

مجلة جامعة البعث

سلسلة العلوم الهندسية الميكانيكية
والكهربائية والمعلوماتية



مجلة علمية محكمة دورية

المجلد 45 . العدد 20

1445 هـ - 2023 م

الأستاذ الدكتور عبد الباسط الخطيب
رئيس جامعة البعث
المدير المسؤول عن المجلة

رئيس هيئة التحرير	أ. د. محمود حديد
رئيس التحرير	أ. د. درغام سلوم

مديرة مكتب مجلة جامعة البعث
بشرى مصطفى

عضو هيئة التحرير	د. محمد هلال
عضو هيئة التحرير	د. فهد شريباتي
عضو هيئة التحرير	د. معن سلامة
عضو هيئة التحرير	د. جمال العلي
عضو هيئة التحرير	د. عباد كاسوحة
عضو هيئة التحرير	د. محمود عامر
عضو هيئة التحرير	د. أحمد الحسن
عضو هيئة التحرير	د. سونيا عطية
عضو هيئة التحرير	د. ريم ديب
عضو هيئة التحرير	د. حسن مشرقي
عضو هيئة التحرير	د. هيثم حسن
عضو هيئة التحرير	د. نزار عبشي

تهدف المجلة إلى نشر البحوث العلمية الأصيلة، ويمكن للراغبين في طلبها

الاتصال بالعنوان التالي:

رئيس تحرير مجلة جامعة البعث

سورية . حمص . جامعة البعث . الإدارة المركزية . ص . ب (77)

. هاتف / فاكس : 2138071 31 963 ++

. موقع الإنترنت : www.albaath-univ.edu.sy

. البريد الإلكتروني : [magazine@ albaath-univ.edu.sy](mailto:magazine@albaath-univ.edu.sy)

ISSN: 1022-467X

شروط النشر في مجلة جامعة البعث

الأوراق المطلوبة:

- 2 نسخة ورقية من البحث بدون اسم الباحث / الكلية / الجامعة) + CD / word من البحث منسق حسب شروط المجلة.
 - طابع بحث علمي + طابع نقابة معلمين.
 - إذا كان الباحث طالب دراسات عليا:
يجب إرفاق قرار تسجيل الدكتوراه / ماجستير + كتاب من الدكتور المشرف بموافقة على النشر في المجلة.
 - إذا كان الباحث عضو هيئة تدريسية:
يجب إرفاق قرار المجلس المختص بإنجاز البحث أو قرار قسم بالموافقة على اعتماده حسب الحال.
 - إذا كان الباحث عضو هيئة تدريسية من خارج جامعة البعث :
يجب إحضار كتاب من عمادة كليته تثبت أنه عضو بالهيئة التدريسية و على رأس عمله حتى تاريخه.
 - إذا كان الباحث عضواً في الهيئة الفنية :
يجب إرفاق كتاب يحدد فيه مكان و زمان إجراء البحث ، وما يثبت صفته وأنه على رأس عمله.
 - يتم ترتيب البحث على النحو الآتي بالنسبة لكليات (العلوم الطبية والهندسية والأساسية والتطبيقية):
عنوان البحث .. ملخص عربي و إنكليزي (كلمات مفتاحية في نهاية الملخصين).
- 1- مقدمة
 - 2- هدف البحث
 - 3- مواد وطرق البحث
 - 4- النتائج ومناقشتها .
 - 5- الاستنتاجات والتوصيات .
 - 6- المراجع.

- يتم ترتيب البحث على النحو الآتي بالنسبة لكليات (الآداب - الاقتصاد - التربية - الحقوق - السياحة - التربية الموسيقية وجميع العلوم الإنسانية):
- عنوان البحث .. ملخص عربي و إنكليزي (كلمات مفتاحية في نهاية الملخصين).
- 1. مقدمة.
- 2. مشكلة البحث وأهميته والجديد فيه.
- 3. أهداف البحث و أسئلته.
- 4. فرضيات البحث و حدوده.
- 5. مصطلحات البحث و تعريفاته الإجرائية.
- 6. الإطار النظري و الدراسات السابقة.
- 7. منهج البحث و إجراءاته.
- 8. عرض البحث و المناقشة والتحليل
- 9. نتائج البحث.
- 10. مقترحات البحث إن وجدت.
- 11. قائمة المصادر والمراجع.
- 7- يجب اعتماد الإعدادات الآتية أثناء طباعة البحث على الكمبيوتر:
 - أ- قياس الورق 25×17.5 B5.
 - ب- هوامش الصفحة: أعلى 2.54- أسفل 2.54 - يمين 2.5- يسار 2.5 سم
 - ت- رأس الصفحة 1.6 / تذييل الصفحة 1.8
 - ث- نوع الخط وقياسه: العنوان . Monotype Koufi قياس 20
- . كتابة النص Simplified Arabic قياس 13 عادي . العناوين الفرعية Simplified Arabic قياس 13 عريض.
- ج . يجب مراعاة أن يكون قياس الصور والجداول المدرجة في البحث لا يتعدى 12سم.
- 8- في حال عدم إجراء البحث وفقاً لما ورد أعلاه من إشارات فإن البحث سيهمل ولا يرد البحث إلى صاحبه.
- 9- تقديم أي بحث للنشر في المجلة يدل ضمناً على عدم نشره في أي مكان آخر، وفي حال قبول البحث للنشر في مجلة جامعة البعث يجب عدم نشره في أي مجلة أخرى.
- 10- الناشر غير مسؤول عن محتوى ما ينشر من مادة الموضوعات التي تنشر في المجلة

11- تكتب المراجع ضمن النص على الشكل التالي: [1] ثم رقم الصفحة ويفضل استخدام التهميش الإلكتروني المعمول به في نظام وورد WORD حيث يشير الرقم إلى رقم المرجع الوارد في قائمة المراجع.

تكتب جميع المراجع باللغة الانكليزية (الأحرف الرومانية) وفق التالي:
آ . إذا كان المرجع أجنبياً:

الكنية بالأحرف الكبيرة . الحرف الأول من الاسم تتبعه فاصلة . سنة النشر . وتتبعها معترضة (-) عنوان الكتاب ويوضع تحته خط وتتبعه نقطة . دار النشر وتتبعها فاصلة . الطبعة (ثانية . ثالثة) . بلد النشر وتتبعها فاصلة . عدد صفحات الكتاب وتتبعها نقطة .
وفيما يلي مثال على ذلك:

-MAVRODEANUS, R1986- Flame Spectroscopy. Willy, New York, 373p.

ب . إذا كان المرجع بحثاً منشوراً في مجلة باللغة الأجنبية:

. بعد الكنية والاسم وسنة النشر يضاف عنوان البحث وتتبعه فاصلة، اسم المجلد ويوضع تحته خط وتتبعه فاصلة . المجلد والعدد (كتابة مختزلة) وبعدها فاصلة . أرقام الصفحات الخاصة بالبحث ضمن المجلة.
مثال على ذلك:

BUSSE,E 1980 Organic Brain Diseases Clinical Psychiatry News ,
Vol. 4. 20 – 60

ج . إذا كان المرجع أو البحث منشوراً باللغة العربية فيجب تحويله إلى اللغة الإنكليزية و
التقيد

بالبنود (أ و ب) ويكتب في نهاية المراجع العربية: (المراجع In Arabic)

رسوم النشر في مجلة جامعة البعث

1. دفع رسم نشر (40000) ل.س أربعون ألف ليرة سورية عن كل بحث لكل باحث يريد نشره في مجلة جامعة البعث.
2. دفع رسم نشر (100000) ل.س مئة الف ليرة سورية عن كل بحث للباحثين من الجامعة الخاصة والافتراضية .
3. دفع رسم نشر (200) مئتا دولار أمريكي فقط للباحثين من خارج القطر العربي السوري .
4. دفع مبلغ (6000) ل.س ستة آلاف ليرة سورية رسم موافقة على النشر من كافة الباحثين.

المحتوى

الصفحة	اسم الباحث	اسم البحث
42-11	د. رانيا لطفي د. أسماء شعار م. حلا ابراهيم	تحليل السلاسل الزمنية لاكتشاف الشذوذ ضمن حركة المرور
78-43	د. نبيل دحوح د. عيد عبود م. ليلي مريم	استخدام الشبكات العصبونية لتخفيض أبعاد الصور فائقة الطيف لأغراض تحسين السرعة والدقة
96-79	م. محمد هيثم الشمالي د. مجد البين العلي	دراسة الخواص المغناطيسية لبعض المركبات النانوية باستخدام نموذج Ising وخوارزميات مونت كارلو
122-97	م. محمد صلاح سوذه د. مصطفى أصلان	الدراسة الديناميكية والتحكم اللاخطي بروبوت تفرعي "دلتا" ذو ثلاثة أذرع دورانية
146-123	م. ميسم زريفه د. سهيل حنا	دراسة تجريبية لتحسين معامل أداء مضخة حرارية ماء-هواء باستخدام نظام استعادة الحرارة من غلاف الضاغط
164-147	م. حسن وسوف د. ماهر ابراهيم	تحسين تصنيف صور الأشعة السينية للصدر للكشف عن الالتهاب الرئوي وفيروس كورونا COVID19 باستخدام التعلم العميق

تحليل السلاسل الزمنية لاكتشاف الشذوذ

ضمن حركة المرور

طالب الدراسات العليا: حلا ابراهيم

كلية: الهندسة المعلوماتية - جامعة: البعث

الدكتورة المشرفة: رانيا لطفي + د. أسماء شعار

ملخص البحث

مع التقدم الذي تشهده التكنولوجيا حالياً، ومع ازدياد التضخم السكاني، أصبحت مراقبة حركة المرور ضرورة لا بد منها لضمان السلامة العامة سواء للسائقين أو للمشاة لتجنب أكبر كمية من الحوادث. لذلك ظهرت الحاجة لإيجاد نظام يعمل على تحليل بيانات الازدحام المروري للكشف عن أي شذوذ محتمل. تهدف هذه الدراسة إلى استخدام تقنيات التعلم العميق وبعض الخوارزميات لمحاولة اكتشاف الشذوذ في البيانات التي يتم استخدامها والمتعلقة بالازدحام المروري على الطرقات مأخوذة من أحد التقاطعات في مدينة انكلترا وقد تم استخدام بعض الخوارزميات مثل خوارزمية ال STL (Seasonal Trend Based on Loess) والتي تعتمد على خصائص الإشارة الزمنية وتقسيمها، بالإضافة لخوارزميات ال Machine Learning وبشكل خاص ال LSTM Autoencoder حيث أظهرت النتائج أن استخدام الشبكات العصبونية ساعد على اكتشاف الشذوذ بشكل أفضل من ال STL وذلك يتوقف على نوع الطبقات المستخدمة لبناء الشبكة .

الكلمات المفتاحية: سلاسل زمنية - اكتشاف الشذوذ - موسمية - LSTM - Autoencoder - شبكات عصبونية - STL .

Time Series Analysis For Anomaly Detection in Traffic Flow

Abstract

With the progress witnessed by technology today ,and with the increase in population inflation ,traffic control has become an absolute necessity to ensure public safety , whether for drivers or pedestrians ,to avoid the largest number of accidents. Therefore, there was a need to find a system that analyzes traffic congestion data to detect any possible anomalies.This study aims to use deep learning techniques and some algorithms to try to detect anomalies in the data and related to traffic congestion on the roads taken from an intersection in the city of England. Some algorithms have been used such as the STL algorithm (Seasonal Trend Based on Loess), which depends on the characteristics of the time signal and its division, in addition to the machine learning algorithms, especially the LSTM Autoencoder. The results show that the use of neural networks helped to detect anomalies better than the STL, depending on the type of layers used to build the network.

Keywords: time series - anomaly detection - seasonality - LSTM Autoencoder - neural networks - STL.

1- المقدمة

مع تقدّم الزمن يشهدُ العالمُ ازدياداً ملحوظاً في محاولة تسهيل وتوفير وسائل الرّفاهية والراحة للإنسان، الأمر الذي ترافقَ مع ازديادِ الطّلبِ على استخدام وسائل النقل سواء الفردي منها أو الجماعي، لضمان سهولة التنقل والذي تبين بحسب إحصائيات الوكالة الدولية للطاقة (International Energy Agency) أن نسبة المبيعات واستخدام العربات قد ازداد بنحو 60% بحسب آخر إحصائية لعام 2022[1]. وعلى الرُغم من الجوانب الإيجابية لهذه الخدمات، إلّا أنها تعاني من عدّة مشاكل كالحوادث سواء نتيجة عوامل جوية أو أخطاء بشرية، وازدحامات قد تعرّض الإنسان للخطر لذلك كان لابد من العمل على إيجاد حلول لمحاولة تقليل الحوادث والوفيات وردء الخطر وتجنب الأسباب التي قد تؤدي بحياته.

ساعد انتشار أجهزة المراقبة والحساسات على الطرقات في القدرة على تسجيل بيانات الحركة المرورية على مدار السنوات، والتي كان لابد من مراقبتها بشكل دوري، ومن ثم الاستفادة من هذه البيانات للقيام بدراسة تحليلية لمحاولة الكشف عن أي شذوذ واتخاذ الإجراءات اللازمة بما يتناسب مع نوع الشذوذ. يمكن تعريف الشذوذ بأنه أنماط أو حالات ضمن مجموعات البيانات يكون سلوكها مختلف عن السلوك الطبيعي (سلوك غير متوقع). تعتبر القيم المتطرفة كنوع من أنواع الشذوذ.

حيث يعد اكتشاف الشذوذ ضمن حركة المرور عنصراً أساسياً في أنظمة النقل الذكية. هذه الشذوذات التي قد تنشأ بسبب عدة عوامل منها: الحوادث، الأحوال الجوية السيئة، ساعات الازدحام اليومية التي يتم توصيفها بالموسمية.

وبحسب آخر إحصائية صادرة عن المملكة المتحدة (Gov UK) لنهاية يونيو عام 2022 بلغ عدد حالات الوفيات حوالي 1760 حالة، وتم الإبلاغ عن 137013 إصابة سواء خطرة أو عرضية.[18]

2- مشكلة البحث

مع ظهور العديد من التطبيقات التي تعمل على تحديد الطريق الأقل ازدحاماً وذلك لضمان سلامة الإنسان، كان لابد من العمل على تحليل البيانات التي تم جمعها بطرق مختلفة سواء عن طريق الحساسات أو كاميرات المراقبة أو الأقمار الصناعية وغيرها على مدى سنة أو أكثر يومياً وذلك للكشف عن أي شذوذ.

كل ذلك دفعنا لدراسة البيانات الملتقطة والبحث عن الشذوذات ومعرفة أسبابها، سواء كان عطل في الأجهزة أو وقوع حوادث أو عوامل جوية مفاجئة في منطقة ما أو دراسة تأثير الموسمية مثل الازدحام اليومي بسبب العمل أو الرحلات بالعطل وغيرها مما قد يؤثر على السلامة.

3- أهمية وهدف البحث

تكمُن أهمية هذا البحث بالكشف عن الازدحام ضمن منطقة أو خلال فترة زمنية معينة والاستفادة من ذلك لتجنب هذه الطرقات والوقاية من الحوادث ومحاولة تسهيل عملية الوصول للوجهة بسلامة وسرعة.

وكما نعلم يوجد العديد من الطرق لاكتشاف الشذوذ ولكن الغاية من هذا البحث هو إيجاد الخوارزمية الأنسب لاكتشاف الشذوذ ضمن السلسلة التي يتم العمل عليها والمتعلقة بالازدحام المروري على الطرقات والتي تم جمعها من أجهزة مستشعرات ومقارنتها مع الطرق المستخدمة في أبحاث أخرى وذلك بغية بناء نموذج قادر على كشف الشذوذ ضمن البيانات الزمنية بشكل دقيق.

4- دراسات مرجعية

هناك العديد من الأبحاث والدراسات التي عملت على اكتشاف الشذوذ ضمن السلاسل الزمنية حيث نجد في البحث [12] أنه تم العمل على بيانات غير مهيكلة وغير معنونة وتم استخدام عدة خوارزميات وهي: Isolation Forests-RNN-LSTM Autoencoders. تم تطبيق كل من خوارزميتي Isolation Forests-RNN على بيانات معنونة ووصلت قيمة مقياس ال F1 score ل 0.98 أما عند تطبيقها على بيانات غير معنونة فكانت النتائج

سيئة. بالنسبة لشبكة ال LSTM Autoencoder تم تطبيقها على بيانات غير معنونة، ووصلت قيمة ال F1 ل0.8.

الدراسة [1] قامت بعملية تدريب نموذج التعلم الآلي (machine learning) لاكتشاف وتصنيف الحالات الشاذة على الطرق السريعة في ستوكهولم. ونظراً لعدم وجود مجموعة بيانات مصنفة، تم العمل على اكتشاف الأنواع المختلفة من القيم المتطرفة التي يمكن العثور عليها وتسميتها يدوياً بناءً على نتائج دراسة استكشاف البيانات. تم أيضاً استخدام dataset تحتوي على معلومات تتعلق بالحوادث والطقس لتوسيع مقدار الحالات الشاذة. تستخدم جميع التجارب مجموعات بيانات حقيقية تأتي من أجهزة الاستشعار الموجودة على الطرق السريعة في ستوكهولم أو من تقارير رسمية عن الحوادث والطقس. تم استخدام Python Spark API for و النماذج التي تم تدريبها هي: logistic regression, random forest, decision trees. وجدوا أن دقة النموذج الذي تم بناؤه باستخدام ال Logistic Regression هو الأفضل بين الثلاث. من مساوئ هذا البحث أن النموذج الذي تم بناؤه لا يزال غير دقيق وذلك بسبب الطبيعة غير المتوازنة للبيانات.

عمل البحث [14] على تطوير نظام قادر على اكتشاف الحالات الشاذة في بيانات السلاسل الزمنية لتدفق حركة المرور، والتي يمكن أن تتعلم أنماط الشذوذ من البيانات دون إشراف، ولا تتطلب أي بيانات معنونة في مرحلة تدريب النموذج أو معرفة عتبة تعريف الشذوذ. يعتمد النموذج المقترح على التعلم المعزز، حيث تم استخدام نموذج ال LSTM مع خوارزمية ال-Q Learning. تم اختبار هذا النموذج على مجموعة بيانات حقيقية في مدينة برسيان في استراليا وكانت النتائج كما يلي : F1 score 85%, recall 80 % precision 90%

من مساوئ هذا البحث أنه تم توليد بيانات تدفق تركيبية صناعية مع تسميات للحالات الشاذة لتقييم أداء النموذج بشكل أكثر موضوعية.

وهناك بعض الأبحاث التي عملت على استخدام بعض شبكات ال CNN حيث استخدم البحث [16] نموذجين الأول هو CNN Autoencoder والذي يأخذ كدخل سلسلة متعددة المتغيرات ، والنموذج الثاني هو lstm autoencoder والذي يأخذ كدخل سلسلة وحيدة المتغير ، ولكن النتائج التي تم الحصول عليها أظهرت عدم قدرتهما على اكتشاف جميع أنواع البيانات الطبيعية بشكل صحيح عند تدريبهما باستخدام البيانات العادية فقط.

وعالج البحث [15] مشكلة البيانات التي تحتوي كميات كبيرة من القيم المفقودة واقترح طرق لتنظيفها ومن ثم اقترح نماذج لاكتشاف الشذوذ ضمن بيانات حركة المرور دون التأثير بهذا النقص في البيانات.

الدراسة [17] اقترحت طريقة لاكتشاف الشذوذ في السلاسل الزمنية، والبيانات التي جمعها باستخدام المستشعرات (loop detector) من 2011 إلى 2014 بمجالات 15 دقيقة) غير معنونة، و تعتمد على مرجعية وخبرة الخبراء للتصنيف. هذه البيانات قد تحتوي على شذوذات إما بسبب عطل في الأجهزة أو لأسباب أخرى. بغض النظر عن هذه الأسباب فإن هذه الشذوذات ستؤثر على نتائج التحليل والتنبؤ.

طريقة اكتشاف الشذوذ المقترحة في هذا البحث تتكون من عدة مراحل:

1- تجميع بيانات ال loop detector ضمن clusters بالاعتماد على الخصائص الداخلية.

2- القيام ببعض عمليات تحضير البيانات لإزالة ال null values .

3- اكتشاف الشذوذ بالاعتماد على الموسمية ومن ثم العنقدة بالاعتماد على ال point-distance و ال different-distance.

4- تحديد العتبة إمّا عن طريق خبير أو تطبيق عملية اختيار عتبة بشكل أوتوماتيكي.

ولكن من مساوئ أو محدوديات هذه الطريقة أنه يمكن تطبيقها على السلاسل الزمنية وحيدة المتغير فقط. وأن الطريقة التي تم تطبيق ال

clustering فيها والمقارنات مكلفة حسابياً ولكن لحسن الحظ لا نحتاج لتطبيق clustering سوى مرة واحدة.

5- المفاهيم المستخدمة في البحث:

5-1 السلاسل الزمنية:

السلسلة الزمنية: هي مجموعة من نقاط البيانات الرقمية المتسلسلة والمرتببة بترتيب متتالي. تقوم هذه السلسلة بتعقب حركة نقاط البيانات التي تم تسجيلها على مدى زمني وتفيدنا في ملاحظة أو اكتشاف نمط أو ظاهرة معينة عبر الزمن.

وتُعرّف السلاسل الزمنية بأنها مجموعة من الإحصائيات التي يتم جمعها على فترات منتظمة [2]، وتظهر هذه السلاسل بشكل طبيعي في العديد من المجالات التطبيقية وأشهرها:

- التمويل: على سبيل المثال، سعر الصرف اليومي، وسعر السهم.
- البيئة: على سبيل المثال، هطول الأمطار اليومي، قراءات جودة الهواء.
- الطب: على سبيل المثال، نشاط الموجات الدماغية لتخطيط القلب كل 2-8 ثواني.

يطلق على السلسلة الزمنية التي تسجل قياسات ظاهرة واحدة أو متغير واحد بالسلسلة أحادية المتغير (univariate)، بينما السلسلة التي تسجل قياسات عدة ظواهر أو التي تمتلك أكثر من متغير تدعى بمتعددة المتغيرات (multivariate).

طريقة أخرى للتمييز بين السلاسل الزمنية هي طريقة تسجيلها، حيث لدينا سلاسل زمنية متقطعة (discrete) وسلاسل زمنية مستمرة (continuous).

5-2 مكونات السلاسل الزمنية:


تُعتبر عملية النّظر في نوع أنماط البيانات المعروضة من خلال الرسوم البيانية إحدى الخطوات الرئيسية في اختيار وتحديد إجراءات النمذجة والتنبؤ المناسبة للسلاسل الزمنية.

أي سلسلة زمنية يمكن أن تحوي بعض أو كل المكونات التالية[3]:

- الاتجاه (Trend): ويرمز له T وهو الاتجاه العام للبيانات، وهو نمط طويل المدى، يمكن أن يكون الاتجاه إيجابياً أو سلبياً اعتماداً على ما إذا كانت السلسلة الزمنية تُظهر نمطاً متزايداً أو متناقصاً.
- الموسمية (Seasonal): ويرمز لها S ، تحدث الموسمية عندما تبدي السلسلة الزمنية تقلبات منتظمة خلال نفس الشهر (أو الأشهر) كل عام، أو خلال نفس الربع من كل عام، وبالتالي تتأثر السلسلة بالعوامل الموسمية وتتكسر على أساس دوري منتظم.
- مكون غير منتظم (Irregular): ويرمز له I ، حيث نجد ضمن كل سلسلة زمنية بعض المكونات غير المتوقعة مما يجعلها متغيراً عشوائياً ولا يمكن التنبؤ بهذا المكون.
- دوري (Cyclic): وذلك عندما ترتفع البيانات وتهبط في فترة غير محددة. حيث يتم تحديد أي نمط يظهر حركة صعوداً وهبوطاً حول اتجاه معين كنمط دوري. تعتمد مدة الدورة على نوع العمل أو الصناعة التي يتم تحليلها.

5-3 الشذوذ (Anomaly)

تعريف الشذوذ ، يمكن أن يختلف من مجال إلى آخر، فيمكن تعريفه على أنه ملاحظة (observation) تنحرف كثيراً عن الملاحظات الأخرى بحيث تثير الشكوك في أنها تم إنشاؤها بواسطة آلية مختلف[4]. كما هو موضح في الشكل (1):



الشكل (1) صورة لمجموعة بيانات تحتوي نقطة شاذة

يعد اكتشاف الشذوذ مجال بحث نشط لعدة عقود، وذلك نظراً للطلب المتزايد والتطبيقات في مجالات واسعة، مثل إدارة المخاطر، والأمن، والمراقبة المالية، والمخاطر الصحية والطبية، وسلامة الذكاء الاصطناعي وغيرها. تم تصنيف أنواع الحالات الشاذة المتعلقة ببيانات السلاسل الزمنية على النحو التالي [5]:

- الشذوذ النقطي POINT ANOMALY
- الشذوذ في السياق CONTEXTUAL ANOMALY
- الشذوذ الجماعي COLLECTIVE ANOMALY

4-5 اكتشاف الشذوذ في السلاسل الزمنية لتدفق حركة المرور:

يلعب اكتشاف الأحداث غير المتوقعة أو الأنماط النادرة لبيانات حركة المرور دوراً مهماً في إدارة أنظمة حركة المرور، والتي تعمل على تقديم تقارير أو تنبيهات بالحوادث المحتملة أو أخطاء الاستشعار. يمكن أن يؤدي الاكتشاف الدقيق للشذوذ في بيانات حركة المرور إلى استكشاف الأخطاء وإصلاحها بسرعة والمساعدة في اتخاذ القرار في الوقت المناسب. بشكل عام، الشذوذ هو ملاحظة أو سلسلة من الملاحظات التي تنحرف بشكل كبير عن التوزيع العام للبيانات المعينة، ويرتبط مقدار الانحراف باحتمال كونه شذوذاً. [13]

في هذا البحث، سنعمل على تحليل البيانات المتعلقة بالازدحام المروري عند تقاطع معين لاكتشاف الشذوذ غير المتكرر الناجم عن حوادث غير متوقعة أو عابرة مثل حوادث المرور، والاحتفالات، والكوارث، وصيانة الطرق الطارئة وغيرها. ينتج عن هذا النوع من شذوذ حركة المرور تغيرات واضحة في حالة الحركة (متوسط عدد لسيارات مثلاً). على عكس الاختناقات المرورية التي تسببها ساعات الذروة أو العطل، فمن الصعب توقع حالات الشذوذ المرورية. لذلك من المهم اكتشاف الحالات الشاذة لاستشعار الأحداث غير الطبيعية ومعرفة تأثيرها على التدفق الطبيعي لحركة المرور.

5-5 اكتشاف الشذوذ غير الخاضع للإشراف

يعد اكتشاف الشذوذ في السلاسل الزمنية من المواضيع التي تم العمل بها بشكل كبير نظراً لأهميتها في العديد من المجالات، منها التشخيص الطبي واكتشاف الاحتيال واختراق الشبكة. توجد العديد من الأساليب التقليدية، سواء للمشكلات الخاضعة للإشراف أو غير الخاضعة للإشراف. بالنسبة لتقنيات التعلم الآلي غير الخاضعة للإشراف لا تتطلب أي بيانات تدريب [6]. يعد عدم الإشراف مفيداً عندما تكون البيانات غير معنونة وبالتالي تتطلب عملاً أقل لمعالجة البيانات. تفترض تقنيات اكتشاف الشذوذ غير الخاضعة للإشراف أن نقاط البيانات العادية ستظهر بشكل أكبر بكثير من نقاط البيانات الشاذة ويستخدم هذا الافتراض لتصنيف نقاط البيانات التي تظهر بشكل أقل على أنها شذوذ. حيث تقوم بتعيين score لكل نقطة [7].

6- مجموعات البيانات (Datasets)

تم العمل في هذا البحث على مجموعة بيانات [11] تتضمن مجموعة من المعطيات لحركة مرور شبكة الطرق السريعة في إنجلترا مكونة من 12 عمود، بتسجيلات كل 15 دقيقة متواجدة على شكل ملفات منفصلة لكل شهر حيث تم اعتماد الفترة من 1-1-2019 حتى 31-12-2020. تم أخذ البيانات عند تقاطع معين.

كل تسجيله أو سطر من هذه الملفات يتضمن الأعمدة التالية:

جدول (1) الأعمدة ضمن القاعدة المستخدمة

العمود	الوصف
Local date	التاريخ المحلي حسب التوقيت البريطاني الصيفي
Local time	الوقت المحلي بفواصل زمنية 15 دقيقة حسب التوقيت البريطاني الصيفي
Quality index	إشارة الى نوعية البيانات المقدمة، فمثلاً تشير القيمة 0 إلى سجلات غير صالحة
Day type	إشارة الى نوع اليوم عطلة أو يوم دوام رسمي
Total carriageway flow	عدد السيارات التي تم رصدها في أي ممر ضمن مجال زمني 15 دقيقة
Total Flow vehicles less than 5.2m	عدد السيارات ضمن مسافة أقل من 5.2 متراً
Total Flow vehicles 5.21m - 6.6m	عدد السيارات ضمن مسافة بين 5.21 m - 6.6m
Total Flow vehicles 6.61m - 11.6m	عدد السيارات ضمن مسافة بين 6.61 m - 11.6m
Total Flow vehicles above 11.6m	عدد السيارات ضمن مسافة تتجاوز 11.6m
Speed Value	متوسط السرعة مقاسة بال كم/ساعة لجميع السيارات على كل الخطوط خلال مدة زمنية 15 دقيقة
Network Link Id	معرف فريد لرابط NTIS
NTIS Model Version	إصدار نموذج NTIS الذي تتعلق به البيانات

وتم علاوة على ذلك اشتقاق متغيرات جديدة من المجموعة المختارة حيث تم دمج عمودي ال Local date وال Local time بعمود new time.

7- الخوارزميات المستخدمة:


بعد دراسة وإيجاد العديد من الخوارزميات والطرق المستخدمة لاكتشاف الشذوذ ومعرفة إيجابيات وسلبيات كل منها، كان لابد من البحث عن الخوارزمية الأنسب في حالة البيانات التي يرجح فيها كمية البيانات الطبيعية على البيانات الشاذة (غير متوازنة) وغير المعنونة. قمنا في هذا الفصل بتقديم شرح عن خوارزمية (STL (Seasonal Trend Based on Loess) والتي تعتمد على مبدأ تقسيم السلسلة لثلاث أجزاء: trend-- seasonal residual ومن ثم تحديد عتبة واعتبار كل ما تجاوز العتبة عبارة عن شذوذ. ومن جهة أخرى شبكة عصبونية مكونة من شبكة LSTM Autoencoder كأحد الخوارزميات الواعدة والتي لا تحتاج لبيانات معنونة.

7-1 خوارزمية (STL (Seasonal Trend Decomposition Based On Loess)

تعرف بأنها إجرائية فلترة تعمل على تقسيم السلسلة الزمنية الموسمية إلى ثلاث مكونات وهي: الموسميّة والاتّجاه وبقية الإشارة. الشكل (2) يوضح مثال عنها. حيث تمثل البيانات في الشكل العلوي قيمة المتوسط اليومي لنسبة غاز ثاني أكسيد الكربون بالجو. المخطط الثاني والذي هو مكون الاتجاه يمثل تغير التردد المنخفض في البيانات لفترة طويلة مع تغيرات غير ثابتة طويلة المدى. المخطط الثالث والذي يعبر عن مكون الموسمية يمثل التغير ضمن البيانات على التردد الموسمي. المخطط لرابع يمثل ماتبقى من الإشارة أو السلسلة إذا رمزنا لكل من البيانات أو السلسلة الأصلية، مكون الاتجاه، مكون الموسمية، البقايا على التالي: Y, T, S, R فيمكن تمثيل السلسلة وفق المعادلة (1) [8]:

$$Y = T + R + S$$

المعادلة (1)



الشكل (2) يمثل تقسيم السلسلة الزمنية لمكوناتها

الهدف من استخدام stl هو تطوير إجرائية تقسيم تحقق المعايير التالية: [8]

- 1- ذات تصميم بسيط واستخدام سهل.
- 2- المرونة في تحديد كمية التباين في كل من مكون الاتجاه والموسميّة.
- 3- القدرة على تقسيم السلاسل التي تحوي قيم فارغة.

