PRC)

تُعتبر مقياساً رئيسياً لقدرات النموذج. تعكس درجة AUC PR متوسط الدرجات الدقيقة المحسوبة عبر جميع العتبات من $[0,0]$ إلى $[1,1]$. يتم إنشاء منحنى PRC من خلال دمج القيمة التنبؤية الإيجابية مع المعدل الإيجابي الحقيقي. يتم حساب القيمة التنبؤية الإيجابية والمعدل الإيجابي الحقيقي لكل عتبة، ثم تُرسم النقطة المقابلة على الرسم البياني. يُفضل أن تتمتع الخوارزمية بدقة وحساسية مرتفعتين، حيث أن هذين المقياسين مرتبطان ببعضهما البعض، مما يتطلب تحقيق توازن بينهما. يُعتبر منحنى (الشكل 8.2) PRC الجيد هو الذي يمتلك AUC أعلى. وقد أظهرت الأبحاث أن PRC أكثر فعالية من الرسوم البيانية ROC عند تقييم المصنفات الثنائية في مجموعات البيانات غير المتوازنة. [28]



شكل 8.2: منحنى الاسترجاع الدقيق PRC

7.2 الخاتمة

في هذا الفصل، تم التطرق إلى أهمية اختيار الميزات ودوره الجوهرى في تحسين أداء نماذج التعلم الآلى، مع التركيز على خوارزميات التحسين الذكية، ولا سيما الخوارزميات المستوحاة من الطبيعة مثل خوارزمية الذئب الرمادى. كما تم استعراض كيفية تحويل مهمة اختيار الميزات إلى مسألة تحسين، وآلية تمثيل الحلول وتقييمها بناءً على مقاييس تصنيف معيارية. ويمثل هذا الأساس النظري خطوة تمهيدية للفصل الموالى، حيث سنتقل من الجانب النظري إلى الجانب التطبيقي، من خلال توظيف تقنيات اختيار الميزات في مهمة حساسة ومهمة وهي الكشف عن مرض باركنسون. وسنعمد في ذلك على التعلم العميق لاستخراج الميزات، متبعاً بتطبيق خوارزمية الذئب الرمادى لاختيار الميزات الأمثل، بهدف بناء نموذج تشخيصي دقيق وفعال.

الفصل 3

نتائج المحاكاة ومناقشتها


1.3 المقدمة

في هذا الفصل، نتعمق في عملية التقييم والنتائج التي تم الحصول عليها لاكتشاف مرض باركنسون. يتم تقييم فعالية النماذج وفحصها من خلال مقاييس مثل دقة التصنيف، النوعية والحساسية. في تقييمنا، استخدمنا مجموعات بيانات التي تضم رسومات يدوية من كل من مرضى مرض باركنسون (PD) والأفراد الأصحاء.

2.3 قاعدة البيانات

تتكوّن مجموعة بيانات NewHandPD من 66 شخصًا، منهم 31 شخصًا تم تشخيصهم بمرض باركنسون و35 شخصًا يُعتبرون أصحاء. تشمل المجموعة بيانات تم جمعها أثناء أداء المشاركين لأربع مهام مختلفة: رسم دوائر، حلزونات، منحنيات متعرجة، بالإضافة إلى تسجيل الإشارات. تم طلب من كل مشارك رسم دائرة واحدة، وأربع رسومات لمنحنيات متعرجة، وأربع رسومات لحلزونات.

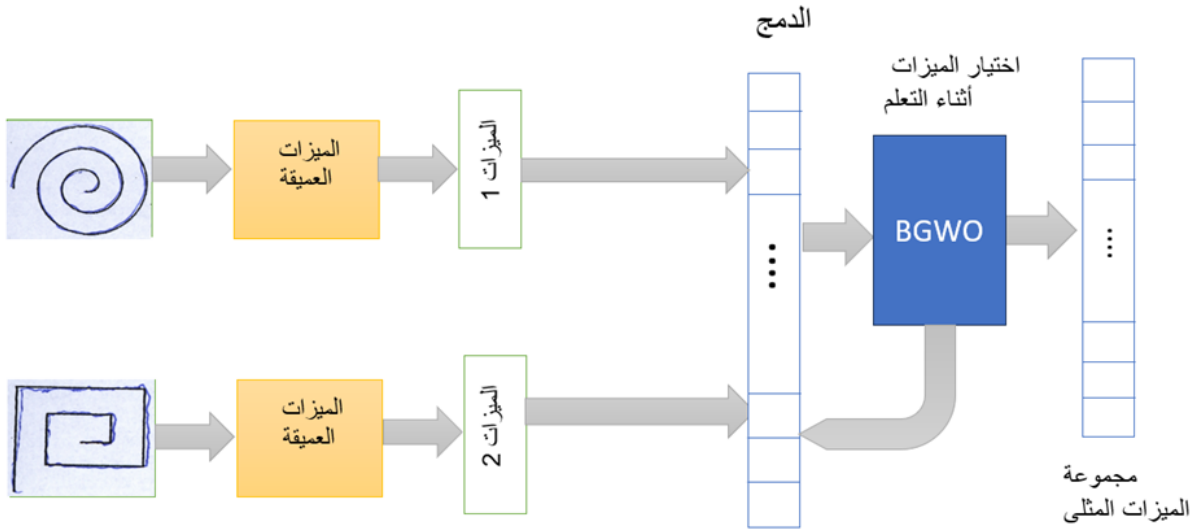
في فئة المنحنيات المتعرجة، يوجد 140 صورة لأشخاص أصحاء و124 صورة لأشخاص مصابين بمرض باركنسون. أما صور الحلزونات، فتحتوي على 140 عينة من الأشخاص الأصحاء و124 عينة من مرضى باركنسون. يُظهر الشكل 1.3 بعض العينات من مجموعة البيانات المستخدمة.



