

مجلة جامعة البعث

سلسلة العلوم الهندسية الميكانيكية
والكهربائية والمعلوماتية



مجلة علمية محكمة دورية

المجلد 46 . العدد 10

1446 هـ . 2024 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
م. ريا قباقلي

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 مشرفي
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 : 963 31 2138071 ++

. 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. عزت حسن م. أسامة زيني	الموقع الأمثل والاستطاعة المثلى للتوليد الموزع الكهروضوئي باستخدام الطريقة التحليلية في شبكة توزيع شعاعية
70-43	م. حسين علي عمران	تحقيق الزمن الأمثل لمسار محدد لذراع روبوت باستخدام متحكم إشرافي ضبابي (FSC) وفقا لخوارزمية (PCTOM)
114-71	م. محمد ديب د. ناصر أبو صالح	إغناء نظام NeuMF بكامل ميزات المعطيات باستخدام نماذج التعلم العميق المعتمدة على الانتباه لتحسين التنبؤ بالتقييمات
154-115	م. ريم مالك إبراهيم	مقارنة دقة كشف الاختراقات الأمنية في مجموعتي البيانات NSL-KDD و UNSWNB15 باستخدام خوارزميات الذكاء الصناعي

الموقع الأمثل والاستطاعة المثلى للتوليد الموزع الكهروضوئي باستخدام الطريقة التحليلية في شبكة توزيع شعاعية

*الدكتور عزت حسن

*المهندس أسامة زيني **

الملخص

ازدادت الدراسات الخاصة بدمج التوليد الموزع مع الشبكة الكهربائية، وذلك بسبب الاهتمام المتزايد بمصادر الطاقات المتجددة من أجل الوصول لحل صديق للبيئة وفي الغرض يكون بديلاً عن الوقود الأحفوري الآيل للنضوب مع التقدم الصناعي المستهلك له.

تحديد الموقع الأمثل والاستطاعة المثلى للتوليد الموزع مهم جداً من أجل تقليل مفايد الاستطاعة وتحسين مستوى الجهد.

في هذا البحث، قمنا بتحديد الموقع الأمثل والاستطاعة المثلى للتوليد الموزع الذي تم تثبيته في نظام توزيع شعاعي بحمولة موزعة بانتظام ومركزة ومتزايدة باستخدام الطريقة التحليلية. كما تم استنتاج العلاقات الرياضية للطريقة المقترحة عند حالة حمولة موزعة بانتظام وتطبيق هذه العلاقات على شبكة توزيع شعاعية للتأكد من صحة النتائج التي توصلنا إليها.

الكلمات المفتاحية: التوليد الموزع، الموقع الأمثل، الاستطاعة المثلى، الطريقة التحليلية، مفايد الاستطاعة.

*أستاذ - قسم هندسة الطاقة الكهربائية - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سوريا
**ماجستير - هندسة الطاقات المتجددة والبيئة - قسم هندسة الطاقة الكهربائية - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سوريا موبايل 963996699340+ ايميل Osama.Zi1989@gmail.com

The Optimum location and optimum power for distributed photovoltaic generation using the analytical method in a radial distribution network

****Engineer: Osama Zaini**

***Dr: Izzat hasn**

Abstract

Studies of integrating distributed generation with the electricity network have increased due to the increasing interest in renewable energies sources to reach an environmentally friendly solution that meets the purpose as an alternative to fossil fuels that are depleting with the industrial progress that consumes them.

Determining the optimal location and the optimal capacity of the distributed generation is very important in order to minimize total power losses and improve the voltage level.

In this article we have determined the optimum location and optimum power of distributed generation installed in a radial distribution system with uniformly distributed, centrally and increasing load using analytical method.

The mathematical relationships of the proposed method were also deduced when a uniformly distributed load and these relationships were applied to a radial distribution network to verify the validity of our findings.

Key words: distributed generation, optimal placement, optimal size, analytical method, power losses.

***Professor, department of electric power engineering, faculty of mechanical and electrical engineering, Tishreen university, Latakia, Syria.**

****postgraduate student, department of electric power engineering, faculty of mechanical and electrical engineering, Tishreen university, Latakia, Syria, email: Osama.Zi1989@gmail.com, tel: +963996699340**

1- مقدمة:

على مدى العقد الماضي شهد استخدام الطاقة الشمسية لتوليد الكهرباء نمواً كبيراً وذلك بسبب فوائدها الكبيرة. ومع ذلك نظراً للطبيعة المتغيرة لتوليد الطاقة الكهروضوئية فإن دمج كمية كبيرة من الألواح الكهروضوئية في شبكة التوزيع من الممكن أن يؤدي إلى تأثيرات سلبية على تشغيل مغذيات التوزيع.

المخاوف المحتملة الأكثر شيوعاً، الناتجة عن التوليد الكهروضوئي هي زيادة الجهد في الحالة المستقرة؛ التأثيرات على مفايد الاستطاعة؛ المشاكل المتعلقة بأجهزة تنظيم الجهد؛ الحماية وتقلب الجهد.

بشكل عام يعد تقليل مفايد الاستطاعة وتحسين استقرار الجهد من المسائل الهامة جداً في مجال نظام القدرة. لذا يعد تحديد الموقع الأمثل والاستطاعة المثلى لوحدة التوليد الكهروضوئية ضرورياً من أجل دعم تنظيم الجهد وتحسين أداء شبكات التوزيع [1]، [4].

بالنسبة لمسألة التوليد الموزع الكهروضوئي هناك العديد من الدراسات لتحقيق التخصيص الأمثل. كما ذكرنا سابقاً، يؤدي تحديد الموقع الأمثل والاستطاعة المثلى للتوليد الموزع إلى الوصول للحد الأدنى لمفايد الاستطاعة وتحسين الجهد الاسمي لنظام التوزيع. تم تطوير منهجيات مختلفة لتحديد الموقع الأمثل والاستطاعة المثلى للتوليد الموزع. تعتمد هذه المنهجيات إما على أدوات تحليلية أو على طرق برمجية تؤدي للوصول إلى الحل الأمثل.

في المرجع [5] قدم الباحثون نهجاً تحليلياً لتحديد الموقع الأمثل للتوليد الموزع بهدف تقليل مفايد شبكات التوزيع والنقل.

وفي المرجع [6] تم تنفيذ خوارزمية جديدة (FWA) meta-heuristic Firework

وهي خوارزمية موضعية ارشادية لحل مشكلة إعادة تشكيل الشبكة وذلك لتقليل مفايد الاستطاعة وتحسين مستوى التوتر.

في المرجع [7] تم اقتراح خوارزمية بحث بسيطة لتحديد الاستطاعة المثلى والموقع الأمثل للتوليد الموزع لنظام شبكي بالاستناد على مفايد الاستطاعة وتابع الكلفة كتابع هدف. هذه الطريقة بسيطة ولكنها تستغرق وقتاً طويلاً للبحث عن أفضل موقع واستطاعة مثلى.

في المرجع [8] استند الباحث على الحد الأدنى للمفايد وكلفة التوليد كبارامترات بالإضافة الى حدود استطاعة التوليد الموزع لتحديد الاستطاعة المثلى والموقع الأمثل للتوليد الموزع. هذه الطريقة دقيقة ولكنها مملة للغاية والحساب الرياضي لها يحتاج الى وقت كبير.

قدم الباحثون في المرجع [9] تقنية فعالة للتوضع الأمثل لصفوف الألواح الكهروضوئية وإعادة تشكيل شبكة توزيع شعاعية في وقت واحد لتقليل مفايد الاستطاعة الحقيقية الإجمالية وتعزيز مستوى الجهد للشبكة. تم تنفيذ خوارزمية التقييم التفاضلي بالاعتماد على قطاع سكني لتحديد مجموعة التحويل المثلى والموقع الأمثل وعدد الوحدات الكهروضوئية في نظام التوزيع.

في المرجع [10] تم اقتراح منهج عشوائي قائم على تقدير كثافة النواة لتحديد الموقع الأمثل لتركيب محطة طاقة كهروضوئية في أنظمة التوزيع بحيث يتم تقليل انحراف الجهد ومفايد الشبكة. لإثبات فعالية الطريقة المقترحة، تم الاختبار على نموذج مغذي توزيع حقيقي. النظام المختبر يقع في الولايات المتحدة ويتكون من 38 مغذي ويتضمن محطة طاقة كهروضوئية.

في المرجع [11] اقترح المؤلفون نهجاً جديداً لدراسة تأثير اختراق الألواح الكهروضوئية العالي على شبكة توزيع وقدرتها على الاستضافة. تجمع الطريقة بين تقييم الموارد المتاحة باستخدام صور أقمار صناعية عالية الدقة مع محاكاة نظام الطاقة على نماذج توزيع حقيقية لدراسة تأثيرات سويات اختراق الألواح الكهروضوئية بنسبة تصل الى 200% على قفزات الجهد، مفايد الخط، واستثمار عمليات التغيير.

في المرجع [12] تم تقديم نهج تحليلي جديد قائم على مؤشر مزدوج لتحديد الموقع الأمثل والاستطاعة المثلى وعامل الاستطاعة لوحدة التوليد الموزع لتقليل مفايد الاستطاعة وتعزيز إمكانية التحميل (قابلية التحميل). يعرف هذا المؤشر على أنه مزيج من مؤشرات مفايد الاستطاعة الفعلية والرديئة عن طريق التوزيع الأمثل والموقع الأمثل وعامل الاستطاعة الأمثل والأعباء التناسبية لعبء كل مؤشر. تؤدي الطاقة الفعلية والرديئة الى تقليل المفايد بشكل كبير وتحسين قابلية التحميل ومستوى الجهد.

في المرجعين [13,14] تم دراسة تأثير حالات التخمين (عدم اليقين) والعشوائية وتغير خرج المولدات الموزعة وعدم اليقين في الحمولة على سريان الاستطاعة ومفايد الشبكة في شبكات التوزيع وذلك عند اختيار الموقع الأمثل.

وفي المرجع [15] تم شرح الفوائد التقنية والاقتصادية لوضع التوليد الموزع في سوق الطاقة، حيث يقلل اختراق التوليد الموزع من كلفة التوليد الحالية ويساهم في تحسين موثوقية النظام.

في المرجع [16] تم تقديم مراجعة لتقنيات الأمثلة المطبقة لدمج التوليد الموزع المقدم من مصادر الطاقة المتجددة في أنظمة التوزيع.

في المرجع [17] تم تقديم منهجية لتحديد الموقع الأمثل واختيار وتشغيل أنظمة تخزين قدرة البطارية والمولدات الموزعة المتجددة في أنظمة التوزيع ذات الجهد المتوسط والمنخفض باستخدام نموذج برمجة لاخطية صحيحة مختلطة لصياغة المشكلة.

في المرجع [18] قدم الباحثون دراسة لإيجاد القيمة العظمى لمؤشر استقرار الجهد في شبكات التوزيع ذات الجهد المتوسط مع الأخذ بعين الاعتبار الموقع الأمثل والاستطاعة المثلى للمولدات المبعثرة. تم صياغة المشكلة من خلال نموذج البرمجة اللاخطية المختلطة والذي تم حله باستخدام نظام النمذجة الجبرية العام.