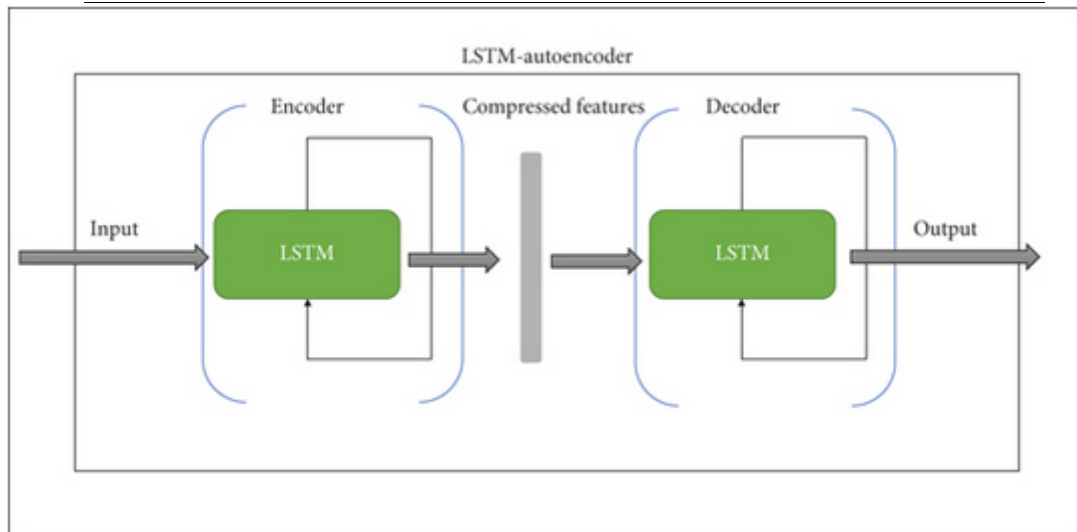
4- سهولة في التنفيذ وسرعة الحساب، حتى بالنسبة للسلاسل الزمنية الطويلة.

7-1-1 مبدأ عمل خوارزمية الـ STL

تتكون STL من إجرائيتين متكررتين: حلقة داخلية وحلقة خارجية. الحلقة الداخلية تقوم بالملائمة مع مكون الاتجاه و حساب المكون الموسمي. كل حلقة داخلية تتكون من ست خطوات خلالها يتم تقطيع السلسلة الزمنية وتطبيق فلتر تنعيم مثل Loess . إذا تم اكتشاف أي شذوذ، فسيتم تطبيق حلقة خارجية واستبدال LOESSs من الحلقة الداخلية بـ Robust LOESS. ولكن يمكن اعتبار تحديد العتبة المناسبة والذي يعتمد على مبدأ التجريب والخطأ هو أحد نقاط ضعف هذه الخوارزمية وكانت الخوارزمية قادرة على اكتشاف عدة نقاط شذوذ ولكن لم تكن كافية لالتقاط كامل النقاط لذلك تم البحث عن خوارزميات ومقارنتها معها.

7-2 شبكات LSTM Autoencoders

يتم تعريف هذه الشبكة على أنها نموذج هجين مقترح يمكنه إجراء اختيار الميزات بشكل فعال بناءً على أهمية المعلومات واكتشاف الشذوذ ومهمة التصنيف. يعطي الشكل 3 لمحة عامة عن بنية الشبكة العصبية العميقة الهجينة المحددة. [9]



الشكل (3) يمثل بنية شبكات ال LSTM Autoencoders

تستخدم شبكة LSTM-Autoencoder إمكانات كل من الشبكة العصبية LSTM و Autoencoder التي تبني شبكات LSTM على مخططات التشفير وفك التشفير الخاصة بـ Autoencoder. يحصل المشفر على تسلسل بيانات الإدخال ذات التمثيل عالي الأبعاد (high dimension) كمتجه ذو حجم ثابت. باستخدام خلايا ذاكرة الخاصة بال LSTM ، فإن البيانات التي تمت معالجتها باستخدام المشفر تقوم بالاحتفاظ بالتسلسل أو التبعية عبر عدة نقاط في أي تسلسل زمني أي تركز على المدى الطويل. تقوم وحدة فك التشفير LSTM بإعادة إنتاج تسلسل الإدخال ذي الحجم الثابت من التمثيل المنخفض لبيانات الإدخال باستخدام معدلات خطأ إعادة البناء لتعيين عتبة. هذه العتبة هي ما يستخدم لاكتشاف الحالات الشاذة. [10] يتم تقييم الشبكة بناء على قدرة النموذج على إعادة إنشاء تسلسل الدخل، عندئذ يمكن إزالة جزء مفك الترميز والبقاء على وحدة الترميز ليتم استخدام خرج مفك الترميز (شعاع بطول ثابت) كدخل للعديد من التطبيقات مثل نماذج التعليم الخاضعة للتعليم بإشراف.

8- مقاييس الأداء:

سنستعرض هنا بعض المقاييس المستخدمة لتقييم النتائج التي تم الحصول عليها. على الرغم من أن الدقة يمكن أن تكون مضللة في البيانات الغير متوازنة وفي تحديد مدى صحة النتائج.

8-1 الدقة والاستدكار Precision & Recall

تعد مقاييس الدقة والاستدكار من أكثر المقاييس استخداماً في البيانات غير المتوازنة.

تعمل درجة الدقة والاستدكار على تقييم مدى جودة الخوارزمية في التقاط الحالات الشاذة الموجودة، وعدد هذه الحالات المصنفة بشكل خاطئ.

يعرف precision بأنه نسبة عدد نقاط البيانات ذات الصلة إلى العدد الكلي لنقاط البيانات التي تم استرجاعها من النموذج. أما ال Recall يعرف بأنه نسبة عدد نقاط البيانات التي صنفها النموذج بشكل صحيح أنها ذات صلة إلى العدد الكلي لنقاط البيانات التي تم استرجاعها من النموذج. يُعطى قانون كل من المقياسين بالعلاقة :

$$\text{Precision} = \frac{tp}{tp + fp} \quad \text{and} \quad \text{Recall} = \frac{tp}{tp + fn}$$

المعادلة (2)

8-2 مقياس F1 Score

تعتبر درجة F1 في التحليل الإحصائي للتصنيف الثنائي مقياساً لدقة الاختبار، فهي المتوسط التوافقي للدقة والاستدكار. تبلغ أفضل قيمة للمقياس عند الواحد (أفضل دقة واستدكار) وأسوء قيمة عند الصفر. مقياس F1 Score يعطى بالعلاقة :

$$F1 = 2 * \frac{1}{1/precision + 1/recall}$$

المعادلة (3)

8-3 مقياس Zscore :

يعرف بأنه مقياس يعطينا فكرة عن مدى بُعد نقطة البيانات عن المتوسط. يشير إلى عدد الانحرافات المعيارية عن المتوسط. ومن ثم، يتم قياس Z-Score من حيث الانحراف المعياري عن المتوسط. على سبيل المثال ، يشير الانحراف المعياري البالغ 2 إلى أن القيمة هي انحرافان معياريان بعيداً عن المتوسط. من أجل استخدام هذا المقياس ، نحتاج إلى معرفة قيمة المتوسط (μ) وكذلك الانحراف المعياري (σ). يعطى بالمعادلة التالية :

$$Z = (X - \mu) / \sigma$$

المعادلة (4)

9- التجربة The Experiment


تم تطبيق خوارزميتي LSTM Autoencoder و STL على مجموعات البيانات أنفة الذكر وذلك لمحاولة كشف الشذوذ ضمن بيانات حركة المرور في انكلترا.

9-1 تحليل البيانات :

بدايةً قبل البدء بتطبيق الخوارزميات قمنا بعملية تحليل للبيانات واختيار الأعمدة التي ستساعدنا في اكتشاف لشذوذ.


9-1-1 تحديد ودراسة العلاقة بين الوقت ومتوسط عدد السيارات في اكتشاف الشذوذ:

في حال رسمنا الإشارة على مدار أسبوع كامل من 1-1-2019 وحتى 7-1-2019 نرى الصفة الموسمية والاتجاه واضحة ضمن البيانات:



الشكل (4) يمثل تغير عدد السيارات خلال أسبوع

حيث نجد أن متوسط عدد السيارات يقلُّ خلال العطل مثل يوم الأحد ويزداد في باقي أيام الأسبوع. وفي حال قمنا برسم المخطَّط الذي يمثل العلاقة بين عدد السيارات في اليوم والتاريخ على مدى شهر سيكون كمايلي:



الشكل (5) يمثل توزيع عدد السيارات على مدى شهر

2-9 تحضير البيانات

بداية تم القيام بدمج الملفات باستخدام بيئة ال knime ومن ثم تم تجهيز بيانات الدخل وإجراء بعض المعالجة عليها مثل تعديل أنماط البيانات وحذف الأسطر المكررة وحذف الأعمدة غير اللازمة للبحث.

3-9 تقييس البيانات Scale Data :

لبناء النموذج القادر على اكتشاف الشذوذ يتطلب أولاً القيام بعملية تقييس للبيانات باستخدام ال StandardScaler . تكمن الفكرة خلف StandardScaler في أنه سيقوم بتطبيق تحويل على البيانات بحيث يكون لتوزيعها قيمة متوسطة 0 وانحراف معياري قدره 1.

9-4 تطبيق شبكة ال LSTM Autoencoder

للتعامل مع الشذوذ والقدرة على كشفه ضمن البيانات المتسلسلة كان لا بد من إيجاد طريقة تأخذ الأحداث السابقة والامتداد عبر الزمن بعين الاعتبار عند التصنيف وهي شبكة ال LSTM، لذلك تم اللجوء لاستخدام أحد نماذج الشبكات العصبونية وهو نموذج LSTM Autoencoder.

وبما أن شبكة ال LSTM Autoencoder تعد من من خوارزميات التعلم بدون إشراف فهي قادرة على عنونة البيانات واكتشاف الشذوذ. تتطلب شبكات ال LSTM عملية إعادة تشكيل (Reshape) لبيانات الدخل على شكل $n_sample * timestamp * n_feature$.


بيانات الدخل مكونة من feature1 و timestamp، تم القيام بمعايرة وتجربة القيم من أجل عدة قيم لل timestamp. وهذه هي الطبقات التي تم بناء النموذج بها:

- 1 Layer (الطبقة الأولى) LSTM (128) تقرأ بيانات الدخل ونحصل كخرج على 128 feature.
- 2Layer (الطبقة الثانية) Dropout (rate=0.2) تقوم هذه الطبقة بتقليل ال over fitting.
- خرج هذه الطبقة هو شعاع الخصائص المرمز (يمثل بيانات الدخل بشكل مضبوط)
- 3 Layer (الطبقة الثالثة) RepeatVector() يمثل جسر وصل بين نموذجين ال encoder وال decoder حيث يكرر شعاع الخصائص.
- Layer 4 و Layer 5 هي صور لطبقات 2 layer 1 layer تقوم بعكس عملية ال encoding.

```
model = Sequential()  
model.add(LSTM(128, input_shape=(X_train.shape[1], X_train.shape[2])))  
model.add(Dropout(rate=0.2))  
model.add(RepeatVector(X_train.shape[1]))  
model.add(LSTM(128, return_sequences=True))  
model.add(Dropout(rate=0.2))  
model.add(TimeDistributed(Dense(X_train.shape[2])))  
model.compile(optimizer='adam', loss='mae')  
model.summary()
```

الشكل (6) يمثل الطبقات المستخدمة لبناء شبكة LSTM Autoencoder حيث تم استخدام Loss MAE (Mean Absolute Error) كتابع خطأ Function وهو أحد الدوال التي تستخدم لحساب معدل الخسارة loss و ذلك عن طريق إيجاد متوسط الفروقات بين القيم الحقيقية و المتوقعة باستخدام النموذج. ويكون استخدامه مفيداً في حالة قياس دقة النماذج المطبقة على البيانات التي تحتوي على قيم شاذة أو متطرفة. تم حساب ال Mean Absolute Error على بيانات التدريب ورسم تابع distribution loss واعتبار أكبر قيمة وصل لها الخطأ كعتبة حيث بلغت أعلى قيمة لها : 1.8

```
X_train_pred = model.predict(X_train, verbose=0)  
train_mae_loss = np.mean(np.abs(X_train_pred - X_train), axis=1)
```



الشكل (7) القيمة المطلقة لمتوسط الخطأ

5-9 معايرة لبعض البرامترات

تم بداية تجربة عدة قيم لل timestep وقياس نسبة المئوية للخطأ:

الجدول (2) قيمة الخطأ عند عدة قيم للخطوة

Timestep	Error(1-precision)
3	27%
6	41%
10	59%
30	36%

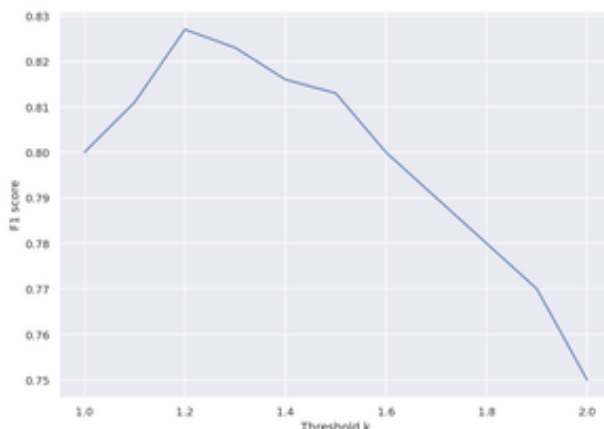
حيث نلاحظ أن أقل نسبة للخطأ عند قيمة ال timestep=3 وهو منطقي حيث أن اكتشاف الشذوذ سواء كحادث وازدحام مفاجئ وغيرها سيكون على حول مدى ساعة أو أكثر بقليل حيث نحتاج لتذكر ثلاث خطوات مسبقة عند تدريب شبكة ال lstm .

من ثم تم بناء نموذج وتدريبه على البيانات المعنونة وكانت دقة النتائج كما يلي:

الجدول (3) نتائج الشبكة

Accuracy	Recall	Precision	F1
0.952	0.931	0.73	0.82

تم بداية أخذ window threshold فوق وتحت قيمة المae التي حصلنا عليها ورسم مخطط يمثل تغير قيمة المقياس F1 score مع تغيير العتبة :



الشكل (8) يمثل تغير قيمة مقياس F1 score مع تغيير العتبة

الجدول التالي يعرض نتائج نموذج لتصنيف لاكتشاف لشذوذ ب timestep=3 من أجل بعض القيم للعتبة :

الجدول (4) نتائج lstm autoencoder


LSTM Autoencoder	العتبة	Recall	Precision	F1 score
	0.9	0.99	0.68	0.81
	1.2	0.97	0.71	0.82
	1.6	0.93	0.72	0.81
	2	0.88	0.74	0.80

حيث يظهر الجدول التالي(4) تزايد قيمة مقياس الاستذكار مع ازدياد العتبة وتناقص قيمة ال recall وكانت أفضل النتائج عند قيمة العتبة 1.2 بعد ذلك تم تجربة تطبيق تابع FFT (Fast Fourier Transformation) على البيانات قبل تدريبها حيث نلاحظ تحسن بمقياس F1 score فكانت النتائج كما يلي:

الجدول (5) نتائج lstm autoencoder بعد تطبيق تابع FFT

LSTM Autoencoder	العتبة	F1 score
	2.6	0.82
2.7	0.82	
2.8	0.83	
2.9	0.80	

المخطط يمثل تغير قيمة المقياس F1 score مع تغيير العتبة لمجال من القيم بعد تغير قيمة ال MAE عند تطبيق تابع FFT:




الشكل (9) يمثل تغير قيمة مقياس F1 score مع تغيير العتبة بعد استخدام
تابع FFT

وبإظهار وعرض عينة من نقاط الشدوذ التي تم التقاطها :

Local Date	Local Time	Day Type ID	Total Carriageway Flow	vehicles less than 5.2m	Flow vehicles 5.21m - 6.6m	Flow vehicles 6.61m - 11.6m	Flow vehicles above 11.6m	Speed Value	Quality Index	Network Link Id
2020-07-17	15:29:00	4	806.0	604.0	66.0	44.0	92.0	93.26	15	200008479
2020-07-17	15:44:00	4	810.0	605.0	69.0	53.0	83.0	90.83	15	200008479
2020-07-17	15:59:00	4	805.0	617.0	62.0	43.0	83.0	95.04	15	200008479
2020-07-17	16:14:00	4	899.0	710.0	60.0	49.0	80.0	92.50	15	200008479
2020-07-17	16:29:00	4	848.0	659.0	69.0	41.0	79.0	96.28	15	200008479

ويرسم مخطط يمثل تغير عدد السيارات مع الزمن خلال هذا النهار يتضح معنا الشدوذ الذي تمكنت الخوارزمية من التقاطه:



الشكل (10) يمثل تغير عدد السيارات مع الزمن في 2020-7-17


9-6 تطبيق خوارزمية STL(Seasonal Trend Based On Loess)

بداية تم تطبيق خوارزمية ال stl ب period=96 أي عدد التسجيلات اليومية حتى تعود وتكرر الاشارة نفسها. مقتطف من الكود البرمجي التالي يوضح ذلك:

```
from scipy import stats
import statsmodels.api as sm
from statsmodels.tsa.seasonal import STL
res = STL(df2,period=96).fit()
res.plot()
plt.show()
```


الشكل (11) تطبيق خوارزمية stl

حيث تم تقسيم السلسلة باستخدام التابع STL لثلاث مكونات وهي الظاهرة في الشكل التالي:



الشكل (12) تقسيم الإشارة إلى ثلاث أجزاء

ومن ثم اعتبار الإشارة الناتجة عن جمع إشارتي الموسمية والاتجاه كخط أساس. الشكل الآتي يبين الإشارة مع خط الأساس:



الشكل (13) الإشارة الأصلية مع خط الأساس

حيث تعطي الخوارزمية بالخرج عمود baseline وعمود score.، وجدول
الخرج هو التالي:

```
STL_df = tsa_using_stl(df2,2)
#Display sample results
STL_df.head()
```

	Local Date	Total Carriageway Flow	residual	trend	seasonal	weights	baseline	score
0	2019-01-01	213	-38	382	-130	1	252	-0.601135
1	2019-01-02	380	8	383	-12	1	371	0.134793
2	2019-01-03	396	12	384	0	1	383	0.198787
3	2019-01-04	408	-4	384	28	1	413	-0.057188
4	2019-01-05	307	-62	385	-15	1	369	-0.985098

الشكل (14) يمثل خرج خوارزمية ال STL

تم استخدام مقياس zscore وتحديد أكثر من عتبة للإشارة المتبقية وكما رأينا أن السلسلة تمتلك صفة الموسمية تم الاعتماد على القيمة الناتجة بالخرج مع قيمة ال score ومقارنتها مع العتبة لتصنيف النقاط التي score لها أكبر من العتبة كشدوذ.

لمعرفة أفضل قيمة للعتبة تم القيام بتجربة عدة قيم وتسجيل النتائج:

جدول (6) تجربة لبعض قيم العتبات

STL	قيمة العتبة	عدد نقاط الشذوذ
	1.9	13
	2	11
	2.1	7
	2.2	3

حيث أنها عند عتبة أقل من 1.9 غير قادرة على الأكتشاف وأكبر من 2.2 تتناقص عدد النقاط التي تقوم باكتشافها

10- نتائج البحث

استطاعت الشبكة الأولى في بنيتها المقترحة إيجاد أفضل دقة بالقدرة على اكتشاف الشذوذ عند العتبة $K=1.2$ حيث بلغ قيمة مقياس F1 Score = 83% ، ولم نتمكن من أخذ قيمة الدقة بعين الاعتبار كون البيانات غير متوازنة لذلك لن تعبر بشكل صحيح عن دقة النتائج.

أما بالنسبة لخوارزمية ال STL فكانت أفضل قيمة لها عند العتبة $K=1.9$ ونجد أن شبكة ال LSTM Autoencoder تمكنت من اكتشاف الشذوذ بشكل أفضل من خوارزمية STL .

11- مقارنة مع دراسات مشابهة

بالمقارنة مع مجموعة الدراسات التي تمت على بيانات تتعلق بالازدحام المروري نجد أن أغلب الدراسات كانت تلجأ لاستخدام طرائق التعلم الألي التقليدية مثل Logistic Regression-Random Forests ... وهناك

دراسات استخدمت بعض تقنيات التعلم الألي بشكل مشابه لما نحاول العمل عليه ولكن النتائج لم تحقق الهدف المرجو منها وهناك دراسة لجأت لاستخدام شبكات CNN Autoencoder. بينما قمنا في هذا البحث باستخدام أحد الخوارزميات الهجينة الناتجة عن دمج شبكة ال LSTM مع شبكة ال Autoencodes .

النتيجة التي تم الحصول عليها في هذا النموذج كمقياس $F1=0.83$ أفضل من النتائج الأبحاث المشابهة. تمت على بيانات غير معنونة ويمكن تطبيقها على بيانات متعددة المتغيرات.

12- الخاتمة:

نعلم أن العالم في وقتنا الحالي بحاجة للاستفادة من البيانات التي يتم جمعها بشكل يومي وتسخيرها لخدمة البشر في كافة المجالات وكما رأينا تم في هذه الدراسة محاولة اكتشاف الشذوذ ضمن مجموعة بيانات التي تتعلق بالازدحام المروري باستخدام خوارزمية STL وشبكات LSTM Autoencoder . قمنا بتطبيق إحدى الشبكات العصبية وهي LSTM Autoencoders وذلك نظراً لما أبرزته من قدرة على اكتشاف الشذوذ في العديد من الأبحاث على بيانات غير مصنفة وغير مهيكلة، وكذلك تطبيق خوارزمية STL والتي تعمل على تقسيم الإشارة الزمنية لمكوناتها الثلاث ومن ثم العمل على بواقي لإشارة. تمّ الاعتماد على مقاييس الأداء، كالاستذكار والدقة ومقياس $F1$ وبعد القيام بدراسة حول الخوارزميات المستخدمة والقيام بعدة تجارب ومعايرة البرامترات توصلنا إلى أن الدقة التي تم الحصول عليها باستخدام شبكة ال LSTM Auoencoder أفضل من خوارزمية ال STL. يمكن العمل مستقبلاً على تسخير استخدام هذا النموذج في أنظمة Recommendation systems لاختيار الطريق الأقل ازدحاماً أو استخدامه في أنظمة الملاحة الألية في السيارات الحديثة.

المراجع

- [1] <https://www.iea.org/commentaries/as-their-sales-continue-to-rise-suvs-global-co2-emissions-are-nearing-1-billion-tonnes>
- [2] Richard Weber .(2019).Time series. Available at : <http://www.statslab.cam.ac.uk/~rrw1/timeseries/t.pdf>
- [3] Halvor Reiten Thomas Kleiven.(2019).Unsupervised Anomaly Detection on Streaming Data in Petrolen Industry Using Deep Neural Networks
- [4] [Yepmo, V., Smits, G., & Pivert, O. \(2022\). Anomaly explanation: A review. Data & Knowledge Engineering, 137, 101946.](#)
- [5] Choi, K., Yi, J., Park, C., & Yoon, S. (2021). Deep learning for anomaly detection in time-series data: review, analysis, and guidelines. IEEE Access, 9, 120043-120065.
- [6] Chandola, V., Banerjee, A., & Kumar, V. (2009). Anomaly detection: A survey. ACM computing surveys (CSUR), 41(3), 1-58.
- [7] Iivari, A. (2022). Anomaly detection techniques for unsupervised machine learning.
- [8] Robert B. Cleveland. William S. Cleveland. Jean E. McRae. And Irma Terpenning. (2018)A Seasonal-Trend Decomposition Proceducer Based on Loess.
- [9] Mobtahej, P., Zhang, X., Hamidi, M., & Zhang, J. (2022). An LSTM-Autoencoder Architecture for Anomaly Detection Applied on Compressors Audio Data. Computational and Mathematical Methods, 2022.

[10] Wei, Y., Jang-Jaccard, J., Xu, W., Sabrina, F., Camtepe, S., & Boulic, M. (2023). Lstm-autoencoder based anomaly detection for indoor air quality time series data. IEEE Sensors Journal.

[11] dataset link <https://www.data.gov.uk/dataset/dc18f7d5-2669-490f-b2b5-77f27ec133ad/highways-agency-network-journey-time-and-traffic-flow-data>

[12] Wolpher, M. (2018). Anomaly Detection in Unstructured Time Series Data using an LSTM Autoencoder.

[13] He, D., Kim, J., Shi, H., & Ruan, B. (2023). Autonomous anomaly detection on traffic flow time series with reinforcement learning. Transportation Research Part C: Emerging Technologies, 150, 104089.

[14] He, D., Kim, J., Shi, H., & Ruan, B. (2023). Autonomous anomaly detection on traffic flow time series with reinforcement learning. Transportation Research Part C: Emerging Technologies, 150, 104089.

[15] He, Q., Harrison, C. W., & Huang, H. H. (2023). Detection of Anomalies in Traffic Flows with Large Amounts of Missing Data. Available at SSRN 4103393.

[16] Méndez, M., Ibias, A., & Núñez, M. (2022, December). Using deep learning to detect anomalies in traffic flow. In Intelligent Information and Database Systems: 14th Asian Conference, ACIIDS 2022, Ho Chi Minh City, Vietnam, November 28–30, 2022, Proceedings, Part I (pp. 299-312). Cham: Springer International Publishing.

[17] Alam, M. R., Gerostathopoulos, I., Amini, S., Prehofer, C., & Attanasi, A. (2019, June). Adaptable anomaly detection in traffic flow time series. In 2019 6th International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS) (pp. 1-9).

[18] <https://www.gov.uk/government/statistics/reported-road-casualties-in-great-britain-provisional-estimates-year-ending-june-2022/reported-road-casualties-in-great-britain-provisional-estimates-year-ending-june-2022>.

استخدام الشبكات العصبونية لتخفيض أبعاد الصور فائقة الطيف لأغراض تحسين السرعة والدقة

طالبة الدراسات العليا: ليلي يحيى مريم كلية الهمة ، جامعة البعث

اشراف: د.م.نبيل دحدوح + د.م.عيد العبود

ملخص البحث:

يزداد استخدام البيانات متعددة الأبعاد في جميع المجالات بسبب دقة المعلومات التي تقدمها والتي تستخدم عادة في قرارات مهمة سواء في المجالات الطبية أو الزراعية أو اللغات أو الآثار، حيث يتميز هذا النوع من البيانات بوجود العديد من الميزات (الأبعاد) لكل عنصر، وفي بحثنا نعمل على الصور فائقة الطيف حيث تمثل بكسلاتها العناصر، أما الميزات فهي البيانات الملتقطة ضمن نطاقات أطوال موجية متعددة عبر الطيف الكهرومغناطيسي (أي لكل بكسل العديد من الميزات).
لكننا عادة ما نعاني خلال تحليل هذه الصور وتصنيفها نتيجة المشاكل التي نواجهها في عملية تخفيض الأبعاد التي تسبق كلتا العمليتين، ومن أهم المشاكل التي نحاول حلها في مرحلة تخفيض الأبعاد تتمثل بالدقة والسرعة والتعقيد واختلاف طبيعة البيانات.
في هذه الورقة تم بناء شبكة عصبونية تعمل على تخفيض الأبعاد حيث تم تطبيقها على مجموعتين من البيانات وقد أثبتت جدارتها في حل المشاكل التي تواجهها خوارزمية تخفيض الأبعاد التقليدية (Principal Component Analysis (PCA).
كما تم مقارنتها مع كافة الخوارزميات المشتقة من PCA مثل (Sparse PCA , Segmented PCA , Kernel PCA)، وذلك لضمان جودة النتائج ومدى مصداقيتها، وهذا تجلي من خلال عملية التصنيف بصورة واضحة .

الكلمات المفتاحية: تصوير فائق الطيف، تخفيض الأبعاد، PCA، شبكة عصبونية،
Sparse PCA، Segmented PCA، Kernel PCA، SVM، التصنيف، KNN.

Using neural networks to reduce hyperspectral images dimensions for the purposes of improving speed and accuracy

Presenting:Eng.Laila Yehia Maream

Supervisor:PHD. Nabil Dahdouh PHD.Ied Alabboud

Abstract:

The use of multidimensional data is increasing in all fields due to the accuracy of the information it provides, which is usually used in important decisions, whether in the medical, agricultural, linguistic or archaeological fields, as this type of data is characterized by the presence of many features (dimensions) for each element, and in our research we are working on Hyperspectral images where pixels represent items, and features are data captured in multiple wavelength ranges across the electromagnetic spectrum (i.e. each pixel has many features).

However, we usually suffer during the analysis and classification of these images as a result of the problems that we face in the process of reducing the dimensions that precede both processes, and among the most important problems that we are trying to solve in the stage of reducing the dimensions are the accuracy, speed, complexity and the different nature of the data.

In this paper, we worked on building a neural network that works on dimensionality reduction, as it was applied to two sets of data, and it proved its worth in solving the problems faced by the traditional Principal Component Analysis (PCA) algorithm.

It was also compared with all algorithms derived from PCA such as (Sparse PCA, Kernel PCA, Segmented PCA) in order to ensure the quality and credibility of the results, and this was clearly demonstrated through the classification process.

key words: Hyperspectral Imaging, Dimensional Reduction, PCA, Neural Network, Sparse PCA ,Segmented PCA, Kernel PCA, SVM, Classification, KNN

1-المقدمة:

يعد التصوير الفائق الطيفي (HSI) hyperspectral imaging تقنية مستخدمة للحصول على البيانات الطيفية لكل بكسل في الصورة، بهدف العثور على الأشياء أو تحديد المواد اعتمادا على الخصائص الفريدة (الانعكاس-الامتصاص) لكل مادة من المواد المصورة. يتم ذلك من خلال استخدام مستشعرات فوق طيفية تعمل على جمع المعلومات كمجموعة من «الصور»، تمثل كل صورة نطاقاً موجياً ضيقاً للطيف الكهرومغناطيسي، تُجمع هذه «الصور» لتشكّل مكعب بيانات فوق طيفي ثلاثي الأبعاد (x,y,λ) للمعالجة والتحليل، حيث يمثل x و y بُعدين مكانيين للمشاهد، وتمثل λ البعد الطيفي (الذي يضم مجموعة من الأطوال الموجية)، حيث تعتمد نطاقات الطول الموجي المقاسة فيه على نوع كاميرا HSI أو المستشعر المستخدم [1].

من العيوب الأساسية ل HSI هي التكلفة والتعقيد حيث أن سعة تخزين البيانات المطلوبة تكون كبيرة، وهي ضرورية لأن المكعبات الفائقة الطيفية تتكون من مجموعات بيانات كبيرة ومتعددة الأبعاد، ومن المحتمل أن تتجاوز مئات الميجابايت. كل هذه العوامل تزيد بشكل كبير من تكلفة الحصول على البيانات الفائقة الطيفية ومعالجتها. من هنا جاءت الحاجة للبحث عن تقنية نستطيع من خلالها الحصول على المعلومات الأكثر أهمية من البيانات للتعامل معها وفهمها بالشكل الصحيح وهذا ما يسمى بعملية تخفيض الأبعاد [2].

وقد برز في هذا المجال تقنية (PCA) Principal Component Analysis التي تعد من أشهر طرق تخفيض الأبعاد حيث تعتمد على المبادئ الرياضية لتصغير وضغط البيانات بهدف الاحتفاظ بالمركبات الأساسية للصورة والتخلص من البيانات غير المهمة دون تأثير سلبي على محتويات الصورة [3]، إلا أنه كنتيجة للمساوئ التي ظهرت في هذه الخوارزمية، والتي تمثلت في صعوبة تفسير المركبات الأساسية الناتجة عنها والزيادة الأسية في التكلفة الحسابية ووقت المعالجة إضافة إلى عدم التأكد من تمثيل المركبات

الأساسية للمعلومات المهمة لمجرد احتوائها على أكبر قدر من التباين، فقد ظهرت العديد من الدراسات التي حاولت حل هذه المشاكل من خلال إضافة التعديلات على خوارزمية PCA أو من خلال إضافة خطوات تسبق PCA للتحسين من أدائها، ففي [4] تم تنفيذ خوارزمية تحليل المكونات الرئيسية (PCA) في أجهزة قابلة لإعادة التشكيل (FPGA) والتي حققت تفوق في الأداء والوقت الفعلي للعملية مقارنة بالطرق التقليدية وذلك لصغر حجمها ووزنها وقوتها الحاسوبية العالية إضافة إلى استهلاكها للطاقة عند مقارنتها بأنظمة الحوسبة الأخرى عالية الأداء وبالتالي أثبتت فعاليتها للتطبيقات التي تتطلب استجابة في الوقت الحقيقي. كما عملت بعض الدراسات على تحسين أداء PCA من خلال المعالجة المسبقة للصورة بتطبيق تحويل فورييه السريع (FFT) وقد أدت هذه الطريقة إلى تحسين دقة PCA وتحسين دقة التصنيف [5].

من خلال الدراسات المرجعية توصلنا إلى استنتاج هام مفاده أن اغلب الدراسات عملت على تحسين نقطة ضعف واحدة في PCA أما الدقة أو الوقت أو جعلها مناسبة لطبيعة بيانات محددة، لذلك فقد حاولنا في هذه الورقة إيجاد طريقة لتخفيض الأبعاد مع الأخذ بعين الاعتبار أغلب نقاط الضعف التي ظهرت في PCA وذلك من خلال بناء شبكات عصبونية تقوم بتخفيض الأبعاد وقد أثبتت هذه الطريقة فعاليتها مقارنة مع الطرق السابقة.