شكل 1.3: الصور للبيانات المستخدمة

3.3 الطريقة المقترحة

يُبين الشكل 2.3 الإطار العام للنهج المقترح. تبدأ العملية بمعالجة صور الإدخال التي تمثل الوسائط الأولية للبيانات، حيث يتم توظيف نموذج قائم على التعلم العميق لاستخلاص مجموعة من الميزات التمثيلية التي تعكس الخصائص الجيدة لكل صورة. في المرحلة التالية، يتم دمج الميزات المُستخرجة من مختلف المصادر أو النماذج في متجه موحد يُمثل التوصيف الكامل للعينات قيد الدراسة. ولغرض تقليل الأبعاد وتحسين كفاءة النموذج، يُجرى اختبار الميزات أثناء التدريب باستخدام خوارزمية تحسين، بهدف تحديد السمات الأكثر تمييزاً وارتباطاً بالمهمة التصنيفية. بعد الحصول على مجموعة الميزات المُنتقاة، يتم إدخالها إلى مصنف لغرض الكشف أو التمييز بين الحالات المرضية. وأخيراً، يتم اعتماد مجموعة من مقاييس التقييم الكمية لقياس أداء النموذج المقترح. في التالي سنقوم بشرح لكل المراحل الأساسية التي ذكرناها في السابق:



شكل 2.3: الاطار العام للطريقة المقترحة

1.3.3 استخراج الميزات العميقة

تتضمن هذه المرحلة استخراج الميزات من نمطين للرسومات اليدوية (الحلزونية و المنحنية) باستخدام تقنيات التعلم العميق، مما ينتج اثنين من متجهات ميزات منفصلة. في هذه الدراسة، تم استخدام كل من AlexNet و ResNet50 لاستخراج الميزات. ولتنفيذ هذه العملية، تم إزالة الطبقة المتصلة بالكامل من كل نموذج. من الجدير بالذكر أنه تم استخدام نموذج تعلم عميق موحد لمعالجة كلا نمطي البيانات، مما يضمن أن الخصائص المميزة لكل نوع من البيانات تم تحليلها وتمثيلها بدقة. [29] يتضمن استخراج الميزات من طبقة fc7 في AlexNet استخدام الشبكة العصبية المدربة مسبقاً لاستخراج ميزات عالية المستوى ومجردة من الصورة المدخلة. تعد طبقة fc7 واحدة من الطبقات المتصلة بالكامل في الجزء الأخير من AlexNet، وهي تحتوي على تمثيل غني للصورة بعد مرورها عبر الطبقات التلافيفية، وطبقات التجميع، وطبقات الاتصال الكامل.

في ResNet50، يتم استخدام طبقة avgpool التي تقوم بتنفيذ عملية التجميع المتوسط العالمي وتنتج متجه ميزات ذو أبعاد 2048. تُستخدم هذه الطبقة على نطاق واسع لاستخراج الميزات نظراً لقدرتها على تلخيص المعلومات المكانية في تمثيلات مضغوطة.

2.3.3 دمج الميزات العميقة

يتم دمج متجهات الميزات المستخرجة من النمطين (مثل الصور الدوامة، والخطوط المتعرجة) باستخدام نماذج التعلم العميق AlexNet و ResNet50 لإنشاء تمثيل موحد. يعالج كل نموذج الأنماط بشكل منفصل، مما يؤدي إلى استخراج اثنين من متجهات ميزات لكل نموذج. على سبيل المثال، يقوم AlexNet باستخراج متجه ميزات ذو أبعاد 4096 لكل نمط، مما ينتج عنه إجمالي 8192 بُعداً للأنماط. بالمثل، يُنتج ResNet50 متجهات ميزات ذو أبعاد 2048 لكل نمط، مما يؤدي إلى متجه مشترك ذو أبعاد 4096.

بعد دمج المخرجات من جميع النماذج عبر النمطين، يتكون متجه الميزات النهائي ذو أبعاد تساوي مجموع جميع متجهات الميزات الفردية، مما ينتج عنه تمثيل ذو أبعاد عالية يصل إلى 12288 بُعداً. يجمع هذا المتجه الشامل بين مزايا النماذج والأنماط المختلفة، مما يعزز الأداء في المهام المستقبلية ويُحسن القدرة على التعميم والتصنيف. [29]

3.3.3 اختيار الميزات أثناء التدريب

يُعدّ محسّن الذئب الرمادي الثنائي (BGWO) من الخوارزميات الفعالة في اختيار الميزات، نظراً لقدرته على تحقيق توازن بين الاستكشاف (البحث عن ميزات جديدة) والاستغلال (تحسين الميزات المختارة)، مما يقلل من خطر الوقوع في الحلول المحلية غير المثلى. بفضل تمثيله الثنائي، حيث تُعبّر كل ميزة إما بالإدراج (1) أو الاستبعاد (0)، فإنه مناسب جداً لمهام اختيار الميزات غير المستمرة. وتؤدي هذه الآلية إلى تقليل الأبعاد، خفض التكاليف الحسابية، تسريع التدريب، وتحسين الأداء العام للنموذج.

أما اختيار الميزات أثناء التدريب، فهو نهج تكيفي يسمح للنموذج بتحديد الميزات الأكثر أهمية بشكل تلقائي خلال عملية التعلم، بدلاً من الاعتماد على مجموعة ثابتة مسبقاً. يُقيّم النموذج باستمرار تأثير مجموعات مختلفة من الميزات على الأداء، ويعتمد فقط الميزات الأكثر فاعلية. وعند دمج BGWO ضمن هذه العملية، يتم تحسين اختيار الميزات بشكل تكراري بناءً على دقة النموذج، مما يؤدي إلى نماذج أكثر كفاءة وموثوقية في الأداء. [29]

4.3.3 تقييم النتائج

لقد قمنا بتقييم أداء الطريقة المقترحة باستخدام ثلاثة مقاييس: الدقة (ACC)، الحساسية (SN) والتحديد (SP).

5.3.3 خوارزميات التحسين

شهد مجال التحسين في التعلم العميق تطوراً ملحوظاً منذ اعتماد خوارزمية الانحدار التدرجي العشوائي (SGD) كمعيار أساسي. ورغم بساطتها وفعاليتها، فإن استخدام معدل تعلم موحد لكافة المعاملات شكّل أحد أبرز قيودها، إذ قلّل من

قدرتها على التكيف مع الأنماط المختلفة لتحديث الأوزان. هذا النقص دفع إلى تطوير خوارزميات ذات معدل تعلم متكيف، أبرزها: Adam، RMSprop، SGDM، والتي تعتمد على معدل تعلم خاص بكل معلمة، مما يجعلها أكثر كفاءة في استكشاف فضاء الحلول مقارنة بـ SGD. [30]

4.3 النتائج المتحصل عليها

1.4.3 نتائج بدون استخدام اختيار الميزات BGWO

1. تقييم تأثير المحسنات ومعدلات التعلم على أداء شبكة AlexNet

في هذا القسم، تم دراسة أداء شبكة AlexNet في مهمة تصنيف صور مستخرجة من مجموعة بيانات NewHandPD، وذلك بهدف تقييم مدى تأثير اختيار خوارزمية التحسين ومعدل التعلم على دقة التصنيف النهائية.