لكن الإضافة المقدمة في هذه الدراسة عن الدراسات السابقة هي استنتاج العلاقات الرياضية للطريقة التحليلية لحالة حمولة منتظمة وكتابة الكود البرمجي الخاص بحالة التحميل المذكورة وتوضيح كيفية الوصول الى النتائج ثم تطبيق هذه العلاقات على شبكة توزيع شعاعية اختبارية مؤلفة من ثلاث عشر باسبار. وتم استخدام هذه الطريقة لتحديد الموقع الأمثل والاستطاعة المثلى للتوليد الموزع بسبب المزايا التي تتمتع بها ألا وهي:

- (1) طريقة تمتاز بالدقة والموثوقية.
- (2) تعطي النتيجة خلال فترة زمنية قصيرة.
- (3) لا تشمل خوارزميات تكرارية والتي تستغرق وقتاً طويلاً.
- (4) يتم افتراض فرضيات حقيقية تؤدي الى نتائج حقيقية.
- (5) تقنية بسيطة وسهلة التنفيذ لمعرفة الموقع الأمثل والاستطاعة المثلى للتوليد الموزع.
- (6) تعطي هذه الطريقة حلول جيدة للنظام عندما تكون الأحمال موزعة بانتظام.

2- أهمية البحث وأهدافه:

زيادة كفاءة شبكات التوزيع من خلال تحديد الاستطاعة المثلى والموقع الأمثل لوحدات التوليد الموزع الكهروضوئية. وتحسين جودة الطاقة. دراسة الطريقة التحليلية وعلاقتها الرياضية لتحديد الموقع الأمثل والاستطاعة المثلى للتوليد الموزع في شبكة توزيع شعاعية مع أحمال منتظمة ومركزة ومتزايدة.

3- طريقة البحث ومواده:

لتبسيط التحليل يتم اعتبار خطوط النقل ذات بارامترات موزعة بشكل منتظم أي أن المقاومة والمفاعلة واحدة على طول الخط والسعة والناقلية مهملة. التيار المغذي في النقطة (x) لخط نقل طوله (u) وممانعته (Z) يعطى بالعلاقة التالية [20], [19]:

$$I(x) = \int_0^x J_d(x). dx \quad (1)$$

حيث أن: $J_d(x)$ كثافة التيار.

وبالتالي فإجمالي مفايد الاستطاعة هي:

$$P_{loss} = \int_0^u \left[\int_0^x J_d(x). dx \right]^2 . R. dx \quad (2)$$


وانحراف الجهد بين النقطة x ونهاية المغذي يمكن حسابه من العلاقة التالية:

$$V_{drop(x)} = \int_0^x \int_0^x J_d(x). dx . Z. dx \quad (3)$$

1-3 الحالة الأولى: حالة حمولة موزعة بانتظام:

1-1-3 استنتاج العلاقات الرياضية لمفايد الاستطاعة قبل وبعد إضافة التوليد

الموزع:



تعطى كثافة التيار في هذه الحالة بالعلاقة التالية [20]:

$$J_d(x) = I \quad (4)$$

نعوض العلاقة (4) في (2) نحصل على العلاقة التالية:

$$P_{loss} = \int_0^u \left[\int_0^x I \cdot dx \right]^2 \cdot R \cdot dx = \int_0^u [I \cdot x]^2 \cdot R \cdot dx = \int_0^u I^2 \cdot x^2 \cdot R \cdot dx$$

$$\Rightarrow P_{loss} = \frac{1}{3} R \cdot I^2 \cdot u^3 \quad (5)$$

تعطى العلاقة (5) مفايد الاستطاعة الإجمالية في المغذي قبل إضافة التوليد الموزع لحالة حمولة منتظمة علماً أن: R : مقاومة الخط، I : التيار المار في المغذي.

أما عند إضافة التوليد الموزع الى المغذي في الموقع (x_0) كمصدر حاقن للتيار (I_{dg}) وبافتراض إهمال التغير في كثافة تيار الحمل الناتج عن هذه الإضافة يمكن حساب تيار المغذي على النحو التالي:

$$I(x) = \begin{cases} \int_0^x J_d(x) \cdot dx & 0 \leq x \leq x_0 \\ \int_0^x J_d(x) dx - I_{dg} & x_0 \leq x \leq u \end{cases} \quad (6)$$

تعطى مفايد الاستطاعة وانخفاض الجهد بعد إضافة التوليد الموزع بالعلاقتين التاليتين على الترتيب:

$$P_{loss} = \int_0^{x_0} \left[\int_0^x J_d(x) \cdot dx \right]^2 \cdot R \cdot dx + \int_{x_0}^u \left[\int_0^x J_d(x) \cdot dx - I_{dg} \right]^2 R \cdot dx \quad (7)$$

$$V_{drop(x)} = \begin{cases} \int_0^x \int_0^x J_d(x) dx \cdot z \cdot dx & 0 \leq x \leq x_0 \\ \int_0^{x_0} \int_0^x J_d(x) dx \cdot z \cdot dx + \int_{x_0}^x \left(\int_0^x J_d(x) dx - I_{dg} \right) z \cdot dx & x_0 \leq x \leq u \end{cases} \quad (8)$$

نعوض العلاقة (4) في العلاقة (7):

$$P_{loss} = \int_0^{x_0} \left[\int_0^x I \cdot dx \right]^2 \cdot R \cdot dx + \int_{x_0}^u \left[\int_0^x I \cdot dx - I_{dg} \right]^2 \cdot R \cdot dx$$

$$\begin{aligned}
 &= \int_0^{x_0} R \cdot I^2 \cdot x^2 dx + \int_{x_0}^u [I^2 \cdot x^2 \cdot dx - 2 \cdot I \cdot I_{dg} \cdot x \cdot dx + I_{dg}^2 \cdot dx] \cdot R \\
 &= R \cdot \int_0^u I^2 \cdot x^2 \cdot dx - 2 \cdot R \cdot \int_{x_0}^u I \cdot I_{dg} \cdot x \cdot dx + R \cdot \int_{x_0}^u I_{dg}^2 \cdot dx \\
 &\Rightarrow P_{loss} = \frac{1}{3} \cdot I^2 \cdot R \cdot u^3 - R \cdot I \cdot I_{dg} (u^2 - x_0^2) \\
 &\quad + R \cdot I_{dg}^2 (u - x_0) \tag{9}
 \end{aligned}$$

للحصول على الموقع الأمثل للتوليد الموزع نشق المعادلة (9) بالنسبة ل (x_0) ونساويها للصفر:

$$\begin{aligned}
 \frac{dP_{loss}}{dx_0} = 0 &\Rightarrow 2 \cdot I_{dg} \cdot I \cdot R \cdot x_0 - I_{dg}^2 \cdot R = 0 \\
 &\Rightarrow x_0 \\
 &= \frac{I_{dg}}{2 \cdot I} \tag{10}
 \end{aligned}$$

يتم وضع التوليد الموزع بعامل استطاعة يساوي الواحد ويؤمن تغذية الحمل كاملاً والمنبع يؤمن تغذية الخط لتغطية مفايد الاستطاعة. عندئذ التيار المقدم من التوليد الموزع المضاف يكون:

$$\begin{aligned}
 I_{dg} &= \int_0^u J_{d(x)} \cdot dx \\
 &= \int_0^u I \cdot dx \\
 &= I \cdot u \tag{11}
 \end{aligned}$$

نعوض العلاقة (11) في العلاقة (10) نحصل على موقع التوليد الموزع الأمثل قبل حساب الاستطاعة:

$$\begin{aligned} x_0 &= \frac{I \cdot u}{2 \cdot I} \\ &= \frac{u}{2} \end{aligned} \quad (12)$$

نعوض العلاقاتين (11) و(12) في العلاقة (9):

$$\begin{aligned} &\Rightarrow P_{loss} \\ &= \frac{1}{12} \cdot I^2 \cdot R \cdot u^3 \end{aligned} \quad (13)$$

العلاقة (13) تعطينا مفايد الاستطاعة الكلية للمغذي بعد إضافة التوليد الموزع في الموقع الأمثل.

لحساب الاستطاعة المثلى للتوليد الموزع نشق المعادلة (9) بالنسبة ل I_{dg} ونساويها للصفر:

$$\begin{aligned} \frac{dP_{loss}}{dI_{dg}} = 0 &\Rightarrow -I \cdot R(u^2 - x_0^2) + 2 \cdot R(u - x_0) \cdot I_{dg} = 0 \\ &\Rightarrow I_{dg} \\ &= \frac{I \cdot (u + x_0)}{2} \end{aligned} \quad (14)$$

بالحل المشترك للمعادلتين (10) و(14) نحصل على الموقع الأمثل والاستطاعة المثلى للتوليد الموزع المضاف:

$$\begin{aligned} x_0 &= \frac{1}{3}u, I_{dg} \\ &= \frac{2}{3}I \cdot u \end{aligned} \quad (15)$$

نعوض العلاقة (15) في العلاقة (9):

العلاقة (16) تعطينا مفايد الاستطاعة بعد إضافة التوليد الموزع في الموقع الأمثل بالاستطاعة المثلى.

3-1-2 استنتاج العلاقة الرياضية لهبوط الجهد قبل وبعد إضافة التوليد الموزع:

قبل إضافة التوليد الموزع:

من العلاقة (3) لدينا:

بتعويض العلاقة (4) في العلاقة (3) نحصل على الآتي:

$$V_{drop(u)} = \int_0^u \int_0^x I \cdot d(x) \cdot Z \cdot dx = \int_0^u I \cdot x \cdot Z \cdot dx$$

$$\begin{aligned} &\Rightarrow V_{drop(u)} \\ &= 0,5 \cdot I \cdot Z \cdot u \end{aligned} \quad (17)$$

العلاقة (17) تعطينا هبوط الجهد قبل إضافة التوليد الموزع.

بعد إضافة التوليد الموزع:

بتعويض العلاقة (4) في العلاقة (8) نحصل على الآتي:

$$\begin{aligned} &= \int_0^{x_0} I \cdot x \cdot Z \cdot dx + \int_{x_0}^u I \cdot x \cdot Z \cdot dx - I_{dg} \cdot Z \cdot dx \\ &= \int_0^{x_0} I \cdot x \cdot Z \cdot dx + \int_{x_0}^u I \cdot x \cdot Z \cdot dx - \int_{x_0}^u I_{dg} \cdot Z \cdot dx \end{aligned}$$

$$\begin{aligned}
 &= \int_0^u I \cdot x \cdot Z \cdot dx \\
 &\quad - \int_{x_0}^u I_{dg} \cdot Z \cdot dx \Rightarrow V_{drop} \\
 &= \frac{1}{2} \cdot I \cdot Z \cdot u^2 - I_{dg} \cdot Z \cdot (u - x_0) \quad (18)
 \end{aligned}$$

نعوض العلاقة (15) في العلاقة (18) نحصل على مايلي:


$$\begin{aligned}
 V_{drop(u)} &= \frac{1}{2} \cdot I \cdot Z \cdot u^2 - \frac{2}{3} \cdot I \cdot u \cdot Z \left(u - \frac{1}{3} u \right) \\
 &= \frac{1}{2} \cdot I \cdot Z \cdot u^2 - \frac{4}{9} \cdot I \cdot Z \cdot u^2 \\
 V_{drop(u)} &= 0,05 \cdot I \cdot Z \cdot u^2 \quad (19)
 \end{aligned}$$

تمثل هذه العلاقة هبوط الجهد بعد إضافة التوليد الموزع.