2-هدف البحث:

يهدف هذا البحث إلى بناء شبكات عصبونية تهدف لتخفيض الأبعاد المكعب الطيفي، من خلال تمتعها بالمقدرة على تحديد المركبات الأساسية للصور الفائقة الطيف من حيث الدقة، والسرعة والتكلفة، والتعامل مع كافة أنواع البيانات، وذلك لضمان نتائج علمية صحيحة عند استخدام النتائج في تحليل البيانات أو تصنيفها.

3- أهمية البحث:

نظرا إلى أن الأبحاث المتعلقة بمعالجة HSI تتطلب التعامل مع بيانات بحجم هائل، وربطاً مع محدودية الإمكانيات (معالجات، ذواكر، برمجيات..الخ) المتاحة مقارنة مع هذا البيانات، كان لابد من البحث عن طريقة جديدة قادرة على تمييز وتقديم المعلومات الأكثر أهمية في HSI أخذة بعين الاعتبار جميع المشاكل التي تعاني منها طرق تخفيض الأبعاد السابقة.

من هنا تأتي أهمية البحث في بناء شبكة عصبونية قادرة على التعامل مع البيانات وإعطاء نتائج دقيقة خلال فترة زمنية جيدة ومناسبة لطبيعة البيانات مما يضمن لنا الحصول على نتائج موثوقة وواضحة لنتمكن من التعامل معها واستخدامها في عمليات معالجة لاحقة.

4- موارد وطرق البحث:

يتطرق البحث لدراسة PCA التقليدية والتعريف بمفاهيمها، ثم التعرف على أهم الطرق المشتقة منها وتحديد التعديلات التي تمت على PCA في كل طريقة، كما يقدم البحث دراسة الشبكات العصبونية وبناء النموذج المتعلق بالدراسة، ومن تم تطبيق جميع ما سبق على مجموعتين من البيانات (Fake & Real، Indian Pines) انتهاء بتصنيف هذه الصور بالاعتماد على Jupyter Notebook [6] وهو تطبيق ويب مفتوح المصدر تسمح واجهته المرنة للمستخدمين بتكوين ومشاركة المستندات حيث يمكننا تشغيل التعليمات البرمجية وعرض المخرجات وأيضاً إضافة تفسيرات وصيغ ومخططات وبالتالي جعل العمل أكثر شفافية وقابلية للفهم إضافة إلى إمكانية استخدام العديد من لغات البرمجة، مما سمح لنا استخدام لغة البايثون Python للنمذجة والحصول على النتائج، وقد تم استخدام حاسوب ذو معالج core i5 من الجيل الثامن ورامات 16G.

5- تحليل المركبات الأساسية (PCA) Principal Component Analysis:

إن تحليل المكون الرئيسي (PCA) هو إجراء إحصائي يستخدم لتخفيض الأبعاد حيث يستخدم تحويلًا متعامدًا لتحويل مجموعة من المتغيرات المرتبطة إلى مجموعة من قيم المتغيرات غير المرتبطة خطيًا تسمى المكونات الأساسية [7]. حيث يحتوي المكون الرئيسي الأول على أكبر نسبة تباين بين المعلومات أما المكون الرئيسي الثاني فيحتوي نسبة تباين أقل وهكذا أما المكون الرئيسي الأخير فيحتوي على ضئيل لأنها ذات التباين الأقل ويتم القيام بذلك بهدف ضغط البيانات مع ضمان الحفاظ على المعلومات المهمة [8]، وتتعتمد PCA على الخطوات التالية:

الخطوة الأولى- Standardize the Dataset (توحيد البيانات): الهدف من هذه الخطوة هو توحيد نطاق المتغيرات الأولية بحيث يساهم كل واحد منها بالتساوي في التحليل. وتعتبر هذه من الخطوات الهامة لأن PCA حساس للغاية فيما يتعلق بتباين المتغيرات الأولية، بالتالي إذا كانت هناك اختلافات كبيرة بين نطاقات المتغيرات الأولية، فإن تلك المتغيرات ذات النطاقات الأكبر ستسيطر على تلك التي لديها نطاقات صغيرة (على سبيل المثال، متغير يتراوح بين 0 و100 سوف يسيطر على متغير يتراوح بين 0 و1)، مما سيؤدي إلى نتائج متحيزة.

رياضياً، يمكن القيام بذلك عن طريق طرح المتوسط والقسمة على الانحراف المعياري لكل قيمة لكل متغير

$$Z = \frac{\text{Value} - \text{mean}}{\text{standard deviation}} \quad (1)$$

الخطوة الثانية- حساب مصفوفة التباين: الهدف من هذه الخطوة هو معرفة ما إذا كانت هناك أي علاقة بين المتغيرات (الميزات). لأنه في بعض الأحيان، ترتبط المتغيرات

ارتباطاً وثيقاً بطريقة تحتوي على معلومات زائدة عن الحاجة. لذلك، من أجل تحديد هذه الارتباطات، نحسب مصفوفة التغاير لثلاث متغيرات X, Y, Z وفق الشكل:

$$\begin{bmatrix} \text{COV}(X, X) & \text{COV}(X, Y) & \text{COV}(X, Z) \\ \text{COV}(Y, X) & \text{COV}(Y, Y) & \text{COV}(Y, Z) \\ \text{COV}(Z, X) & \text{COV}(Z, Y) & \text{COV}(Z, Z) \end{bmatrix} \quad (.2)$$

الخطوة الثالثة - حساب المتجهات الذاتية والقيم الذاتية: والهدف من هذه الخطوة الحصول على إحداثيات متعامدة جديدة تحدد لنا الاتجاه الذي تتغير وفقه البيانات. حيث أن المتجهات الذاتية لمصفوفة التغاير هي في الواقع اتجاهات المحاور حيث يوجد معظم التباين (معظم المعلومات) والتي نسميها المكونات الرئيسية. والقيم الذاتية هي ببساطة المعاملات المرتبطة بالمتجهات الذاتية، والتي تعطي مقدار التباين الذي يحمله كل مكون رئيسي. من خلال ترتيب متجهات $eigenvectors$ الخاصة بك بترتيب قيمها الذاتية، من الأعلى إلى الأدنى، تحصل على المكونات الرئيسية بترتيب الأهمية.

الخطوة الرابعة - FEATURE VECTOR (متجه الميزة):

بعد حساب المتجهات الذاتية وترتيبها حسب قيمها الذاتية بترتيب تنازلي، يسمح لنا بإيجاد المكونات الرئيسية بترتيب الأهمية. في هذه الخطوة، يتم اتخاذ القرار فيما إذا كنا سنحتفظ بكل هذه المكونات أو نتجاهل العناصر الأقل أهمية (ذات القيم الذاتية المنخفضة)، ونشكل مع باقي العناصر مصفوفة من المتجهات التي نسميها متجه الميزة.

ومتجه الميزة: هو ببساطة مصفوفة تحتوي كأعمدة على المتجهات الذاتية للمكونات التي قررنا الاحتفاظ بها. هذا يجعلها الخطوة الأولى نحو تخفيض الأبعاد.

الخطوة الخامسة - إعادة صياغة البيانات على طول محاور المكونات الأساسية: في هذه الخطوة، وهي الخطوة الأخيرة، يتمثل الهدف في استخدام متجه الميزات المتكون باستخدام المتجهات الذاتية لمصفوفة التغاير، لإعادة توجيه البيانات من المحاور

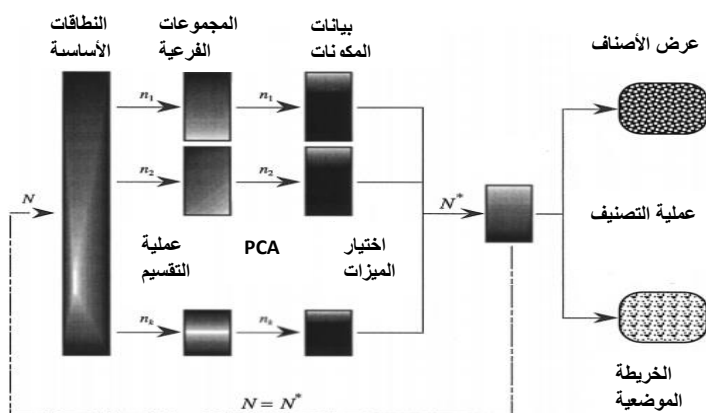
الأصلية إلى المحاور التي تمثلها المكونات الرئيسية (ومن هنا جاء اسم تحليل المكونات الرئيسية). ويتم ذلك من خلال المعادلة [7][9]:

$$\text{FinalDataSet} = \text{FeatureVector}^T * \text{StandardizedOriginalDataSet}^T \quad (3)$$

6- مقارنة PCA مع أهم الخوارزميات المشتقة منها:

6-1: تحليل المكون الرئيسي المقسم (Segmented principal component Analysis)

في هذه الطريقة يتم أولاً تقسيم مجموعة البيانات الكاملة إلى مجموعات فرعية، حيث يتم تحديد النطاقات شديدة الارتباط كمجموعات فرعية (النطاقات شديدة الارتباط عادة ما تكون النطاقات المتتالية القريبة من بعضها أما النطاقات البعيدة عن بعضها فتعتبر أقل ارتباطاً). بعد ذلك يتم إجراء (PCT principal component transform) بشكل منفصل على كل مجموعة فرعية من البيانات، ثم يتم تجميع المكونات الرئيسية حيث يتم اختيار المكونات التي تحقق أعلى نسبة تباين (تحتوي على أكبر قدر من المعلومات)، بشكل عام، يمكن تكرار الخطوات حتى يتم تحقيق نسبة تخفيض البيانات المطلوبة لأغراض التصنيف أو التخزين، بينما يتم الاحتفاظ بالمعلومات المهمة بشكل أساسي. ويوضح الشكل (1) عملية تحليل المكون الرئيسي المقسم متعددة المراحل بشكل تخطيطي [10].




الشكل (1) - مخطط لطريقة عمل Segmented PCA

نلاحظ من الشكل تقسيم النطاقات الأساسية (الميزات الأساسية) إلى عدة مجموعات فرعية، ثم نطبق PCA على كل مجموعة على حدة، ونحصل على المكونات الأساسية لكل مجموعة، ثم يتم اختيار المكونات الأساسية من كل مجموعة اعتماداً على التباين الأعلى، بعدها يتم جمع المكونات الأساسية المختارة من المجموعات، بعد ذلك يكون لدينا خيارين إذا أردنا ضغط البيانات بشكل أكبر نقوم بجعل بيانات المكونات الأساسية كدخل أي ($N=N^*$) ونعيد الخطوات السابقة، وفي حال كانت البيانات مضغوطة بشكل كافٍ ننتقل لمرحلة التصنيف حيث تكون نتيجتها الأصناف و الخريطة الموضوعية التي تحدد توزع هذه الأصناف ضمن الصورة المصنفة.

: Kernel PCA:2-6

Kernel PCA هو امتداد لـ PCA يسمح بفصل البيانات غير الخطية عن طريق عرض البيانات غير القابلة للفصل خطياً على مساحة ذات أبعاد أعلى لكن نتيجة التعقيد الحسابي الكبير تم استخدام خدعة النواة، و هي الطريقة التي تستخدم تابعاً يسمح لنا بالعمل في مساحة الميزة الأصلية دون حساب إحداثيات البيانات في مساحة ذات أبعاد أعلى لنحصل نتيجة تطبيق هذا التابع على مصفوفة النواة التي تلعب نفس دور مصفوفة التغاير في PCA الخطي، وبمجرد أن نحصل على هذه المصفوفة، نتبع نفس الإجراء المتبع في PCA التقليدي، لذلك يمكننا حساب قيمها الذاتية والمتجهات الذاتية. هناك بالطبع خيارات مختلفة لهذا التابع ولكن الشائعة منها هي نواة متعددة الحدود (polynomial kernel) أو نواة غاوس (Gaussian kernel). وعادة ما يتم اختيار النواة اعتماداً على التجريب وهذا الأمر يعد من نقاط ضعف هذه الطريقة. [11][12]

ويوضح الشكل (2) بيانات تم تمثيلها في بعدين ولا يمكن فصلها بشكل خطي وتم نقلها إلى بعد أعلى (البعد الثالث) لتصبح قابلة للفصل بشكل خطي



الشكل (2) -نقل البيانات إلى بعد أعلى

6-3 Sparse PCA (تحليل المكونات الرئيسية المتناثر):

تعاني PCA من حقيقة أن كل مكون رئيسي هو مزيج خطي من جميع المتغيرات الأصلية، وبالتالي يصعب تفسير النتائج غالبًا (وجود العديد من العناصر غير الصفرية). لمعالجة هذه المشكلة في PCA التقليدي، يفرض Sparse PCA قيودًا إضافية على عدد العناصر غير الصفرية (الحمولات غير الصفرية) [13].

ولتوضيح مفهوم الحمولات (الأوزان)، نأخذ مصفوفة البيانات X ذات الأبعاد $(m \times p)$ ، حيث أن m هي عدد العينات و p هي عدد الميزات (المتغيرات) وعندها يمكن كتابة المكون الرئيسي الأول الذي يمثل مزيج خطية من المكونات الأساسية X_1, X_2, X_3, \dots بالشكل:

$$PC_1 = W_{11}X_1 + W_{12}X_2 + \dots + W_{1p}X_p \quad (4)$$

حيث تعتبر عناصر الشعاع الذاتي w_{1j} الأحمال (loadings) وبعبارة أخرى الأحمال هي معاملات التركيبة الخطية للمتغيرات الأصلية التي يتم من خلالها إنشاء المكونات الرئيسية (Principal Components) [14].

وقد تم اتباع عدة طرق للقيام بالتناثر منها العتبة والدوران (rotation) تعمل هذه الطريقة على تحسين إمكانية تفسير PCA عن طريق قصر thresholding and


الاهتمام على المتغيرات ذات الأحمال الكبيرة وتصفية المتغيرات ذات الأحمال الصغيرة. هذه الطريقة مفيدة إذا كان الفرق بين عمليات تحميل المتغيرات المختلفة واضحاً، ولكنه أقل فائدة عندما لا يكون هناك فرق واضح بين عمليات التحميل.

لذلك تم الاعتماد على طريقة (Sparse PCA LASSO) والتي تعتمد على كل من l_0 و l_1 norm واختيار الميزات التي يجب أن تكون أوزانها (0) إضافة إلى تحديد عدد القيم الصفرية [15]. وهي الطريقة المستخدمة في هذا البحث.

7- الشبكات العصبونية:

الشبكات العصبية الاصطناعية التي تسمى أيضاً الشبكات العصبية هي شكل من أشكال خوارزميات التعلم الآلي مع هيكل يعتمد على الدماغ البشري. مثل الأنواع الأخرى من خوارزميات التعلم الآلي، يمكنهم حل المشكلات من خلال التجربة والخطأ دون أن تتم برمجتهم صراحة بقواعد يجب اتباعها.


في الشبكات العصبية، يتعلم الكمبيوتر أداء مهمة من خلال تحليل بيانات التدريب، ويتم تصنيف البيانات التي سيتم تدريبها مسبقاً بالخرج المتوقع قبل تغذيتها في النموذج. نظراً لأن الشبكة العصبية مبنية على الدماغ البشري، فإنها تحتوي على آلاف العقد المترابطة بواسطة عوامل مهمة تسمى الأوزان. تتكون الشبكة العصبية النموذجية عادةً من طبقة إدخال وطبقات مخفية عديدة وطبقة إخراج. تتكون طبقة الإدخال من بيانات التدريب التي تتعلم منها الخوارزمية، والتي يتم تمريرها بدورها إلى الطبقة المخفية التي تحتوي على عقد مترابطة مع الأوزان، وفي هذه الطبقة تقوم خوارزمية لدينا بضبط الأوزان حتى يصبح هامش الخطأ ضئيلاً، في طبقة الإخراج تقوم بالتصنيفات التي تحددها الخوارزمية المتبعة. يوضح الشكل (3) شكل مبسط للشبكة العصبونية [16].



الشكل (3) - نموذج مبسط للشبكة العصبونية

وفيما يتعلق بالشبكات العصبونية يجب أن نميز بين نوعين من أنواع التعلم:

- (1) التعلم الخاضع للإشراف (supervised Learning): وفيها تقسم البيانات إلى بيانات للتدريب وأخرى للاختبار. نبدأ بتدريب الشبكة حيث نكون على علم بمتغير الإدخال x ومتغير الإخراج المقابل المرغوب y . ندخل x إلى الشبكة العصبونية فتولد الشبكة العصبونية مخرجات بناءً على المدخلات. ثم تتم مقارنة هذا الخرج مع الخرج المطلوب الذي حصل عليه وفي نفس الوقت يتم إنتاج إشارة خطأ. يتم بعد ذلك ضبط الأوزان للشبكة خطوة بخطوة بحيث يكون الخطأ في حده الأدنى. يتوقف التعلم عندما تصل الخوارزمية إلى مستوى مقبول من الأداء. وبهذا نكون قد انتهينا من مرحلة تدريب الشبكة لنبدأ باختبارها. يوضح الشكل (4) آلية عمل الشبكة العصبونية وفق التعلم الخاضع للإشراف.



الشكل (4) - آلية عمل الشبكات العصبونية وفق التعلم الخاضع للإشراف

في هذا الشكل لدينا P الدخل الذي يتم ضربه بالأوزان الأولية W ثم يتم جمعه مع الانحياز b باستخدام الجامع \sum لتكون النتيجة $Z=PW+b$ ، بعد ذلك لدينا تابع النقل F الذي ينتج عنه الخرج وفق $F(Z)=y$ ويتم اختيار تابع النقل حسب طبيعة التطبيق ثم يتم حساب قيمة الخطأ من خلال المقارنة بين القيمة المطلوبة t والخرج y وعليه تقوم قواعد التعلم بتعديل الانحياز والأوزان وتكرر نفس الخطوات حتى الحصول على قيمة خطأ مقبول.

(2) التعلم غير الخاضع للإشراف (Unsupervised Learning): يحتوي التعلم الآلي غير الخاضع للإشراف على بيانات إدخال X ، ولا توجد لها متغيرات خرج مقابلة معروفة. أي على عكس التعلم الخاضع للإشراف، لا يتم تقديم أي تدريب للآلة لذلك تتعامل الشبكة مع المعلومات غير المصنفة وفقاً لأوجه التشابه والأنماط والاختلاف دون توجيهه [16].

اعتمدنا في هذه الورقة البحثية على التعلم الخاضع للإشراف لأنه أكثر دقة وأكثر ملائمة لطبيعة التطبيق المستخدم.

8- خوارزميات التصنيف المستخدمة:


تم في هذا البحث استخدام نوعين من خوارزميات التصنيف، حيث طبق كل منها على $data$ مختلفة، وذلك بسبب اختلاف طبيعة البيانات، فطبقنا على قاعدة بيانات (Indian Pines) خوارزمية SVM لأن قاعدة البيانات الأولى فيها عمود واحد كقيم مرجعية يحدد جميع الأصناف (16 صنف)، أما في بيانات (Fake & Real) فقد تم اعتماد خوارزمية KNN وذلك لأن القيم المرجعية لقاعدة البيانات هي قيم RGB أي ثلاث قيم مرجعية ولا يمكن ل SVM التعامل مع هذه الحالة.

8-1: **Support Vector Machines (SVM)**: هي خوارزمية تعلم خاضعة للإشراف تقوم بفرز البيانات إلى فئتين. يتم تدريبها بسلسلة من البيانات المصنفة بالفعل إلى فئتين بعد ذلك يمكنها تحديد الفئة التي تنتمي إليها بيانات جديدة. وتتم عملية الفصل

من خلال إيجاد مستوي فائق (hyperplane) الذي يعتبر حدود القرار هذا يعني أن أي شيء يقع على جانب واحد منه سنعنّفه على أنه فئة، وأي شيء يقع على الجانب الآخر هو فئة أخرى.

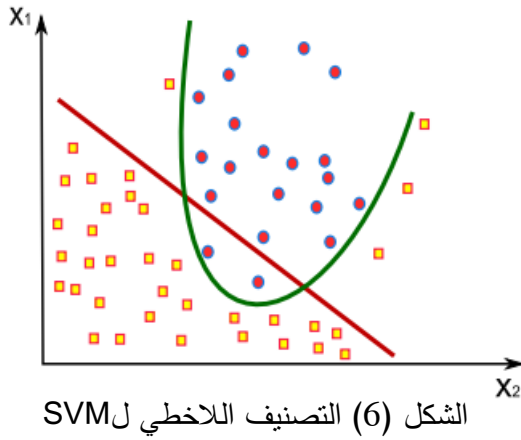
لفهم أساسيات SVM نفترض أن لدينا مجموعتين: المربعات والدوائر وهنا نريد مصنّفًا مع العلم أن المستوي الفائق هو مجرد خط في بعدين وهناك عدة احتمالات له ولكن يعتبر أفضل خيار هو الذي تكون المسافة التي تفصله عن أقرب عنصر من كل مجموعة أكبر ما يمكن. لذلك نفترض أن المستوي الفائق ذو اللون الأصفر هو الخيار الأفضل ضمن الخيارات المتاحة في

الشكل (5) الذي يوضّح عملية التصنيف الخطي واختيار أفضل مستوى فائق.



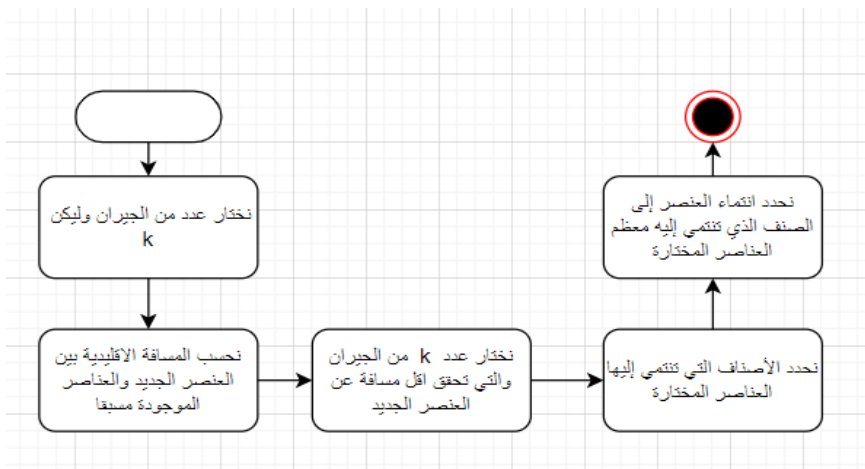
الشكل (5) -التصنيف الخطي ل SVM

نلاحظ أن البيانات في هذا المثال كانت قابلة للفصل خطيًا - يمكننا رسم خط مستقيم للفصل بين المربعات والدوائر. لكن عادة ما تكون الأمور ليست بهذه البساطة. كما هو موضح في الشكل (6) لدينا بعض البيانات غير القابلة للفصل بشكل خطي وهنا يمكننا نقل البيانات إلى بعد أعلى من خلال تابع النواة ثم جعلها قابلة للفصل خطيًا واختيار المستوي الفائق المناسب [17].

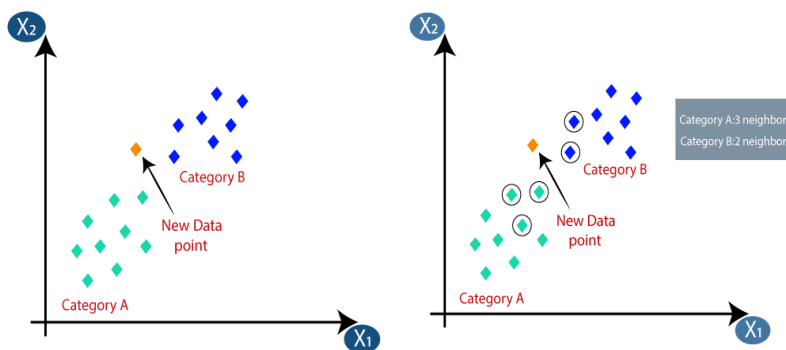


8-2: **K-Nearest Neighbors (KNN)** هي خوارزمية تعلم آلي خاضعة للإشراف تعمل على فصل نقاط البيانات إلى مجموعات، لكن هذه الخوارزمية لا يتم تدريبها وإنما يُقدم لها مجموعة تدريب وهي بيانات تشمل الدخل والخرج الهدف وعندما يُطلب منها تنبؤات لتصنيف بيانات جديدة تُستخدم جميع بيانات التدريب وذلك من أجل حساب المسافة بين العنصر المراد التنبؤ بصنفه و مجموعة التدريب حيث تفترض أن نقاط البيانات الموجودة على مقربة من بعضها البعض متشابهة للغاية، بينما إذا كانت نقطة البيانات بعيدة، فإنها تختلف عن نقاط البيانات هذه. هناك طرق متعددة لحساب المسافة بين النقاط، ولكن مقياس المسافة الأكثر شيوعاً هو المسافة الإقليدية (المسافة بين نقطتين في خط مستقيم). يوضح الشكل (7) الخطوات التي تعمل وفقها KNN:

مع العلم أن قيمة K يتم تحديدها بالتجريب. وللتوضيح كما في الشكل (8) لدينا نقطة جديدة نريد تصنيفها مع اختيار $K=5$ ومن خلال حساب المسافة الإقليدية، حصلنا على أقرب جيران، حيث أن ثلاثة أقرب جيران في الفئة A واثنان من الجيران الأقرب في الفئة B هذا يعني أن نقطة البيانات الجديدة تنتمي إلى الفئة A [18] [19].



الشكل (7) - خطوات عمل KNN



الشكل (8) - آلية التصنيف في KNN

9- الدراسة العملية:

تتلخص الدراسة العملية بتطبيق خوارزميات تقليل الأبعاد المذكورة سابقا والشبكات العصبونية على مجموعتين من البيانات للحصول على المكونات الأساسية وتحديد الزمن التي تحتاجه للقيام بهذا العمل لتحديد سرعة الأداء لكل منها.

بعد ذلك تم استخدام المكونات الأساسية الناتجة عن كل خوارزمية للقيام بعملية التصنيف للتأكد من مدى تمثيل المكونات الأساسية للبيانات الأصلية أي تحديد دقة عمل خوارزميات تقليل الأبعاد إضافة إلى تحديد سرعة المصنف لتحديد أثر تخفيض الأبعاد على سرعة العمليات التي تليها.

9-1 : شرح موديل الشبكة العصبونية المقترح:

موديل مجموعة البيانات الأولى

تتكون هذه الشبكة من طبقة إدخال تحتوي على 200 خلية عصبية (يكون مساوٍ لعدد الميزات) وتحتوي الطبقة المخفية على 40 خلية عصبية (تمثل المكونات الأساسية المراد الحصول عليها)، وتحتوي طبقة الإخراج على 200 خلية عصبية تمثل البيانات المعاد بناؤها من المكونات الأساسية.

تعتمد الشبكة المستخدمة على التعلم الخاضع للإشراف حيث يتم تدريب الشبكة باستخدام 90% من البيانات وتم الاختبار باستخدام 10%. تتلخص عملية تقليل الأبعاد من خلال تعديل الأوزان خلال فترة التدريب للحصول على الخرج الهدف، وهنا لا بد أن ندرك أن نتيجة عملية تخفيض الأبعاد المراد إدخالها إلى المصنف هي خرج الطبقة المخفية من الشبكة العصبونية لأن خرج هذه الطبقة هي المكونات الأساسية كما ذكرنا سابقاً.

عند بنائنا للشبكة العصبونية تم تحديد بعض البارامترات الأساسية في تدريب هذه الشبكة وهي:

(1) تابع النقل: حيث تم اعتماد تابع النقل (The rectified linear activation

ReLU function) هي دالة خطية متعددة التعريفات ستخرج المدخلات مباشرة

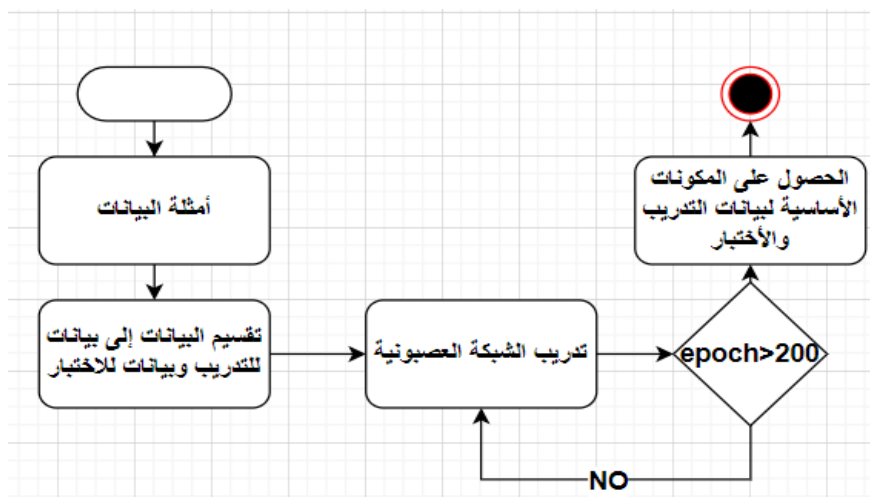
إذا كانت موجبة، وإلا فإنها ستخرج صفراً.

(2) حجم الدفعة (Batch size): وهو عدد العينات المعالجة قبل تحديث الأوزان

والانحياز وفي نموذجنا حددناه بالرقم 16.

3) عدد مرات تكرار التدريب (epoch): وهو عدد مرات تكرار تدريب الشبكة على بيانات التدريب كاملة وحددناه بالرقم 200 حيث يتم تحديد هذا البارامتر من خلال التجريب بحيث تزداد دقة النتائج دون الوصول إلى حالة overfitting (حالة إعطاء دقة سيئة بسبب التدريب بشكل كبير ومبالغ فيه).

مع العلم أن جميع هذه البارامترات يتم تحديدها من خلال التجريب. ولتوضيح خطوات تخفيض الأبعاد لمجموعة البيانات الأولى باستخدام هذا الموديل مثلنا الخطوات في الشكل (9).



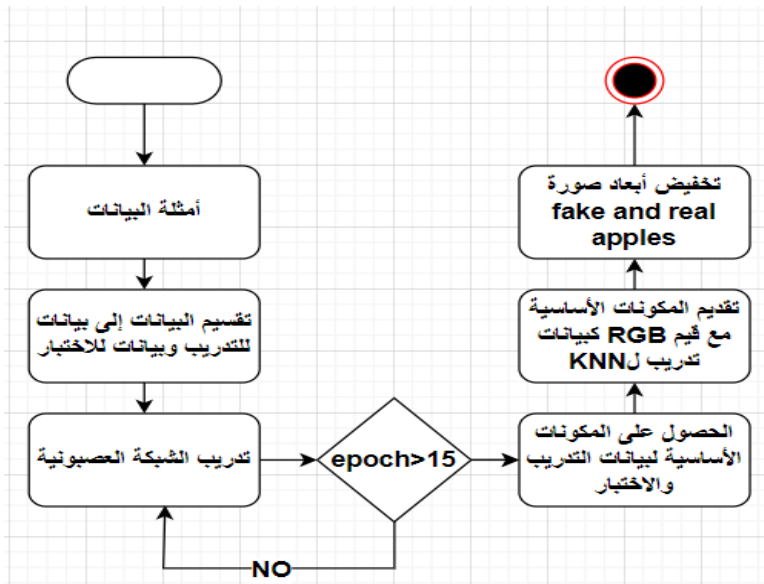
الشكل (9) -آلية عمل الشبكات العصبونية على مجموعة

نلاحظ من الشكل أننا في البداية نقوم بأمثلة البيانات من خلال جعل متوسط كل عمود مساو للصفر وذلك بهدف توحيد نطاق المتغيرات الأولية ثم نقوم بتقسيم البيانات إلى بيانات للتدريب وبيانات للاختبار، بعد ذلك نقوم باستخدام بيانات التدريب لتدريب شبكتنا مع الأخذ بعين الاعتبار البارامترات السابقة وهنا لا بد من تكرار عملية التدريب 200 مرة وإلا سنعود لخطوة التدريب وعند انتهاء 200 مرة تدريب يمكننا تخفيض الأبعاد للبيانات المدربة ثم ادخال بيانات الاختبار وتقليل أبعادها أيضا.

موديل مجموعة البيانات الثانية

لم تتجح الشبكة العصبية التي استخدمناها مع البيانات الأولى حيث فقدنا قدرًا كبيرًا من المعلومات، لذلك عملنا على جعل التباين أكثر وضوحًا من خلال نقل البيانات إلى أبعاد أعلى (زيادة عدد العصبونات في الطبقات المخفية بالتدرج) ثم عدنا لتخفيض الأبعاد بطريقة عكسية مما يجعل الشبكة متناظرة حيث أن عدد العصبونات ضمن الشبكات بالترتيب هو (32,32,64,128,64,32,3,32,64,128,64) حيث تم تخفيض البيانات إلى 3 مكونات رئيسية تمثل معظم البيانات.