عرض نتائج Alexnet

تم استخدام ثلاث خوارزميات تحسين شائعة في مجال التعلم العميق، وهي: Adam، RMSProp، و Stochastic (SGDM). كما تم اختبار كل محسن باستخدام ثلاثة معدلات تعلم مختلفة: $1e^{-6}$ ، $1e^{-5}$ ، و $4 \cdot 1e^{-5}$ ، تهدف هذه الدراسة إلى تحديد أفضل توليفة من المحسن ومعدل التعلم لتحقيق أعلى دقة تصنيف ممكنة، بالإضافة إلى فهم تأثير هذه المتغيرات على سرعة التقارب واستقرار النموذج أثناء عملية التدريب. حيث قمنا بتغيير في معدل التعلم والمحسن وقد تم تلخيص النتائج المحققة في الجداول 1.3-3.3

جدول 1.3: نتائج تقييم نموذج AlexNet مع مُحسِّن Adam

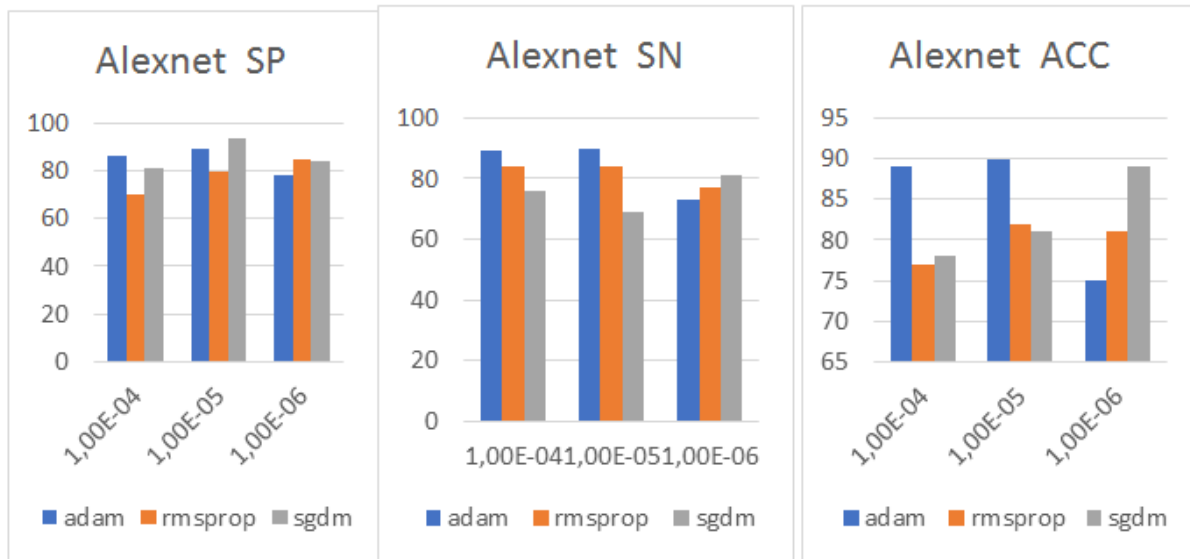
$1e^{-6}$		$1e^{-5}$		$1e^{-4}$		
max	mean	max	mean	max	mean	
83.02	75.02	96.32	89.75	94.34	87.50	ACC(%)
85.71	72.86	100	90	100	88.57	SN(%)
84	77.47	100	89	100	86.30	SP(%)

جدول 2.3: نتائج تقييم نموذج AlexNet مع مُحسِّن RmsProp عبر ثلاثة مُعدلات تعلُّم

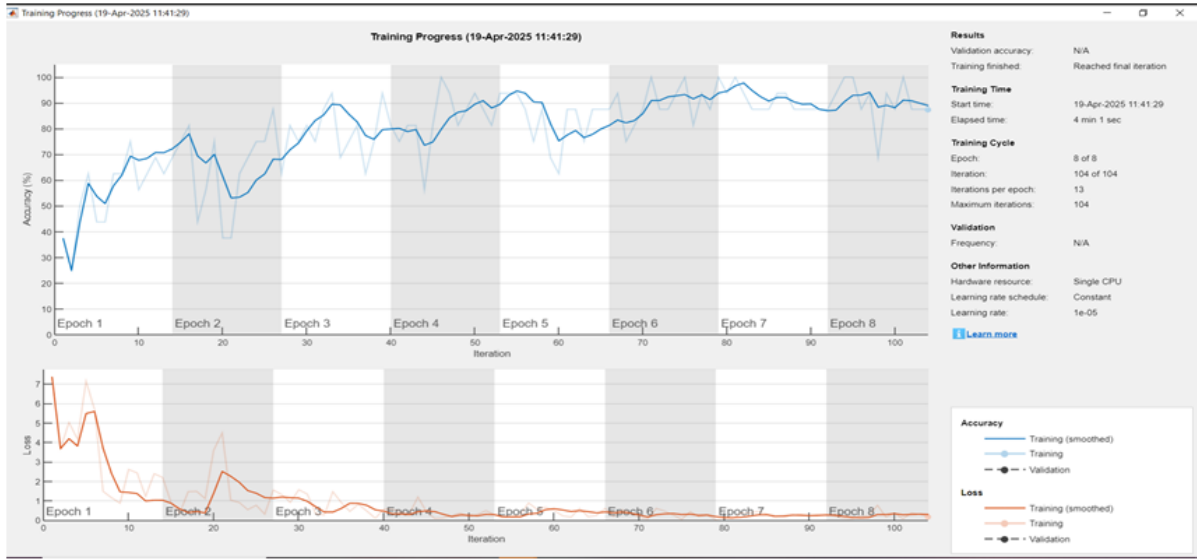
$1e^{-6}$		$1e^{-5}$		$1e^{-4}$		
max	mean	max	mean	max	mean	
88.68	81.07	92.45	81.84	86.54	77.31	ACC(%)
89.29	77.14	100	83.57	100	84.29	SN(%)
96	85.43	100	80	100	69.47	SP(%)