2-3 الحالة الثانية: حالة حمولة مركزة:

تعطى كثافة التيار في هذه الحالة بالعلاقة التالية:

$$J_d(x) = \begin{cases} I \cdot x & 0 \leq x \leq \frac{u}{2} \\ I(u - x) & \frac{u}{2} \leq x \leq u \end{cases} \quad (20)$$



باتباع الخطوات السابقة والترتيب نفسه من تعويض وتكامل واشتقاق نحصل على العلاقات التالية:

$$P_{loss} = \frac{23}{960} I^2 \cdot R \cdot u^5 \quad (21)$$

تمثل هذه العلاقة مفايد الاستطاعة قبل إضافة التوليد الموزع.

$$x_0 = \frac{u}{2}$$

العلاقة (22) تعطينا الموقع الأمثل للتوليد الموزع المضاف قبل حساب الاستطاعة المثلى.

وبالتالي تعطى مفايد الاستطاعة بعد إضافة التوليد الموزع في الموقع الأمثل فقط وفق العلاقة التالية:

$$P_{loss} = \frac{1}{320} I^2 \cdot R \cdot u^5 \quad (23)$$

يعطى الموقع الأمثل للتوليد الموزع المضاف بعد حساب استطاعته المثلى في هذه الحالة وفق العلاقة التالية:

$$x_0 = 0,446 \cdot u, \\ I_{dg} = \frac{1}{5} I \cdot u^2 \quad (24)$$


تكون مفايد الاستطاعة في هذه الحالة كالتالي:

$$P_{loss} = 2 \cdot 10^{-3} \cdot I^2 \cdot R \cdot u^5 \quad (25)$$

3-3 الحالة الثالثة: حالة حمولة متزايدة:

يتم حساب كثافة التيار في هذه الحالة كمايلي:

$$J_d(x) = I. (u - x) \quad (26)$$



العلاقات الرياضية في هذه الحالة تعطي كمايلي:

مفايد الاستطاعة قبل إضافة التوليد الموزع يتم حسابها من العلاقة التالية:

$$P_{loss} = 0,133. I^2. R. u^5 \quad (27)$$

الموقع الأمثل للتوليد الموزع المضاف قبل حساب استطاعته يكون:

$$x_0$$

$$= 0,29. u$$

وبالتالي مفايد الاستطاعة بعد إضافة التوليد الموزع في الموقع الأمثل يتم حسابها من

العلاقة التالية:

$$P_{loss} = 0,0155. I^2. R. u^5 \quad (29)$$

الموقع الأمثل للتوليد الموزع المضاف بعد تحديد استطاعته المثلى يكون كمايلي:

$$x_0 = 0,225 \cdot u,$$

$$I_{dg}$$

$$= \frac{2}{5} \cdot I \cdot u^2 \quad (30)$$

وبالتالي مفايد الاستطاعة بعد إضافة التوليد الموزع باستطاعته المثلى في الموقع الأمثل تحسب من العلاقة التالية:

$$P_{loss} = 9,4 \cdot 10^{-3} \cdot I^2 \cdot R \cdot u^5 \quad (31)$$

3-4 تجريب العلاقات الرياضية للطريقة التحليلية في بيئة ماتلاب:

تم كتابة كود برمجي في بيئة برمجية وهي ماتلاب والتجربة على احدى حالات الحمولة وهي الحمولة المنتظمة. الشكل العام لعلاقة تحديد الاستطاعة المثلى والموقع الأمثل هي كالتالي:

$$\frac{d}{dx_0} P_{loss} = \frac{d}{dI_{dg}} P_{loss}$$

$$= 0 \quad (32)$$


يعطي حل المعادلة (29) وبالاستناد على العلاقات الرياضية التي توصلنا اليها بالنسبة لنظام توزيع مع حمولة منتظمة الاستطاعة المثلى للتوليد الموزع $\frac{2}{3} \cdot I \cdot u$ أي ما يعادل 67% من إجمالي الحمل.

وبالنسبة لحمولة مركزة فإن الاستطاعة المثلى للتوليد الموزع 80% من إجمالي الحمل. وبالنسبة للحمولة المتزايدة 80% من إجمالي الحمل.

أما المواقع المثلى للتوليد الموزع فهي بالنسبة لحمولة منتظمة 0,33 من طول المغذي من جهة النهاية، وبالنسبة لحمولة مركزة 0,446 من طول المغذي، وبالنسبة لأحمال متزايدة 0,225 من طول المغذي. ويتم عرض النتائج في فقرة النتائج والمناقشة.

4- تطبيق العلاقات الرياضية على شبكة توزيع شعاعية:

لفهم ما سبق بشكل جيد والتأكد من صحة العلاقات الرياضية السابقة نقوم بتطبيق تلك العلاقات على شبكة توزيع شعاعية اختبارية [20] في حالات الحمولة الثلاث (منتظمة، مركزة، متزايدة) كما في الشكل التالي:



الشكل (1) شبكة توزيع شعاعية

بارامترات شبكة التوزيع موضحة في الجدول التالي [20]:

الجدول (2) بارامترات النظام

اجمالي الحمل [MW]	جهد الباسبار = 20													بارامترات الخط	
	R=0,538 Ω/Km X=0,4626 Ω/Km [Kv]													المسافة بين باسبارين متجاورين : 2,5Km	
نوع الحمولة	حمل كل باسبار [MW]													نوع الحمولة	
	13	12	11	10	9	8	7	6	5	4	3	2	1	نوع الحمولة	
منتظمة	3,9	0,3	0,3	0,3	0,3	0,3	0,3	0,3	0,3	0,3	0,3	0,3	0,3	0,3	منتظمة
مركزة	2,94	0,06	0,12	0,18	0,24	0,3	0,36	0,42	0,36	0,3	0,24	0,18	0,12	0,06	مركزة
متزايدة	3,51	0,45	0,42	0,39	0,36	0,33	0,3	0,27	0,24	0,21	0,18	0,15	0,12	0,09	متزايدة

4-1 حالة حمولة منتظمة:

مفايد الاستطاعة قبل إضافة التوليد الموزع تحسب من العلاقة (5):

$$P_{loss} = 409,39[kw]$$

الموقع الأمثل للتوليد الموزع قبل حساب الاستطاعة الأمثل يتم تحديده من العلاقة (12):

$$x_0 = \frac{u}{2} = \frac{30}{2} = 15[km]$$

أي يجب وضع التوليد الموزع في منتصف المغذي وهذا يوافق الباسبار السابع.

مفايد الاستطاعة بعد إضافة التوليد الموزع في الموقع الأمثل فقط تحسب من العلاقة (13):

$$P_{loss-new1} = 102,308[kw]$$

النسبة المئوية لانخفاض مفايد الاستطاعة في هذه الحالة تكون:

$$\begin{aligned} loss\ reduction_1\% &= \left[\frac{P_{loss} - P_{loss\ new1}}{P_{loss}} \right] \cdot 100 \\ &= \left[\frac{409,39 - 102,308}{409,39} \right] \cdot 100 \approx 75\% \end{aligned}$$

الموقع الأمثل للتوليد الموزع بعد حساب الاستطاعة المثلى له التي تعادل 67% من حمل المغذي يتم تحديده من العلاقة (15):

$$x_o = \frac{1}{3} \cdot u = \frac{1}{3} \cdot 30 = 10[km]$$

أي يجب وضع التوليد الموزع على الباسبار 9.

مفايد الاستطاعة بعد إضافة التوليد الموزع في الموقع الأمثل وباستطاعته المثلى تحسب من العلاقة (16):

$$P_{loss-new2} = 45,329[kw]$$

النسبة المئوية لانخفاض مفايد الاستطاعة في هذه الحالة تكون:

$$\begin{aligned} \text{Loss reduction}_2\% &= \left[\frac{P_{\text{loss}} - P_{\text{loss-new2}}}{P_{\text{loss}}} \right] \cdot 100 \\ &= \left[\frac{409,39 - 45,329}{409,39} \right] \cdot 100 = 88,89\% \end{aligned}$$

أما هبوط الجهد قبل إضافة التوليد الموزع يحسب من العلاقة (17):

$$V_{\text{drop1}} = 2,541[\text{kV}]$$

النسبة المئوية لهبوط الجهد قبل إضافة التوليد الموزع:

$$\Delta U_1\% = \frac{V_{\text{drop1}}}{V_n} * 100 = \frac{2,541}{20} * 100 = 12,7\%$$

وبعد إضافة التوليد الموزع يحسب هبوط الجهد من العلاقة (19):

$$V_{\text{drop2}} = 0,256[\text{kV}]$$

النسبة المئوية لهبوط الجهد بعد إضافة التوليد الموزع:

$$\Delta U_2\% = \frac{V_{\text{drop2}}}{V_n} * 100 = \frac{0,256}{20} * 100 = 1,28\%$$

2-4 حالة حمولة مركزة:

مفايد الاستطاعة قبل إضافة التوليد الموزع تحسب من العلاقة (21):

$$P_{\text{loss}} = 119,351[\text{kW}]$$

مفايد الاستطاعة بعد إضافة التوليد الموزع في الموقع الأمثل فقط تحسب من العلاقة
(23):

$$P_{loss-new1} = 15,557[kw]$$

النسبة المئوية لانخفاض مفايد الاستطاعة في هذه الحالة هي:

$$\begin{aligned} loss\ reduction_1\% &= \left[\frac{P_{loss} - P_{loss\ new1}}{P_{loss}} \right] \cdot 100 \\ &= \left[\frac{119,351 - 15,557}{119,351} \right] \cdot 100 = 86,96\% \end{aligned}$$

مفايد الاستطاعة بعد إضافة التوليد الموزع في الموقع الأمثل وباستطاعته المثلى تحسب
من العلاقة (25):

$$P_{loss-new2} = 9,958[kw]$$

وتكون النسبة المئوية لانخفاض مفايد الاستطاعة هي:

$$\begin{aligned} loss\ reduction_2\% &= \left[\frac{P_{loss} - P_{loss\ new2}}{P_{loss}} \right] \cdot 100 \\ &= \left[\frac{119,351 - 9,958}{119,351} \right] \cdot 100 = 91,65\% \end{aligned}$$

مفاقد الاستطاعة قبل إضافة التوليد الموزع تحسب من العلاقة (27):

$$P_{loss} = 1211,091[kw]$$

مفاقد الاستطاعة بعد إضافة التوليد الموزع في الموقع الأمثل فقط تحسب من العلاقة (29):

$$P_{loss-new1} = 141,09[kw]$$

النسبة المئوية لانخفاض مفاقد الاستطاعة في هذه الحالة تكون:

$$\begin{aligned} loss\ reduction_1\% &= \left[\frac{P_{loss} - P_{loss\ new1}}{P_{loss}} \right] . 100 \\ &= \left[\frac{1211,09 - 141,09}{1211,091} \right] . 100 = 88,35\% \end{aligned}$$