ولقد تم العمل بالاعتماد على نفس تابع النقل (RELU) واستخدام epoch=15. خطوات العمل مع هذه الشبكة موضحة في الشكل (10).



الشكل (10) -آلية عمل الشبكات العصبونية على مجموعة البيانات2

نلاحظ من الشكل أننا قمنا بأمثلة للبيانات X (التي تمثل ميزات 10 صور وبالطبع دون الهدف Y) ثم قمنا بتقسيمها لبيانات تدريب (85% من البيانات) وأخرى للاختبار (15% من البيانات) للشبكة العصبونية حيث انتهى التدريب بعد تكرار 10 مرات، بعد انتهاء التدريب ادخلنا بيانات الاختبار وبالتالي أصبح لدينا المكونات الأساسية لكل من بيانات التدريب والاختبار وهنا قمنا بحساب الزمن اللازم لعملية تخفيض الأبعاد وقدمنا هذه المكونات كاملة مع القيم المرجعية RGB لتشكل مجموعة تدريب KNN، ثم قمنا بتطبيق شبكتنا على صورة واحدة وهي real and fake apples لنحصل على المكونات الأساسية لها.

9-2: التطبيق على مجموعة البيانات:

مجموعة البيانات الأولى

Indian Pines هي عبارة عن مجموعة بيانات للصور الفائقة الطيفية. تتكون بيانات الإدخال من نطاقات فائقة طيفية لمنظر طبيعي واحد (صورة واحدة) في إنديانا، الولايات المتحدة (145 × 145 بكسل). لكل بكسل 200 نطاق انعكاس طيفي تمثل أجزاء مختلفة من الطيف الكهرومغناطيسي في نطاق الطول الموجي 400 نانومتر إلى 2500 نانومتر. حيث لدينا 16 فئة تمثل مجموعة متنوعة من المواد مثل (الأسفلت، الماء...).

يوضح الشكل (9) بيانات المجموعة الأولى. [20]

آلية العمل على مجموعة البيانات الأولى:

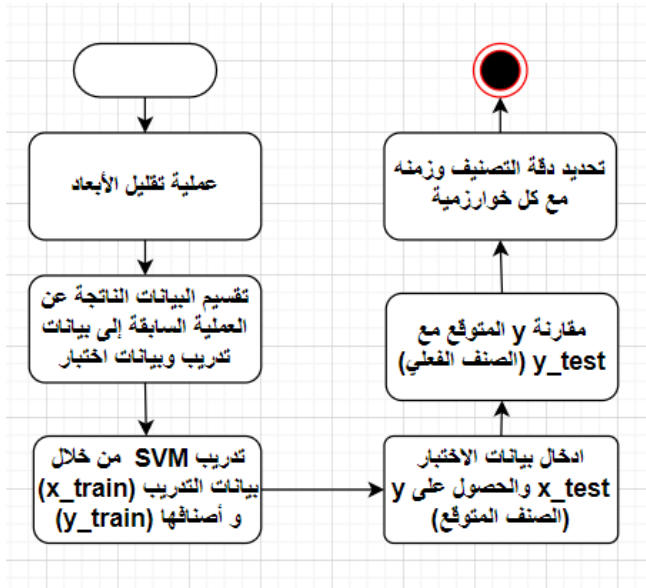
وفق الشكل (9) تم شرح آلية التعامل مع البيانات بوجود الشبكة العصبونية وفي هذه الفقرة سيتم شرح خطوات العمل باستخدام خوارزميات تقليل الأبعاد المدروسة والتي تتمثل بالآتي:

1. قمنا بتقسيم البيانات إلى X (ميزات) و Y (الصف).

2. تحتوي البيانات (X) على 200 ميزة (نطاقات) لذلك نريد تخفيض عدد الميزات إلى 40 مكون رئيسي (وذلك حسب التجريب حيث وجدنا أنها تمثل 99,5 من البيانات).

3. طبقنا كل خوارزميات تخفيض الأبعاد التي تم شرحها مسبقا على (X) وتم تحديد الزمن الذي تستغرقه كل منها.

أما خطوات التصنيف لجميع الطرق إضافة إلى الشبكات العصبونية فتتمثل في الشكل (11)



الشكل (11) - خطوات عملية التصنيف باستخدام SVM مع مجموعة البيانات الاولى

مجموعة البيانات الثانية (Fake & Real):

هي قاعدة بيانات مكونة من 10 صور متعددة الأطياف التي تم استخدامها لمحاكاة كاميرا GAP. الصور هي مجموعة متنوعة من المواد والأشياء في العالم الحقيقي. حيث أن كل صورة 512×512 بكسل. تحتوي مجموعة البيانات هذه على 32 ميزة ضمن نطاقات من 400 نانومتر إلى 700 نانومتر بخطوة 10 نانومتر. والقيم المرجعية (الهدف) في هذه البيانات هو قيم RGB تمثل اللون الحقيقي للصورة. [21]

آلية العمل على مجموعة البيانات الثانية:

1. قمنا بتقسيم البيانات إلى X (الميزات الممثلة ل 10 صور وهي مجموعة البيانات كاملة) و Y (الهدف) والهدف هنا ثلاث قيم ممثلة ل RGB لكل بكسل ثم أمثلة قمنا بأمثلة X .
2. طبقنا كل من خوارزميات تخفيض الأبعاد على X وتم الحصول على المكونات الرئيسية وهنا حددنا زمن عملية تقليل الأبعاد ثم جعلنا المكونات الرئيسية الناتجة عن الخوارزمية مع Y (الهدف) مجموعة بيانات التدريب ل KNN (الهدف من هذه الخطوة تأمين مجموعة تدريب للمصنف ولكن KNN يكون ذو أداء ضعيف عند استخدام مجموعة تدريب كبيرة لذلك استخدمنا المكونات الأساسية الممثلة للبيانات).
3. طبقنا خوارزميات تقليل الأبعاد على بيانات صورة واحدة وقد اخترنا fake and real apples والتي تحتوي على 32 ميزة (نطاقات) ونريد تخفيض عدد الميزات بتشكيل 3 مكونات رئيسية. باستخدام خوارزميات تخفيض الأبعاد (هنا الهدف اختبار الخوارزميات)

أما بالنسبة للتصنيف سواء مع خوارزميات تقليل الأبعاد أو الشبكات العصبونية نكتفي بإدخال نتيجة تخفيض أبعاد fake and real apples للمصنف وتحديد زمن التصنيف ودقة التصنيف.

مع الإشارة إلى أن البيانات المعطاة لكل صورة ملونة هي عبارة عن 32 صورة كل منها يمثل نطاق (قيمة البكسل في هذه الصورة تشكل قيمته عند طول موجي معين) لذلك تم تشكيل حلقة تقوم بالحصول على قيم البكسلات من هذه الصور وتشكيل مصفوفة البيانات (X). أما قيم RGB فلقد تم الحصول عليها من الصورة الهدف (الصورة الملونة).

9-3: النتائج:

9-3-1: نتائج خوارزميات تقليل الأبعاد:

وفي الجدول (1) مقارنة من حيث الوقت المستغرق لتخفيض الأبعاد لمجموعة البيانات الأولى ومجموعة البيانات الثانية.

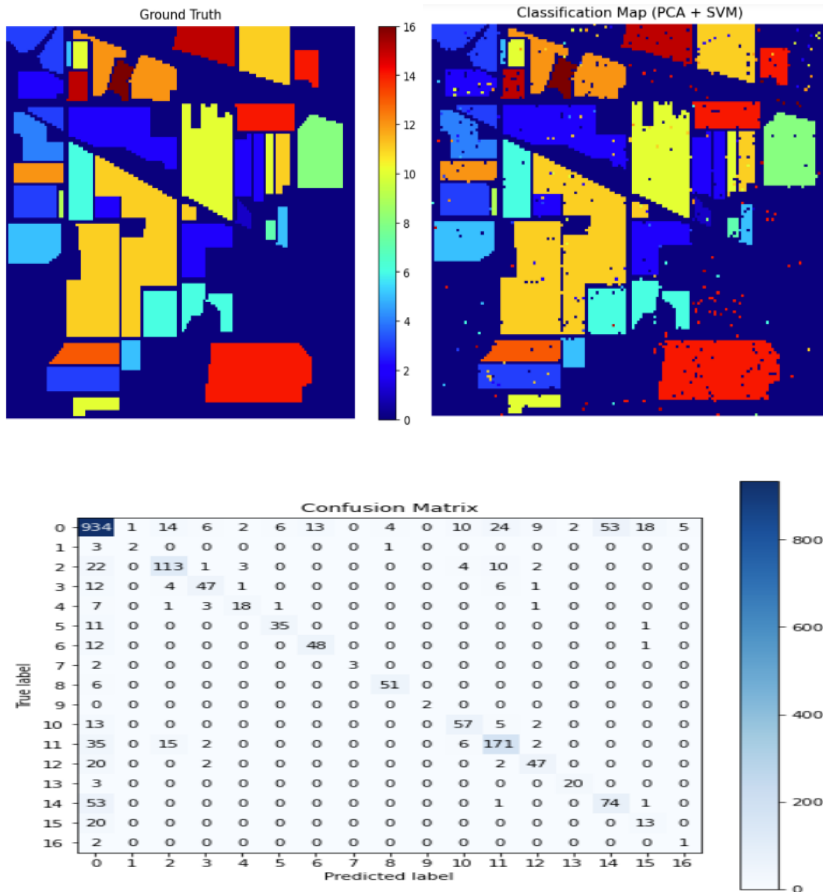
الجدول (1) - الزمن المستغرق لتخفيض الأبعاد

	الوقت المستغرق لتخفيض أبعاد مجموعة البيانات الأولى	الوقت المستغرق لتخفيض أبعاد مجموعة البيانات الثانية
PCA	694 ms	8.54 s
Sparse PCA	12.7 s	12.7 s
Kernel PCA	2min 2s	Couldn't be performed due to huge complexity
Segmented PCA	353ms	2.5 s
neural network	21 min(training)- one time only- 41ms execution	15 min(training)- one time only- 1.33 s execution

9-3-2: نتائج التصنيف:

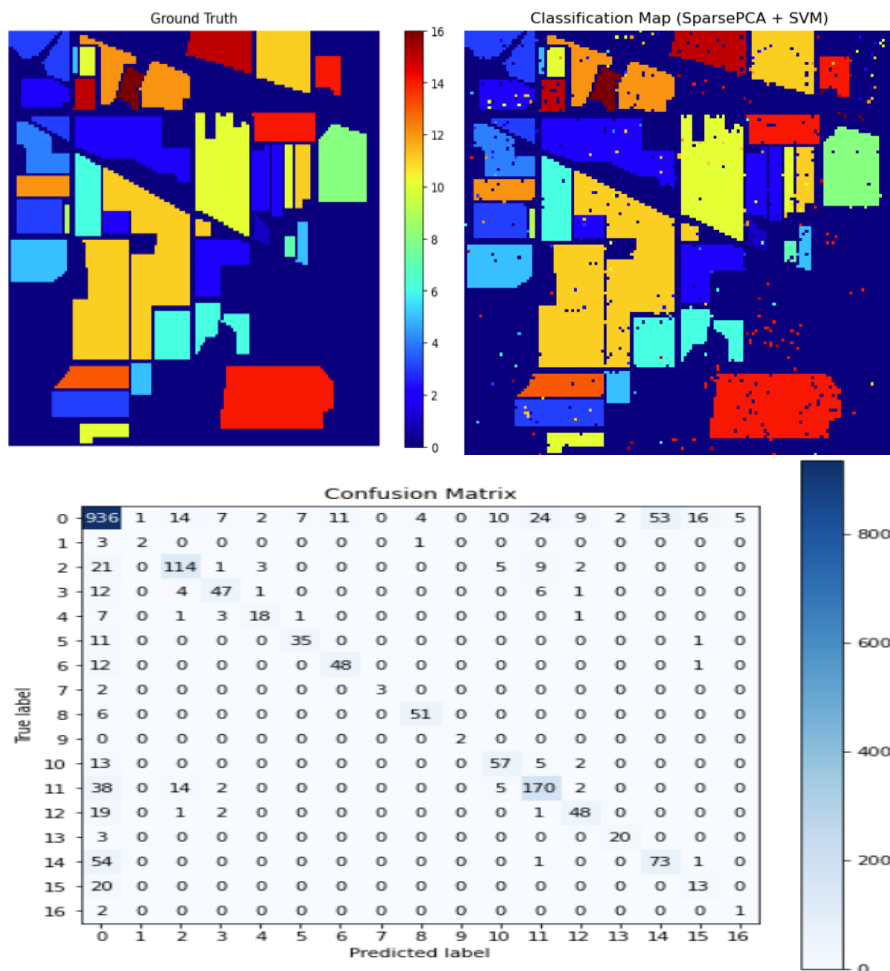
مجموعة البيانات الأولى:

في الشكل (12) المقسم إلى (a,b,c,d,e) توضيح لنتائج التصنيف عند تطبيق الخوارزميات على مجموعة البيانات الأولى على شكل ثنائيات لمقارنة كل منها مع الصورة الأساسية. إضافة إلى وجود تفصيل للتصنيف من خلال Confusion Matrix الذي يوضح الصنف الحقيقي والصنف المتوقع.

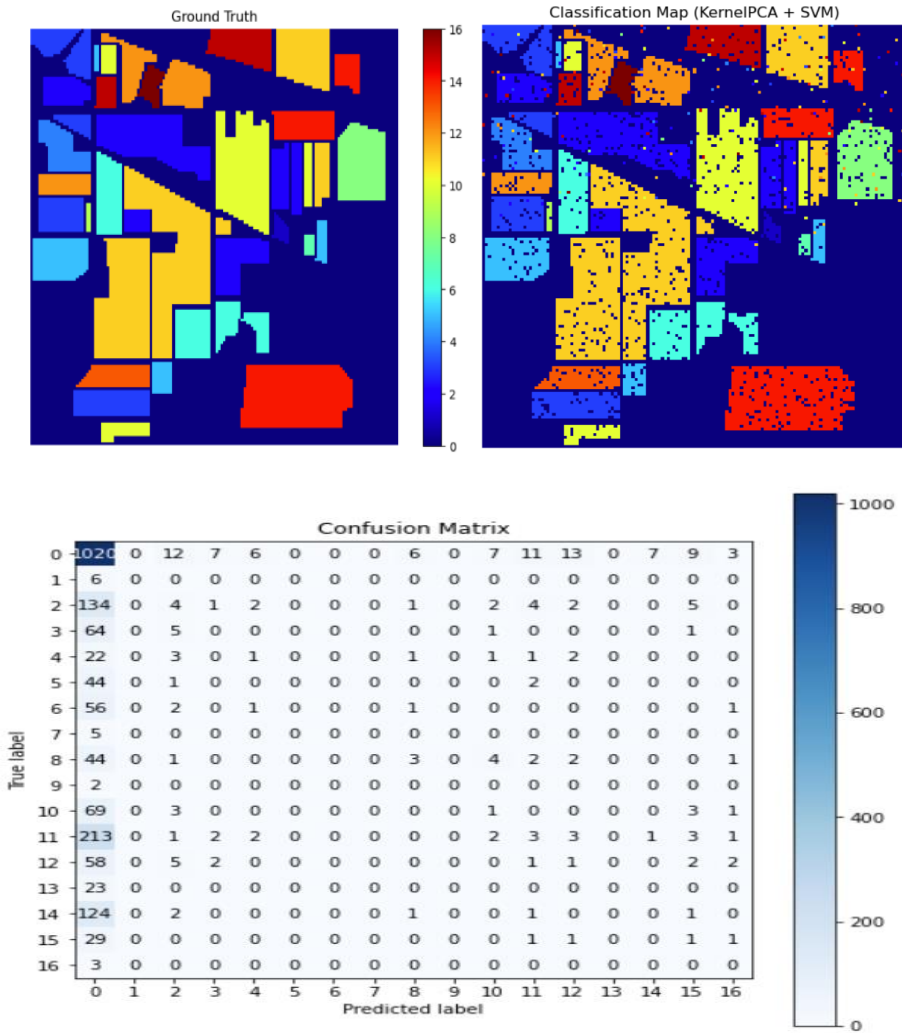


الشكل (12) a- نتيجة التصنيف بعد استخدام PCA

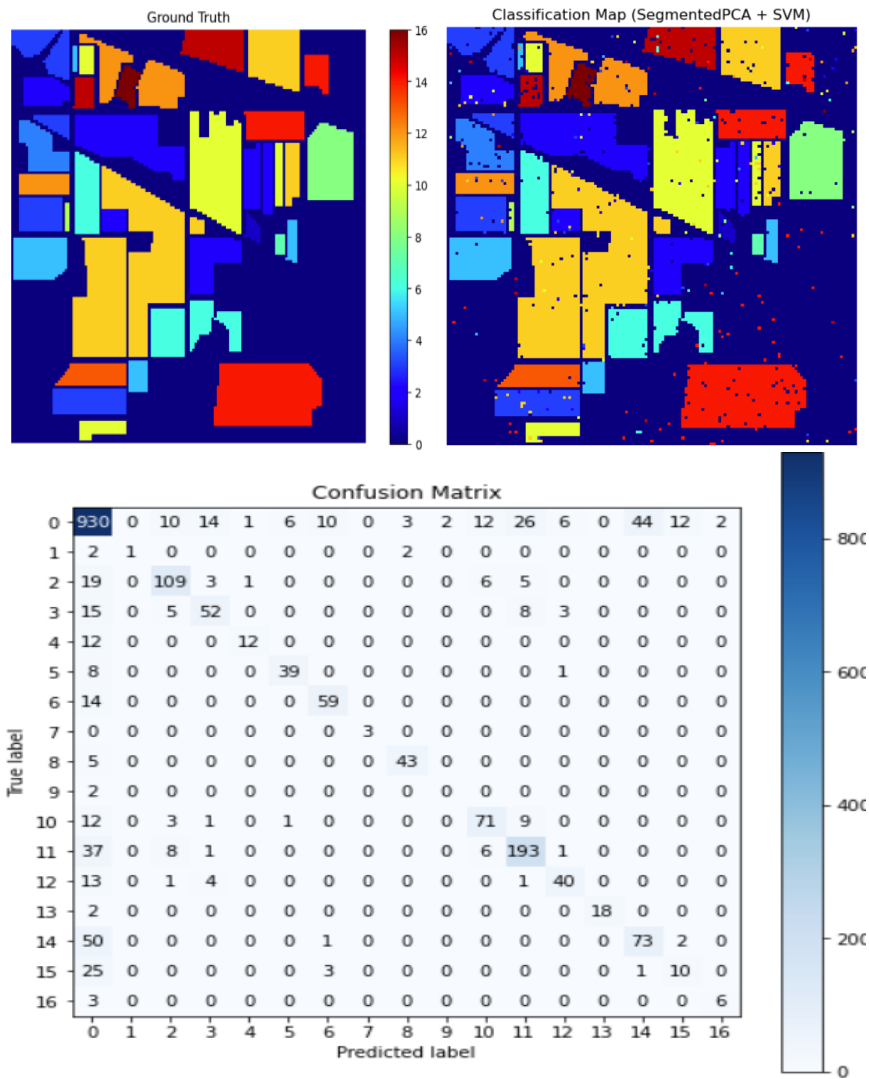
في الشكل (12) a- نتيجة للتصنيف بعد استخدام PCA ولتوضيح فكرة Confusion matrix نجد من السطر الأول والعمود الأول أنه لدينا 934 من الصنف 0 وتم تصنيفها على أنها صفر ومن السطر الأول والعمود الثاني لدينا قيمة واحدة تابعة للصنف 0 ولكن تم تصنيفها على أنها تابعة للصنف 1 وهكذا.



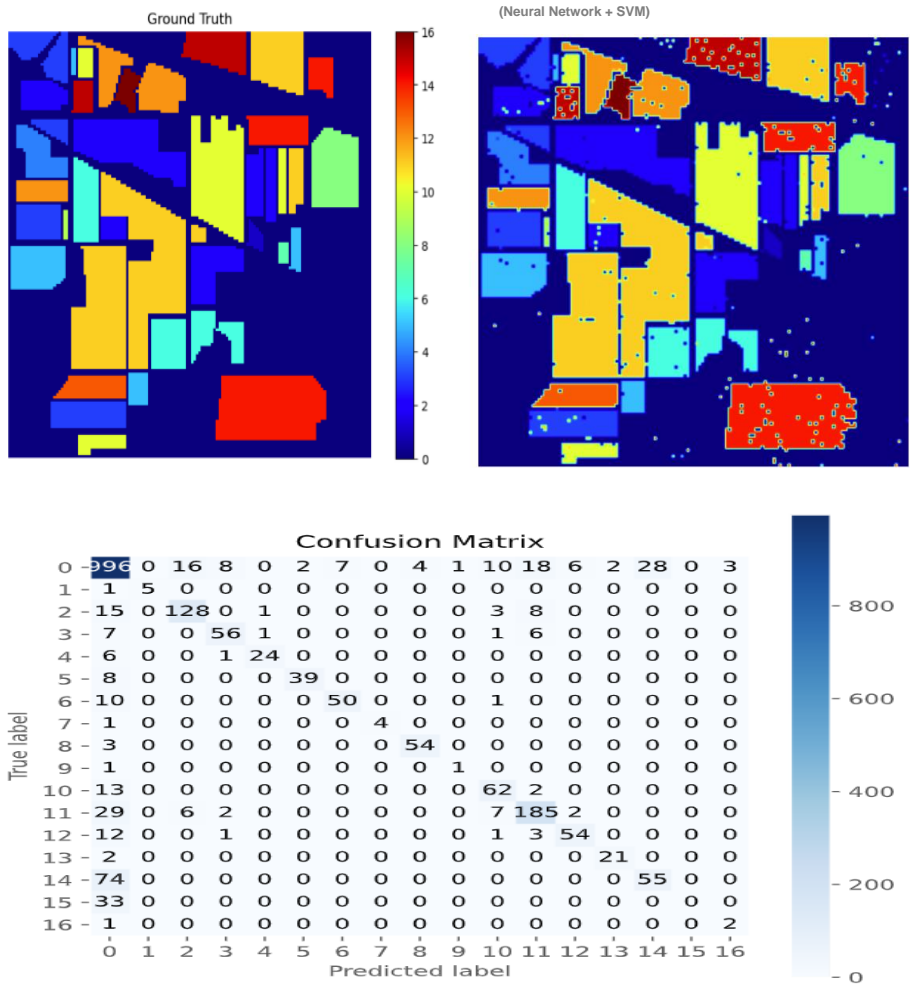
الشكل (12) b- نتيجة التصنيف بعد استخدام Sparse PCA



الشكل (12) -c: نتيجة التصنيف بعد استخدام Kernel PCA



الشكل (12) d- : نتيجة التصنيف بعد استخدام Segmented PCA



الشكل (12) e-: نتيجة التصنيف بعد استخدام الشبكة العصبونية

نلاحظ من الشكل السابق أن Ground truth يحدد توزيع الأصناف وهو المرجع أما الصور المقابلة لها تحتوي على نتائج التصنيف بعد استخدام خوارزميات تخفيض الأبعاد حيث أن النقاط ضمن الصور تعبر عن التصنيف الخاطئ للخوارزمية.

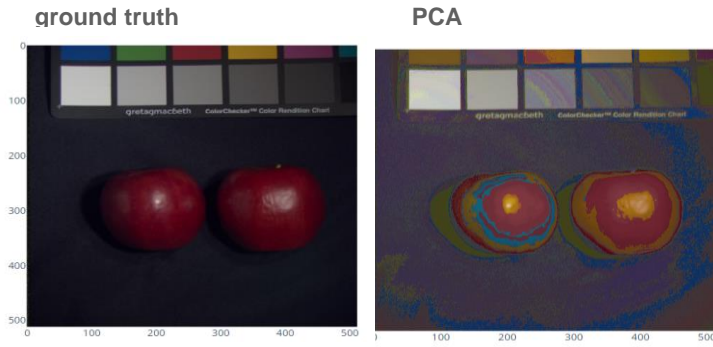
يوضح الجدول (2) دقة التصنيف والزمن اللازم لهذه العملية باستخدام المصنف SVM ومجموعة البيانات الأولى

الجدول (2) -نتائج التصنيف لمجموعة البيانات الأولى

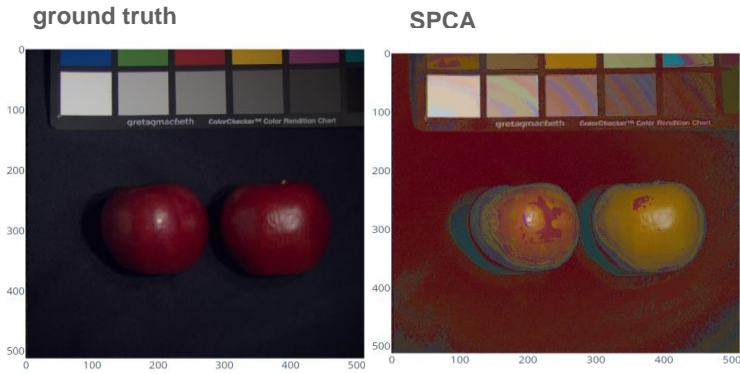
الخوارزمية	الزمن اللازم للتصنيف	دقة التصنيف
PCA	4min 29s	77.79%
SPCA	5min 8s	77.89%
Kernel PCA	40min 50s	49.17%
Segmented PCA	5min 6s	78.89%
neural network	1min 42s	82.55%

مجموعة البيانات الثانية:

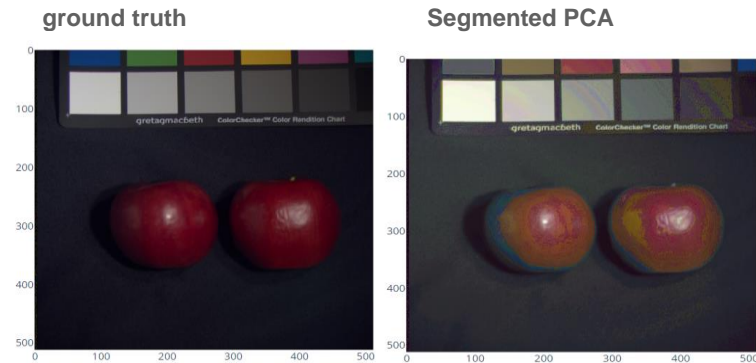
في الشكل (13) المقسم إلى (a,b,c,d) توضيح لنتائج التصنيف عند تطبيق الخوارزميات على مجموعة البيانات الثانية على شكل ثنائيات لمقارنة كل منها مع الصورة الأساسية ولكن هنا لا يمكن استخدام Confusion Matrix لأن لدينا ثلاث قيم مرجعية وليست قيمة واحدة كما في المثال السابق.



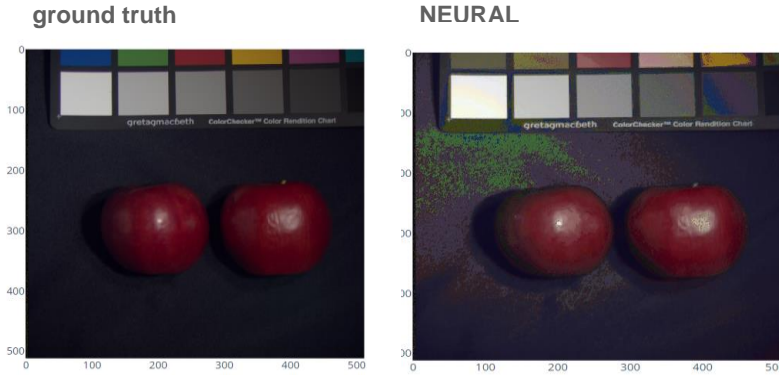
الشكل (13) a- : نتيجة التصنيف بعد استخدام PCA



الشكل (13) b- : نتيجة التصنيف بعد استخدام Sparse PCA



الشكل (13) c- : نتيجة التصنيف بعد استخدام Segmented PCA



الشكل (13) d-: نتيجة التصنيف بعد استخدام الشبكة العصبونية

أيضاً هنا Ground truth هو المرجع وهو صورة RGB أما الصور المقابلة لها تحتوي على نتائج التصنيف بعد استخدام خوارزميات تخفيض الأبعاد وتُحدد دقة التصنيف بقدرة المصنف على تحديد الألوان بشكل مطابق للصورة الأصل. يوضح الجدول (3) دقة التصنيف والزمن اللازم لهذه العملية باستخدام المصنف KNN ومجموعة البيانات الثانية.

الجدول (3)- نتائج التصنيف لمجموعة البيانات الثانية

الخوارزمية	الزمن اللازم للتصنيف	دقة التصنيف
PCA	851 ms	52.71%
SPCA	533 ms	57.77%
Kernel PCA	Couldn't be performed due to huge complexity	
Segmented PCA	1.54 s	64.36%
neural network	702 ms	72.6%

10: المناقشة:

تصور المحاكاة السابقة تحليل أداء خوارزميات تخفيض الأبعاد التي تم تطبيقها على مجموعتين من البيانات (لكل منها خصائص مختلفة عن الأخرى). وقد تم بناء نموذجين للشبكات العصبونية للقيام بعملية تخفيض الأبعاد. والهدف من ذلك تحديد الخوارزمية الأكثر فعالية من حيث الزمن الذي تستغرقه للقيام بالعملية وتأثيرها على خوارزميات التصنيف من حيث الزمن اللازم للقيام بالتصنيف ودقة هذا التصنيف، إضافة إلى تحديد أي من هذه الطرق قادرة على تجاوز نقاط الضعف (المذكورة سابقاً) الخاصة بخوارزمية تخفيض الأبعاد الأساسية PCA الكلاسيكية.

ولقد اتضح أن Kernel PCA كان الأسوأ لأنه خاص بالبيانات غير الخطية التي تحتوي على عدد قليل من العينات الأمر الذي يشير إلى أنها تحتوي تعقيد زمني يتعلق بعدد العينات لأنه في مجموعة البيانات الثانية رغم أن عدد الميزات أقل بكثير مقارنة بمجموعة البيانات الأولى إلا أننا لم نحصل على نتائج، لكن عدد عينات مجموعة البيانات الثانية أكبر بكثير مقارنة مع مجموعة البيانات الأولى مما أثر على أداء الخوارزمية، أما Segmented PCA فلقد كانت أفضل خوارزمية بين الخوارزمية التقليدية لجميع البيانات سواء في الزمن المستغرق لتخفيض الأبعاد أو الدقة.

بالنسبة للشبكة العصبونية المقترحة هي الأفضل بين جميع الطرق في كلتا الحالتين، رغم اختلاف بنية البيانات ومواصفاتها هذا يدل على أن الشبكات العصبونية قادرة على التعامل مع أي نوع من البيانات بشرط فهم طبيعتها، كما وكانت الأسرع بين جميع الخوارزميات ففي مجموعة البيانات الأولى كانت أسرع من Segmented PCA بحوالي 8 أضعاف وفي مجموعة البيانات الثانية تفوقت على أسرع منها بمقدار الضعف رغم أن Segmented PCA كانت الخوارزمية الأسرع مقارنة بباقي الخوارزميات في كلا الحالتين.

أما عند تحليل نتائج زمن ودقة التصنيف لاحظنا من نتائج مجموعة البيانات الأولى أنه عند استخدام الشبكات العصبونية كان المصنف أسرع بحوالي أربع أضعاف مقارنة

بأعلى سرعة حققها عند استخدام باقي الخوارزميات وكان ذلك عند استخدام PCA مع تفوق لدقة التصنيف بحوالي 3,66% مقارنة بأعلى دقة محققة عند استخدام باقي الخوارزميات وكانت عند استخدام Segmented PCA. أما في مجموعة البيانات الثانية فقد حقق المصنف أعلى سرعة تصنيف عند استخدام Sparse PCA حيث تبعتها سرعة التصنيف عند استخدام الشبكات العصبونية بفارق حوالي 169ms لكن ذلك مقابل فارق كبير في دقة التصنيف وهو 14,83%، حيث كانت دقة التصنيف بعد استخدام الشبكات العصبونية هي الأفضل بمقدار 8,24% مقارنة بدقة تصنيف بعد استخدام Segmented PCA وهي أعلى دقة تصنيف محققة عند استخدام الخوارزميات الأخرى.

11-الاستنتاجات والتوصيات:

في هذا العمل تم تقييم أداء الشبكة العصبونية في عملية تخفيض الأبعاد للصور الفائقة الطيف محاولين حل عدة مشاكل تعاني منها PCA وقد أثبتت قدرتها على ذلك حتى عند مقارنتها مع جميع الخوارزميات المعدلة عن PCA وأثبتت تفوقها على كل منهم في أهم الميزات التي طوروا فيها عن PCA.