جدول 3.3: نتائج تقييم نموذج AlexNet مع مُحسِّن Sgdm عبر ثلاثة مُعدلات تعلُّم

$1e^{-6}$		$1e^{-5}$		$1e^{-4}$		
max	mean	max	mean	max	mean	
90.57	82.19	90.57	81.07	83.02	78.43	ACC(%)
69.43	80.71	89.29	69.29	100	76.43	SN(%)
100	83.83	100	94.37	100	80.80	SP(%)



شكل 3.3: الاعمدة البيانية لكل من مقاييس الدقة (ACC) ، الحساسية (SN) والتحديد (SP). نموذج Alexnet




شكل 4.3: دقة التدريب وخسارة الاختبار خلال عملية التعلم لنموذج AlexNet

Confusion Matrix: ALEXNET

	Healthy	Parkinson	
Healthy	28 52.8%	2 3.8%	93.3% 6.7%
Parkinson	0 0.0%	23 43.4%	100% 0.0%
	100% 0.0%	92.0% 8.0%	96.2% 3.8%
	Healthy	Parkinson	
	Target Class		

شكل 5.3: مصفوفة الالتباس



شكل 6.3: منحنى خصائص التشغيل التلقائي لنموذج Alexnet

تحليل نتائج AlexNet

بالاطلاع على نتائج المعروضة لثلاثة محسنات مختلفة (Adam, RmsProp, Sgdm) مع ثلاثة معدلات تعلم مختلفة (1×10^{-6} ; 1×10^{-5} ; 1×10^{-4}) لشبكة AlexNet، يمكننا ان نلاحظ أن مُحسِّن Adam يقدم أداءً أفضل بشكل ملحوظ عبر مختلف معدلات التعلم ومقاييس الأداء (ACC, SN, SP). يحقق Adam باستمرار قيماً أعلى للمتوسط والحد الأقصى للدقة والحساسية والنوعية مقارنةً بـ RmsProp و Sgdm.

على سبيل المثال، عند معدل تعلم 1×10^{-4} ، يحقق Adam متوسط دقة يبلغ 87,50% وحد أقصى للدقة يبلغ 94,34%، وهو أعلى بكثير من متوسط دقة RmsProp (بحد أقصى 77,31% بحد أقصى 94,34%) و Sgdm (بحد أقصى 78,43% بحد أقصى 83,02%) عند نفس معدل التعلم. وبالمثل، يحقق Adam أعلى متوسط وحساسية قصوى (86,30% و 100% على التوالي) ونوعية قصوى (88,57% و 100% على التوالي) عند هذا المعدل.

بينما يظهر RmsProp أداءً جيداً في بعض الحالات، مثل تحقيقه أعلى حد أقصى للدقة 96,32% عند معدل تعلم 1×10^{-5} ، إلا أنه لا يتفوق باستمرار على Adam عبر جميع المقاييس ومعدلات التعلم. يُلاحظ أن أداء RmsProp يتقلب بين معدلات التعلم المختلفة، حيث يحقق أداءً جيداً عند معدل تعلم معين ولكنه قد ينخفض عند معدلات أخرى.

أما بالنسبة لمُحسِّن Sgdm، فيبدو أنه الأقل أداءً من بين الثلاثة في معظم السيناريوهات المعروضة، حيث يحقق قيماً أقل في المتوسط والحد الأقصى لمعظم المقاييس. على سبيل المثال، عند معدل تعلم 1×10^{-4} ، يحقق Sgdm أقل متوسط للدقة 78,43% وأقل حد أقصى للدقة 83,02%. مع ذلك، يمكن أن نلاحظ أنه كلما كان معدل التعلم صغيراً، يؤدي ذلك إلى انخفاض الأداء لجميع المُحسِّنات في كل من المتوسط والحد الأقصى.

باختصار، تشير هذه النتائج إلى أن مُحسِّن Adam هو الخيار الأفضل لتدريب شبكة AlexNet في هذه التجربة، حيث يحقق أداءً متفوقاً باستمرار عبر مختلف المقاييس ومعدلات التعلم، سواء من حيث الأداء المتوسط أو الحد الأقصى.

2. تقييم تأثير المحسنات ومعدلات التعلم على أداء شبكة Resnet-50

وايضا هنا، تم دراسة أداء شبكة Resnet-50 في مهمة تصنيف صور مستخرجة من مجموعة بيانات NewHandPD، وذلك بهدف تقييم مدى تأثير اختيار خوارزمية التحسين ومعدل التعلم على دقة التصنيف النهائية.

عرض نتائج Resnet-50

وهنا كذلك في نموذج Resnet-50 قمنا بتغيير في معدل التعلم والمحسن وتحصلنا على النتائج التي نلخصها في الجدول في الجداول 6.3-4.3

جدول 4.3: نتائج تقييم نموذج Resnet-50 مع مُحسِّن Adam عبر ثلاثة مُعدَّلات تُعَلَّم


$1e^{-6}$		$1e^{-5}$		$1e^{-4}$		
max	mean	max	mean	max	mean	
58.73	36.61	96.23	86.75	98.11	89.78	ACC
85.71	57.14	100	77.86	100	86.43	SN
96	66	100	96.80	100	93.60	SP

جدول 5.3: نتائج تقييم نموذج Resnet-50 مع مُحسِّن RmsProp عبر ثلاثة مُعدَّلات تُعَلَّم


$1e^{-6}$		$1e^{-5}$		$1e^{-4}$		
max	mean	max	mean	max	mean	
86.79	72.73	96.23	84.47	98.11	90.16	ACC(%)
96.43	80	100	79.29	100	86.42	SN(%)
88	64.37	100	90.40	100	94.40	SP(%)

جدول 6.3: نتائج تقييم نموذج Resnet-50 مع مُحسِّن Sgdm عبر ثلاثة مُعدَّلات تُعَلَّم


$1e^{-6}$		$1e^{-5}$		$1e^{-4}$		
max	mean	max	mean	max	mean	
71.70	56.84	88.68	76.54	94.34	86.38	ACC(%)
100	68.57	96.43	82.14	96.43	82.14	SN(%)
88	43.37	100	70.40	100	91.2	SP(%)




شكل 7.3: الاعمدة البيانية لكل من مقاييس الأداء (ACC،SN،SP) لنموذج Resnet-50



شكل 8.3: دقة التدريب وخسارة الاختبار خلال عملية التعلم لنموذج ResNet-50



شكل 9.3: مصفوفة الالتباس



شكل 10.3: منحنى خصائص التشغيل التلقائي لنموذج Resnet-50

تحليل نتائج ResNet-50

بالاطلاع على نتائج المعروضة لثلاثة مُحسِّنات مختلفة (Adam, RmsProp, Sgdm) مع ثلاثة معدلات تعلم مختلفة (1×10^{-4} , 1×10^{-5} , 10^{-6}) لشبكة ResNet-50، نلاحظ اتجاهات مماثلة لتلك التي شوهدت في نتائج AlexNet، مع بعض الاختلافات البارزة.