مفاقد الاستطاعة بعد إضافة التوليد الموزع في الموقع الأمثل وبالاستطاعة المثلى تحسب من العلاقة (31):

$$P_{loss-new2} = 85,446[kw]$$

وبالتالي تكون النسبة المئوية لانخفاض مفاقد الاستطاعة هي:

$$\begin{aligned} loss\ reduction_2\% &= \left[\frac{P_{loss} - P_{loss\ new2}}{P_{loss}} \right] . 100 \\ &= \left[\frac{1211,091 - 85,446}{1211,091} \right] . 100 = 92,94\% \end{aligned}$$

5- النتائج والمناقشة:

يتم عرض نتائج التحليل النظري ونتائج تطبيق العلاقات الرياضية من خلال الجدول التالي [19], [20]:

الجدول (2) نتائج التحليل النظري لمغذي شعاعي مع أنواع حمولة مختلفة (أ) لأجل الموقع الأمثل للتوليد الموزع المضاف

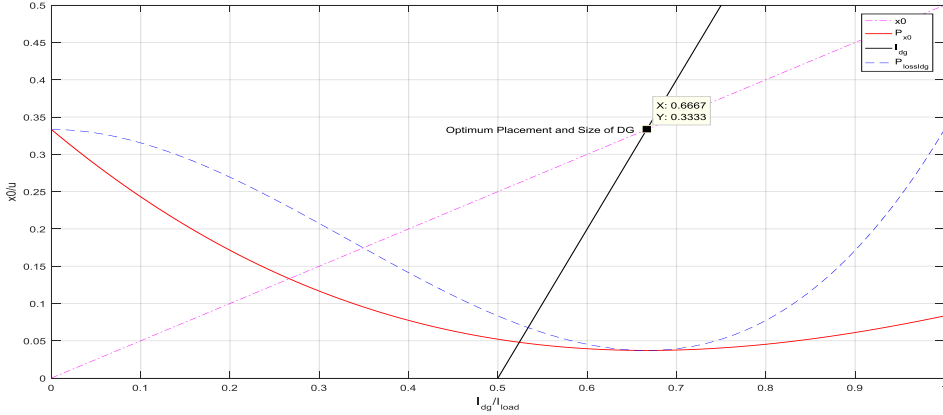
التوليد الموزع المضاف في الموقع الأمثل		بدون توليد موزع		نوع الحمولة
نسبة انخفاض مفايد الاستطاعة %	P_{loss}	x_0	P_{loss}	
75%	$I^2 \cdot R \cdot u^3 / 12$	$\frac{u}{2}$	$I^2 \cdot R \cdot u^3 / 3$	حمل منتظم
86,94%	$\frac{1}{320} I^2 \cdot R \cdot u^5$	$\frac{u}{2}$	$\frac{23}{960} I^2 \cdot R \cdot u^5$	حمل مركز
88,34%	$0,0155 \cdot I^2 \cdot R \cdot u^5$	$0,29 \cdot u$	$0,133 \cdot I^2 \cdot R \cdot u^5$	حمل متزايد

(ب) لأجل الموقع الأمثل والاستطاعة المثلى للتوليد الموزع المضاف

التوليد الموزع المضاف في الموقع الأمثل وباستطاعته المثلى				بدون توليد موزع	نوع الحمولة
نسبة انخفاض مفاوئد الاستطاعة %	P_{loss}	I_{dg}	x_0	P_{loss}	
88,89%	$\frac{1}{27} R \cdot I^2 \cdot u^3$	$\frac{2}{3} I \cdot u$	$\frac{1}{3} u$	$I^2 \cdot R \cdot u^3 / 3$	حمل منتظم
91,67%	$2 \cdot 10^{-3} I^2 \cdot R \cdot u^5$	$\frac{1}{5} I \cdot u^2$	$0,446 \cdot u$	$\frac{23}{960} I^2 \cdot R \cdot u^5$	حمل مركز
92,93%	$9,4 \cdot 10^{-3} I^2 \cdot R \cdot u^5$	$\frac{2}{5} I \cdot u^2$	$0,225 \cdot u$	$0,133 \cdot I^2 \cdot R \cdot u^5$	حمل متزايد

في الجدول (2) تعطى النتائج النظرية للموقع الأمثل والاستطاعة المثلى للتوليد الموزع لتقليل مفاوئد الاستطاعة بالنسبة للأنظمة المدروسة ونتائج التطبيق على شبكة توزيع شعاعية. ينخفض إجمالي مفاوئد الاستطاعة لكل نظام عندما يتم تحديد موقع التوليد الموزع بالشكل الأمثل. إضافة إلى ذلك عندما يتم اختيار الاستطاعة المثلى للتوليد الموزع يصبح الانخفاض في مفاوئد الاستطاعة أكبر. للحصول على الموقع الأمثل للتوليد الموزع مع وبدون الاستطاعة المثلى نلاحظ أن الموقع الأمثل للتوليد الموزع يتأثر بمستوى الحمل عندما يتم تحديد الموقع الأمثل للتوليد الموزع مع الاستطاعة المثلى. من ناحية أخرى فإن الموقع الأمثل للتوليد الموزع هو نفسه بالنسبة لحمل منتظم ومركز وذلك في حال تحديد الموقع الأمثل فقط. ويتم عرض المنحنيات البيانية التي حصلنا عليها من

تجريب الطريقة التحليلية برمجياً في بيئة ماتلاب في الشكل التالي وأثبتت صحة النتائج التي حصلنا عليها.



a. حمولة منتظمة

الشكل (2) الموقع الأمثل والاستطاعة المثلى لإضافة التوليد الموزع وإجمالي مفايد الاستطاعة

الشكل (2) يوضح المواقع المثلى للتوليد الموزع بالنسبة لنماذج الحمولة المنتظمة حيث أن منحنى x_0 الذي يمثل الموقع الأمثل للتوليد الموزع والذي يتغير مع تغير استطاعة التوليد الموزع من الصفر إلى إجمالي الحمل. منحنى $P_{loss}x_0$ مفايد الاستطاعة الكلية الذي يتطابق مع منحنى x_0 الموقع الأمثل.

بنفس الطريقة منحنى I_{dg} الذي يمثل منحنى الاستطاعة المثلى للتوليد الموزع والذي يتغير مع موقع التوليد الموزع من الصفر حتى u . منحنى $P_{loss}I_{dg}$ الذي يتطابق مع منحنى I_{dg} الاستطاعة المثلى للتوليد الموزع. نقطة تقاطع منحنى x_0 مع منحنى I_{dg} تمثل الموقع الأمثل والاستطاعة المثلى للتوليد الموزع.

6- الاستنتاجات والتوصيات:

قدمت هذه الدراسة مايلي:

- (1) استخدام الطريقة التحليلية لتحديد الموقع الأمثل والاستطاعة المثلى للتوليد الموزع المضاف الى شبكة توزيع شعاعية.
- (2) تطبيق الطريقة التحليلية على شبكة توزيع بثلاث حالات تحميل مختلفة (منتظمة، مركزة، متزايدة).
- (3) استنتاج العلاقات الرياضية للطريقة التحليلية في حالة حمولة منتظمة فقط.
- (4) تجريب الطريقة التحليلية في بيئة برمجية وهي الماتلاب.
- (5) التأكد من صحة العلاقات الرياضية التي توصلنا اليها بتطبيقها على شبكة توزيع شعاعية.
- (6) اجراء مقارنة بين حالتين الاولى إضافة التوليد الموزع في الموقع الأمثل فقط والثانية إضافة التوليد الموزع في الموقع الأمثل بالاستطاعة المثلى وحساب نسبة انخفاض مفايد الاستطاعة في الحالتين.
- (7) اثبتت النتائج فعالية ومساهمة إضافة التوليد الموزع عند تثبيته في الموقع الأمثل وبالاستطاعة المثلى في انخفاض مفايد الاستطاعة بنسبة كبيرة جداً مقارنة بحالة إضافته في الموقع الأمثل فقط.

أخيراً يوصى مايلي:

- ✓ استنتاج العلاقات الرياضية للطريقة التحليلية في حالتى التحميل الباقيتين (مركزة، متزايدة).
- ✓ كتابة الكود البرمجي الخاص بحالتى التحميل الباقيتين (مركزة، متزايدة).
- ✓ استخدام التوليد الموزع كتقنية فعالة لتخفيض المفاقد في شبكات التوزيع الشعاعية.

References:

- [1] M. M. Haque and P. Wolfs, "A review of high PV penetrations in LV distribution networks: Present status, impacts and mitigation measures," *Renew. Sustain. Energy Rev.*, vol. 62, pp. 1195–1208, 2016.
- [2] M. J. E. Alam, K. M. Muttaqi, and D. Sutanto, "A comprehensive assessment tool for solar PV impacts on low voltage three phase distribution networks," *2012 2nd Int. Conf. Dev. Renew. Energy Technol.*, pp. 1–5, 2012.
- [3] *IEEE*, pp. 1–5, 2014.
- [4] T. Tayjasanant and V. Hengritawat, "Comparative evaluation of DG and PV-DG capacity allocation in a distribution system," *Proc. Int. Conf. Harmon. Qual. Power, ICHQP*, pp. 293–298, 2012.
- [5] C. Wang and M. H. Nehrir, "Analytical Approaches for Optimal Placement of Distributed Generation Sources in Power Systems," *IEEE Trans. Power Syst.*, vol. 19, no. 4, pp. 2068–2076, Nov. 2004.
- [6] A. Mohamed Imran and M. Kowsalya, "A new power system Reconfiguration scheme for power loss minimization and voltage profile enhancement using Fireworks Algorithm," *Int. J. Electr. Power Energy Syst.*, vol. 62, pp. 312–322, 2014.
- [7] S. Ghosh, S. P. Ghoshal, and S. Ghosh, "Optimal sizing and placement of distributed generation in a network system," *Int. J. Electr. Power Energy Syst.*, vol. 32, no. 8, pp. 849–856, 2010.
- [8] A. Medina, J. C. Hernández, and F. Jurado, "Optimal placement and sizing procedure for PV systems on radial distribution systems," *2006 Int. Conf. Power Syst. Technol. POWERCON2006*, 2007.