يمكن العمل على تطوير نموذج الشبكة العصبونية ليكون مناسب لبعض التطبيقات التي لا تحتاج إلى دقة عالية كالتسامح في نسبة الخطأ. أو حتى العمل على زيادة السرعة مع الحفاظ على الدقة من خلال اجراء عمليات معالجة مسبقة للميزات قبل الادخال إلى الشبكة العصبونية. كما ويمكن العمل على تقسيم الشبكة العصبونية إلى مجموعة من الشبكات لتقوم كل منها بالحصول على المكون الرئيسي لقسم من البيانات ثم يتم إعادة دمج المكونات انطلاقاً من مبدأ Segmented PCA التي حققت نتائج جيدة مقارنة ببقية الخوارزميات. حيث يمكن لهذه الطريقة توظيف إيجابيات كل من الطريقتين.

المراجع

- [1] Vishvanathan,S, Kp,S, Hassaballah,M, 2019 Hyperspectral Image: Fundamentals and Advances, researchgate,1-24
- [2] Pandey,P, Balzter,H, Srivastava ,P, Petropoulos ,G, Bhattacharya,B, 2020 Future perspectives and challenges in hyperspectral remote sensing, Elsevier, 429-439
- [3] Alfahaam, A 2016 The quantitative and qualitative classification of remote sensing images using spectral unmixing technique Al-Baath University Journal,1-29.
- [4] Fernandez,D,Gonzalez,C,Mozos,D, Lopez,S,2016 FPGA implementation of the principal component analysis algorithm for dimensionality reduction of hyperspectral images, Springer,1-12
- [5] Zhang,D, Ding,D, Li ,J, Liu,Q,2015 PCA Based Extracting Feature Using Fast Fourier Transform for Facial Expression Recognition, Springer ,413-424
- [6] <https://jupyter.org> ,23/11/2021,8:00PM
- [7] Mishra,S, Sarkar,U, Taraphder,S, Datta,S, 2017 Principal Component Analysis, International Journal of Livestock Research, VOL.7,60-78
- [8] Rodarmel,C, and Shan,J, 2002 Principle Component Analysis for Hyperspectral Image Classification, Surveying and Land Information System, vol. 62, 115-123.
- [9] Kramizadeh1,S, Abdullah1,S, Manaf1,A, Zamani1,M, Hooman,A, 2013 An Overview of Principal Component

Analysis ,Journal of Signal and Information Processing,
vol.4 ,173–175

- [10] Rashedul Islam,MD, Ahmed,B, Ali Hossain,MD,2019
Feature Reduction Based on Segmented Principal Component
Analysis for Hyperspectral Images Classification, IEEE, 1–6.
- [11] Tripathy,B, Ghela,S, 2021 Kernel PCA, researchgate, 21–
23
- [12] García,A, Huerta,A, Zlotnik,S, Díez,P, 2020 A kernel
Principal Component Analysis (kPCA) Digest with a New
Backward Mapping (pre–image reconstruction) Strategy,
researchgate,1–16
- [13] Nielsen,A, Larsenb ,R, Vestergaardb,J,2011 Sparse
Principal Component Analysis in Hyperspectral Change
Detection, SPIE , Vol. 8180 ,1–6
- [14]<https://scentellegher.github.io/machine-learning/2020/01/27/pca-loadings-sklearn.html> , 2/5/2022,9:00AM
- [15] Guerra–Urzola,R, Van Deun ,K, Vera,J, Sijtsma,K, 2021
A GUIDE FOR SPARSE PCA: MODEL COMPARISON AND
APPLICATIONS , Springer ,1–27
- [16] ALBUSTANI,H,2016–Neural network . Tishreen university,
Syria ,618.

- [17] Cervantes,J, Garcia–Lamont,F, Rodríguez–Mazahua,L, Lopez,A, 2020 A comprehensive survey on support vector machine classification :Applications, challenges and trends , Elsevier , vol.408 , 189–215
- [18] Haroon,M 2021 K–Nearest Neighbour (KNN) Algorithm with Example, researchgate ,1–4
- [19] Taunk,K, De,S, Verma,S, Swetapadma,A, 2019 A Brief Review of Nearest Neighbor Algorithm for Learning and Classification ,IEEE ,1255–1260
- [20] Hyperspectral Image Analysis — Classification | by Syam Kakarla | Towards Data Science .5/4/2021,3:09PM
- [21] <https://www.cs.columbia.edu/CAVE/databases/multispectral/> 5/4/2021,9:00PM.

دراسة الخواص المغناطيسية لبعض المركبات النانونية باستخدام نموذج Ising وخوارزميات مونت كارلو

* م. محمد هيثم الشمالي
** د.م. مجد الدين العلي

الملخص:

تستخدم طريقة مونت كارلو في دراسة الخواص المغناطيسية للمواد النانونية عن طريق محاكاة النظام الفيزيائي للمادة باستخدام عدد كبير من العينات العشوائية. وتعتمد هذه الطريقة على تطبيق مبدأ العينات العشوائية المستقلة والمتطابقة لإيجاد الحل الأمثل للنظام.

يتم تنفيذ هذه الطريقة مع نموذج Ising وهو نموذج فيزيائي يدرس تبادل الطاقة والزيادة في الإحصاءات الحرارية في الأنظمة المغناطيسية.

في هذا البحث تم استخدام نموذج Ising وخوارزميات مونت كارلو لدراسة الخواص المغناطيسية للمركب $Bi_{1-x}Sr_xFeO_3$ من أجل $x = 0.25 - 0.5$ من خلال عرض منحنيات المغنطة $M(H)$ والقابلية المغناطيسية χ كتابع لدرجة الحرارة وكذلك عكس القابلية المغناطيسية للمركب في درجتَي الحرارة 2K و 300K.

من خلال منحنيات المغنطة تبين أنها على شكل حلقات تخلفية يتغير عرضها من مركب لآخر، وأنه عند درجات الحرارة العالية قيمة المغنطة تكون ثابتة مما يدل على أن المركب ذو خواص مضادة للمغناطيسية الحديدية.

كلمات مفتاحية: خوارزميات مونت كارلو، نموذج Ising، المغنطة، حلقات التخلفية، الناقلية المغناطيسية.

* طالب دراسات عليا، قسم الهندسة الالكترونية والاتصالات، كلية الهندسة الميكانيكية والكهربائية، جامعة البعث.
** أستاذ مساعد في قسم الهندسة الالكترونية والاتصالات، كلية الهندسة الميكانيكية والكهربائية، جامعة البعث.

Studying the Magnetic properties of some nanocomposites using Ising Model and Monte Carlo Algorithms

* Eng. Mohammad Alshimali

** Dr. Majdeddin Ali

Abstract

The Monte Carlo method is used to study the magnetic properties of nanomaterial by simulating the physical order of the material using a large number of random samples. This method is based on applying the principle of independent and identical random samples to find the optimal solution for the system. This method is implemented with the Ising model, which is a physical model that studies energy exchange and increase in thermal statistics in magnetic system.

In this research, Ising model and Monte Carlo algorithms are used to study the Magnetic properties of the compound $\text{Bi}_{1-x}\text{Sr}_x\text{FeO}_3$ for $x= 0.25 - 0.5$, by displaying magnetization and magnetic susceptibility curves as a function of temperature, as well as reverse the magnetic susceptibility of the compound in the two temperatures 2K and 300K.

From the magnetization curves, it was found that they are in the form of hysteresis loops whose width varies from one compound to another. And that at high temperatures, the value of magnetization is constant, which indicates that the compound has antiferromagnetism properties.

Keywords: Monte Carlo algorithms, Ising model, magnetization, hysteresis loops, susceptibility.

* Postgraduate Student, Department of Electronic and Communications Engineering - Faculty of Mechanical and Electrical Engineering - Al-Baath University.

** Assistant Professor in the Department of Electronic and Communications Engineering - Faculty of Mechanical and Electrical Engineering - Al-Baath University.

1- مقدمة:

توجد العديد من الخوارزميات التي تستخدم لدراسة الخواص المغناطيسية للمواد النانوية، تعتبر Density Functional Theory – DFT من الخوارزميات الأكثر استخداما والتي تستند إلى مفهوم الحالة الأساسية للنظام الإلكتروني، ولكنها لا تعتبر دقيقة بشكل مطلق وتعتمد العديد من التقريبات والفروض المبنية على نماذج بسيطة للنظام الإلكتروني.

تستخدم خوارزمية الحسابات الكمومية الجزيئية Molecular Quantum Mechanics MQM – لحساب الخصائص المغناطيسية للمواد النانوية وتستند إلى مفهوم الحالة الأساسية للجزيء وتأخذ بعين الاعتبار تفاعلات وتأثيرات الإلكترونات على الخصائص المغناطيسية، وتعتبر دقيقة بشكل عام لكنها تتطلب موارد حسابية كبيرة وتأخذ وقتا أطول، كما تعتمد على النماذج المستخدمة للجزيء والتي يمكن أن تحتوي على تقريبات. أما بالنسبة للحسابات الكمومية المتقدمة Advanced Quantum Calculations فهي تشمل تقنيات مثل حسابات الفونون وحسابات النظرية النسبية العامة والتي تأخذ بعين الاعتبار تأثيرات الجاذبية النسبية على الخواص المغناطيسية، ومن المميزات الرئيسية لهذه الطريقة هي دقتها واحتسابها لعدد كبير من العوامل المؤثرة على الخواص المغناطيسية. ومع ذلك فهي تتطلب موارد حسابية كبيرة وتأخذ وقتا أطول لإجراء الحسابات.

طريقة مونت كارلو بالاعتماد على نموذج Ising تعتمد على التفاعلات بين الجسيمات والتي تنتج عنها طاقة مغناطيسية، وذلك يعتمد على عزوم دوران الإلكترونات في الجسيمات المتجاورة. تساعد هذه الطريقة في فهم الظواهر المغناطيسية وتحليل الخواص المغناطيسية بطريقة فعالة من حيث التكلفة والوقت.

2- الدراسات المرجعية:

في عام 2017 تمت دراسة الخصائص المغناطيسية والمغناطيسية الحرارية لبنى DyNi₄Si النانوية باستخدام طرائق مونت كارلو وبينت أن تحسين الخصائص المغناطيسية والمغناطيسية الحرارية ينتج عن طريق تقليل كل من البعد والحجم [3]، كما تمت دراسة مخططات الطور والخصائص المغناطيسية لطبقة واحدة من الجرافين النانوية وبينت قدرة الجرافين النانوي أن يظهر طور عالي النفاذية محصور بين الطور المضاد للمغناطيسية والنفاذية العالية [4]، تم أيضا دراسة السلوك المغناطيسي والديناميكي الحراري لنفاذية الجزر النانوية حيث بينت تأثير الحقول البلورية، وصلات التبادل والحقل المغناطيسي الخارجي على السلوك المغناطيسي والديناميكي الحراري للنظام [5]، في عام 2020 استخدمت محاكاة مونت كارلو لدراسة هضاب المغنطة والخصائص الديناميكية الحرارية لبنى الجرافين النانوي مع دوران مختلط $3/2$ و $5/2$ في حقل مغناطيسي طولي وبينت النتائج أن الطاقة الداخلية للنظام يمكن أن تنخفض بانقاص تباينات الخواص وزيادة اقتران التبادل بين الطبقات بالإضافة للحقل المغناطيسي الطولي [6].

في هذا البحث قمنا بدراسة الخواص المغناطيسية للمركب $\text{Bi}_{1-x}\text{Sr}_x\text{FeO}_3$ من أجل $x = 0.25 - 0.5$ باستخدام نموذج Ising وخوارزميات مونت كارلو. يعد نموذج Ising أحد أبسط الأنظمة التي توضح انتقال الطور. يتكون هذا النظام من N دوران بقيمة 1- أو 1 مرتبة على بعض الشبكات ولها انتقال طوري عند درجة حرارة محدودة. في هذا البحث، ننظر إلى انتقال الطور هذا من خلال النظر إلى متوسط المغناطيسية، والسعة الحرارية لكل دوران، وقابلية الدوران في نطاق درجات الحرارة باستخدام خوارزميات مونت كارلو.

3- هدف البحث:

الهدف من البحث دراسة الخواص المغناطيسية للمركب $\text{Bi}_{1-x}\text{Sr}_x\text{FeO}_3$ من أجل $x = 0.25 - 0.5$ من خلال عرض منحنيات المغنطة $M(H)$ والقابلية المغناطيسية χ كتابع لدرجة الحرارة وكذلك عكس القابلية المغناطيسية للمركب في درجتي الحرارة 2K و 300K.

وهنا تكمن أهمية البحث بالتأكد من قدرة الخوارزمية على دراسة خواص المواد النانوية دون الحاجة لإجراء تجارب عليها باستخدام أجهزة مكلفة داخل مخبر مخصص لمثل هذه المواد، وبالتالي التقليل من الضياعات في التجارب المخبرية.

4- مواد وطرائق البحث:

يعتمد هذا البحث على المنهج العلمي التحليلي، ويقوم بتطبيق نموذج Ising وطرائق حساب مونت كارلو على المركب $\text{Bi}_{1-x}\text{Sr}_x\text{FeO}_3$. أما أدوات البحث هي أدوات برمجية حيث تم استخدام لغة البرمجة Python.

4-1- نموذج Ising

نموذج Ising هو نموذج بسيط لدراسة المغناطيسية. يتكون النموذج من نظام دورانات يمكن أن يشير إما للأعلى أو للأسفل. توجد بين دورانين متجاورين ، طاقة تفاعلية وتكتسب الدورات أيضاً طاقة مغناطيسية في وجود مجال مغناطيسي. تم وصف النظام من قبل هاميلتونيان التالي:

$$H = -J \sum_{\langle i,j \rangle} s_i s_j - H \sum_i s_i \quad (1)$$

حيث J هي طاقة التفاعل بين دورانين متجاورين (s_i, s_j) و H هو المجال المغناطيسي. نظراً لأن الدورانات تدور فقط للأعلى أو للأسفل: $s_i \in \{-1, 1\}$. إذا كانت قيمة طاقة التفاعل موجبة $J > 0$ سيصبح النظام مغناطيسياً حديدياً وستتم

محاذاة جميع الدورات عند درجات حرارة منخفضة. بالنسبة لتكوين بدء عشوائي، فإن كلا الاتجاهين الذين يمكن أن تتماشى فيه الدورات (لأعلى أو لأسفل) يكونان متساويين في الاحتمال في حالة عدم وجود مجال مغناطيسي. إذا كان هناك مجال مغناطيسي، فإن الدورات تدور مع اتجاه المجال المغناطيسي.

في كلتا الحالتين، يحتوي نموذج Ising على مرحلة انتقالية لبعدين أو أعلى. عند درجة الحرارة الحرجة، سينتقل النظام من نظام مغناطيسي حديدي مرتب إلى نظام مضطرب بدون مغنطة.

يمكن تحديد العديد من المتغيرات المثيرة للاهتمام لنموذج Ising. الأول هو متوسط المغناطيسية لكل دورة:

$$m = \frac{1}{N^2} \sum_i s_i \quad (2)$$

حيث m هي المغنطة، N هو عدد الدورات و s_i هي قيمة الدوران. وبالمثل، يمكن الحصول على متوسط الطاقة لكل دوران من هاملتونيان (المعادلة 1). يمكن استخدام متوسط إجمالي المغنطة والطاقة لحساب القابلية المغناطيسية (المعادلة 3) والحرارة النوعية (المعادلة 4).

$$\chi M = \frac{\beta}{N^2} (\langle M^2 \rangle - \langle M \rangle^2) \quad (3)$$

χM القابلية المغناطيسية، β درجة الحرارة العكسية، و M المغنطة الكلية. تشير الأقواس إلى المتوسطات.

يتم إعطاء الحرارة النوعية بواسطة

$$C_v = \frac{1}{N^2 k_B T^2} (\langle E^2 \rangle - \langle E \rangle^2) \quad (4)$$

حيث C_v هي الحرارة النوعية، T هي درجة الحرارة و E هي الطاقة الكلية للنظام. [8].

4-2- طريقة مونت كارلو

لمعالجة محاكاة نموذج Ising نستخدم طريقة مونت كارلو المعروفة باسم تكامل مونت كارلو [9]. هذه الطريقة مفيدة في هذا السياق ، لأننا ندرس في النهاية الآليات الإحصائية لهذا النظام ، والتي تتطلب بالضرورة حساب التكاملات عالية الأبعاد. بعبارة سريعة ، تكامل مونت كارلو $\int_a^b f(x)dx$ يعمل على حساب القيمة المتوقعة لـ f من أجل توزيع احتمالي معطى $p(x)$. وهذا يتم تلخيص f من أجل عدد N من الحالات x_i التي يتم أخذ عينات منها عشوائياً وفقاً لـ $p(x)$.

في حالة التوزيع الاحتمالي الموحد ، $p(x) = 1/(b - a)$ ، يبدو هذا على النحو التالي:

$$\begin{aligned} \int_a^b f(x)dx &= (b - a) \int_a^b \frac{1}{b - a} f(x)dx = (b - a) \int_a^b p(x)f(x)dx \\ &\approx \frac{b - a}{N} \sum_{i=1}^N f(x_i) \end{aligned} \quad (5)$$

بالنسبة لتكامل MC يتم قياس الخطأ على أنه $1/\sqrt{N}$ فقط ، بينما في طريقة المستطيل (وطرق أخرى مماثلة) مقاييس الخطأ تكون $1/N^{k/d}$ ، حيث d هو بُعد النظام ، مما يجعل تكامل مونت كارلو متفوقاً على الأنظمة التي تتمتع بدرجات عديدة من الحرية.

بالطبع، في حالة الميكانيكا الإحصائية، تبدو التكاملات التي نتطلع إلى حلها أشبه ما تكون

$$\int A(x)e^{-\beta H(x)} dx \quad (6)$$

حيث $\beta = 1/k_B T$ و H هاميلتوني النظام. والتابع $A(x)e^{-\beta H(x)}$ بلغ ذروته بشكل حاد للغاية ، مما يجعل أخذ العينات على توزيع منتظم غير فعال للغاية. بدلا من ذلك ، نحدد التوزيع الاحتمالي ليكون $p(x) \propto e^{-\beta H(x)}$ ونحل بالمثل.

$$\int A(x)p(x)dx \approx \frac{1}{N} \sum_{i=1}^N A(x_i) \quad (7)$$

من الناحية الحسابية ، للتأكد من أننا نختار مع توزيع احتمالي مماثل ، فإننا ننفذ تكامل مونت كارلو الخاص بنا باستخدام خوارزمية Metropolis.

4-3- خوارزمية متروبوليس

تعمل خوارزمية Metropolis باستخدام سلسلة Markov لحالات النظام المختلفة الممكنة $\{x_i\}$ ، حيث احتمال وجود حالة جديدة x' يعتمد فقط على الحالة الحالية x . احتمال وجود كل حالة في السلسلة عند رقم الخطوة i يمكن حسابها ب:

$$p(x, i + 1) = p(x, i) - \sum_{x'} p(x, i)T(x \rightarrow x') + \sum_{x'} p(x', i)T(x' \rightarrow x) \quad (8)$$

حيث $T(x \rightarrow x')$ احتمال الانتقال من x إلى الحالة التالية الممكنة المعطاة x' . في حالة المحاكاة لدينا ، نريد أن ننظر إلى النظام عندما يكون في حالة توازن حراري. في هذه الحالة ، توزيع الاحتمالات لحالة معينة x يجب أن تكون ثابتة ، لذلك $p(x, i + 1) = p(x, i)$ في هذه الحالة، المعادلة أعلاه تصبح :

$$\sum_{x'} p(x, i)T(x \rightarrow x') = \sum_{x'} p(x', i)T(x' \rightarrow x) \quad (9)$$

من أجل البساطة ، نطلب موازنة تفصيلية:

$$p(x, i)T(x \rightarrow x') = p(x', i)T(x' \rightarrow x) \quad (10)$$

احتمال الانتقال ، T ، تعتمد على عاملين :

$$T(x \rightarrow x') = w_{xx'} \times A_{xx'} \quad (11)$$

$w_{xx'}$ هو احتمال أن x' هي (أو يمكن أن تكون) الحالة المقترحة التالية. من الضروري أن تكون هذه القيمة متناظرة، على هذا النحو $w_{xx'} = w_{x'x}$. في حالتنا ، لتبسيط نموذج Ising الخاص بنا ، اخترنا أن نفرض أنه لا يمكن أن ينقلب دورانان في نفس الوقت ، لذلك فإن كل حالة نظام ممكنة جديدة هي ببساطة الحالة الحالية مع انعكاس دوران واحد. هذا يعني أن هناك $N \times N$ من الحالات التالية الصالحة ، لكل منها احتمالية متساوية.

$$w_{xx'} = \begin{cases} 1/N^2 & \text{if } x \text{ and } x' \text{ have one spin difference} \\ 0 & \text{otherwise} \end{cases} \quad (12)$$

يتم تنفيذ هذا بطريقتين. أولاً ، عن طريق الاختيار العشوائي (من توزيع منتظم) الإحداثيات (i, j) للدوران الفردي المراد قلبه للحالة المحتملة التالية. ثانياً ، نتأكد من أنه في كل خطوة زمنية يتم اتخاذها ، يتم اختبار N^2 من الحالات الجديدة الممكنة من خلال السلسلة ، والتي تمثل "مسحاً" كاملاً للمصفوفة وتقليب كل دورة مرة واحدة ، وسطياً.

$A_{xx'}$ هو احتمال أن x' هي "مقبولة" كحالة جديدة ، على أساس x . لتلبية المعادلة 10 ، يمكننا تحديد احتمال القبول على النحو التالي:

$$A_{xx'} = \begin{cases} 1 & \text{if } p(x') > p(x) \\ p(x')/p(x) & \text{if } p(x') < p(x) \end{cases} \quad (13)$$

هناك تفسير إضافي لهذه النتيجة. في سياق الفيزياء الإحصائية نحن نعلم أن $p(x) \propto e^{-\beta H(x)}$ حيث H هو نظام هاميلتوني. هذا يعني أنه بالنسبة لدرجة حرارة معينة ، يمكننا بدلا من ذلك مقارنة طاقات الأنظمة للعثور على A :

$$A_{xx'} = \begin{cases} 1 & \text{if } H(x') < H(x) \\ e^{-\beta \Delta E} & \text{if } H(x') > H(x) \end{cases} \quad (14)$$

بمعنى ، إذا كانت طاقة الحالة الجديدة المقترحة أقل من طاقة الحالة الحالية ، فسيحدث الانتقال. إذا كان أكبر ، فقد يحدث الانتقال اعتماداً على حجم الزيادة ودرجة حرارة النظام. عند درجة حرارة T أعلى ، يرتفع احتمال الانتقال. يتناسب هذا تماماً مع توقعنا: تميل الأنظمة عموماً إلى حالات الطاقة المنخفضة ، لكن درجات الحرارة المرتفعة يمكن أن تمنعها من القيام بذلك. هذا مهم أيضاً من حيث أن حساب ΔE أسهل من مقارنة الاحتمالات . أيضا باستخدام ΔE بدلا من هاميلتونيان الفردي ، يحفظ الذاكرة ويمنع الفائض عند حساب A .

بهذا ، تعمل خطوة واحدة من خوارزمية Metropolis لنموذج Ising الخاص بنا على النحو التالي:

1. إنشاء مجموعة نظام أولية من $N \times N$ دوران لتكون الحالة الحالية x . حساب وحفظ طاقتها.

2. اختر عشوائياً دوراناً للقلب. الحالة القادمة x' ، هي ببساطة x ولكن مع هذا الدوران الذي يشير إلى الاتجاه المعاكس.

3. احسب طاقة الحالة المقترحة ، وقارن بين طاقات x و x' واحسب A وفقاً للمعادلة 14 . اقبل أو ارفض الانتقال من x إلى x' مع الاحتمالات الخاصة A و $1 - A$. إذا قبلت ، قم بتعيين $x = x'$.

4. كرر الخطوتين 2 و 3 بإجمالي N^2 مرة ، تمثل "عملية مسح" واحدة لمصفوفة النظام.


يتم إجراء ذلك لعدد من الخطوات الزمنية التي يُدخلها المستخدم في الكود. [9]

5- التطبيق العملي:


في هذا القسم تم تنفيذ النموذج المقترح باستخدام لغة البرمجة Python للحصول على كل من المغنطة والقابلية المغناطيسية.

5-1 المغنطة بدلالة الحقل المغناطيسي المطبق للمركب $\text{Bi}_{1-x}\text{Sr}_x\text{FeO}_3$ من أجل


$$x = 0.25 - 0.5$$



الشكل (1): منحى المغنطة وفقا للحقل المغناطيسي المطبق للمركب $\text{Bi}_{0.5}\text{Sr}_{0.5}\text{FeO}_3$.




الشكل (2): منحى المغنطة وفقا للحقل المغناطيسي المطبق للمركب




من الشكل (1) والشكل (2) نلاحظ علاقة المغنطة بدلالة الحقل المغناطيسي والتي تظهر على شكل حلقات تخلفية يختلف عرضها من مركب لآخر، كما يتناقص عرضها وتميل للخلفية بزيادة درجة الحرارة. ولكن يبين الشكلان وبالرغم من الاختلاف في حلقات التخلفية أن للمركبين المدروسين خصائص مغناطيسية واضحة.


5-2- القابلية المغناطيسية وعكسها بدلالة درجة الحرارة للمركب $\text{Bi}_{1-x}\text{Sr}_x\text{FeO}_3$ من أجل $x = 0.25 - 0.5$:



الشكل (3) القابلية المغناطيسية وعكسها بدلالة درجة الحرارة للمركب $\text{Bi}_{0.5}\text{Sr}_{0.5}\text{FeO}_3$



الشكل(4): القابلية المغناطيسية وعكسها بدلالة درجة الحرارة للمركب



من دراسة القابلية المغناطيسية للمركبين بدلالة درجة الحرارة يبين الشكل (3) والشكل (4) العلاقة الغير خطية حيث تتناقص القابلية المغناطيسية مع زيادة درجة الحرارة، ولكن الأشكال تؤكد أن لهذين المركبين خواص مغناطيسية واضحة.

6- تقييم النتائج:

من خلال منحنيات المغنطة $M = f(H)$ نلاحظ أنها على شكل حلقات تخلفية يتغير عرضها من مركب لآخر ولكن بشكل عام نجزم بأن المركبين يحملان خاصية مغناطيسية حديدية.

ومن المنحني $M = f(T)$ عند درجة الحرارة العالية نلاحظ أن قيمة التمعنط ثابتة والتي تميز المركب على أنه ذو خاصية مضادة للمغناطيسية الحديدية.

كما نلاحظ التغير الغير خطي في المنحني $\chi = f(T)$ إذن فهي تخضع لقانون كوري مما يؤكد على أن المركب يتمتع بخواص مغناطيسية حديدية.

من المنحنيات $M = f(H)$ يتبين أن درجة حرارة الانتقال المغناطيسي من المغناطيسية الحديدية إلى ضد المغناطيسية الحديدية للمركبين يتغير حسب نسبة مساهمة ذرة Sr في وسط BiFeO_3 مما يمكننا من الجزم أنه توجد علاقة بين الطبيعة الكيمائية والخصائص المغناطيسية للمادة.

7- التطلعات المستقبلية:

تتطلب طريقة مونت كارلو مع نموذج Ising موارد حاسوبية كبيرة ولذلك لابد من تطوير العديد من التقنيات لتحسين أدائها وتقليل الوقت والموارد المطلوبة. استخدام الطريقة لدراسة خواص أخرى للمركبات النانوية مثل الخواص الكهربائية والحرارية وغيرها.

8- المراجع:

- [1] L. Onsager, "Crystal statistics. I. A two-dimensional model with an order-disorder transition", Physical Review, Series II. (1944)
- [2] A. Tanaka & A. Tomiya, Detection of Phase Transition via Convolutional Neural Networks, Journal of the Physical Society of Japan 86, 063001. (2017)
- [3] El Mehdi Salmani, Omar Mounkachi, El mostafa Benchafia, Mustapha Dehmani, Hamid Ez- Zahraouy, Abdelilah Benyoussef, The enhanced magnetic and magnetocaloric properties of DyNi₄Si nanostructures: First Principle study and Monte-Carlo simulation, 2017.
- [4] A.Feraoun and M.Kerouad, Nano-graphene monolayer with higher-order exchange couplings: Monte Carlo study, Faculty of Sciences, University Moulay Ismail, Morocco. 2017.
- [5] Zhou Peng, Wei Wang, Dan Lv, Rui-jia Liu, Qi Li, Magnetic properties of a cubic nanoisland in the longitudinal magnetic field : A Monte Carlo study, 2017.
- [6] Dan Lv, Ye Ma, Xiao-hong Luo, Wei Jiang, Feng Wang, Qian Li, Monte Carlo study of magnetization plateaus and thermodynamic properties of a nano-graphene with a sandwich-like structure in a longitudinal magnetic field, 2020.

[7] J.M. Thijssen, Computational Physics, Cambridge University Press, Cambridge, UK. (2013)

[8] Swendsen, R.H. An introduction to statistical mechanics and thermodynamics. Oxford University Press, 2012.

[9] Alexandrou, Constantia et al. “The critical temperature of the 2D-Ising model through deep learning autoencoders” . In: The European Physical Journal B 93.12 (2020).

الدراسة الديناميكية والتحكم الالخطي بروبات

تفرعي "دلنا" ذو ثلاثة أذرع دورانية

د. مصطفى أصلان* م. محمد صلاح سوده**

* قسم هندسة القيادة الكهربائية، كلية الهندسة الكهربائية والإلكترونية - جامعة حلب
** قسم هندسة التحكم والأتمتة، كلية الهندسة الكهربائية والإلكترونية - جامعة حلب

ملخص البحث

يقدم هذا البحث كل من الدراسة الحركية العكسية والدراسة الديناميكية للروبات التفرعي دلنا بثلاث درجات حرية ذو الأذرع الدورانية باستخدام الجبر الشعاعي ومع استخدام جداء لاغرانج لتقريب المعادلات للحصول على معادلات ديناميكية مبسطة، وذلك للاستفادة منها في دراسة وتصميم متحكم غير خطي وفق منهجية الخطوة الخلفية Back stepping للتحكم بموضع النهاية المنفذة للروبات دلنا. تم إجراء مقارنة بين النموذج الديناميكي المبني في برنامج Matlab والنموذج الميكانيكي المبني في برنامج Solidworks والتحقق من النتائج وفقاً لمبدأ الحفاظ على الطاقة والتي أظهرت تقارب لقوى المحركات وتقارب سلوك كلا النموذجين مع وجود تفاوت بسيط بينهما. تم تطبيق إشارة ذات شكل دائري كإشارة دخل مرجعية لموضع النهاية المنفذة للروبات على محوري الاحداثيات X,Y وتطبيق إشارة ثابتة كإشارة مرجعية بالنسبة للموضع على محور الاحداثيات الشاقولي Z، واستخدام منهجية تخطيط المسار عن طريق إضافة مسار للإشارة المرجعية لتحسين آلية وصول الروبوت إلى المسار الدائري المطلوب. تمت مناقشة النتائج وإجراء المحاكاة باستخدام بيئة المحاكاة Matlab\Simulink، أوضحت نتائج المحاكاة الأداء الديناميكي العالي عند استخدام متحكم الخطوة الخلفية حيث أن النهاية المنفذة تلاحق المسار المرغوب بشكل دقيق مع وجود خطأ أعظمي لانحراف النهاية المنفذة عن المسار بمقدار 0.09mm وزمن استقرار بمقدار 0.4 ثانية.

الكلمات المفتاحية: الدراسة الديناميكية للروبات دلنا، متحكم الخطوة الخلفية، معادلات الحركة العكسية، الروبوت دلنا، تخطيط المسار.

Dynamic Study and Nonlinear Control of a "Delta" Parallel Robot With Three Rotating Arms

Moustapha Asslan *

Mohammad Salah Souda **

**Dept. of Electrical Drives, Faculty of Electrical and Electronic Engineering, University of Aleppo*

***Dept. of Control and Automation, Faculty of Electrical and Electronic Engineering, University of Aleppo*

Abstract

In This research the inverse kinematic and the dynamic of parallel delta robot was presented by using vector algebra and Lagrangian multiplier to approximate the equations to obtain simplified dynamic equations. In order to benefit from it in studying and designing of a nonlinear controller according to back stepping methodology to control the position of the robot end-effector. A comparison was made between the dynamic model and the mechanical model in order to verified according to the principle of energy conservation, which showed a convergence of the motor forces and the behaviour of both models with a slight discrepancy between them. A circular shape was applied as a reference input signal for the position on the X,Y axes, and a fixed signal was applied on the vertical coordinate Z axis, in addition a path planning methodology was used to improve the end-effector to reach the desired circular shape. The results were discussed and the simulation of the system response was performed by Matlab\Simulink. as a result the simulation show the high dynamic performance, as the end-effector follows the desired path With a maximum deviation error of 0.09 mm and a stabilize time of 0.4 second.

Keywords: The dynamic study of the delta robot, Back-stepping control, delta robot, reverse kinematic equations of delta robot, path planning.