بالنسبة لنموذج ResNet-50 مع مُحسِّن Adam، يُظهر أداءً قوياً عبر جميع معدلات التعلم. عند معدل تعلم 1×10^{-4} يحقق Adam متوسط دقة يبلغ 89,78% وحد أقصى للدقة يبلغ 98,11%. كما يحافظ على حساسية ونوعية عاليتين في المتوسط والحد الأقصى عند هذا المعدل. بشكل عام، يبدو أن Adam يقدم أداءً مستقرًا وجيدًا لشبكة ResNet-50 أيضًا. عند النظر إلى مُحسِّن RmsProp مع ResNet-50، نلاحظ أن الأداء جيد بشكل عام، ولكنه قد يكون أقل استقرارًا قليلاً عبر معدلات التعلم المختلفة مقارنة ب Adam. على سبيل المثال، عند معدل تعلم 1×10^{-5} ، يحقق RmsProp حدًا

أقصى للدقة يبلغ 96,23%، وهو جيد، لكن متوسط الدقة 84,47% أقل قليلاً من Adam عند أعلى معدل تعلم. أما بالنسبة لمُحسِّن Sgdm مع ResNet-50، فيبدو أنه يحقق أقل أداء بشكل عام مقارنة ب Adam و RmsProp، خاصة عند معدلات التعلم الأصغر. على سبيل المثال، عند معدل تعلم 1×10^{-6} ، يحقق Sgdm متوسط دقة منخفضاً نسبياً 56,84%. ومع ذلك، يظهر تحسناً ملحوظاً في الأداء عند زيادة معدل التعلم، حيث يقترب من أداء المُحسِّنات الأخرى عند 1×10^{-4} .

بشكل عام، تشير نتائج ResNet-50 أيضاً إلى أن مُحسِّن Adam يعد خياراً قوياً لتدريب هذه الشبكة، حيث يوفر أداءً جيداً ومستقرّاً عبر مختلف معدلات التعلم. بينما يمكن أن يحقق RmsProp نتائج جيدة في بعض الحالات، يبدو أن Adam أكثر موثوقية بشكل عام. يظهر Sgdm أنه قد يحتاج إلى ضبط أكثر دقة لمعدل التعلم لتحقيق أداء مماثل للمُحسِّنات الأخرى، ويبدو أنه أقل فعالية عند استخدام معدلات تعلم صغيرة. كما هو الحال مع AlexNet، يؤدي استخدام معدل تعلم صغير جداً إلى انخفاض الأداء لجميع المُحسِّنات على ResNet-50 أيضاً.

2.4.3 نتائج بعد استخدام خوارزمية تحسين الذئب الرمادي الثنائية لاختيار الميزات

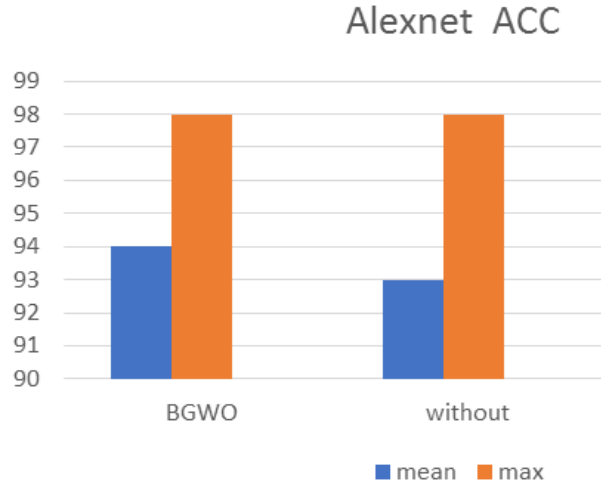
لقد قمنا في هذه التجربة باستعمال خوارزمية تحسين الذئب الرمادي الثنائية، وتطبيقها على نموذجي تعلم عميق AlexNet و ResNet50، حيث قمنا بأخذ انماط الكتابة اليدوية ودجمها مع بعض ، مما أدى إلى سيناريوهات تجريبية متعددة.

عرض نتائج Alexnet


في هذا القسم، تم دراسة أداء شبكة AlexNet في مهمة تصنيف صور مستخرجة من مجموعة بيانات NewHandPD، ثم دمجها مع خوارزمية اختيار الميزات (BGWO) بهدف تقليل الميزات التي ليس لها فائدة وذلك لمعرفة مدى تأثير هذا التقليل على دقة التصنيف. وقد تم تلخيص النتائج في الجداول 7.3-8.3.

جدول 7.3: نتائج تقييم أداء نموذج AlexNet قبل وبعد تطبيق خوارزمية BGWO


AUC		ACC		
Max	Mean	Max	Mean	
0.9986	0.9813	98.11	93.17	Without (%)
0.9986	0.9810	98.11	93.93	BGWO (%)




شكل 11.3: الاعمدة البيانية لمقياس الأداء (ACC) لنموذج Alexnet



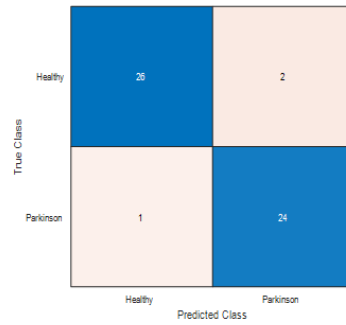
(ب)



(أ)



(د)



(ج)

شكل 12.3: (أ)، (ب) مصفوفة الالتباس ومنحنى خصائص التشغيل التلقائي لخوارزمية BGWO و(ج)، (د) مصفوفة الالتباس ومنحنى خصائص التشغيل التلقائي بدون خوارزمية نموذج Alexnet

كما يوضح الجدول 8.3 بعد تطبيق خوارزمية اختيار الميزات BGWO على شبكة Alexnet كان عدد الميزات في البداية 8192 ميزة ، وبعدها انخفض بفعالية ليصبح محصوراً بين 3850 و4136 ، مما يدل على نجاح الخوارزمية في تقليل عدد الميزات بشكل جيد.