- [9] M. Dixit, P. Kundu, and H. R. Jariwala, “Optimal Placement of PV Array in Distribution System for Power Loss Minimization Considering Feeder Reconfiguration,” 2016.
- [10] Y. Chen, M. Strothers, and A. Benigni, “A Stochastic Approach to Optimum Placement of Photovoltaic Generation in Distribution Feeder,” 2016.
- [11] A. Nguyen *et al.*, “High PV penetration impacts on five local distribution networks using high resolution solar resource assessment with sky imager and quasi-steady state distribution system simulations,” *Sol. Energy*, vol. 132, pp. 221–235, 2016.
- [12] D. Q. Hung and N. Mithulananthan, “Loss reduction and loadability enhancement with DG: A dual-index analytical approach,” *Appl. Energy*, vol. 115, pp. 233–241, 2014.
- [13] Intermittent and stochastic character of renewable energy sources: Consequences, cost of intermittence and benefit of forecasting Gilles Nottona, □, Marie-Laure Niveta, Cyril Voyanta, Christophe Paolib, Christophe Darrasa, Fabrice Mottea, Alexis Fouilloya, 2018.
- [14] Overview of wind power intermittency: Impacts, measurements, and mitigation solutions Guorui Ren, Jinfu Liu, Jie Wan, Yufeng Guo, Daren Yu, 2017.
- [15] Ritu Jain, Vasundhara Mahajan” Benefits of committing Distributed Generation in Energy Market” ©2018 IEEE.
- [16] Review of optimization techniques applied for the integration of distributed generation from renewable energy sources Zeineb Abdmouleh, Adel Gastli, Lazhar Ben-Brahim, Mohamed Haouari, Nasser, Ahmed Al-Emadi, 2017.

[17] Optimal location, selection, and operation of battery energy storage systems and renewable distributed generation in medium–low voltage distribution networks, Alejandro Valencia, Ricardo A. Hincapie, Ramn A. Gallego, *Journal of Energy Storage* 34 (2021) 102158.

[18] Optimal Integration of Dispersed Generation in Medium-Voltage Distribution Networks for Voltage Stability Enhancement, Brayan Enrique Aguirre-Angulo, Lady Carolina Giraldo-Bello, Oscar Danilo Montoya 2,3, and Francisco David Moya. *Algorithms* 2022, 15, 37. <https://doi.org/10.3390/a15020037>.

[19] C. Wang, M. H. Nehrir, “Analytical Approaches For Optimal Placement of DG Sources In Power Systems”, *IEEE Trans. On Power Syst.*, Vol. 19, No. 4, November 2004; pp. 2068–2076.

[20] Tuba GÖZEL, M. Hakan HOCAOGLU, Ulas EMINOGLU, Abdulkadir BALIKCI, "Optimal Placement and Sizing of Distributed Generation on Radial Feeder with Different Static Load Models".

] G. Guerra, J. a Martinez, and S. Member, “A Monte Carlo Method for Optimum Placement of Photovoltaic Generation Using a Multicore Computing Environment,” *PES Gen. Meet. Conf. Expo. 2014 IEEE*.

الملحق 1

الكود البرمجي لتحديد الموقع الأمثل والاستطاعة المثلى للتوليد الموزع بيانياً

```
close all; clear; clc;
```

```
syms x x0 I_dg;
```

```
u = 1; R = 1;
```

```
I_d = 1;
```

```
I = int(I_d, x, 0, u);
```

```
P = simplify(int(R*int(I_d, x, 0, x)^2, x, 0, x), 'steps', 50);
```

```
P_dg = simplify(int(R*int(I_d, x, 0, x)^2, x, 0, x0) + int(R*(int(I_d,  
x, 0, x) - I_dg)^2, x, x0, u), 'steps', 50);
```

```
eq1 = simplify(solve(diff(P_dg, x0) == 0, x0), 'steps', 50);
```

```
eq2 = simplify(solve(diff(P_dg, I_dg) == 0, I_dg), 'steps', 50);
```

```
sol = cell2sym(struct2cell(solve([x0 == eq1(1), I_dg == eq2(1)],  
[x0; I_dg])));
```

```
s = sol(1:length(sol)/2:end);
```

```
P_opt = simplify(subs(P_dg, {x0, I_dg}, transpose(s)), 'steps', 50);
```

```
%% Plotting the results
```

```
n = 100;
```

```
I_test = eval(linspace(0, I, n));
```



```
X0 = eval(subs(eq1(1) , I_test));  
I_DG = subs(eq2(1), {I_dg, x0}, {s(2), X0});  
  
P_X0 = eval(subs(P_dg, {I_dg, x0}, {I_test, X0}));  
P_Idg = eval(subs(P_dg, {I_dg, x0}, {I_DG, X0}));
```

```
x = 0:1e-3:1;  
J = -(x+1/2)+2;  
g = J-1/2;  
h = 2*J-1;  
f = 1/3 - h.*(1-g.^2) + (h.^2 .* (1 - g));
```

```
figure  
plt = plot(I_test/I, X0, 'magenta-.', I_test/I, P_X0, 'red-', I_DG, X0,  
'k-', x, f, 'b--', s(2), s(1), 'ko');  
legend({'x0', 'P_{x0}', 'I_{dg}', 'P_{lossIdg}'});  
set(plt(end), 'markerfacecolor', [0,0,0]);  
xlabel('I_{dg}/I_{load}')  
ylabel('x0/u')  
text(eval(s(2))-0.225, eval(s(1)), 'Optimum Placement and Size of  
DG')  
grid
```

الملحق 2

الكود البرمجي لتحديد الموقع الأمثل والاستطاعة المثلى للتوليد الموزع حسابياً

```
close all; clear; clc;
```

```
syms x x0 I_dg Im u R;
```

```
I_d = Im;
```

```
I = int(I_d, x, 0, u);
```

```
P = simplify(int(R*int(I_d, x, 0, x)^2, x, 0, x), 'steps', 50);
```

```
P_dg = simplify(int(R*int(I_d, x, 0, x)^2, x, 0, x0) + int(R*(int(I_d,  
x, 0, x) - I_dg)^2, x, x0, u), 'steps', 50);
```

```
eq1 = simplify(solve(diff(P_dg, x0) == 0, x0), 'steps', 50);
```

```
eq2 = simplify(solve(diff(P_dg, I_dg) == 0, I_dg), 'steps', 50);
```

```
sol = cell2sym(struct2cell(solve([x0 == eq1(1), I_dg == eq2(1)],  
[x0; I_dg])));
```

```
s = sol(1:length(sol)/2:end);
```

```
X0 = s(1)
```

```
IDG = s(2)
```

```
P_opt = simplify(subs(P_dg, {x0, I_dg}, transpose(s)), 'steps', 50);
```

تحقيق الزمن الأمثل لمسار محدد لذراع روبوت باستخدام متحكم إشرافي ضبابي (FSC) وفقاً لخوارزمية (PCTOM)

*م. حسين علي عمران

الملخص

يعد التحكم في الروبوتات الصناعية من المواضيع المهمة جداً في المصانع من أجل وضع النهاية المؤثرة للروبوت في الموقع المطلوب بدقة وكفاءة من حيث السرعة ودقة التنفيذ.

تم في هذا البحث حساب الزمن الأمثل لمسار دائري محدد عن طريق تخطيط الحركة حيث تم إنشاء منحنى للسرعة وفق خوارزمية (PCTOM) ومن ثم تطبيق تقنيات التحكم باستخدام نوعين من المتحكمات هما: المتحكم التناسبي التكامل التفاضلي (PID) ومتحكم الإشراف الضبابي (FSC)، وذلك من أجل تحقيق تتبع دقيق وفعال للمسار المحدد.

أوضحت نتائج تخطيط الحركة باستخدام كلا المتحكمين في حساب الزمن الأمثل لمسار دائري أفقي أن المتحكم الإشرافي الضبابي FSC أفضل من المتحكم PID. كما أوضحت نتائج تتبع المسار باستخدام كلا المتحكمين أن المتحكم الإشرافي الضبابي FSC أفضل من المتحكم PID.

الكلمات المفتاحية: خوارزمية حساب الزمن الأمثل لمسار محدد، المتحكم التناسبي التكامل التفاضلي، متحكم الإشراف الضبابي

*ماجستير في هندسة الميكاترونيك - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين

Temporal optimization of a specific path of a robot arm using a fuzzy supervisory controller (FSC) according to the (PCTOM) algorithm.

***Eng. Hussien omran**

ABSTRACT

Controlling industrial robots is a very important issue in factories in order to accurately and efficiently place the robot at the desired location in terms of speed and execution accuracy. This research calculated the optimal time for a specific circular path by motion planning, where a velocity curve was created using the (PCTOM) algorithm, then control techniques were applied using two types of controllers: Proportional-Integral-Derivative (PID) controller and Fuzzy Supervisory Controller (FSC), in order to achieve accurate and efficient tracking of the specified path.

The results of motion planning using both controllers showed that FSC is better than PID in calculating the optimal time for a circular path. The results of control using both controllers also showed that FSC is better than PID controller.

Keyword: Path-Constrained Time-Optimal Motions (PCTOM), Proportional–Integral–Derivative Controller (PID), Fuzzy Supervisory Controller (FSC).

مقدمة:

في السنوات الأخيرة، استفادت الأنظمة الصناعية والتجارية من مزايا تكنولوجيا الروبوتات ذات الكفاءة العالية والأداء الجيد، حيث ظهر عدد كبير من الأبحاث التي ركزت على التحكم في الروبوت وتقليل الزمن اللازم لقطع المسار.

الروبوت المناول هو واحد من التطبيقات الصناعية والتعليمية والطبية المهمة، حيث يعمل في ظروف لا يمكن التنبؤ بها، وفي أماكن خطيرة التي لا يمكن للإنسان الوصول إليها مثل العمل في المفاعلات الكيميائية والنوية، لذلك فإن تحسين أداء التحكم وحساب الزمن الأمثل مهم جداً عند استخدام الروبوت في هذه الظروف من أجل العمل بدقة عالية.

يقدم البحث المقترح طريقة جيدة لنمذجة روبوت تسلسلي مؤلف من ستة درجات حرية دون الاعتماد على المعادلات الديناميكية، حيث تم استخدام (Sims cape Toolbox Multibody Link) من أجل نقل التصميم الميكانيكي من Solid works إلى نموذج محاكاة ضمن Matlab [1]، ومن ثم دراسة تخطيط الحركة وحساب الزمن الأمثل وفي النهاية تم تطبيق نوعين من المتحكمات هما PID و FSC لدراسة تتبع المسار.

هدف البحث

تعمل المناولات على خطوط الإنتاج وفق حركات متكررة تنقل فيها القطع من موضع أولي إلى موضع نهائي، حيث يؤدي تقليل زمن الحركة إلى زيادة في الإنتاج وبالتالي زيادة في الأرباح.

يهدف البحث إلى دراسة حركة المناول وفق مسار محدد مسبقاً، من أجل تقليل الزمن اللازم لقطع هذا المسار مع تحقيق أفضل تتبع للمسار.

ظهرت العديد من الأبحاث التي تهدف إلى دراسة حركة المناول والتحكم بها وفق مسار محدد من أجل تقليل الزمن والحصول على تموضع مثالي للنهاية المؤثرة. حيث اعتمد Stepan [2] على خوارزمية PCTOM التي تؤول فيها مسألة حساب الزمن الأمثل الى دراسة سرعات المفاصل، وذلك عن طريق تخطيط الحركة.