1. مقدمة

إن الحاجة إلى استبدال العنصر البشري في عملية الإنتاج الصناعي أسفرت عن ظهور أشكال جديدة من الروبوتات والتي يمكن استخدامها في فئات جديدة من العمليات الإنتاجية الحديثة منها الروبوتات ذات الأذرع التفرعية والتي يمكن أن تأمن زيادة في سرعة ودقة الإنتاج وذلك بالمقارنة مع الروبوتات الكلاسيكية.

تم في هذه الدراسة اعتماد نموذج روبوت دلتا من طراز IRB360 وهو من إنتاج شركة (FlexPicker ABB) والتي تعتبر الشركة الرائدة في مجال تقنيات الالتقاط والتعبئة الآلية عالية السرعة.

إن النموذج من طراز IRB360 هو أسرع روبوت دلتا صناعي في العالم يقدم موثوقية ودقة عالية، حيث يمكن لـ IRB360 العمل بسرعة عالية جداً ضمن مساحات العمل الخاصة به.

ومع ظهور مثل هذا النوع من الروبوتات بأن هناك حاجة إلى دراسة ديناميكية لهذه الأنظمة والتي تختلف كلياً عن سابقتها من الروبوتات ذات الأذرع التسلسلية حيث أن دراسة مثل هذه الأمور أكثر تعقيداً بكثير ويعود السبب إلى الارتباط بين أذرع الروبوت المتفرعة وتغير مركز توازن النهاية المنقذة مع تغير موضعها.

بالإضافة إلى صعوبة عملية النمذجة وتطبيق منهجيات التحكم بسبب لا خطية وتعقيد المعادلات الديناميكية للنظام ولأن تطبيق تغير بسيط بموضع أو حالة أحد الأذرع يحدث فرقا ملحوظاً بموضع النهاية المنقذة فإن منهجية التحكم تقوم بتأمين استجابة مناسبة تضمن تقليص إشارة الخطأ إلى الحد الأدنى لموضع أذرع الروبوت.

إن طريقة الجبر الشعاعي تعتبر طريقة جيدة وسهلة لتمثيل أذرع الروبوتات وفي إيجاد معادلات الحركة والتي من خلالها يمكننا فهم آلية تغير موضع النهاية المنقذة عند تغير موضع الأذرع التفرعية.

يستخدم هذا البحث مفهوم الجبر الشعاعي لإيجاد معادلات الحركة العكسية والتي استخدمت في حساب الموضع المرغوب للأذرع التفرعية الثلاثة عند موضع مرغوب للنهاية المنفذة ضمن جملة الاحداثيات الديكارتية. أما من أجل التحكم بالنهاية المنفذة للروبوت المدروس، فقد تم استخدام منهجية التحكم بالخطوة الخلفية ضمن مستوى التحكم بزوايا مفاصل الأذرع الدورانية.

2. هدف البحث

تكمن أهمية البحث في شقين اثنين، الشق الأول يتعلق بدراسة النموذج الرياضي الديناميكي للروبوت دلتا ذو الأذرع الدورانية، ويتعلق الشق الثاني بتصميم متحكم لا خطي وفق منهجية التحكم بالخطوة الخلفية لملاحقة المسار المطلوب ومناقشة نتائج استجابة النظام وموضع النهاية المنفذة، وعرض النتائج وإجراء المناقشة لاستجابة الروبوت عند تطبيق مسار دائري كإشارة دخل مرغوبة للنظام.

3. مواد وطرق البحث

سيتم بداية عرض طريقة استنتاج معادلات الحركة العكسية للنظام المدروس باستخدام مفهوم الجبر الشعاعي. بعد ذلك سيتم استنتاج النموذج الديناميكي بالاعتماد على قانون نيوتن للحركة، ليتم في الخطوة التالية تبسيط المعادلات الديناميكية للحركة وذلك باستخدام قوانين التوازن وعلاقة جداء لاغرانج.

في الجزء الثاني من البحث سيتم دراسة تصميم متحكم غير خطي للتحكم بالنهاية المنفذة للروبوت بالاعتماد على منهجية الخطوة الخلفية، ومن ثم محاكاة النظام في بيئة MATLAB\Simulink وعرض ومناقشة النتائج.

4. دراسة النموذج الرياضي للروبوت

1.4 الدراسة الهندسية والافتراضات

يتألف الروبوت دلتا من ثلاث أذرع ذات حركة دورانية وكل ذراع تحتوي على زوج من الوصلات حرة الحركة لتشكل بذلك ست وصلات مثبتة جميعها من الطرف الآخر بقطعة سنطلق عليها المنصة المتحركة والتي يتم عليها تثبيت النهاية المنفذة.

- إن الأذرع المثبتة على قاعدة الروبوت تميل عن بعضها بزاوية 120° ضمن المستوي $X-Y$ ، تلك الأذرع لديها نفس الطول والتي سنطلق عليها L .
- جميع أزواج وصلات الأذرع الثلاثة لها نفس الطول.
- النهاية المنفذة مثبتة بالضبط بمنتصف المنصة المتحركة (moving platform).

هنالك بعض القيود الحركية في الروبوت "دلتا". أحدها الزاوية العظمى للذراع والتي يمكن بلوغها، مع الأخذ بعين الاعتبار أن هذه الزاوية تقلل من سرعة المنصة المتحركة مقارنةً مع الزيادة السريعة لسرعة حركة الحامل [1].

بالإضافة إلى أن الزوايا الصغيرة تزيد من ثبات النقطة الفعالة، على خلاف الروبوتات التسلسلية والتي تكون السرعات والدقة بها ثابتة مع اختلاف زوايا الأذرع [1].

2.4 الجبر الشعاعي لإيجاد معادلات الحركة العكسية

نظرية الأشعة هي إحدى الطرق الممكنة لإيجاد الحل الرياضي للروبوت. تعتمد هذه الطريقة على تمثيل الوصلات والأذرع بأشعة يمتد كل شعاع من بداية إلى نهاية الوصلة المسببة للحركة أو الانتقال. حيث أن الشعاع في الدراسة الحركية سيمثل مقدار من الانتقال الخطي [2] [3].

يتم تحديد كل وصلة أو ذراع ثابتة أو متغيرة بشعاع يمتد على طول الانتقال ومن ثم إيجاد مقدار الانتقال أو موضع النهاية المنفذة من خلال شعاع يربط بين مبدأ الأحداثيات

والنهاية المنفذة لروبوت ويمكن حساب بارامترات هذا الشعاع عن طريق جمع جميع الأشعة السابقة والمعرفة للوصلات والأذرع.

وبحسب علاقة جمع الأشعة \overrightarrow{OE} يمثل الشعاع الواصل من مبدأ الأحداثيات (0,0,0) وإلى النهاية المنفذة (End effector) وفق العلاقة التالية:

$$\overrightarrow{OE} = \left(\sum_{i=1}^{E-1} \overrightarrow{v_{i-1}^i} \right) + [R] \times \overrightarrow{v_{E-1}^E} \quad (1)$$

حيث تمثل $i-1$ بداية كل شعاع و i نهاية كل شعاع

في حين أن المصفوفة $[R]$ تمثل مصفوفة التدوير لجملة إحداثيات النهاية المنفذة منسوبةً إلى جملة الإحداثيات المرجعية.

ومن خلال إسقاط الأشعة على المحاور الإحداثية يمكن كتابة معادلات تربط بين الموضع للنهاية المنفذة ومفاصل وأجزاء النموذج.


$$|v|_X = |v| \times \cos \varphi \times \sin \gamma \quad (2)$$

$$|v|_Y = |v| \times \sin \varphi \times \sin \gamma \quad (3)$$

$$|v|_Z = |v| \times \cos \gamma \quad (4)$$

حيث

- φ الزاوية بين مسقط الشعاع على المستوي (X,Y) مع المحور X ودوران حول المحور Z.
- γ زاوية الشعاع مع المحور الشاقولي Z ودوران حول المحور Y.
- $|v|$ طول الشعاع الخطي.



الشكل (1) فرض الأشعة بالنسبة لإحدى الأذرع

ومن أجل روبوت بثلاث أذرع متفرعة ينتج لدينا ثلاث معادلات شعاعية

$$\overrightarrow{OE} = \overrightarrow{Rb} + \overrightarrow{C} + \overrightarrow{L} + \overrightarrow{P} + [R] \times \overrightarrow{Re} \quad (5)$$

حيث [R] مصفوفة تدوير جملة إحداثيات النهاية المنفذة حول جملة الإحداثيات X,Y,Z

ومن أجل الروبوت المدروس

$$[R] = [Rz(\alpha)] \cdot [Ry(\beta)] \quad (6)$$

$$\cdot [Rx(\gamma)] = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

وبالإسقاط على جملة الاحداثيات الديكارتية.

$$PX = (Rb - Re) \times \cos \theta_i + L \times \cos \theta_i \times \sin \gamma_i \quad (7)$$

$$+ P \times \cos \theta p_i \times \sin \gamma p_i$$

$$PY = (Rb - Re) \times \sin \theta_i + L \times \sin \theta_i \times \sin \gamma_i \quad (8)$$

$$+ P \times \sin \theta p_i \times \sin \gamma p_i$$

$$PZ = L \times \cos \gamma_i + P \times \cos \gamma p_i - C \quad (9)$$

حيث أن i رقم الذراع المتحركة (1,2,3) و γ_i تمثل الزاوية بين الذراع والمحور الشاقولي Z.

و θ_i تمثل الزاوية بين الذراع ومحور الاحداثيات الافقي X

$$\text{حيث } \theta_1 = \frac{\pi}{3}, \theta_2 = -\frac{\pi}{3}, \theta_3 = \pi$$

ومن الحل للمشارك للمعادلات (7) (8) (9) يمكن إيجاد معادلات الحركة العكسية.

$$\gamma_i = \cos^{-1} \left(\frac{\alpha_i \times \sqrt{\alpha_i^2 + Z_i^2 - \delta_i^2} + Z_i \times \delta_i}{\alpha_i^2 + Z_i^2} \right) \quad (10)$$

حيث أن

$$\alpha_i = X_i \times \cos \theta_i + Y_i \times \sin \theta_i \quad (11)$$


$$\delta_i = \frac{X_i^2 + Y_i^2 + Z_i^2 + l^2 - p^2}{2 \times l} \quad (12)$$

$$X_i = Px - (Rb - Re) \times \cos \theta_i \quad (13)$$

$$Y_i = Py - (Rb - Re) \times \sin \theta_i \quad (14)$$

$$Z_i = Pz + c \quad (15)$$

وإن المعادلة رقم (10) تمثل معادلات الحركة العكسية للروبوت للأذرع المتحركة الثلاثة ومن خلالها يتم إيجاد احتمالات الأذرع المسببة لحركة النهاية الفعالة عند معرفة موضع النهاية الفعالة منسوبةً إلى جملة الاحداثيات المرجعية. وتستخدم هذه الدراسة لحساب الزوايا المرغوبة للأذرع المتحركة من أجل موضع مرغوب للنهاية الفعالة في الفراغ.



الشكل (2) يوضح زوايا الأذرع المتحركة مع المحاور الإحداثية

3.4 النموذج الديناميكي للروبوت المدروس

إن هندسة التحكم بالروبوتات تهتم بتحريك النهاية المنفذة إلى الموضع المطلوب، باتباع مسارات محددة مسبقاً. والذي يمكن تحقيقه من خلال معرفة النموذج الهندسي الذي يربط مفاصل الروبوت -يمكن أن تكون زوايا أو مقدار انسحابي- مع النهاية المنفذة [4].

تُمكن النماذج الديناميكية من تصميم الحركات بموضع النهاية المنفذة وسرعتها المطلوبة، وغالباً ما تُستخدم في مهام الانتقال لموضع النهاية المنفذة، وللمزيد من المهام المتقدمة، مع ديناميكيات الحركة العالية هناك حاجة إلى معرفة النموذج الديناميكي ووحدات التحكم القائمة على النموذج الديناميكي، يربط النموذج الديناميكي للروبوت التسارع المشترك بمحصلة مجموع القوى، وهو امتداد لقانون نيوتن الثاني (وقوانين أويلر للحركة) والذي يعرف بالعلاقة [4].

$$\sum \vec{F} = m\vec{a} \quad (16)$$

مجموع القوى المؤثرة على جسم تساوي كتلة الجسم مضروباً بالتسارع

$$\sum \vec{\tau} = J\vec{\alpha} \quad (17)$$

ومن أجل قوى عزوم دورانية فإن مجموع عزوم القوى المؤثرة على جسم تساوي عزم عطالة الجسم مضروباً بالتسارع الزاوي.

إن النظام الذي تشكله روابط الروبوت. فالقوة وتسارع نواقل الحركة لكل مفصل، والكتلة عبارة عن مصفوفة والتي تعرف بمصفوفة القصور الذاتي. هذه العلاقات غير خطية تعتمد على تصميم الروبوت ووضعيته، وتعتمد مصفوفة القصور الذاتي أيضاً على المعلومات الديناميكية للروبوت: الكتل ومراكز الكتلة وقوى التوتر وقوى عزوم الدوران تشمل قوى مشغلات الروبوت وقوى الاحتكاك وقوى أخرى [4].

من معرفة ودراسة النموذج الديناميكي يتيح إمكانية دراسة تقنيات ومنهجيات التحكم المتقدمة المختلفة.

ومن العلاقة (17) يمكن إيجاد محصلة القوى المأثرة على أذرع الروبوت الثلاثة.

$$t_i + m_1 \cdot \nabla g + \left(2m_p + \frac{m_e}{3}\right) \cdot \nabla g + \nabla f g_i = J \cdot \ddot{\gamma}_i \quad (18)$$

$$t_i + \left\{m_1 \cdot L_1 + \left(2m_p + \frac{m_e}{3}\right) \cdot L\right\} \cdot \sin \gamma_i \cdot g + L \cdot f g_i = J \cdot \ddot{\gamma}_i \quad (19)$$

حيث أن J يعبر عن عزم العطالة الكلي للذراع

$$J = \frac{1}{2} \left(m_l + 2m_p + \frac{m_e}{3}\right) \times L^2 \quad (20)$$

وحيث أن ml كتلة الذراع المتحركة ويقاس بـ (Kg)

mp كتلة الوصلة المتحركة الواحدة ويقاس بـ (Kg)

me كتلة المنصة المتحركة والحاملة للنهاية المنفذة ويقاس بـ (Kg)

$L1$ المسافة بين محور دوران الذراع و مركز ثقلها ويقاس بـ (m)

L طول الذراع الدورانية ويقاس بـ (m)

g ثابت الجاذبية الأرضية ويقاس بـ (N)

$\ddot{\gamma}_i$ التسارع الزاوي للذراع الدورانية ويقاس بـ (rad/sec^2)

t_i قوة العزم الدوراني للذراع ويقاس بـ $(N.m)$

وحيث أن القوى fg_i هي جزء من قوة ثقل المنصة والوصلات المتحركة موزعة على كل من الأذرع الثلاثة للروبوت بشكل متغير وذلك بحسب موضع المنصة بالنسبة للأذرع المذكورة.

وبما أن القوى الثلاثة السابقة هي أجزاء من الكتلة الكلية للمنصة المتحركة بالإضافة إلى كتلة الوصلات الستة يمكننا القول

$$fg_1 + fg_2 + fg_3 = (m_e + 6m_p) \times g \quad (21)$$

وبما أن العلاقة السابقة محققة دوماً أي أن الترابط الميكانيكي يحاول دائماً موازنة الكتلة عند نقطة توازن جديدة عند الحركة والاستقرار وذلك الأمر محقق عند عدم وجود تأثير خارجي على الجسم المدروس.

وبذلك يمكن دراسة الجسم عند حالة التوازن لإيجاد كل من القوى fg_1 و fg_2 و fg_3

من أجل دراسة حالة التوازن يجب أن يتحقق شرطين الأول

$$\sum \vec{F} = 0$$

مجموع القوى الماثرة على حركة جسم مساوية للصفر والجسم لدينا هنا هو المنصة المتحركة.

والتي تقودنا إلى نفس العلاقة المذكورة مسبقاً

$$fg_1 + fg_2 + fg_3 - (m_e + 6m_p) \times g = 0 \quad (22)$$

والشرط الثاني

$$\sum \vec{\tau} = 0$$

محصلة العزوم حول نقطة التوازن مساوي للصفر

إن الشرطين السابقين يضمنان ثبات الجسم أي السرعة مساوي للصفر والتسارع مساوي للصفر

وتعطينا علاقة مجموع العزوم للوصلات المتحركة حول نقطة توازن عند النهاية المنفذة العلاقة.

$$\sum_{i=1}^3 \vec{\tau}_i = \sum_{i=1}^3 \vec{p}_i \times \vec{f}g_i = 0 \quad (23)$$

وبأخذ القيمة الكبرى لعلاقة جداء لاغرانج من أجل ثلاث معادلات قيد والتي تعطى كما يلي [5]

$$\nabla f = \lambda_1 \nabla \Gamma_1 + \lambda_2 \nabla \Gamma_2 + \lambda_3 \nabla \Gamma_3 \quad (24)$$

بالنظر إلى النموذج نلاحظ وبسبب ارتباط الأذرع مع بعضها البعض بالمنصة المتحركة والحاملة للنهاية المنفذة يوجد لدينا فرق أعظمي بين زاويتي كل ذراعين حيث أن

$$-\frac{\pi}{2} \leq (\gamma_1 - \gamma_2) \leq \frac{\pi}{2} \quad (25)$$

حيث $\frac{\pi}{2}$ هو أكبر فرق بين زاويتين لذراعين يمكن تحقيقه وذلك عندما تكون النهاية الفعالة تقع على إحدى رؤوس مساحة العمل الثلاثة.

ومنه

$$(\gamma_1 - \gamma_2)^2 \leq \frac{\pi^2}{4} \quad (26)$$

ومنه يمكننا كتابة

$$\Gamma_1 = (\gamma_1 - \gamma_2)^2 - F1(X, Y, Z) = 0 \quad (27)$$

وبالمثل

$$\Gamma_2 = (\gamma_1 - \gamma_3)^2 - F2(X, Y, Z) = 0 \quad (28)$$

$$\Gamma_3 = (\gamma_2 - \gamma_3)^2 - F3(X, Y, Z) = 0 \quad (29)$$

من العلاقة (24)

$$\nabla f_{(\gamma_1, \gamma_2, \gamma_3)} = \lambda_1 \nabla \Gamma_1 + \lambda_2 \nabla \Gamma_2 + \lambda_3 \nabla \Gamma_3 \quad (30)$$

حيث

$$\lambda_1 = \lambda_2 = \lambda_3 = \lambda$$

وذلك بسبب تماثل الأذرع الثلاث والوصلات الست بين الأذرع والمنصة والتمائل بطريقة الربط والكتل وحيث أن λ مقدار يمكن اعتباره ثابتاً من أجل النقاط المأخوذة.

$$\nabla \Gamma_i = \frac{\partial \Gamma_j}{\partial \gamma_i} \quad (31)$$

وبالتالي

$$f_{gi} = 2\lambda(3\gamma_i - \gamma_1 - \gamma_2 - \gamma_3) \quad (32)$$

ومنه يمكن إيجاد تقريب لقيمة λ ليحقق التابع زاوية عظمى حيث تم حسابها باستخدام

برنامج matlab

$$\lambda = - \frac{\left(2m_p + \frac{m_e}{3}\right) \times g}{2\pi} \quad (33)$$

بالتعويض في (19)

$$t_i = J \times \ddot{\gamma}_i - \left\{ m_1 \times L_1 + \left(2m_p + \frac{m_e}{3}\right) \times L \right\} \times \sin \gamma_i \times g - 2 \times L \times \lambda(3\gamma_i - \gamma_1 - \gamma_2 - \gamma_3) \quad (34)$$


وبعد تعويض ثوابت النموذج

$$\ddot{\gamma}_i = 27 \times t_i + 45 \times \sin \gamma_i - 6 \times (3\gamma_i - \gamma_1 - \gamma_2 - \gamma_3) \quad (35)$$


حيث إن العلاقة (35) تعبر عن المعادلة لديناميكية الحركة من أجل إحدى أذرع الروبوت الثلاثة.

4.4 مقارنة بين النموذج الميكانيكي والنموذج الديناميكي


من أجل معرفة التفاوت بين النموذجين تم تطبيق مسارين مختلفين الأول خطي والثاني مسار بشكل دائري ضمن المستوي (x,y) من أجل سرعة وتسارع معلومين وتم قياس مقدار عزم القوة كخرج للنظام، وقد تم التحقق من النتائج وفقاً لمبدأ الحفاظ على الطاقة حيث أن مجموع عزوم قوى المحركات مساوي لمجموع عزوم عطالة ثقل الأذرع، ومنه يمكن ملاحظة تأثير مقدار عزم القوة المقدر واللازم للحركة على المسار المفروض.




الشكل (3) العزوم المقدره للأذرع الثلاثة للنموذج الميكانيكي عند تطبيق مسار خطي



الشكل (4) العزوم المقدره للأذرع الثلاثة للنموذج الديناميكي عند تطبيق مسار خطي



الشكل (5) العزوم المقدرة للأذرع الثلاثة للنموذج الميكانيكي عند تطبيق مسار دائري



الشكل (6) العزوم المقدرة للأذرع الثلاثة للنموذج الديناميكي عند تطبيق مسار دائري

الاختلاف الذي يمكن ملاحظته هو وجود إزاحة بسيطة بمقدار عزوم القوى بين النموذجين عند اقتراب المنصة المتحركة إلى أطراف مساحة العمل ويعود السبب إلى الاختلاف في القيم العشرية للأوزان والأطوال وقوة الجاذبية والتقريب الذي أجريناه لقوى الارتباط والثقالة للوصلات وهي أخطاء تسبب زيادة بمقدار التسارع للمنصة المتحركة. في حين أن التقريب الذي يتم من خلال عدم مراعاة القصور الذاتي للروابط ومراكز ثقل الوصلات ليس له تأثير كبير بسبب سرعات الدوران المنخفضة للوصلات والمفاصل، وهي أشياء تحدث عند ظروف التشغيل الطبيعية [1] [2].

وبرغم من هذه الاختلافات البسيطة نلاحظ وبشكل واضح التقارب الكبير لسلوك كلا النموذجين في ظروف العمل المختلفة وعليه يمكن اعتبار النموذج الديناميكي ناجح وصحيح من أجل دراسة سلوك النموذج المدروس وخوارزميات التحكم الحديثة.


5. تصميم نظام التحكم بالروبوت المدروس

1.5 مسار الإشارة المرغوبة

إن المسار المرجعي المختار للدراسة هو عبارة عن مسار دائري بنصف قطر 15 سم وعلى ارتفاع 10- سم، وقد تم اختيار هذا النوع من المسارات على اعتباره مسار ذو علاقة غير خطية. يمكن من خلال هذا الأمر تحديد مدى قوة المتحكم المدروس حيث تفشل المتحكمات الكلاسيكية بتقديم الأداء المطلوب عند تطبيق مثل هذا النوع من المسارات.

ونلاحظ أن قيمة الخطأ عند بداية التشغيل تكون أعظمية الأمر الذي يسبب تغيرات كبيرة في استجابة نظام التحكم ويعود السبب إلى ابتعاد الموضع الحقيقي للنهائية الفعالة عن الموضع المرغوب (في دراستنا هذه محيط الدائرة) والذي يسبب تغيرات كبيرة في أنظمة التحكم وقد تسبب اهتزازات أو انحراف عن المسار المطلوب عند حدوث فارق بمسافات الانتقال للمسارات المطلوبة.

يمكن حل هذا النوع من المشاكل عن طريق استخدام منهجية تخطيط المسار حيث تم اتباع آلية مبسطة وذلك من خلال إضافة مسار أو عدة مسارات مساعدة إلى مسار الإشارة المرجعية تصل بين النقطة الحقيقية للنهاية الفعالة والإشارة المرغوبة. يوضح الشكل (7) كيفية إضافة هذا النوع من المسارات.



الشكل (7): مسار الإشارة المرغوبة مع استخدام منهجية تخطيط المسار

وقد تم ذلك برمجياً بإضافة مسارين إلى المسار الدائري المرغوب الأول عبارة عن مسار يصل بين موضع النهاية المنفذة عند بداية التشغيل ومركز الدائرة والمسار الثاني يصل بين مركز الدائرة ونقطة تقع على محيطها.

2.5 التحكم بالروبوت وفق منهجية الخطوة الخلفية

تعتبر منهجية التحكم بالخطوة الخلفية من طرق التحكم المتقدمة والتي تعتمد في استنتاج قانون التحكم على معيار ليابونوف للاستقرار، حيث يتم أولاً تشكيل تابع ليابونوف على

أن يكون معرف موجب. من أجل تحقيق استقرار النظام فيجب أن يكون مشتق تابع ليابونوف معرف سلبى [6] [7] [8] [9].

من أجل تنظيم الموضع الزاوي لإحدى الأذرع (في الحلقة الخارجية) نفرض تابع ليابونوف على النحو الآتي:

$$v_i = \frac{1}{2} \varepsilon_1 e_i^2 + \frac{1}{2} \varepsilon_2 z_i^2 \quad (36)$$

حيث أن:

$$z_i = \int e_i dt \quad (37)$$

تم اختيار تابع ليابونوف الموضح من خلال العلاقة (36) على هذا النحو حيث يتألف من حدين، الأول حد تناسبي والذي يوفر سرعة في الاستجابة عند التغيرات المفاجئة لقيمة الخطأ والحد الآخر تكاملي والذي يضمن زيادة في استقرار النموذج وتقليل قيمة الخطأ الستاتيكي بالإضافة إلى حذف تأثير التفاوت بين النموذج الديناميكي المعتبر للنظام والنموذج الميكانيكي الحقيقي.

حيث أنه باشتقاق العلاقة (37) نجد:

$$\dot{z}_i = e_i \quad (38)$$

علاقة الخطأ e_i هي:

$$e_i = \gamma_{i-ref} - \gamma_i \quad (39)$$

باشتقاق العلاقة (39) نجد:

$$\dot{e}_i = \dot{\gamma}_{i-ref} - \omega_i \quad (40)$$

حيث ω_i يعبر عن السرعة الزاوية لإحدى الأذرع.

وباشتقاق العلاقة (36) وتعويض العلاقة (40) نجد:

$$\dot{v}_i = \varepsilon_1 (\dot{\gamma}_{i-ref} - \omega_i) e_i + \varepsilon_2 \dot{z}_i z_i \quad (41)$$

نضيف ونطرح $(k_1 e_i^2)$ وبعد تعويض العلاقة (38) نجد:

$$\dot{v}_i = \varepsilon_1 \gamma_{i-ref} \dot{e}_i - \varepsilon_1 \omega_i e_i + \varepsilon_2 e_i z_i + k_1 e_i^2 - k_1 e_i^2 \quad (42)$$

بإصلاح العلاقة (42) نجد:

$$\dot{v}_i = -k_1 e_i^2 + e_i (\varepsilon_1 \gamma_{i-ref} \dot{e}_i - \varepsilon_1 \omega_i + \varepsilon_2 z_i + k_1 e_i) \quad (43)$$

لكي يكون مشتق تابع ليايونوف في العلاقة (43) معرف سالب يجب ان يتحقق:

$$\omega_{ref} = (\gamma_{i-ref} \dot{e}_i + \varepsilon_2 z_i + k_1 e_i) / \varepsilon_1 \quad (44)$$

من أجل تنظيم السرعة الزاوية (في الحلقة الداخلية) لإحدى الأذرع، نفرض تابع جديد مشابه للعلاقة (36).

$$v_j = \frac{1}{2} \varepsilon_3 e_j^2 + \frac{1}{2} \varepsilon_4 z_j^2 \quad (45)$$

حيث أن:

$$z_j = \int e_j dt \quad (46)$$

حيث أنه باشتقاق العلاقة (46) نجد:

$$\dot{z}_j = e_j \quad (47)$$

علاقة الخطأ e_j هي:

$$e_j = \omega_{j-ref} - \omega_j \quad (48)$$

باشتقاق العلاقة (48) نجد:

$$\dot{e}_j = \omega_{j-ref} \dot{e}_j - \left(27t_j + 45 \sin \gamma_j - 6(3\gamma_j - \gamma_1 - \gamma_2 - \gamma_3) \right) \quad (49)$$

وباشتقاق العلاقة (45) وتعويض العلاقة (49) نجد:

$$\dot{v}_j = \varepsilon_3 \left(\omega_{j-ref} \dot{e}_j - 27t_j - 45 \sin \gamma_j \right) \quad (50)$$

$$+ 6(3\gamma_j - \gamma_1 - \gamma_2 - \gamma_3) e_j + \varepsilon_4 e_j z_j$$

نضيف ونطرح $(k_2 e_j^2)$ وبعد تعويض العلاقة وإصلاح العلاقة نجد:

$$\dot{v}_j = -k_2 e_j^2 + e_j \left(\varepsilon_3 \omega_{j-ref} \dot{e}_j - 27\varepsilon_3 t_j - 45\varepsilon_3 \sin \gamma_j \right) \quad (51)$$

$$+ 6\varepsilon_3 (3\gamma_j - \gamma_1 - \gamma_2 - \gamma_3) + \varepsilon_4 z_j + k_2 e_j^2$$

إن مشتق تابع لياونوف لحقلة التنظيم الداخلية يجب أن يكون أيضاً معرف سالب،
ولذلك يجب أن يتحقق:

$$t_j = (\varepsilon_3 \omega_j \dot{\tau}_{ref} + 6\varepsilon_3(3\gamma_j - \gamma_1 - \gamma_2 - \gamma_3) - 45\varepsilon_3 \sin \gamma_i + \varepsilon_4 z_j + k_2 e_j) / (27\varepsilon_3) \quad (52)$$


حيث أن: k, ε ثوابت تجريبية موجبة.

6. النتائج والمناقشة:


تم في البداية استخدام برنامج solidworks لبناء النموذج الميكانيكي، ومن ثم، تم تصدير هذا النموذج لبرنامج matlab باستخدام مكتبة Simmechanics لإجراء المحاكاة، بعد إضافة المدخلات والمخرجات اللازمة وإضافة نظام التحكم المقترح ومعادلات الحركة العكسية.

1.6 نتائج المحاكاة عند استخدام منهجية التحكم بالخطوة الخلفية:


تم تحديد المسار المرجعي على يكون بشكل دائرة على ارتفاع محدد كما هو موضح في الشكل (7)، يوضح الشكل (9) استجابة الروبوت ضمن جملة احداثيات x, z و y, z ، ويبين الشكل (8) استجابة الروبوت لملاحقة النهاية المنفذة للموضع المطلوب ضمن جملة احداثيات x, y, z ، ويوضح الشكل (10) استجابة النظام لتنظيم زوايا الأذرع الحاملة للنهاية المنفذة.




الشكل (8): استجابة الروبوت ضمن جملة احداثيات x, y, z عند استخدام متحكم BS




الشكل (9): استجابة الروبوت ضمن جملة احداثيات x, z و x, y عند استخدام متحكم BS



الشكل (10): استجابة أذرع الروبوت الثلاثة عند استخدام متحكم BS



الشكل (11): تغيرات قيمة الخطأ للأذرع من أجل تنظيم موضع الأذرع الثلاثة عند استخدام متحكمات BS



الشكل (12): تغيرات القوة المطبقة على الأذرع من أجل تنظيم الموضع عند استخدام متحكمات BS



الشكل (13): تغيرات قيمة الخطأ للموضع للنهاية المنفذة عند استخدام متحكمات BS

2.6 المناقشة:

نلاحظ من الشكل (11) أن نظام التحكم يحقق أداءً ديناميكيًا عالٍ وأن زوايا الأذرع الثلاثة تلاحق الزوايا المطلوبة، وبخطأ ستاتيكي لا يتجاوز 0.01 درجة، وبخطأ أعظمي لا يتجاوز 0.08 درجة وكما نلاحظ من الشكل (13) أن النظام يحقق ملاحقة للموضع المطلوب بخطأ ستاتيكي لا يتجاوز 0.02mm وخطأ أعظمي 0.09mm دون وجود انحراف عن المسار المرغوب، ويعود السبب في ظهور هذا المقدار الطفيف من الخطأ بسبب التقريب العشري لقيم الأوزان وأطوال الوصلات والأذرع المتحركة، بالإضافة إلى التفاوت الناتج عن التقريب الذي أجريناه لديناميكية النظام وإهمال قوى القصور الذاتي للوصلات والأذرع.

ومن الشكل (13) نلاحظ أيضاً أن النظام يحقق ملاحقة لمسار الإشارة بزمن استقرار 0.4 ثانية ويعود السبب لقدرة نظام التحكم على الملاحقة بزمن استجابة منخفض كونه يأخذ بعين الاعتبار لا خطية النظام المدروس ووجود حلقتي تحكم داخلية وخارجية (التحكم بالسرعة الزاوية والتحكم بالموضع الزاوي).