جدول 8.3: نتائج دقة نموذج Alexnet مع وبدون تضمين ميزة BGWO عند تقليل حجم الميزات لنموذج Alexnet

الميزات	4136	4078	3850	4071	4094
(%) ACC(BGWO)	92.31	92.45	96.23	90.57	98.11
(%) ACC(without)	90.39	92.45	94.34	90.57	98.11

تحليل نتائج AlexNet

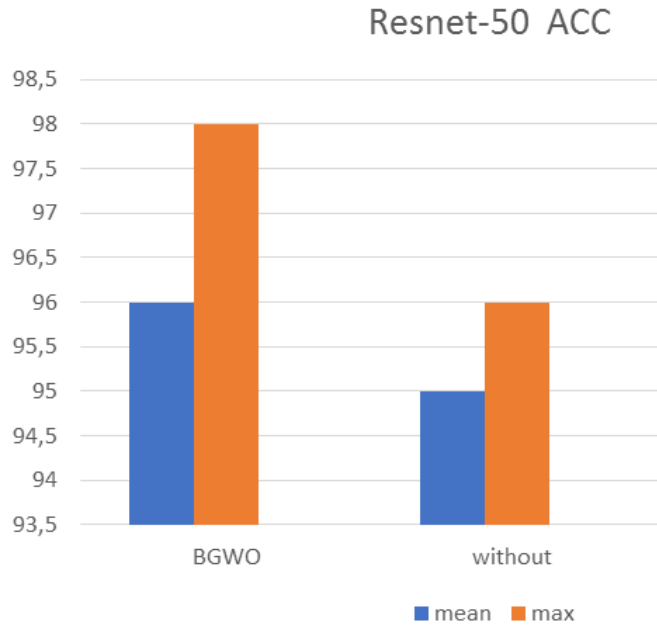
نلاحظ ان متوسط الدقة باستخدام خوارزمية BGWO يساوي 93,93% و بدون استخدام الخوارزمية يساوي 93,17% والحد الاقصى للدقة عند استخدام الخوارزمية و بدونها يساوي 98,11%، وبالتالي نرى تحسناً طفيفاً في المتوسط عند استخدام BGWO ، اما من ناحية نسبة التي تحت المنحنى (AUC) فان قيمته القصوى و المتوسط عند استخدام الخوارزمية تساوي (99,86% و 98,13% على التوالي) و عند عدم استخدامه تساوي (99,86% للقيمة القصوى و 98,10% للقيمة المتوسطة) مما يشير إلى أن تقليل عدد الميزات الذي وصل الى نصف العدد الإجمالي و الذي هو 8192 ساعد على تحسين أداء AlexNet دون التأثير سلباً على الأداء الأقصى أو القيمة تحت المنحنى (AUC).

عرض نتائج Resnet-50

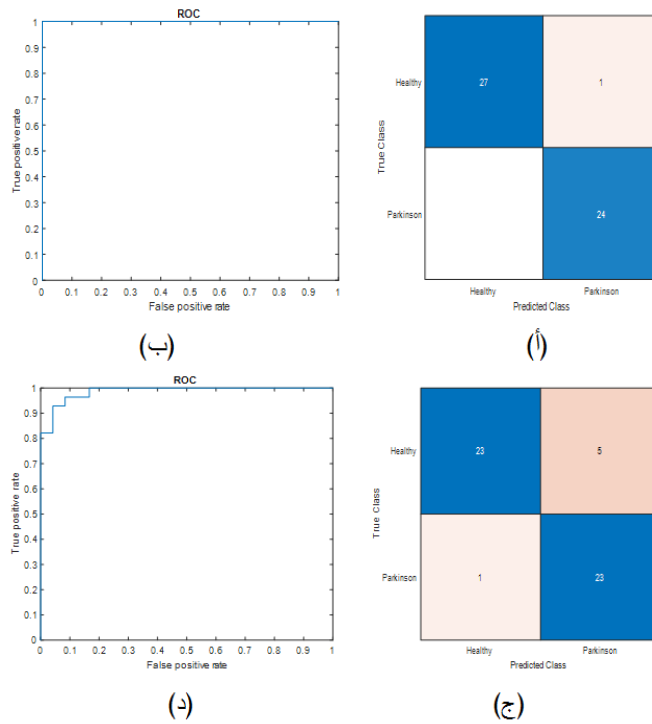
في هذا القسم، تم دراسة أداء شبكة Resnet-50 في مهمة تصنيف صور مستخرجة من مجموعة بيانات NewHandPD، ثم دمجها مع خوارزمية اختيار الميزات (BGWO) بهدف تقليل الميزات التي ليس لها فائدة وذلك لمعرفة مدى تأثير هذا التقليل على دقة التصنيف. وقد تم تلخيص النتائج في الجداول 9.3-10.3

جدول 9.3: نتائج تقييم أداء نموذج ResNet-50 قبل وبعد تطبيق خوارزمية BGWO

AUC		ACC		
Max	Mean	Max	Mean	
1	0,9873	96,23	94,68	Without (%)
1	0,9866	98,11	95,84	BGWO (%)



شكل 13.3: الاعمدة البيانية لمقياس الأداء (ACC) لنموذج Resnet-50



شكل 14.3: (أ)، (ب) مصفوفة الالتباس ومنحنى خصائص التشغيل التلقائي لخوارزمية BGWO و(ج)، (د) مصفوفة الالتباس ومنحنى خصائص التشغيل التلقائي بدون خوارزمية نموذج Resnet-50

يمثل الجدول 10.3 عدد الميزات بعد تطبيق خوارزمية اختيار الميزات BGWO على شبكة ResNet-50، حيث كان عدد الميزات في البداية 4096، وبعد تطبيق الخوارزمية انخفض ليصبح محصوراً بين 1925 و2076. وهذا يدل على كفاءة الخوارزمية في تقليل عدد الميزات بشكل فعال.