فيما بعد استخدم John [3] خوارزمية (SPCTOM) كنموذج محسن للخوارزمية (PCTOM) وهي تهدف إلى تعميم المسار. لاحقاً استخدم كل من Nasr و Bang [4,5] خوارزميات تخطيط الحركة مع تقنيات التحكم من أجل تحقيق تتبع فعال ودقيق للمسار حيث استخدمت خوارزمية (PCTOM) مع تقنيات تحكم مثل (PID). اعتبر Chen [6] أن إيجاد الزمن الأمثل يؤول إلى إيجاد المنحني المحدب الأمثل (convex optimization) حيث تكون جميع القيود الخاصة بالسرعة عبارة عن دالة محدبة في حين اعتمد Liu [7] على توابع الاستيفاء (spline curves) من أجل تخطيط المسار حيث أظهرت النتائج تتبع سلس وفعال للمسار.

مواد وطرائق البحث

استخدم البحث مناوول ذو ستة درجات حرية تم تصميمه باستخدام برنامج Solid works وتم نقل التصميم إلى برنامج ماتلاب باستخدام المكتبة (Sims Toolbox) (cape Multibody Link)، أما بالنسبة لتخطيط الحركة تمت دراستها باستخدام برنامج رياضي (Maple) الذي يمكننا من تمثيل العلاقات الرياضية بشكل أسهل ونقلها إلى ماتلاب ويمكن تلخيص منهجية البحث بالخطوات التالية:

1- تصميم الروبوت باستخدام Solid works ومن ثم نمذجتها في MATLAB.


2- تطبيق خوارزمية PCTOM باستخدام برنامج Maple.

3- تصميم خوارزميات التحكم.

4- دراسة النتائج.

أولاً: تصميم الروبوت

تم اعتماد تصميم الروبوت ABB IRB 140 ذو ست درجات حرية من أجل نمذجته في هذا البحث [8] ، تتم محاكاة الروبوت باستخدام برنامج Solid works ومنصة المحاكاة Simulink التي يوفرها برنامج Matlab في البداية يتم تصميم المناول في Solid works الشكل 1.

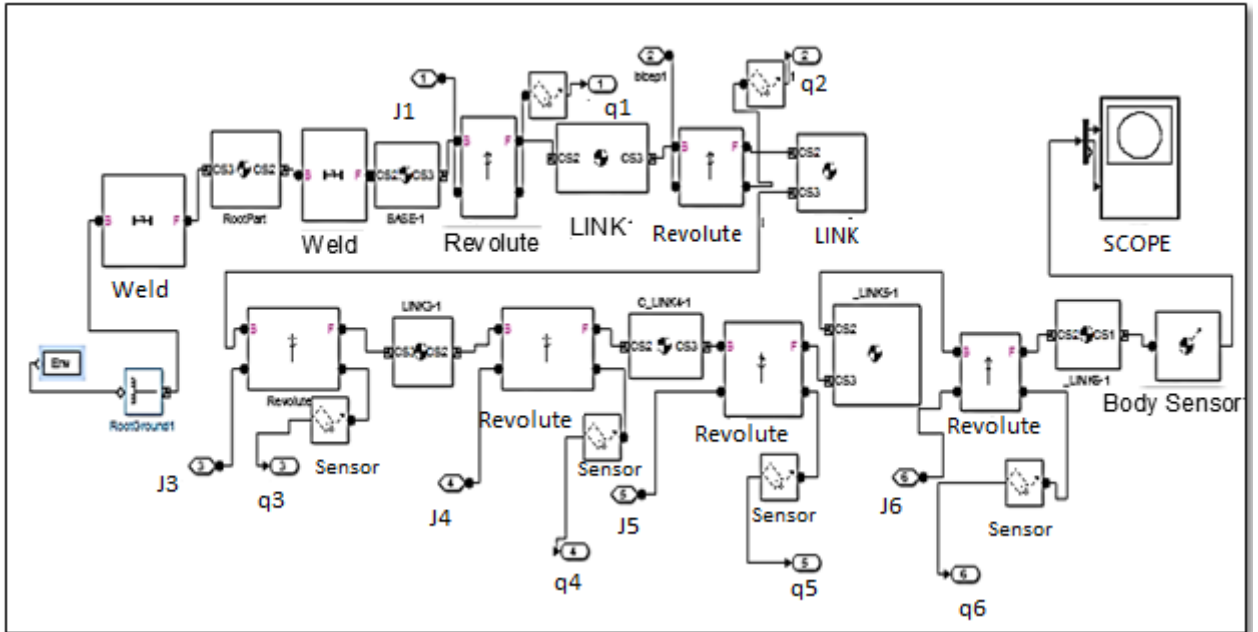


الشكل (1): تصميم المناول باستخدام برنامج Solid works.

يتم نقل النموذج التصميمي الميكانيكي من Solid works إلى نموذج محاكاة برمجية ضمن MATLAB باستخدام أداة برمجية تكاملية هي Simscape Multibody حيث تسمح لبرنامج Solid works بتحليل الأجزاء التجميعية للروبوت وتحويلها إلى ملفات (STL) ذات أبعاد حقيقية ومن ثم ادخالها إلى Simulink على

تحقيق الزمن الأمثل لمسار محدد لذراع روبوت باستخدام متحكم إشرافي ضبابي (FSC) وفقاً
لخوارزمية (PCTOM)

شكل بلوكات برمجية تعبر عن الوصلات (أبعاد وكتلة) والمفاصل (نوع الحركة وقيم الدخل). يوضح الشكل 2 نمذجة الروبوت باستخدام Simulink مع المداخل والمخارج.



الشكل (2): محاكاة المناول ABB IRB 140 باستخدام Simscape Multibody.

ثانياً خوارزمية PCTOM

يهدف البحث إلى دراسة تخطيط الحركة والتحكم بها وفق مسار محدد من أجل حساب الزمن الأمثل لهذا المسار، وذلك باستخدام طريقة path-constrained time-optimal motions (PCTOM). الغرض من تخطيط الحركة هو تحديد زوايا معينة لكل مفصل من المناول مع مراعاة قيود السرعة، أما الغرض من وحدة التحكم هو تحقيق تتبع دقيق وفعال للمسار المفروض. يتم تطبيق تخطيط الحركة على المفاصل الثلاث الأولى من المناول السابق، من أجل سهولة الحساب كما أنها تمكن المناول من الوصول

الى أي نقطة في فضاء عمله في حين أن المفاصل الثلاث المتبقية مسؤولة عن توجيه النهاية المؤثرة فقط ولا تتعلق بالمسار.


تخط بيط الحركية بأسـة تخدام (PCTOM):

حيث يتم استخدام برنامج (MAPLE) من أجل إيجاد المعادلات الرياضية اللازمة ونوضح الخطوات المتبعة في خوارزمية (PCTOM) وهي:

1- تخطيط المسار (Path planning):

يعتبر تخطيط المسار من أعقد العمليات في علم الحاسوب، يهدف تخطيط المسار إلى إيجاد مسار محدد يصف الطريق التي يجب على الروبوت أن يسلكه، تم اختيار المسار ليكون دائري أفقي.

بفرض أن الدائرة في مستوي x-y و إحداثيات مركزها $(m) = (x_{c1}, y_{c1})$ و نصف قطرها $R_1 = 0.2(m)$ و $(0, z_{c1} = 0.3)$.



الشكل (3): الروبوت في المستوي (x-y).

تحقيق الزمن الأمثل لمسار محدد لذراع روبوت باستخدام متحكم إشرافي ضبابي (FSC) وفقا لخوارزمية (PCTOM)

تحدد الزاوية θ الموقع الزاوي على محيط الدائرة حيث يعطى الموقع على الدائرة بدلالة θ وفق العلاقة (1):


$$P = \begin{bmatrix} x \\ y \\ z \end{bmatrix} = \begin{bmatrix} R_1 \cos(\theta) + x_{c1} \\ R_1 \sin(\theta) \\ z_{c1} \end{bmatrix} \quad (1)$$

تعطي θ بدلالة احداثيات الموقع $p(x, y)$ وفق العلاقة (2):

$$\theta = \text{atan2}(y(t), x(t) - x_{c1}) \quad (2)$$

حيث تأخذ القيم ضمن المجال $[-\pi, \pi]$

يوضح الشكل 4 المناول والمسار الدائري المحدد في المستوي $(x-z)$.



الشكل (4): المناول في المستوي $(x-z)$.

من الشكل 3 يمكن حساب زاوية المفصل الأول كتابع للمتغير θ وفق العلاقة (3):

$$q1(\theta) = \arctan(R_1 \sin(\theta), R_1 \cos(\theta) + x_{c1}) \quad (3)$$

وبشكل مشابه من الشكل 4 يمكن تمثيل المفصلين الآخرين وذلك بعد حساب بعض الأطوال و الزوايا المهمة ، حيث نستخدم نظرية فيثاغورث من أجل حساب الطول $l(\theta)$ وفق العلاقة (4) :

$$l(\theta) = \sqrt{(d_1 - z_{c1})^2 + (x_{c1} - a_1 + R_1 \cos(\theta))^2} \quad (4)$$

ثانياً يتم حساب θ_m باستخدام قانون كوساين وفق العلاقة (5) :

$$\theta_m = \arccos\left(\frac{a_3^2 + a_2^2 - l^2(\theta)}{2a_2a_3}\right) \quad (5)$$

ثالثاً حساب الزاوية θ_b وهي الزاوية بين a_2 و $l(\theta_1)$ و تعطى بالعلاقة (6) :

$$\theta_b = \frac{a_3 \sin(\theta_m)}{l(\theta_1)} - \theta_f \quad (6)$$

حيث θ_f هي الزاوية بين المستقيمين $l(\theta)$ و $h(\theta)$ وفق العلاقة (7) :

$$\theta_f = \arctan\left(\frac{d_1 - z_{c1}}{x_{c1} - a_1 + R_1 \cos(\theta)}\right) \quad (7)$$

وبالتالي يمكن تمثيل المفصلين المتبقين

$$q2 = \theta_b$$

$$q3 = \theta_m$$

من علاقات المفاصل نجد أن قيمة زاوية المفصل تابع للمتغير θ وفق العلاقة (8) أي


$$q_i = q_i(\theta) \quad (8)$$

يأخذ θ قيم متغيرة مع الزمن ضمن المجال $[-\pi, \pi]$ وبالتالي يكون تابع للزمن وفق
العلاقة (9)

$$\theta = \theta^*(t) \quad (9)$$

وبذلك يمكن تحديد الوقت الذي تستغرقه الحركة من خلال تحديد θ .

يوضح الشكل 5 المسارات الثلاث للمفاصل (q_1, q_2, q_3) الناتجة وهي متعلقة
بالمحول θ وذلك باستخدام برنامج MAPLE.



الشكل (5): q_1, q_2, q_3 كتابع للمتغير θ .

بالاشتقاق نجد العلاقة (10):

$$\dot{q}_i = \dot{q}(\theta)\dot{\theta} \quad (10)$$

تعبّر العلاقة السابقة عن السرعة بدلالة θ حيث

$\dot{\theta}$: منحنى السرعة .

$\dot{q}(\theta)$: سرعة المفصل.

2- إيجاد الزمن الأمثل:

يهدف إلى تقليل الزمن المستغرق على طول المسار بدءاً من الزمن t_0 و حتى الزمن t_e وفق العلاقة (11):

$$\text{minimize } \int_{t_0}^{t_e} dt \quad (11)$$

تعتمد خوارزمية (PCTOM) في إيجاد الوقت الأمثل على تخطيط الحركة وذلك بتحديد سرعات المفاصل مع مراعات قيود السرعة. وبالتالي تؤول مشكلة تحديد الزمن الأمثل إلى تحديد سرعات للمفاصل (منحنيات السرعة) تحقق زمن حركة أقل.