ونلاحظ من النتائج السابقة أن المنحكم وفق منهجية الخطوة الخلفية قدم أداءً ديناميكياً عالياً حيث نلاحظ انطباق شبه تام لمسار حركة النهاية المنفذة على مسار الإشارة المرغوبة مع وجود فوارق بسيطة في نمطية الاستجابة حيث لوحظ أن نظام التحكم وفق منهجية الخطوة الخلفية أعطى انحرافاً عن المسار عند الانعطاف بنسبة 0.09%، فضلاً عن عدم وجود أي اهتزازات في استجابة الروبوت عند الملاحقة لمسار الإشارة الدائري المطلوب.

7. الخاتمة والاستنتاجات

تم في هذا البحث إلقاء الضوء على كل من الدراسة الحركية ومعادلات الحركة العكسية وذلك باستخدام التحليل الرياضي والجبر الشعاعي. ومن ثم إيجاد معادلات القيد الديناميكية من خلال قانون نيوتن الثاني للحركة وقوانين التوازن الميكانيكية ومنه يمكن إيجاد تابع ديناميكي مبسط وقد أعطت نتائج المقارنة بين النموذج الديناميكي المبسط المستخرج والنموذج الميكانيكي والمبني باستخدام برنامج Solidworks وبرنامج المحاكاة matlab تقارب كبير في القيم والاستجابة فقد تم تطبيق مسارين خطي وآخر دائري للحركة ولوحظ أن كلا النموذجين يسلكان نفس السلوك وبتفاوت بسيط وعليه تم اعتبار النموذج الديناميكي صحيح وقابل للاستخدام. تم تصميم نظام التحكم وفق منهجية الخطوة الخلفية والذي أظهر تفوقاً واضحاً من حيث السرعة والدقة لملاحقة المسار المطلوب وقد قدم أداءً ديناميكياً عالياً وخطأً ستاتيكي منخفض لا يتجاوز 0.02%، كما أظهرت النتائج فعالية متحكم الخطوة الخلفية من حيث التجاوز الأعظمي للمسار المطلوب عند الانعطاف فضلاً عن عدم وجود أي اهتزازات في استجابة النظام.

References

- [1] BORELLI, V., 2018- **Kinematic and dynamic analysis of a machine for additive manufacturing**. POLITECNICO DI TORINO.
- [2] COLOMBO, F. and LENTINI, L., 2020 June- **Prismatic Delta Robot: A Lagrangian Approach**. Springer, In International Conference on Robotics in Alpe-Adria Danube Region (pp. 315-324), Cham.
- [3] R.M.KHAN. 2013- **Analytical Geometry and Vector Algebra**. New Central Book Agency, India.
- [4] BRESSER, G., 2015- **Improving the Stewart Platform Design of the Ampelmann System for Asymmetric Load Cases**. delft university of technology, Netherlands.
- [5] GORDON, G., 2016- **Linear programming, lagrange multipliers, and duality**. International Journal of Mechanical Engineering and Robotics Research, 10(9).
- [6] TAN, Y., CHANG, J. and TAN, H., 2003- **Adaptive backstepping control and friction compensation for AC servo with inertia and load uncertainties**. IEEE Transactions on Industrial Electronics, 50(5), pp.944-952.
- [7] YOU, X., CHEN, W., YU, S. and WU, X., 2011 June- **Dynamic control of a 3-DOF cable-driven robot based on backstepping technique**. In 2011 6th IEEE Conference on Industrial Electronics and Applications (pp. 1302-1307). IEEE.
- [8] KARABACAK, M. and ESKIKURT, H.I., 2012- **Design, modelling and simulation of a new nonlinear and full adaptive backstepping speed tracking controller for uncertain PMSM**. Applied Mathematical Modelling, 36(11), pp.5199-5213.
- [9] WEIRONG Yang, WEIDONG Liu, and WEN Tang. 2022- **Impedance and Backstepping Controller of Delta Robot Trajectory Tracking**. IEEE.

دراسة تجريبية لتحسين معامل أداء مضخة حرارية ماء-هواء باستخدام نظام استعادة الحرارة من غلاف الضاغط

طالب الدراسات العليا: ميسم زريفه

كلية: الهمك - جامعة: البعث

الدكتور المشرف: سهيل حنا

الملخص

تم في هذا البحث اختبار نظام استعادة الحرارة من السطح الخارجي لغلاف الضاغط لمضخة حرارية مجهزة تجريبياً تستخدم مبخراً حلزونياً، ومخصصة لتدفئة حجرة اختبارية . حيث يتكون نظام استعادة الحرارة المقترح من وحدة امتصاص الحرارة من غلاف الضاغط (مبادل حراري على شكل قميص يغلف جزء من غلاف الضاغط) ومضخة تسريع المياه ومبخر مائي حلزوني و هذه العناصر الثلاثة مرتبطة بدارة مغلقة الأنابيب . تم الحصول على النتائج التجريبية من خلال سلسلة من الاختبارات على مضخة حرارية تستخدم وسيط التبريد R407 . ومن خلال التجارب تم التوصل إلى أفضل تدفق يحقق أكبر معامل أداء COP بدون استخدام دارة استعادة الحرارة حيث كان أكبر معامل الأداء للدارة 3.27 عند تدفق 250 L/h . وعند استخدام دارة الاستعادة تحسن معامل الأداء للدارة بشكل ملحوظ حيث وصلت قيمته إلى 3.63 عند تدفق 200 L/h وبالتالي كانت نسبة التحسن في أداء الدارة المستخدمة لدارة الاستعادة 11% مقارنة مع الدارة التي تستخدم المياه الجوفية .

كلمات مفتاحية:

مضخة حرارية، معامل الأداء الحراري، المبخر المائي، الاستعادة الحرارية.

Abstract:

In this research, the heat recovery system from the outer surface of the compressor shell was tested for an empirically equipped heat pump that uses a helical evaporator and is intended for heating a test chamber. Where the proposed heat recovery system consists of a heat absorption unit from the compressor shell (a heat exchanger in the form of a casing that encapsulates part of the compressor shell), a water accelerator pump, and a spiral water evaporator, and these three elements are connected to a closed circuit.

The experimental results were obtained through a series of tests on a heat pump using R401C refrigerant. Through experiments, the best flow achieved the largest COP performance coefficient without using the heat recovery circuit, as the largest performance coefficient for the circuit was 3.27 at a flow of 250 L / h. When using the recovery circuit, the performance coefficient of the circuit improved significantly, as it reached 3.63 at a flow of 200 L / h. Thus, the percentage of enchantment in the performance of the circuit used for the recovery circuit was 11% compared to the circuit that used groundwater.

Key Words:

Heat pump, Coefficient of performance, water evaporator, Heat recovery.

1- مقدمة

في السنوات الأخيرة اكتسب موضوع توفير الطاقة أهمية كبيرة، وخاصة مع الطلب المتزايد على الطاقة مع النقص في مصادرها، حيث يستهلك قطاع التدفئة و التبريد حوالي ثلث إجمالي الطاقة التي تستهلكها المباني السكنية و التي تمثل بدورها حوالي خمس الطاقة المستهلكة على الصعيد العالمي [1,2] .

ومؤخراً انتشرت في قطاع التدفئة وسائل التدفئة الصديقة للبيئة كبديل لوسائل التدفئة التقليدية التي تعتمد على الوقود الأحفوري و هذه الوسائل هي المضخات الحرارية . ومن هنا اكتسبت هذه المضخات مكانتها في سوق التدفئة و التكييف [3] .

هناك العديد من الأصناف للمضخات الحرارية و ذلك حسب المصدر الحراري الذي تعتمد عليه وحسب مكان استخدامها "تطبيقها " و هي هواء_هواء ، هواء_ماء ، ماء_هواء ، ماء_ماء. إلا أن المضخات الحرارية التي تعتمد المياه كمصدر حراري تعد خياراً مهماً لحل المشاكل التي تعانيها المضخات الحرارية هواء-هواء في المناطق الباردة وخاصة في الطقس ذي درجات الحرارة تحت الصفر . فقد عملت العديد من الأبحاث على استخدام المياه سواءً من خلال المضخات الحرارية أو باستخدام المياه الجوفية لما تتمتع به من حرارة شبه مستقرة على مدار فصول السنة .

من هنا جاء تركيز هذا البحث على هذا النوع من المضخات و التي تستخدم المياه الجوفية كمصدر حراري حيث تم تجريبياً فحص تأثير تدفق مياه البئر على أداء المضخة الحرارية الاختبارية المجهزة بمبادل مائي حلزوني تم استخدامه كمبخر ، وتم التوصل إلى أفضل تدفق تجريبي يحقق أعلى قيمة لمعامل أداء المضخة الحرارية COP ، وتم اقتراح نظام يقوم على امتصاص الحرارة الضائعة من غلاف الضاغط واستخدامه كمصدر للحصول على مياه دافئة للمبخر المائي كحل بديل مبتكر يؤمن مصدر مائي ذي حرارة أعلى من حرارة مصادر المياه التقليدية وبتجهيزات رخيصة الثمن عوضاً عن الكلف

التأسيسية الكبيرة المرتبطة باستخدام المياه الجوفية . تعمل دارة الاستعادة المقترحة كدارة مغلقة تتكون من مبادل حراري مائي على شكل قميص يغلف جزء من الضاغط ويمتص حرارة غلافه ومضخة تسريع مياه باستطاعة صغيرة ومبادل مائي حلزوني يستخدم كمبخر ضمن دارة المضخة الحرارية .

تناولت العديد من الابحاث في السنوات الأخيرة موضوع المضخات الحرارية التي تستخدم المياه الجوفية [4,5,6,7] أو الطاقة الجيوحرارية [8,9,10,11,12] ودرست هذه الأبحاث معامل الأداء لهذا النوع من المضخات ، إلا أن جميع هذه الأبحاث درست معامل الأداء COP لتصاميم مفروضة لمبادلات حرارية ضمن الماء دون الخوض في دراسة تأثير تدفقات المياه على أداء الدارة كما هو الحال في البحث الحالي.

كما افترضت أبحاث عدة أنظمة استعادة الطاقة في غلاف الضاغط [13,14,15,16] لكن هذه الأبحاث وظفت هذه الأنظمة في مبادلات حرارية من النوع هواء-هواء كما أنها استخدمت عدة مواد كوسيط لنقل الحرارة من غلاف الضاغط مثل الزيت [13] أو المواد المتحولة الطور [14,15] أو استخدمت مبادلات أنبوبية نحاسية حول الضاغط وتعمل على تسخين وسيط التبريد بشكل مباشر [16] وثم يتم ضخ (حقن) هذا الوسيط الساخن في خط السحب للضاغط ، أما في بحثنا هذا فقد استخدمت المياه كوسيط يمتص الحرارة الضائعة من غلاف الضاغط ويتم ضخ هذه المياه إلى المبخر الحلزوني في مضخة حرارية من نوع ماء-هواء ، فتكون هذه المياه الساخنة هي المصدر الحراري للمضخة المدروسة .

2- التجهيزات التجريبية :

من أجل تنفيذ التجارب تم تجهيز منصة تجريبية لمضخة حرارية (ماء-هواء) حيث تم استخدام ضاغط يتناسب مع ضغوط العمل للدارة المراد إنشاؤها و التي تستخدم الفريون R407 كوسيط تبريد . تم أيضاً تصميم وتجهيز مبخر مائي حلزوني باستطاعة

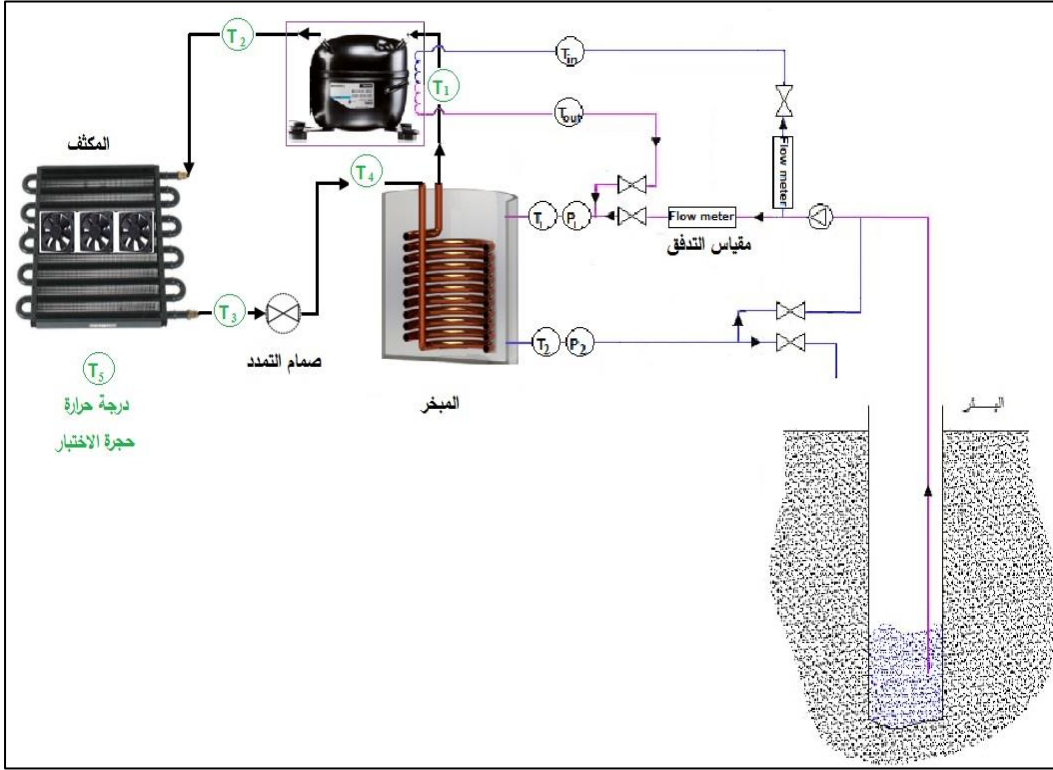
تتناسب مع دائرة المضخة الحرارية بالإضافة إلى مكثف هوائي ذي زعانف مزود بمروحة كهربائية تم وضعه في حجرة اختبارية معزولة ذات جدران خشبية بأبعاد $210 \times 150 \times 200$ cm لمراقبة تغيرات درجة حرارة الهواء فيها .

تم تزويد المنصة بحساسات لقياس الحرارة thermocable على مداخل ومخارج كل من المكثف و المبخر هذا بالإضافة إلى عدة مقاييس مثل مقياس تدفق وسيط التبريد ، ساعات لقياس الضغط عند كل من خط السحب و الطرد للضاغط ، ومقاييس فولت و أمبير والاستطاعة الكهربائية للضاغط .

بعد تجهيز أجزاء المضخة الحرارية تم تجهيز دائرة مياه ملحقة بها و مرتبطة مع المبخر المائي الحلزوني . تحوي هذه الدارة على مضخة تسريع لضخ مياه البئر إلى المبخر الحلزوني وأيضاً زُوِّدت دائرة المياه هذه بمقياس تدفق ومقاييس حرارة عند مدخل ومخرج المياه من المبخر ومقاييس ضغط على أطراف المضخة ، و أيضاً تم إلحاق دائرة مياه البئر بدارة استعادة الحرارة من غلاف الضاغط H.R Heat Recovery حيث تم تجهيز مبادل حراري حول غلاف الضاغط و هو عبارة عن قميص معدني يغلف جزء من الضاغط و تم ربطه بأنابيب مع مضخة تسريع المياه ثم مع المبخر المائي لتكون هذه العناصر الثلاثة دائرة مغلقة مستقلة مزودة بمقياس تدفق ومقاييس حرارة للمياه بالإضافة لمقاييس الضغوط على أطراف المضخة .

يوضح الشكل (1) المخطط الرمزي للدارة التي تم إنشاؤها و يبين الشكل (2) أجزاء المنصة التجريبية المجهزة .

دراسة تجريبية لتحسين معامل أداء مضخة حرارية ماء-هواء باستخدام نظام استعادة الحرارة من غلاف الضاغط



الشكل (1) المخطط الرمزي للدائرة التي تم إنشاؤها



الشكل (2) أجزاء المنصة التجريبية المجهزة ، 1: الضاغط مع وحدة امتصاص الحرارة، 2: المبخر المائي ، 3: حساسات قياس الحرارة، 4: مقياسا ضغط السحب والطرء، 5: مقاييس استطاعة كهربائية، 6: مضخة تدوير المياه، 7: مقاييس تدفق المياه مع التوصيلات.

كما يوضح الجدول (1) المواصفات الفنية للمكونات الرئيسية للمضخة الحرارية المجهزة خلال تنفيذ التجارب تم أخذ قراءات حساسات الحرارة "تُرموكل" بالإضافة إلى الاستطاعة الكهربائية المستهلكة من قبل الضاغط بالإضافة إلى ضغوط و تدفق وسيط التبريد في الدارة و يوضح الجدول (2) قيمة الخطأ الأعظمية للحساسات المستخدمة .

الجدول (1) المواصفات الفنية للمكونات الرئيسية للمضخة الحرارية المجهزة.

المواصفات الفنية		
R407		وسيط التبريد
مكبسي، استطاعة 1/3 hp،		الضاغط
مبادل نو زعانف 270×280×110 mm ، مساحة تبادل 0.54 m ² ، مروحة بتدفق 1.5 kg/h		وحدة المكثف الهوائي
مبادل حلزوني ، عدد الحلقات 15 ، قطر الحلقة 190mm ، قطر الأنبوب 9.5 mm ، خطوة الحلزون 20mm		المبخر المائي
1.8 ±0.2 bar	ضغط السحب	شروط عمل الدارة
13 ±0.3 bar	ضغط الطرد	
0.15 ±0.01 l/min	تدفق وسيط التبريد	

الجدول (2) قيمة الخطأ الأعظمية للحساسات المستخدمة.

الخطأ الأعظمي	الحساس
$\pm 0.5\text{ C}^\circ$	ثرموكبل
$\pm 0.2\%$	مقياس الضغط
$\pm 0.8\%$	مقياس الاستطاعة الكهربائية

3- النتائج التجريبية ومناقشتها :

3-1 - تجارب دارة المياه الجوفية :

في سلسلة من التجارب تمت دراسة تأثير تدفق مياه البئر على معامل أداء المضخة الحرارية المجهزة من خلال تغيير تدفق مياه البئر عبر صمام كروي موجود في دارة المياه . تم أثناء تشغيل دارة المضخة قياس التغيرات في درجات الحرارة للأجزاء الداخلية للمضخة الحرارية .


فمن أجل كل قيمة لتدفق المياه عند بداية التجربة تكون درجات الحرارة لأجزاء المضخة ككل من حرارة الجو المحيط ومع الزمن تبدأ درجات حرارة الأجزاء الداخلية بالتغير حتى تستقر عند درجات محددة . تم تسجيل هذه الدرجات من أجل كل قيمة تدفق و فحص تأثير تدفق المياه على مدخل ومخرج المكثف ومدخل ومخرج المبخر عند التدفق 250 L/h على سبيل المثال .

فكما هو ملاحظ من الشكل (3) تستقر درجات حرارة الأجزاء الداخلية بعد حوالي 17 دقيقة من تشغيل الدارة عند قيم محددة وهذه القيم التي تم اعتبارها عند تسجيل درجات الحرارة من أجل كل تدفق .


دراسة تجريبية لتحسين معامل أداء مضخة حرارية ماء-هواء باستخدام نظام استعادة الحرارة من غلاف الضاغط

باستخدام درجات الحرارة المقاسة على أطراف كل من المبخر و المكثف تم حساب الأحمال الحرارية لهذه المبادلات ، حيث يبين الشكل (4) قيم الحملات الحرارية المحسوبة لكل من المبخر والمكثف عند كل تدفق من التدفقات التي تم اختبارها .


نلاحظ من الشكل (4) أن الأحمال الحرارية لكل من المبخر و المكثف تزداد بشكل كبير كلما زاد تدفق المياه و لكن عند الوصول إلى تدفقات أكبر تصبح التغيرات في قيمة الحمل الحراري ضئيلة مع زيادة قيمة التدفق وتكون أقل من 0.3% كما هو واضح من محور نسبة التغيرات في الحمل " المحور اليميني من المخطط " . حيث تستقر الأحمال الحرارية للمكثف تقريباً عند تدفق 175 L/h بينما تستقر في المبخر عن تدفق 250 L/h .



الشكل (3) المخطط الزمني لتغير درجات حرارة الأجزاء الداخلية للمضخة الحرارية عند التدفق 250L/h.



(a)



(b)

الشكل (4) الأحمال الحرارية المحسوبة بدلالة التدفقات المختبرة (a) الأحمال الحرارية للمكثف، (b) الأحمال الحرارية للمبخر.

وبيقاس الاستطاعة المستهلكة من قبل الضاغط ومضخة تدوير المياه عند التدفقات

المختبرة تم حساب معامل الـ COP اعتماداً على العلاقة (1):


$$COP = \frac{q}{P_c + P_p} \quad \dots (1)$$

حيث أن q : الحمل الحراري للمكثف ، P_c, P_p : طاقة كل من الضاغط ومضخة التدوير على التوالي.

وقد وجد كما هو واضح لاحقاً من الشكل (11) أن أعظم قيمة لمعامل الأداء هي 3.27 والتي تتحقق عند تدفق 250 L/h للدارة المختبرة ضمن الظروف التجريبية و استطاعة الضاغط المستخدم .

2-3- تجارب دارة الاستعادة (H.R) : Heat Recovery


أُجريت سلسلة من التجارب على دارة الاستعادة المجهزة والتي تتكون مبادل حراري مائي حول غلاف الضاغط ومضخة تسريع المياه ومبخر مائي حلزوني ضمن دارة مغلقة وُقِّدَت هذه التجارب باستخدام تدفقات مختلفة لإيجاد أفضل تدفق لهذه الدارة و لكن في البداية و لفحص مدى تأثير دارة الاستعادة على درجة حرارة غلاف الضاغط تم قياس هذه الحرارة خلال تشغيل المضخة الحرارية بدون استخدام دارة الاستعادة ومن ثم تم إجراء تجربة لقياس حرارة غلاف الضاغط خلال تشغيله مع استخدام دارة الاستعادة ، حيث يبين الشكل (5) مقارنة تغير درجات حرارة غلاف الضاغط بدلالة الزمن في كلا الحالتين (مع وجود دارة استعادة وبدون وجود دارة استعادة) ونرى بوضوح انخفاض درجة حرارة غلاف الضاغط حوالي 12°C عند استخدام دارة الاستعادة .



الشكل (5) المخطط الزمني لتغير درجات حرارة غلاف الضاغط : (مع وجود دارة استعادة وبدون وجود دارة استعادة)

وأيضاً قبل البدء بتنفيذ تجارب تأثير تدفق المياه على عمل أجزاء المضخة الحرارية تم اختبار تأثير تغير تدفق مياه دارة الاستعادة على كمية الحرارة المكتسبة من غلاف الضاغط خلال عمل هذه الدارة وكما هو مبين من الجدول (3) تم اختبار تأثير ثلاثة تدفقات مختلفة ومراقبة التغيرات في درجة حرارة مياه دارة الاستعادة مع الزمن فمثلاً من أجل التدفق 200 L/h كما هو مبين بالشكل (6) تستقر درجة الحرارة عند 20 c بعد مرور 30 دقيقة من بدء التجربة .

دراسة تجريبية لتحسين معامل أداء مضخة حرارية ماء-هواء باستخدام نظام استعادة الحرارة من غلاف الضاغط



الشكل (6) تغيير درجات حرارة مياه دائرة الاستعادة عند تدفق 200 l/h.

الجدول (3) تأثير تدفق المياه على كمية الحرارة المكتسبة من غلاف الضاغط

تدفق المياه [l/h]	درجة حرارة المياه [C]	الزمن [min]
100	19	37
200	20	30
300	20.6	25


وهكذا فإن الجدول (3) يوضح قيم درجات الحرارة لمياه دائرة الاستعادة والأزمنة اللازمة للوصول إلى الاستقرار الحراري في دائرة مياه الاستعادة، فهنا من أجل التدفقات الثلاثة نلاحظ أن التغيير في تدفق المياه لا يؤثر بشكل كبير على درجة الحرارة التي تكتسبها المياه أو حتى على الزمن اللازم لتسخينها ، حيث تستقر درجة حرارتها عند 20 c وسطياً وذلك بعد مدة حوالي نصف ساعة ، لذلك تم اعتبار الفترة قبل الوصول إلى

استقرار درجة حرارة مياه دارة الاستعادة مرحلة عابرة و بالتالي خلال تجارب دارة الاستعادة تم أخذ قراءات حساسات حرارة الأجزاء الداخلية للمضخة الحرارية في المرحلة المستقرة لدارة الاستعادة .

وللبحث عن أفضل تدفق لمياه دارة الاستعادة من حيث معامل الأداء تم إجراء سلسلة من التجارب بتغير تدفق مياه دارة الاستعادة و أخذ قراءات الحساسات في المرحلة المستقرة عند مدخل ومخرج كل من المبخر والمكثف . يبين الشكل (7) تأثير تدفق المياه على كل من درجة حرارة مخرج المبخر المائي و مدخل المكثف (درجتي حرارة خطي السحب و الطرد) في حال استخدام دارة الاستعادة HR أو بدونها و نلاحظ من الشكل (7) ما يلي :

1. بازدياد تدفق مياه المبخر تزداد كل من درجة حرارة مخرج المبخر و مدخل المكثف في كلا الحالتين : مع دارة HR وبدون دارة HR وذلك حتى تدفق 250 L/h بالنسبة للتجارب بدون استخدام دارة استعادة ، بينما في التجارب التي استخدمت دارة استعادة تثبت درجات الحرارة عند تدفق حوالي 225 L/h بالنسبة للمبخر و تدفق 175 L/h بالنسبة للمكثف .


2. في حال استخدام دارة HR تزداد درجة الحرارة عند مدخل ومخرج الضاغط مقارنة مع عدم استخدام دارة الاستعادة وذلك من أجل كل التدفقات التي تم اختبارها ، حيث ارتفعت درجة حرارة وسيط التبريد عند مخرج المبخر حتى $20\text{ }^{\circ}\text{C}$ عند تدفق 225 L/h مما يدل على حصول عملية تجميد إضافية لوسيط التبريد قبل دخوله إلى الضاغط .



الشكل (7) مقارنة تأثير تدفق المياه في حالتي استخدام دارة الاستعادة وبدونها (a) درجة حرارة مخرج المبخر (b) درجة حرارة مدخل المكثف.


باستخدام درجات الحرارة المقاسة على أطراف أجزاء المبادل الحراري يتم حساب الأحمال الحرارية لكل من المكثف و المبخر عند كل تدفق وكذلك قياس طاقة الضاغط المستهلكة.

يوضح الشكل (8) تأثير تدفق مياه الاستعادة على كل من الحمل الحراري في المكثف و الحمل الحراري في المبخر وكذلك الطاقة التي يستهلكها الضاغط عند كل تدفق . نلاحظ أنه بزيادة التدفق يزداد الحمل الحراري للمكثف حتى تدفق 175 L/h ثم يثبت بعدها بينما تستمر زيادة الحمل الحراري للمبخر بزيادة التدفق حتى الوصول إلى تدفق 225 L/h و بزيادة التدفق تتناقص الطاقة الكهربائية التي يستجرها الضاغط بشكل شبيه خطي ثم تستقر عند قيمة استهلاك محددة بعد تدفق 175 L/h .



الشكل (8) تأثير تدفق مياه الاستعادة على الحمل الحراري في المكثف و الحمل الحراري في المبخر و طاقة الضاغط

وبمقارنة الطاقة المستهلكة للضاغط و التي تم قياسها خلال زمن التشغيل عند استخدام دارة الاستعادة تحت تدفق 200 L/h مع الطاقة المستهلكة بدون وجود دارة الاستعادة عند تدفق 250 L/h ، كما هو مبين بالشكل (9) نجد أن استهلاك الضاغط في حال استخدام دارة HR أقل وسطياً بحوالي 3% .



الشكل (9) مقارنة استهلاك الضاغط في أفضل حالات دارة المياه الجوفية مقابل أفضل حالات دارة الاستعادة.


يمكن تفسير النتائج السابقة من خلال الدارة الترموديناميكية المبينة في الشكل (10) حيث يتضح من مخطط دارة الترموديناميكية وبالاعتماد على التغير في درجات الحرارة المقاسة على أطراف الضاغط في كل من حالة دارة الاستعادة HR و المرمزة بالرمز (1, 2) ، حيث أنه في حال استخدام دارة استعادة يكون لدينا عملية تجميع إضافية لوسيط التبريد مما يدل على حمل حراري أكبر مكتسب في المبخر المائي .

وكذلك نلاحظ أن مساحة المثلث تحت الخط الممثل العمل الضاغط في حال استخدام دارة HR أقل من مساحته مقارنة مع عدم استخدام دارة الاستعادة مما يعطي عملاً نظرياً (W) أقل بسبب فرق انتالبي وسيط التبريد على أطراف الضاغط ، هذا من ناحية ومن

ناحية أخرى عند زيادة درجة حرارة وسيط التبريد عند مدخل الضاغط (مخرج المبخر) فإن كثافة وسيط التبريد عند مدخل الضاغط تتخفض قليلاً مما يقلل أيضاً من التدفق الكتلي لوسيط التبريد بشكل بسيط [17] وهذا ما تم ملاحظته فعلاً في التجربة ، كل هذا ينعكس على طاقة الضاغط المستهلكة كما هو واضح من العلاقة (2)

$$W = m \cdot \Delta h_{1-2} \quad \dots (2)$$

حيث m : التدفق الكتلي لوسيط التبريد . Δh_{1-2} : فرق انتالي وسيط التبريد على أطراف الضاغط .




الشكل (10) مخطط الدارة الترموديناميكية للمضخة الحرارية.

4 - مقارنة النتائج من ناحية معامل الـ COP :

وضحت سلسلة التجارب السابقة التي تم إجراؤها على المضخة الحرارية (ماء-هواء) المعدة في حالة عدم استخدام دارة استعادة وكذلك مع استخدام دارة الاستعادة تأثير تدفق المياه على عمل الأجزاء الداخلية للمضخة الحرارية (الأحمال الحرارية للمكثف و المبخر) .

وبحساب معامل الأداء COP للتدفقات المختلفة باستخدام العلاقة (1) وذلك من أجل كلا الحالتين كما هو موضح في الشكل (11) نجد أن أفضل تدفق من ناحية الـ COP هو 200 L/h في حالة استخدام دائرة استعادة و التي تبلغ قيمته 3.63 ، بينما كانت أعظم قيمة لمعامل الـ COP في حال عدم وجود دائرة استعادة 3.27 عند تدفق أكبر للمياه وهو 250 L/h مما يعني ارتفاع في قيمة معامل الـ COP بمقدار 11% مقارنة مع عدم استخدام دائرة HR .



الشكل (11) تأثير تدفق المياه على معامل أداء الدارة في كل من دائرة الاستعادة ودائرة المياه الجوفية

5- الاستنتاجات Conclusion :

- بينت نتائج تجارب المياه الجوفية المنفذة أنه مع زيادة قيمة التدفق تزداد قيم الأحمال الحرارية في كل من المكثف و المبخر إلى حد معين تصبح أي زيادة في التدفق غير

مجدية و لا تترك أثراً على الأحمال الحرارية في كل من المكثف و المبخر ، وكانت أكبر قيمة تدفق تؤثر على عمل الدارة هي 250 L/h .

- تبين من خلال التجربة أن دارة الاستعادة تخفض درجة حرارة غلاف الضاغط حوالي 12 °C .

- من خلال التجربة أيضاً تبين أن التغير في قيمة تدفق مياه دارة الاستعادة لا يؤثر بشكل كبير على قيمة الحمل الحراري المنتقل في الميته إلى وحدة امتصاص الحرارة في غلاف الضاغط .

- خلال نتائج تجارب دارة الاستعادة اتضح أن أفضل تدفق لمياه دارة الاستعادة 200 L/h .

- عند استخدام دارة الاستعادة ترتفع درجة حرارة وسيط التبريد عند مدخل الضاغط حيث ترتفع من الدرجة 12 إلى الدرجة 20 و أيضاً ترتفع عند مخرج الضاغط (من الدرجة 67 إلى 73)، مما يؤثر على قيم الأحمال الحرارية في كل من المبخر و المكثف .

- مكن استخدام دارة الاستعادة من تخفيض قيمة الطاقة المستهلكة من قبل الضاغط فبمقارنة القيم المقاسة للطاقة المستهلكة للمضخة في حال استخدام دارة الاستعادة نلاحظ أنها انخفضت حوالي 3% أقل من استهلاكه في حال استخدام دارة المياه الجوفية . عند استخدام دارة الاستعادة طراً تحسن ملحوظ في معامل أداء المضخة الحرارية حيث ازدادت قيمته من 3.27 حتى 3.63 وكانت نسبة التحسن 11% .

- إن النظام المقترح _ والذي يقوم على امتصاص الحرارة الضائعة من غلاف الضاغط من أجل تسخين مياه ليتم استغلالها بدورها ضمن دارة مغلقة مع المبخر المائي في المضخة الحرارية _ يعتبر حلاً مبتكراً و رخيصاً يؤمن مصدراً مائياً دافئاً مقارنة مع مصادر المياه الجوفية التقليدية لذلك نوصي بتعميم هذه التجربة.