جدول 10.3: نتائج دقة نموذج Resnet-50 مع وبدون تضمين ميزة BGWO عند تقليل حجم الميزات لنموذج Resnet-50

الميزات	1925	2001	2076	2014	2041
(%) ACC(BGWO)	98.08	96.23	90.57	96.23	98.11
(%) ACC(without)	88.46	96.23	96.23	96.23	96.23

تحليل نتائج ResNet-50

نلاحظ ان متوسط الدقة باستخدام خوارزمية BGWO يساوي **95,84%** و بدون استخدام الخوارزمية يساوي **94,67%** والحد الأقصى للدقة قيمته عند استخدام الخوارزمية يساوي **98,11%** و بدون استخدام الخوارزمية يساوي **96,23%**، اما من ناحية نسبة التي تحت المنحنى فان قيمته القصوى و المتوسطة عند استخدام الخوارزمية تساوي (**100%** و **98,66%** على التوالي) وعند عدم استخدام الخوارزمية تساوي (**100%** و **98,73%** على التوالي)، بالتالي نرى تحسن كبير في كل من المتوسط والحد الأقصى لدقة التصنيف وذلك بعد استخدام خوارزمية BGWO مع نموذج ResNet-50، مما يشير إلى أن تقليل عدد الميزات الذي وصل الى اقل من نصف العدد الإجمالي و الذي هو **4096** ساعد على تحسين أداء النموذج.

5.3 مقارنة بين استخدام خوارزمية BGWO و بدونها

مقارنة بين استخدام خوارزمية BGWO و بدونها تشير النتائج إلى أن استخدام خوارزمية تحسين الذئب الرمادي الثنائية (BGWO) لاختيار الميزات قد ساهم في تحسين أداء كل من نموذجي AlexNet و ResNet-50. من حيث متوسط الدقة والقيمة القصوى لها على الرغم من وجود انخفاض طفيف جداً في قيمة AUC في بعض الحالات، إلا أن التحسن في الدقة يعتبر أكثر أهمية في العديد من تطبيقات التصنيف. و بالتالي فان استخدام الخوارزمية احسن لنتائج جيدة.

6.3 الخاتمة

يقدم هذا الفصل تقييماً شاملاً لأثر استخدام خوارزمية تحسين الذئب الرمادي الثنائية (BGWO) في عملية اختيار الميزات لتعزيز أداء نماذج التعلم العميق، وتحديدًا معماريات AlexNet و ResNet-50. تركز هذه الدراسة على تحليل التغيرات في مقاييس الأداء الرئيسية، بما في ذلك دقة التصنيف (ACC) ومنطقة تحت المنحنى (AUC)، عبر مُحسِّنات تعلم ومعدلات تعلم مختلفة. وقد أظهر دمج BGWO في عملية التدريب إمكانية تحسين دقة التصنيف بشكل ملحوظ لكلا النموذجين. ويبدو أن قدرة BGWO على انتقاء الميزات الأكثر تميزاً تساهم بشكل فعال في تعزيز أداء النماذج. وقد حقق نهجنا باستخدام BGWO تحسناً في متوسط دقة AlexNet لتصل إلى **93,93%** و تحسناً كذلك في القيمة القصوى لتصل إلى **98,11%**. وحققتنا أيضاً تحسناً في متوسط دقة ResNet-50 لتصل إلى **95,84%** و في القيمة القصوى لتصل إلى **98,11%**. تساهم هذه الدراسة في فهم أعمق لكيفية تأثير تقنيات اختيار الميزات على أداء نماذج التعلم العميق، وتبرز أهمية دمج خوارزميات التحسين الذكي في مهام التصنيف المختلفة.

خاتمة عامة

في الختام، قدم هذا العمل دراسة شاملة ونهجاً جديداً للكشف عن مرض باركنسون. اعتمد النهج الجديد على الاستفادة من أنماط الرسم، والتي توفر رؤى قيمة حول العلامات المبكرة للحالة، خاصةً في وظائف اليد الحركية. كما يقدم طريقة تقييم غير مكلفة وسهلة الوصول وعن بُعد.

تم في هذا العمل استخدام خوارزمية الذئب الرمادي الثنائية (BGWO) في عملية اختيار الميزات بهدف تعزيز كفاءة نماذج التعلم العميق، وتحديدًا نموجي AlexNet و ResNet-50، في الكشف عن مرض باركنسون.

وقد أظهرت النتائج أن دمج خوارزمية BGWO في عملية التدريب أدى إلى تحسين ملحوظ في دقة التصنيف لكلا النموذجين، حيث في نموج AlexNet حققنا تحسناً في متوسط الدقة لتصل إلى 93,93% والقيمة القصوى لتصل إلى 98,11%، وكذلك حققنا تحسناً في متوسط دقة ResNet-50 لتصل إلى 95,84% والقيمة القصوى كذلك لتصل إلى 98,11%، مقارنةً بالنتائج بدون دمج خوارزمية BGWO حيث كان متوسط الدقة في كلا النموذجين يصل إلى 87,50% و 81,84% على التوالي و كانت القيمة القصوى للنموذجين يصل إلى 98,11% و 96,23% على التوالي . ويعزى هذا التحسن إلى قدرة الخوارزمية على اختيار الميزات الأكثر تميزاً وأهمية من بين مجموعة كبيرة من الميزات المستخرجة، مما يقلل من تأثير الميزات غير الضرورية أو المضللة.

ومع ذلك، لا يزال هناك مجال لمزيد من البحث في هذا المجال. في المساعي المستقبلية، يمكن أن يؤدي توسيع حجم مجموعة البيانات بعدد أكبر من الحالات إلى تحسين دقة الشبكات العصبية العميقة وتخفيف مشكلات التجاوز. بالإضافة إلى ذلك، فإن دمج ميزات جديدة مثل الكلام وتطوير نظام متعدد الوسائط يمكن أن يزيد من دقة تشخيص مرض باركنسون.