وبالتالي يجب ربط الوقت مع السرعة باستخدام chain rule وفق العلاقة (12):

$$\frac{dq_i(\theta)}{dt} = \frac{dq_i(\theta)}{d\theta} \frac{d\theta}{dt} = \frac{dq_i(\theta)}{d\theta} \dot{\theta} \quad (12)$$

$$\frac{dq_i(\theta)}{dt} = \frac{dq_i(\theta)}{d\theta} \dot{\theta}$$

ومنه نجد العلاقة (13)

$$dt = \frac{1}{\dot{\theta}} d\theta \quad (13)$$

وبالتالي تصبح مشكلة الوقت وفق العلاقة (14):

$$\text{minimize } \int dt = \text{minimize } \int \frac{1}{\dot{\theta}} dt \quad (14)$$

تحقيق الزمن الأمثل لمسار محدد لذراع روبوت باستخدام متحكم إشرافي ضبابي (FSC) وفقا لخوارزمية (PCTOM)

أي أن تقليل الوقت يكافئ تقليل معكوس السرعة و بالتالي يجب زيادة θ أكبر مقدار .

3- إيجاد منحنى السرعة (Velocity Profiles):

إن المحركات التي تحرك المناول لها قيود سرعة وزاوية تفرضها الشركة المصنعة يجب عدم تجاوزها، يوضح الجدول الحدود العليا للسرعة وفق شركة ABB المصنعة للمناول المدروس [9] .

الجدول 1 الحدود العليا والدنيا للسرعة والموقع

LINK	$q_{i,min}(rad)$	$q_{i,max}(rad)$	$\dot{q}_{min}(rad/s)$	$\dot{q}_{max}(rad/s)$
1	-3.1415	3.1415	-3.4907	3.4907
2	-1.5708	1.9199	-3.4907	3.4907
3	-4.0143	0.8727	-4.5379	4.5379

يجب أن تكون السرعة أقل أو تساوي القيم العليا للسرعة التي تحددها الشركة المصنعة وفق العلاقة (15):

$$\|q'_i(\theta)\dot{\theta}\| \leq \bar{q}_i \quad (15)$$

ومنه نجد العلاقة (16)

$$\|\dot{\theta}\| \leq \frac{\bar{q}_i}{q'_i(\theta)} \quad (16)$$

حيث $\frac{\bar{q}_i}{q'_i(\theta)}$ هي الحدود العليا لمنحني السرعة والتي لا يجب تجاوزها كما يوضح الشكل

.6

بعد تعيين الحدود العليا لمنحني السرعة، يتم تحديد منحني السرعة باستخدام تابع استيفاء تكعيبي (cubic spline)، حيث يوضح الجدول 2 نقاط تابع الاستيفاء التي يتم


اختيارها باستخدام Maple

الجدول 2 نقاط تابع Spline.

POINT	θ	$\dot{\theta}$	POINT	θ	$\dot{\theta}$
1	-3.14159	7.8	11	0	12
2	-2.9	8.25	12	0.152	10.5
3	-2.56	10.9	13	0.25	8.6
4	-2.3	9.7	14	0.59	5.9
5	-1.88	7.1	15	1	5.5
6	-1.43	5.9	16	1.43	5.9
7	-1	5.5	17	1.88	7.1
8	-0.59	5.9	18	2.3	9.7
9	-0.25	8.6	19	2.56	10.9
10	-0.152	10.5	20	2.9	8.25
			21	3.14159	7.8

تحقيق الزمن الأمثل لمسار محدد لذراع روبوت باستخدام متحكم إشرافي ضبابي (FSC) وفقاً
لخوارزمية (PCTOM)

يوضح الشكل 6 منحنى السرعة مع الحدود العليا للسرعة للمفاصل الثلاثة.




الشكل (6): منحنى السرعة مع الحدود العليا للسرعة.

ثالثاً تصميم خوارزميات التحكم:

يعتبر التحكم بالحركة مهم من أجل تحقيق تخطيط الحركة حيث تتم مقارنة المسار الناتج عن الحساس مع المسار المرغوب لكل مفصل وبالتالي تتبع دقيق للمسار المرغوب. تم استخدام متحكمين هما PID, FSC ومقارنة أداء كل منهما ودراسة تأثير التحكم على حساب الزمن الأمثل.

تحتوي دارة التحكم على ثلاث متحكمات وثلاث محركات من نوع (DC) كما تحوي على ثلاث حساسات (Joint Sensor) كما يوضح الشكل 7.



الشكل (7): محاكاة دائرة التحكم ضمن Matlab.

3-1 استخدام متحكم PID

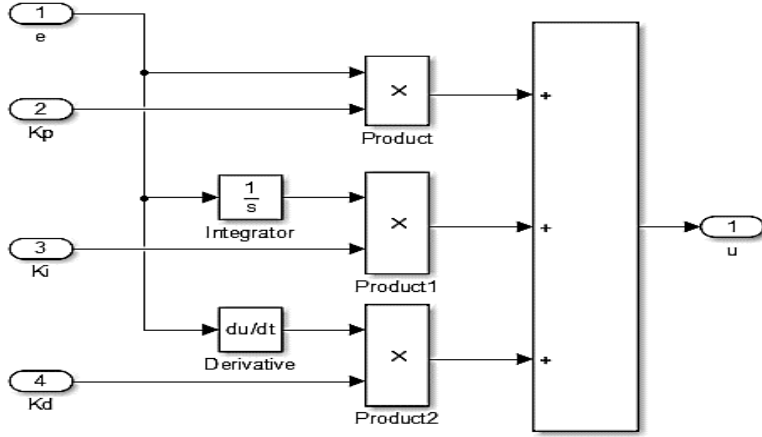
تعطى علاقة المتحكم وفق الشكل التالي بالعلاقة (17)[10] :

$$u(t) = K_p e + K_i \int e + K_d \dot{e} \quad (17)$$

حيث تعطى قيم الثوابت ($k_p = 30, k_i = 0.1, k_d = 0.1$) وبالتالي يمكن نمذجة


المتحكم في بيئة Simulink كما يوضح الشكل 8.

تحقيق الزمن الأمثل لمسار محدد لذراع روبوت باستخدام متحكم إشرافي ضبابي (FSC) وفقا لخوارزمية (PCTOM)



الشكل (8): محاكاة المتحكم PID مع قيم بارامترات التحكم.

يوضح الشكل تكامل منحني السرعة يعطي θ الذي يحدد موقع النهاية المؤثرة على الدائرة كما يوضح الشكل




الشكل (9) : يعبر عن تغير θ مع الزمن عند استخدام متحكم PID

إن الزمن الذي يستغرقه المناول للانتقال من $-\pi$ الى π هو زمن الحركة و هو يكافئ الزمن الأمثل ويساوي هنا

$$T(\text{PID}) = 0.86 \text{sec}$$



يعتمد المتحكم (FSC) في ضبط قيم البارامترات (K_P, K_I, K_D) على متغيرين هما الخطأ (E) و مشتق الخطأ (dE) وعلى مجموعة من القواعد الضبابية التي تربط الدخل مع الخرج [11,12].

يتألف المتحكم من دخلين هما خطأ الموقع و خطأ السرعة و خرجين هما (K_P, K_D) حيث تم اهمال K_I لأنها ضبطت على القيمة صفر في المتحكم PID .



الشكل (11) تابع الانتماء للدخل dE

الشكل (10) تابع الانتماء للدخل e



الشكل (13) تابع الانتماء للخرج K_D

الشكل (12) تابع الانتماء للخرج K_P

يتم ربط الدخل مع الخرج عن طريق آلية استدلال وهي في هذا البحث (Mamdani) وبما أنه لدينا دخلين لكل منهما (7) توابع انتماء بالتالي لدينا (49) قاعدة تكتب وفق الشكل التالي:

تحقيق الزمن الأمثل لمسار محدد لذراع روبوت باستخدام متحكم إشرافي ضبابي (FSC) وفقا
لخوارزمية (PCTOM)

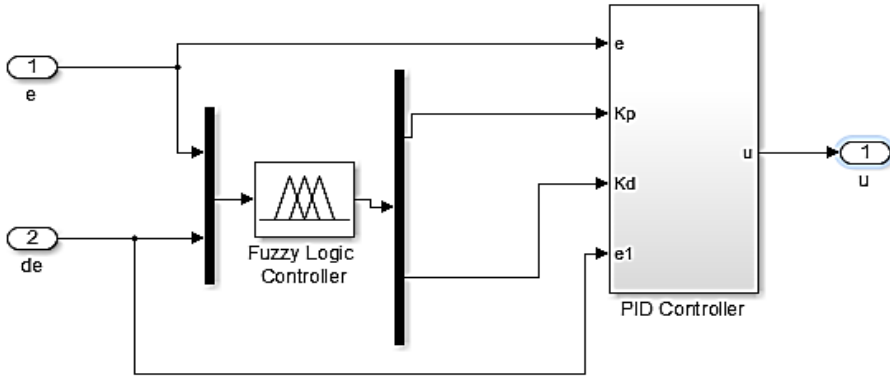
الجدول 3 عدد من القواعد المستخدمة ضمن المنطق الضبابي

1. If (e is NB)	And	(edot is NB)	Then	(kpp is B)	(kii is S)	(kdd is S)
2. If (e is NB)	And	(edot is NM)	Then	(kpp is B)	(kii is S)	(kdd is S)
3. If (e is NB)	And	(edot is NS)	Then	(kpp is B)	(kii is S)	(kdd is S)
4. If (e is NB)	And	(edot is ZE)	Then	(kpp is B)	(kii is S)	(kdd is S)
5. If (e is NB)	And	(edot is PS)	Then	(kpp is B)	(kii is S)	(kdd is S)
6. If (e is NB)	And	(edot is PM)	Then	(kpp is B)	(kii is S)	(kdd is S)
7. If (e is NB)	And	(edot is PB)	Then	(kpp is B)	(kii is S)	(kdd is S)
8. If (e is NM)	And	(edot is NB)	Then	(kpp is S)	(kii is M)	(kdd is B)
9. If (e is NM)	And	(edot is NM)	Then	(kpp is B)	(kii is M)	(kdd is B)
10. If (e is NM)	And	(edot is NS)	Then	(kpp is B)	(kii is S)	(kdd is S)
11. If (e is NM)	And	(edot is ZE)	Then	(kpp is B)	(kii is S)	(kdd is S)
12. If (e is NM)	And	(edot is PS)	Then	(kpp is B)	(kii is S)	(kdd is S)
13. If (e is NM)	And	(edot is PM)	Then	(kpp is B)	(kii is M)	(kdd is B)
14. If (e is NM)	And	(edot is PB)	Then	(kpp is S)	(kii is M)	(kdd is B)
15. If (e is NS)	And	(edot is NB)	Then	(kpp is S)	(kii is B)	(kdd is B)
16. If (e is NS)	And	(edot is NM)	Then	(kpp is S)	(kii is M)	(kdd is B)
17. If (e is NS)	And	(edot is NS)	Then	(kpp is B)	(kii is M)	(kdd is B)
18. If (e is NS)	And	(edot is ZE)	Then	(kpp is B)	(kii is S)	(kdd is S)
19. If (e is NS)	And	(edot is PS)	Then	(kpp is B)	(kii is M)	(kdd is B)

الجدول 4: معاني الرموز الخاصة بتوابع الانتماء

NB: كبير وسالب	PM: متوسط و موجب
NM: متوسط و سالب	PB: كبير و موجب
NS: صغير و سالب	S: صغير
Z: صفر	M: متوسط
PS: صغير و موجب	B: كبير


يوضح الشكل 14 نمذجة المتحكم FSC في بيئة Simulink



الشكل (14): محاكاة متحكم FSC.