6 - المراجع :

1. International Energy agency. EBC Annex 53 :total energy use in buildings: analysis and evaluation methods–project summary report (2016).
2. U.S. Energy information Administration . International Energy outlook (2016).
3. Zheng Wang, et al , State of the Art on Heat Pumps for Residential Buildings ,Buildings (2021), 11, 350.
4. Cakir U, et al, An experimental exergetic comparison of four different heat pump systems working at same conditions: As air to air, air to water, water to water and water to air. Energy (2013), 58,210–219.
5. Sarbu I, et al, General review of ground–source heat pump systems for heating and cooling of buildings. Energy build.(2014),70,441,454.
6. Schibuola L, et al, Experimental analysis of the performance of a surface water source heat pump. Energy build.(2016),113,182,188.
7. Chen X, et al, The performance of an open–loop lake water heat pump system in south China. Appl.therm.Eng.2006,26.2255–2261.

8. Yin P, et al, In-field performance evaluation and economic analysis of residential ground source heat pumps in heating operation. *J.build.Eng.*(2019),26,100932.
9. Boban F, et al, Application and design aspect of ground heat exchangers. *Energis* (2021),14,2134.
10. Alshehri F, et al, Techno-economic Analysis of ground source heat pumps in hot dry climates. *J.Build.Eng.*(2019),26,100825.
11. Wu .W, et al, HVAC and PV systems for residential net-zero energy buildings across the United States. *Energy Convers Manag.*(2018),177,605-628.
12. Bocklemann F, et al, It work Long term performance measurement and optimization of six ground source heat pump system in Germany. *Energies* (2019),12,4691.
13. Remeli MF, Date A, Orr B, Ding LC, Singh B, Affandi NDN, et al. Experimental investigation of combined heat recovery and power generation using a heat pipe assisted thermoelectric generator system. *Energy Convers Manage* (2016);111:147-57.
14. Zhongbao Liu, et al, Enhancing Heating Performance of Low-Temperature Air Source Heat Pumps Using Compressor Casing Thermal Storage, *Energies* (2020), 13, 3269

15. Lui Z et al, Air source heat pump with water heater based on a bypass-cycle defrosting system using compressor casing thermal storage , Applied Thermal Engineering 128 (2018) 1420–1429.
16. Bi Huang , et al, Experimental study of enhancing heating performance of air-source heat pump by using a novel recovery device designed for reusing the energy of the compressor shell, Energy Conversion and Management 138 (2017) 38–44.
17. Lei Jin, et al, Performance investigations of an R404A air-source heat pump with an internal heat exchanger for residential heating in northern China, j.ijrefrig.(2016).03.004.

تحسين تصنيف صور الأشعة السينية للصدر

للكشف عن الالتهاب

الرئوي وفيروس كورونا COVID19

باستخدام التعلم العميق

* الدكتور المهندس ماهر ابراهيم ** المهندس حسن محمد وسوف

المخلص:

تُستخدم صور الأشعة السينية الصدرية للمريض من أجل معرفة نوع المرض الذي قد أصاب الرئة. هنالك تزايد كبير في المرضى وفي صور الأشعة السينية الأمر الذي يخلق أعباء هائلة على الطبيب الذي يقوم بتحليل الصور الشعاعية.

يُعد استخدام التعلم العميق في مجال تحليل الصور عموماً والصور الطبية خصوصاً أمراً منتشرًا في وقتنا الحالي نظراً لقدرته على معالجة الحجم الكبير من البيانات الناتجة عن الصور وقصور طرائق تعلم الآلة التقليدية عن معالجتها مما يوفر الوقت والجهد على الكادر الطبي مع تحقيق دقة عالية موثوقة.

قدّم البحث طريقة لتصنيف صور الأشعة السينية للصدر التي من شأنها أن تزيد دقة التنبؤ بنوع المرض الرئوي سواء كان التهاب أم مرض كورونا COVID19 حيث أعطت النتائج النهائية تحسين ملحوظ بدقة التنبؤ مقارنة مع الدراسات السابقة المتعلقة بهذا المجال ويجب الإشارة إلى أن الطريقة المستخدمة في هذا البحث ليست طريقة مبتكرة وإنما تطبيقها على البيانات المستخدمة ومقارنتها مع نماذج موجودة في دراسات سابقة مع الاعتماد على نفس البيانات هو الشيء الجديد والذي أدى إلى تحسين نتائج الدقة.

الكلمات المفتاحية: التعلم العميق، الشبكات العصبونية، صور الأشعة السينية، التصنيف،

الشبكات العصبونية الالتفافية.

* مدرس في قسم هندسة تكنولوجيا المعلومات -كلية هندسة تكنولوجيا المعلومات والاتصالات -جامعة طرطوس -سوريا

** ماجستير في هندسة تكنولوجيا المعلومات -كلية هندسة تكنولوجيا المعلومات والاتصالات - جامعة طرطوس- سوريا

Improving chest x-ray images analysis for pneumonia and COVID19 detection using deep learning

Dr. Eng. Maher Ibrahim*

Eng. Hasan Mohammad Wassouf**

Abstract:

A patient's chest x-ray images are used to find out what type of lung disease has occurred. There is a large increase in patients and in the X-ray images, which creates enormous burdens on the physician who analyzes the X-ray images.

The use of deep learning in the field of image analysis in general and medical images in particular is widespread today due to its ability to process the large volume of data generated

from images and the inability of traditional machine learning methods to process them, which saves time and effort on the medical staff with achieving high reliable accuracy.

The research provided a method for analyzing chest x-ray images that would increase the accuracy of predicting the type of lung disease, whether it is inflammation or COVID19, as the final results gave a significant improvement in the prediction accuracy compared to previous studies related to this field, It should be noted that the method used in this research is not an innovative method, but rather applying it to the data used and comparing it with existing models in previous studies while relying on the same data is the new thing that led to improving the results of accuracy.

Key words: Deep learning, neural networks, x-ray images, classification, convolutional neural network

*Teacher, Information Technology Engineering Department, Information and communication Technology Engineering, Tartous University, Syria

** Master in Information Technology Engineering Department, Information and communication Technology Engineering, Tartous University, Syria

1- مقدمة:

يُعتبر التعلم العميق من أهم المجالات المستخدمة في الطب ولاسيما تحليل الصور الطبية من أجل استخلاص الميزات التي من الممكن أن تساهم في تحسين عملية اتخاذ القرار الطبي كالتشخيص المعتمد على الصور الشعاعية مثلاً.

يعتبر فيروس كورونا COVID-19 مرض سريع الانتشار، إذ أنه لا يصيب الإنسان فقط بل ممكن أن يكون هنالك حيوانات مصابة به. لا يصيب هذا المرض دولة واحدة فقط بل يعاني منه العالم كله. يفقد الناس حياتهم بشكل يومي بسبب فيروس كورونا، وتكون التكلفة التشخيصية لهذا المرض مرتفعة جداً. في آذار عام 2020 أصبحت صور الأشعة السينية لأشخاص مصابين بفيروس كورونا وأشخاص سليمين متاحة عبر الشبكة العنكبوتية وفي مستودعات بيانات مختلفة مثل Github و Kaggle من أجل استخدامها في عمليات التحليل [1]. إضافة إلى ذلك أصبحت هذه المستودعات تضم صور الأشعة السينية الخاصة بأشخاص مصابين بالتهاب رئوي وأشخاص سليمين منه وبالتالي يمكن الاعتماد على هذه الصور من أجل تمييز الأشخاص المصابين بفيروس كورونا عن الأشخاص المصابين بالتهاب الرئوي عن الأشخاص السليمين. يُستخدم التصوير الطبي من أجل التحليل والتنبؤ بتأثيرات فيروس كورونا على جسم الإنسان [1] بينما تعتبر الطريقة الأكثر استخداماً في أنحاء العالم للكشف عن الالتهاب الرئوي هي استخدام صور الأشعة السينية [2].

إن عملية الكشف عن الالتهاب الرئوي تتطلب إجراء فحص دقيق لصور الصدر الشعاعية وهذا الأمر يحتاج إلى خبير أشعة يملك خبرة عالية جداً بالتالي فإن العملية الموماً إليها هي مهمة صعبة وتستغرق وقتاً طويلاً ومع ذلك فإن أي خطأ بسيط يمكن أن يتبعه عواقب وخيمة وهذا هو الحال بالنسبة للكشف عن فيروس كورونا. بالرغم من تواجد العديد من الأدوات الحاسوبية التي من شأنها أن تساعد خبراء الأشعة على تحليل الصور الشعاعية إلا أنها لم تحقق الفائدة الكبرى المرجوة من قبل المختصين [2] لذا برزت الحاجة إلى تقنيات أكثر تطوراً وأعلى كفاءة.

أثبتت خوارزميات التعلم العميق قدرتها في مجال التصوير الطبي وفي تحليل وتصنيف الصور الطبية مقارنة مع خوارزميات التعلم الآلي التقليدي وذلك للكشف عن

الأمراض المختلفة مثل سرطان الجلد وسرطان الثدي والسل وأورام الدماغ وغيرها مما شجع على استخدامها في تحليل صور الأشعة السينية للصدر واستخراج الميزات آلياً لاستخدامها في تصنيف الصور المصابة من خلال بناء شبكة عصبونية التفاضلية عميقة Convolutional neural network (CNN) [2]. إن الطريقة آنفة الذكر أعطت دقة أعلى وبوقت أقل مقارنة مع الطرق اليدوية المستخدمة [2]. تتطلب نماذج CNN كمية كافية من الصور لتقوم بعملية التصنيف بكفاءة ودقة أكبر [3]. اعتمد في هذا البحث على التعلم العميق عموماً و CNN خصوصاً من أجل استخراج الميزات آلياً وتصنيف الصور اعتماداً على شبكة عصبية إذ استخدم البحث التعلم بالنقل بالtransfer learning.

2- هدف البحث:


يكمن الهدف من البحث في تحسين طريقة معالجة صور الأشعة السينية للصدر من أجل الحصول على دقة أعلى في التنبؤ فيما إذا كانت صورة الأشعة السينية تدل على وجود فيروس كورونا أو التهاب رئوي أم أنّ الشخص سليم، من خلال تحسين طريقة استخراج الميزات آلياً من الصور مما يساعد في اتخاذ قرار طبي أكثر دقة وذلك مقارنة مع الدراسات السابقة المتعلقة بموضوع هذا البحث.

3- مواد وطرق البحث:


تُعد نقطة البداية في البحث القيام بالدراسة المرجعية عن كيفية استخدام شبكات CNN في تحليل صور الأشعة السينية للصدر. استخدم في هذا البحث بيئة التطوير السحابية Colab الخاصة بلغة البرمجة بايثون (python). إن السبب الرئيسي لاستخدام هذه البيئة هو السرعة في المعالجة والتعامل مع مجموعة البيانات وكونها تدعم لغة البرمجة بايثون التي تتميز بسهولةها واحتوائها الكثير من مكاتب تعلم الآلة والتعلم العميق التي من شأنها أن تسهل عملية البرمجة. اعتمد في هذا البحث على الدراسات السابقة [15][14][13][4]. إن التحسين على عملية تحليل صور الأشعة السينية للصدر ومقارنة النتائج مع الدراسة [4] والمقارنة مع النماذج والطرق المستخدمة في الدراسات [15][14][13] هو الجزء الأساسي من هذا البحث. اعتمدت البيانات المستخدمة في الدراسة [4] والموجودة ضمن موقع Kaggle [11].

3-1- تعريف التعلم العميق:

يشكل التعلم العميق تقنية حديثة لمعالجة الصور وتحليل البيانات، مع نتائج واعدة وإمكانيات كبيرة. إن فكرة التعلم العميق هي عبارة عن توسيع لفكرة تعلم الآلة من خلال إضافة العمق إلى النموذج وتحويل البيانات باستخدام وظائف مختلفة تسمح بتمثيل البيانات بشكل هرمي بالتالي فإن أهم ميزة من ميزات التعلم العميق قدرته على الاستخراج التلقائي للميزات من بيانات الدخل. يمكن للتعلم العميق أن يحل المشكلات الأكثر تعقيداً بسرعة وكفاءة[5]. يمكن القول إن التعلم العميق هو مجال فرعي من تعلم الآلة يستخدم الشبكات العصبية الصناعية *artificial neural networks* (ANN) التي تحوي على طبقتين أو أكثر من الطبقات المخفية مع وجود مجموعة من الوظائف أو التوابع الرياضية التي من شأنها أن تربط الدخل بالخرج أي أنها تُستخدم لتحويل بيانات الدخل إلى تمثيلات جديدة تقيد في عملية التنبؤ والتصنيف. إن فكرة الشبكات العصبية الصناعية مستوحاة من الشبكة العصبية البيولوجية والمكونة من مجموعة من الخلايا العصبية أو العقد المترابطة لتقوم كل خلية عصبية بتحويل مدخلاتها إلى ناتج واحد عن طريق تطبيق عملية أو وظيفة غير خطية على المدخلات حيث تكون الوصلات بين العقد موزونة ومحددة بوزن خاص بكل وصلة. يوضح الشكل (1) بنية الشبكة العصبية الصناعية[6]. يعد التعلم العميق تقنية متقدمة لتحليل البيانات الضخمة أيضاً حيث كان هنالك عدد كبير من الحالات الناجحة في معالجة الصور والتعرف على الكلام والتعرف على النماذج وتحليل المشاعر وغيرها[7]. إن زيادة حجم البيانات التي تحتاج إلى معالجة يجعل التعلم العميق أكثر كفاءة من تعلم الآلة كما هو موضح بالشكل (2)[8]. إن النماذج العميقة المختلفة المشار إليها في الشكل (2) تختلف عن بعضها باختلاف عدد الطبقات المخفية الموجودة ضمن كل نموذج.



الشكل (1): بنية الشبكة العصبية الصناعية




الشكل (2): مقارنة بين النماذج حسب حجم البيانات

2-3- الشبكة العصبية الالتفافية Convolutional neural network(CNN) :

تعد الشبكة العصبية الالتفافية واحدة من أهم الشبكات في مجال التعلم العميق، إذ أنها حققت إنجازات رائعة ومكنت الرؤية الحاسوبية من تحقيق ما كان مستحيلًا سابقاً مثل التعرف على الوجوه والمركبات ذاتية القيادة والعلاجات الطبية الذكية وغيرها [9]. تتكون CNN من مجموعة من الطبقات الالتفافية والتجميعية (pooling) إضافة إلى طبقات الاتصال الكامل. تُستخدم الطبقات الالتفافية من أجل استخراج الميزات من بيانات الدخل (كالصور مثلاً) ليتم تقليلها باستخدام طبقات التجميع، وفي النهاية يكون هنالك طبقات الاتصال الكلي التي تلعب دور المصنف لبيانات الدخل. يمكن لـ CNN أن تستقبل أي نوع من الدخل

كالصوت والفيديو والصور وغيرها. يوضح الشكل (3) مثالاً عن شبكة عصبونية التلافيفية مع ملاحظة الطبقات آفة الذكر حيث يوجد مجموعة متنوعة من الطبقات الالتفافية التي من شأنها أن تعطي تمثيلات مختلفة لبيانات الدخل. تبدأ شبكة CNN بطبقات عامة كبيرة في البداية ثم تصبح أكثر تخصيصاً في الطبقات الأعمق. يعطي دمج الطبقات الالتفافية مع طبقات من نوع Dense الموجودة ضمن طبقات الاتصال الكامل نتائج تنبؤ جيدة [10]. يقصد بالطبقات العامة أي التي تستوعب كامل الدخل في البداية ثم تبدأ الطبقات الأعمق في استخراج وتلخيص الدخل.



الشكل (3): مثال عن شبكة عصبونية التلافيفية (CNN)

3-3- النماذج المستخدمة للعمل:


تكمن الفكرة الرئيسية من البحث في استخدام التعلم العميق وتحديداً الشبكات العصبونية الالتفافية من أجل تحليل صور الأشعة السينية للصدر بطريقة من شأنها أن تزيد دقة التنبؤ بتواجد فيروس Covid19 أو مرض الالتهاب الرئوي. استُخدمت CNN في هذا البحث حيث طُبقت على مجموعة من البيانات تتكون من عدد كبير من الصور إذ أن عدد الصور الخاصة بتدريب CNN يصل إلى 5144 صورة موزعة على ثلاث فئات، فئة covid-19، فئة مرض التهاب الرئة وفئة رئة طبيعية. اختُبرت CNN بعد عملية التدريب عن طريق 1288 صورة من أجل إيجاد دقة التنبؤ بالفئة. تم الحصول على البيانات من [11] وتم الالتزام بالعدد المحدد من الصور نظراً لتواجدها هكذا من المصدر. لم يتم الاعتماد على الشبكات العصبونية المتكررة (RNN) Neural Recurrent Networks عموماً و الذاكرة طويلة المدى (LSTM) Long Short-Term Memory خصوصاً لأن هذا النوع من

تحسين تصنيف صور الأشعة السينية للصدر للكشف عن الالتهاب الرئوي وفيروس كورونا
COVID19 باستخدام التعلم العميق

الشبكات مُستخدم مع الأنظمة الديناميكية التي تتعامل مع بيانات تعتمد على الترتيب والتسلسل الزمني كالفديو و الصوت وما شابهها [12]. في هذا البحث استُخدمت CNN لأن البيانات المعتمدة عبارة عن صور ليس لها علاقة بالتسلسل الزمني.

3-3-1- البيانات المستخدمة:

اعتمد في هذا البحث صور من موقع Kaggle خاصة بالصدر حيث يبين الشكل (4) صورة لصدر يتضمن فيروس covid-19.




الشكل (4): صورة صدرية تحوي فيروس covid-19

يبين الشكل (5) صورة صدر يعاني من التهاب رئوي بينما يحوي الشكل (6) على صورة صدرية سليمة:



الشكل (5): صورة صدرية تحوي التهاب رئوي



الشكل (6): صورة صدرية سليمة

3-2-3- منهج التعلم العميق المستخدم:

اعتمد المنهج على استخدام نماذج مدربة مسبقاً pre-trained models من أجل القيام بعملية تصنيف الصور حيث أن استخدام نماذج مدربة مسبقاً على عدد كبير من الصور يوفر زمن تدريب النموذج من البداية. طُبقت شبكة عصبونية متصلة Connected NN على خرج النموذج المدرب مسبقاً كمرحلة ثانية حيث أن النموذج المدرب مسبقاً المستخدم هو VGG19، يتضمن الشكل (7) ملخصاً عن النموذج VGG19 المستخدم لمقارنته مع نماذج الدراسات السابقة المعتمدة.

يبين الشكل (7) أن عدد الطبقات التي يحتويها هذا النموذج هو 21 طبقة بدون طبقة الدخل إذ أن الطبقة الالتفافية Conv تتكرر ضمن طبقات النموذج بكثرة يرافقها في بعض الأحيان طبقة التجميع pool. يتواجد أمام كل طبقة أبعاد الصورة التي سوف تكون دخلاً لها مع عدد الوسائط (parameters) الموجودة ضمنها. وصل عدد الوسائط المُشكّلة باستخدام هذا النموذج إلى 20,024,384 حسب الشكل (7).

يجب الإشارة إلى أن طبقات الشبكات العصبونية الموجودة ضمن VGG19 مدربة مسبقاً أي أنها لا تحتاج إلى تدريب من جديد وهذا ما يميز استخدام pre-trained models مسبقاً عند تصنيف الصور. إن طبقات VGG19 والذي يعتبر نوع من أنواع

الشبكات العصبونية الالتفافية تقوم بعملية استخراج أهم السمات من الصور المُدخلة لها بالتالي تأتي وظيفة الشبكة العصبونية المتصلة والتي تأخذ خرج VGG19 لتقوم وبناء على السمات المستخرجة بتصنيف الصور.

قامت الدراسة [4] باستخدام النموذج VGG16 والفرق بينه وبين النموذج VGG19 يكون في عدد الطبقات التي يتضمنها كل نموذج وكذلك الحال بالنسبة للنماذج RESNET,DENSENET,INCEPTION المستخدمة في الدراسات [15][14][13].

تجدر الإشارة أيضاً إلى استخدام التكبير Augmentation والذي يقوم بزيادة وتكبير حجم صور الدخل بالتالي زيادة كفاءة التدريب إذ أن الشبكة العصبونية المتصلة تحتاج إلى تدريب حتى تقوم بتصنيف خرج VGG19.

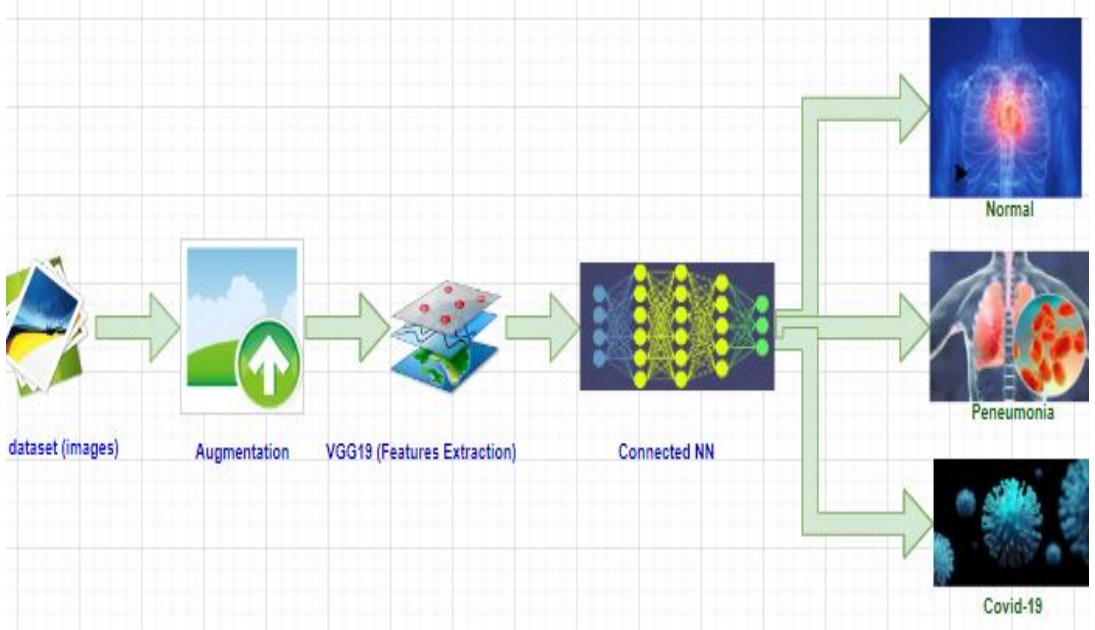
يتضمن augmentation العديد من العمليات حيث تم في البداية تطبيق الاسترداد Rescalling والتي تقوم بتحويل قيم الصور pixels إلى قيم أصغر بتقسيمها على أعلى قيمة موجودة وهي 255 إضافة إلى ذلك طبقت عملية القص shearing على الصور والتي تقوم بتشويه الصورة على أحد المحاور أي تغيير زاوية رؤية الصورة. طبقت أيضاً عملية تكبير الصورة Zooming بالتالي يمكن القول إن Augmentation هو عبارة عن عملية تطبيق مجموعة من العمليات على صور الدخل من أجل الحصول على صور جديدة من القديمة.

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 224, 224, 3)]	0
block1_conv1 (Conv2D)	(None, 224, 224, 64)	1792
block1_conv2 (Conv2D)	(None, 224, 224, 64)	36928
block1_pool (MaxPooling2D)	(None, 112, 112, 64)	0
block2_conv1 (Conv2D)	(None, 112, 112, 128)	73856
block2_conv2 (Conv2D)	(None, 112, 112, 128)	147584
block2_pool (MaxPooling2D)	(None, 56, 56, 128)	0
block3_conv1 (Conv2D)	(None, 56, 56, 256)	295168
block3_conv2 (Conv2D)	(None, 56, 56, 256)	590080
block3_conv3 (Conv2D)	(None, 56, 56, 256)	590080
block3_conv4 (Conv2D)	(None, 56, 56, 256)	590080
block3_pool (MaxPooling2D)	(None, 28, 28, 256)	0
block4_conv1 (Conv2D)	(None, 28, 28, 512)	1180160
block4_conv2 (Conv2D)	(None, 28, 28, 512)	2359808
block4_conv3 (Conv2D)	(None, 28, 28, 512)	2359808
block4_conv4 (Conv2D)	(None, 28, 28, 512)	2359808
block4_pool (MaxPooling2D)	(None, 14, 14, 512)	0
block5_conv1 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv2 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv3 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv4 (Conv2D)	(None, 14, 14, 512)	2359808
block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0
=====		
Total params: 20,024,384		
Trainable params: 0		

الشكل (7): ملخص طبقات VGG19

تحسين تصنيف صور الأشعة السينية للصدر للكشف عن الالتهاب الرئوي وفيروس كورونا
COVID19 باستخدام التعلم العميق

يوضح الشكل (8) النموذج النهائي المستخدم لتحسين معالجة الصور الصدرية من أجل تحسين دقة التصنيف إن كان هناك مرض covid-19 أم التهاب رئوي أم أن الصدر سليم لا يعاني من المرضين آنفي الذكر.



الشكل (8): خطوات النموذج المستخدم

4- النتائج والمناقشة:

اعتمد في هذا البحث على الدقة Accuracy والخسارة loss بشكل أساسي من أجل التقييم حيث تعطي علاقة الصحة وفق المعادلة (1) [2] بينما تُعطي علاقة الخسارة وفق المعادلة (2)[2].

$$Accuracy = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \quad (1)$$

Tp: True positive

Tn: True negative

Fp: False positive

Fn: False negative

$$Loss = -\frac{1}{N} \sum_{j=1}^N (y^j \log \hat{y}^j + (1 - y^j) \log(1 - \hat{y}^j))$$

y: actual class, \hat{y} : predicted class,

n: number of test samples


تدل Tp على عدد الحالات التي يتم التنبؤ بها بصنف إيجابي وبالفعل يكون الصنف الصحيح إيجابي بينما تدل Tn إلى عدد الحالات التي يتم التنبؤ بها بصنف سلبي وهي بالحقيقة صنف سلبي. نميز أيضاً بين Fp و Fn حيث أن Fp هي عدد الحالات التي يتم التنبؤ بها بصنف إيجابي وهي بالحقيقة صنف سلبي بينما Fn هي عدد الحالات التي يتم التنبؤ بها أنها صنف سلبي وهي بالحقيقة صنف إيجابي. تتضمن معادلة الخسارة القيمة التي تم التنبؤ بها \hat{y} والقيمة الحقيقية y . اعتمد في هذا البحث على الدراسة [4] من أجل مقارنة الدقة التي وصل إليها النموذج المستخدم إذ أنه في الدراسة [4] استُخدم النموذج المدرب مسبقاً VGG16 بينما في هذا البحث استُخدم VGG19 على نفس البيانات مع تطبيق أنواع مختلفة من النماذج المدربة مسبقاً حيث طبق النموذج RESNET بحسب الدراسة [13] والنموذج DENSENET بحسب الدراسة [14] و النموذج INCEPTION اعتماداً على الدراسة [15] من أجل المقارنة بين نتائج الدقة والضياع لمعرفة أداء كل نموذج اعتماداً على البيانات المستخدمة في هذا البحث. يتضمن الشكل (9) دقة الاختبار الخاصة بالنماذج الخمسة المطبقة على نفس البيانات مع عدد مرات تكرار تصل إلى 25.



الشكل (9): مقارنة دقة الاختبار

تحسين تصنيف صور الأشعة السينية للصدر للكشف عن الالتهاب الرئوي وفيروس كورونا COVID19 باستخدام التعلم العميق

يوضح الشكل (9) مقارنة من حيث دقة الاختبار بين نتائج الدراسة [4] ونتائج هذا البحث مع إضافة مقارنة لثلاثة نماذج مذكورة سابقاً كونها استخدمت في الدراسات [15] [14] [13] وذلك على نفس البيانات المستخدمة في [4] بعدد تكرارات 25. يبين الشكل (9) أن الدقة الأعلى وصل إليها النموذج VGG19 المستخدم في هذا البحث وبسرعة يليه النموذج DENSENET ثم النموذج VGG16. يوضح الشكل (9) أيضاً أن النموذج INCEPTION وصل إلى دقة أقل من النماذج آنفة الذكر مع ملاحظة تذبذب خلال عملية التدريب وسجل النموذج RESNET أسوأ دقة مقارنة مع كل النماذج المستخدمة. يحتوي الشكل (10) مقارنة من حيث الخسارة المتعلقة بالدراسة [4] مع مقارنة بين النماذج المستخدمة في الدراسات [15][14][13] والنموذج VGG19 المستخدم بهذا البحث وكل النماذج تم تطبيقها على نفس البيانات.



الشكل (10): مقارنة الخسارة

من خلال الشكل (10) يتضح أن الخسارة الأقل تم الوصول إليها من قبل VGG19, VGG16, DENSENET وأسوأ نتيجة حققها النموذج INCEPTION ثم RESNET مع العلم أن أقل خسارة بدأ بها النموذج VGG19 واستمر بأصغر القيم تقريباً على كامل عدد مرات تكرار التدريب.

5- الاستنتاجات والتوصيات:

يمكن القول ومن خلال النتائج السابقة أن هذا البحث حقق دقة أعلى من الدراسة [4] ومن النماذج المطبقة في الدراسات [15][14][13] وبشكل أسرع وأيضاً تم الحصول على خسارة أقل بزمن أقل بالتالي فإن استخدام VGG19 لمعالجة وتحليل الصور الأشعة السينية للصدر الموجودة في البيانات المستخدمة في هذا البحث أفضل وأكثر كفاءة. إن التوصيات التي من الممكن القيام بها مستقبلاً تُلخص وفق التالي:

- 1- تطبيق عدة نماذج إضافية مدربة مسبقاً في عملية المعالجة.
- 2- ربط نموذج التعلم العميق بمنظومة تصوير أشعة من أجل تشخيص المرض مباشرة.
- 3- القيام بدمج العديد من أنواع الشبكات العصبونية من أجل المقارنة من حيث الدقة واختيار الأفضل.

6- المراجع References

- [1]. Jain, R., Gupta, M., Taneja, S., & Hemanth, D. J. (2021). Deep learning based detection and analysis of COVID-19 on chest X-ray images. *Applied Intelligence*, 51(3), 1690-1700.
- [2]. Sharma, H., Jain, J. S., Bansal, P., & Gupta, S. (2020, January). Feature extraction and classification of chest x-ray images using cnn to detect pneumonia. In *2020 10th International Conference on Cloud Computing, Data Science & Engineering (Confluence)* (pp. 227-231). IEEE.
- [3]. Reshi, A. A., Rustam, F., Mehmood, A., Alhossan, A., Alrabiah, Z., Ahmad, A., ... & Choi, G. S. (2021). An efficient CNN model for COVID-19 disease detection based on X-ray image classification. *Complexity*, 2021.
- [4]. Hasan, M. D., Ahmed, S., Abdullah, Z. M., Monirujjaman Khan, M., Anand, D., Singh, A., ... & Masud, M. (2021). Deep learning approaches for detecting pneumonia in COVID-19 patients by analyzing chest X-ray images. *Mathematical Problems in Engineering*, 2021.
- [5]. Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and electronics in agriculture*, 147, 70-90.
- [6]. Johnson, J. M., & Khoshgoftaar, T. M. (2019). Survey on deep learning with class imbalance. *Journal of Big Data*, 6(1), 1-54.

- [7]. Zhou, L., Zhang, C., Liu, F., Qiu, Z., & He, Y. (2019). Application of deep learning in food: a review. *Comprehensive reviews in food science and food safety*, 18(6), 1793-1811.
- [8]. Chalapathy, R., & Chawla, S. (2019). Deep learning for anomaly detection: A survey. *arXiv preprint arXiv:1901.03407*.
- [9]. Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*.
- [10]. Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). A review of the use of convolutional neural networks in agriculture. *The Journal of Agricultural Science*, 156(3), 312-322.
- [11]. 30 October.2022.
<https://www.kaggle.com/datasets/prashant268/chest-xray-covid19-pneumonia>.
- [12]. Smagulova, K., & James, A. P. (2019). A survey on LSTM memristive neural network architectures and applications. *The European Physical Journal Special Topics*, 228(10), 2313-2324.
- [13]. Rajpal, S., Lakhyani, N., Singh, A. K., Kohli, R., & Kumar, N. (2021). Using handpicked features in conjunction with ResNet-50 for improved detection of COVID-19 from chest X-ray images. *Chaos, Solitons & Fractals*, 145, 110749.

- [14]. Liu, Q., Leung, C. K., & Hu, P. (2020). A two-dimensional sparse matrix profile DenseNet for COVID-19 diagnosis using chest CT images. *IEEE Access*, 8, 213718-213728.
- [15]. Horry, M. J., Chakraborty, S., Paul, M., Ulhaq, A., Pradhan, B., Saha, M., & Shukla, N. (2020). X-ray image based COVID-19 detection using pre-trained deep learning models.