المصادر

- [1] B. Khellat Kihel and S. Mme. La reconnaissance automatique de la maladie de parkinson. *Université Des Sciences Et De La Technologie D'Oran USTO- MB; Mémoire de MAGISTER. Spécialité : Informatique, ,62 .2013*
- [2] Peter Drotár, Jiří Mekyska, Irena Rektorová, Lucia Masarová, Zdeněk Smékal, and Marcos Faundez-Zanuy. Evaluation of handwriting kinematics and pressure for differential diagnosis of parkinson's disease. *Artificial Intelligence in Medicine, ,46--67:39 .2016*
- [3] Hamdane Assia and Saidani Nadjet. La dysarthrie chez les personnes atteintes de la maladie de parkinson 75--37) ans). *Mémoire de fin d'études en vue de l'obtention du diplôme de Master en Orthophonie, .2022*
- [4] Michela Tinelli, Panos Kanavos, and Federico Grimaccia. The value of early diagnosis and treatment in parkinson's disease. Technical report, The London School of Economics and Political Science (LSE), March .2016 A literature review of the potential clinical and socioeconomic impact of targeting unmet needs in Parkinson's disease.
- [5] Cyrine Bibi. Maladie de parkinson et thérapies innovantes: perspectives d'avenir? *Sciences pharmaceutiques, .2015 [dumas-01362561](#)*.
- [6] Brahim Khelfia and Dia Errahmane Boukhris. Parkinson's disease detection from spiral and wave drawings using convolutional neural networks. *Thesis for Master Degree in Automatic and Systems, .2023*
- [7] Gennaro Pagano, Flavia Niccolini, and Marios Politis. Imaging in parkinson's disease. *Clinical Medicine, ,375--371:(4)16 .2016*
- [8] Shobha S. Rao, Laura A. Hofmann, and Amer Shakil. Parkinson's disease: diagnosis and treatment. *American Family Physician, ,2054--2046:(12)74 .2006*

- [9] Yasuo Miki, Masahiko Tomiyama, Tatsuya Ueno, Rie Haga, Haruo Nishijima, Chieko Suzuki, Fumiaki Mori, Mitsuomi Kaimori, Masayuki Baba, and Koichi Wakabayashi. Clinical availability of skin biopsy in the diagnosis of parkinson's disease. *Neuroscience Letters*, 359--357:(3)469 .2010
- [10] Nour K. Majbour, Nishant N. Vaikath, Karin D. Van Dijk, Mustafa T. Ardah, Shiji Varghese, Louise B. Vesterager, Liliana P. Montezinho, Stephen Poole, Bared Safieh-Garabedian, Takahiko Tokuda, et al. Oligomeric and phosphorylated alpha-synuclein as potential csf biomarkers for parkinson's disease. *Molecular Neurodegeneration*, 15--1:(1)11 .2016
- [11] Ela Kumar. *Artificial Intelligence*. J. K. International Pvt Ltd, .2013 Published on .2013/12/30
- [12] Nvssrsridevi Lalitha Sri Sravani Seemakurthi. Parkinson's disease detection using existing machine learning algorithms. *Faculty of Faculty, Blekinge Institute of Technology*, 371 79 Karlskrona, Sweden, June .2024
- [13] Y.Z. Lin, Z.H. Nie, and H.W. Ma. Structural damage detection with automatic feature-extraction through deep learning. *Engineering*, pages ,1046--1025 March .2020
- [14] Julius Kallio. Support vector machine and deep learning in medical applications. *University of Tampere Faculty of Natural Sciences Master's Degree Programme in Computational Big Data Analytics*, July .2017
- [15] Mohamad Alissa. Parkinson's disease diagnosis using deep learning. *School of Mathematical & Computer Sciences Thesis submitted for the M.Sc. in Artificial Intelligence with Speech and Multimodal Interaction*, August .2018
- [16] Remi Cadene. Deep learning for visual recognition. .2016 Wednesday 7th September.
- [17] Amel Tuama ALHUSSAINY. Forensic source camera identification using features: a machine learning approach. *Université de Montpellier, école doctorale I2S, unité de recherche LIRMM*, .2016
- [18] Safaa El Morabit. New artificial intelligence techniques for computer vision based medical diagnosis. *Université Polytechnique Hauts-de-France*, .2023

- [19] Philippe Pérez de San Roman. Forensic source camera identification using features: a machine learning approach. *Université de Montpellier, école doctorale I2S, unité de recherche LIRMM*, .2016
- [20] Vipin Kumar and Sonajharia Minz. Feature selection: A literature review. *Smart Computing Review*, June .2014
- [21] Prachi Agrawal, Hattan F. Abutarboush, Talari Ganesh, and Ali Wagdy Mohamed. Metaheuristic algorithms on feature selection: A survey of one decade of research -2009) .(2019- .2021
- [22] José Barrera-García, Felipe Cisternas-Caneo, Broderick Crawford, Mariam Gómez Sánchez, and Ricardo Soto. Feature selection problem and metaheuristics: A systematic literature review about its formulation, evaluation and applications. .2023
- [23] Hedfia Dida. Multimodality image registration and fusion techniques using metaheuristic algorithm based approaches. *Thesis Submitted to the Department of Electronics and Telecommunications, Doctorate 3rd Cycle LMD in Telecommunications System*, .2023
- [24] Benzid Kenza and Zaatout Kheira. Fusion d'images médicales multimodales utilisant les méthodes meta-heuristiques. *MASTER en Système des Télécommunication*, Juin .2023
- [25] Thé van Luong. Métaheuristiques parallèles sur gpu. *Recherche opérationnelle [math.OC]*, *Université des Sciences et Technologie de Lille - Lille I*, .2011
- [26] Jingwei Too, Abdul Rahim Abdullah, Norhashimah Mohd Saad, Nursabillilah Mohd Ali, and Weihown Tee. A new competitive binary grey wolf optimizer to solve the feature selection problem in emg signals classification. .2018
- [27] M. Hossin and M.N. Sulaiman. A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining & Knowledge Management Process (IJDKP)*, March .2015
- [28] Željko Đ. Vujović. Classification model evaluation metrics. *(IJACSA) International Journal of Advanced Computer Science and Applications*, ,12 .2021
- [29] Charfi Fella and Benchabane Abderrazak. Parkinson's disease detection through hand drawings using alexnet model. *Diagnostyka*, ,25 .2024

- [30] XiaoHao Wen and MengChu Zhou. Evolution and role of optimizers in training deep learning models. *IEEE/CAA Journal of Automatica Sinica*, 2056--2039:(10)11 October .2024 Perspective.