يوضح الشكل تكامل منحنى السرعة يعطي θ وهو مولد الحركة كما يوضح الشكل 15.

تحقيق الزمن الأمثل لمسار محدد لذراع روبوت باستخدام متحكم إشرافي ضبابي (FSC) وفقاً
لخوارزمية (PCTOM)



الشكل (15): يعبر عن تغير θ مع الزمن عند استخدام متحكم FSC

إن الزمن الذي يستغرقه المناول للانتقال من $-\pi$ إلى π هو زمن الحركة و هو يكافئ
الزمن الأمثل

ويساوي هنا


$$T(\text{FSC})= 0.81\text{sec}$$

رابعاً النتائج والمناقشة

تؤول مشكلة الزمن الأمثل حسب خوارزمية PCTOM إلى ايجاد ملف سرعة مثالي كما
شرح في الفصل الخامس ،حيث ان تكامل ملف السرعة يعطي θ وهو يعبر عن الموقع
على الدائرة ، حيث يبدأ المناول الحركة من $-\pi$ إلى π ، لذلك يعتبر زمن الحركة هو
زمن تغير θ ضمن المجال $[-\pi, \pi]$ ، ويدعى هذا الزمن بالزمن الأمثل.

توصل البحث المقترح الى زمن أمثل 0.86 ثانية عند استخدام متحكم PID وزمن 0.81 عند استخدام متحكم FSC وهي نتيجة أفضل من حيث الزمن.

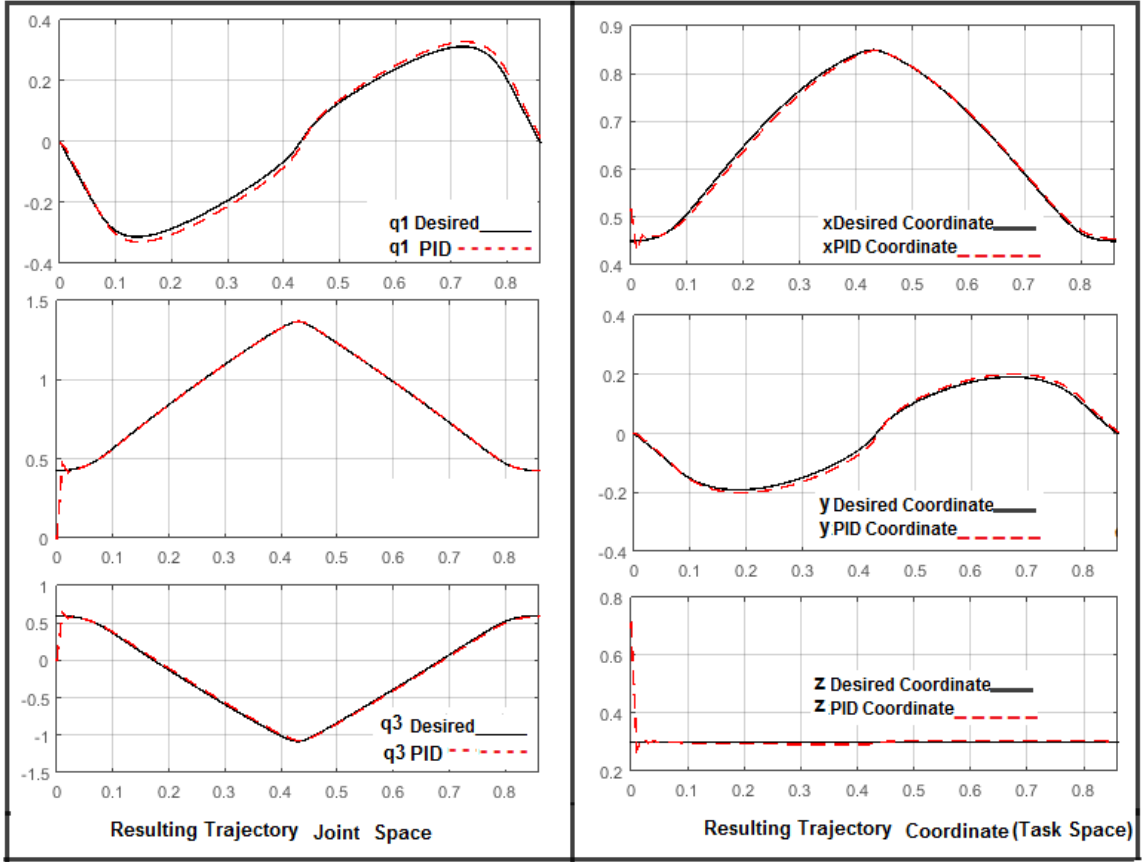
تمت مقارنة نتائج البحث مع البحث [2] الذي استخدم نفس النوع من الروبوت ونفس المسار ولكنه اعتمد الطريقة الديناميكية حيث توصل إلى زمن أمثل قدره (0.92) ثانية كما يوضح الشكل 16 الذي يشير أيضاً إلى الزمن الخاص بالشركة الصانعة والذي يتجاوز الثانية.



الشكل (16): الزمن الأمثل في البحث [1].

أما بالنسبة لدقة تتبع المسار تمت المقارنة في مستوي المسار (q_1, q_2, q_3) ومستوي احداثيات موقع النهاية على الدائرة ($x-y-z$) حيث يوضح الشكال 17 أن احداثيات الموقع وفق المحور Z تساوي الصفر وهذا طبيعي لأن المسار الدائري المرسوم أفقي وبالتالي لا يتغير المسار على المحور Z.

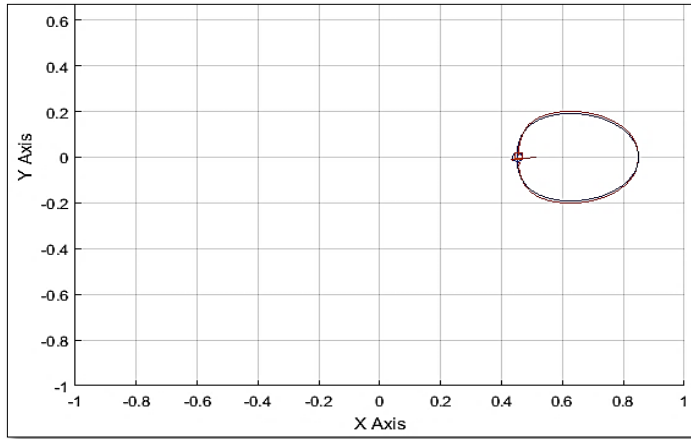
تحقيق الزمن الأمثل لمسار محدد لذراع روبوت باستخدام متحكم إشرافي ضبابي (FSC) وفقاً لخوارزمية (PCTOM)



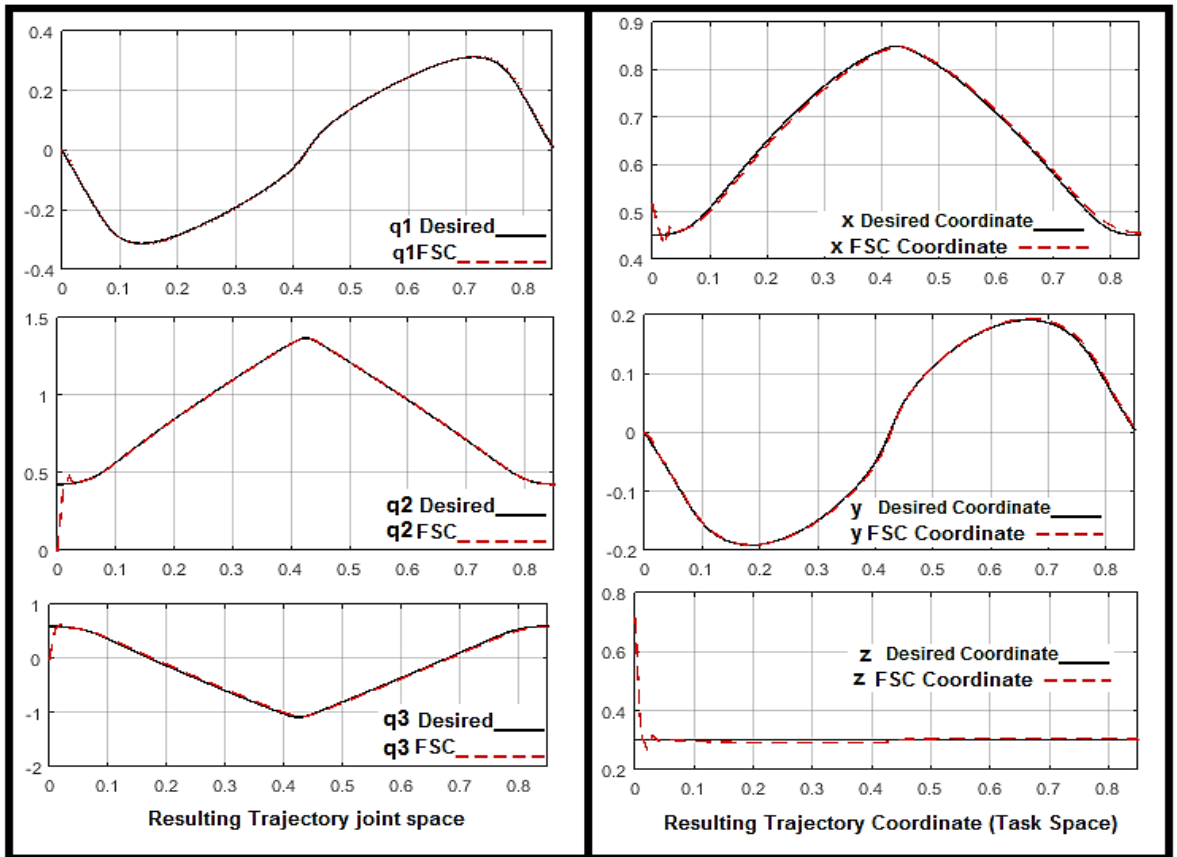
الشكل (17): المسار الناتج في Task Space، Joint Space باستخدام PID.

نلاحظ من الشكل السابق وجود خطأ بين المسار المرجعي والمسار الناتج عند استخدام المتحكم PID وفق المفصل q1 وكذلك خطأ وفق الأحداثي X عند استخدام المتحكم pid وكذلك الأمر بالنسبة للإحداثي Y.

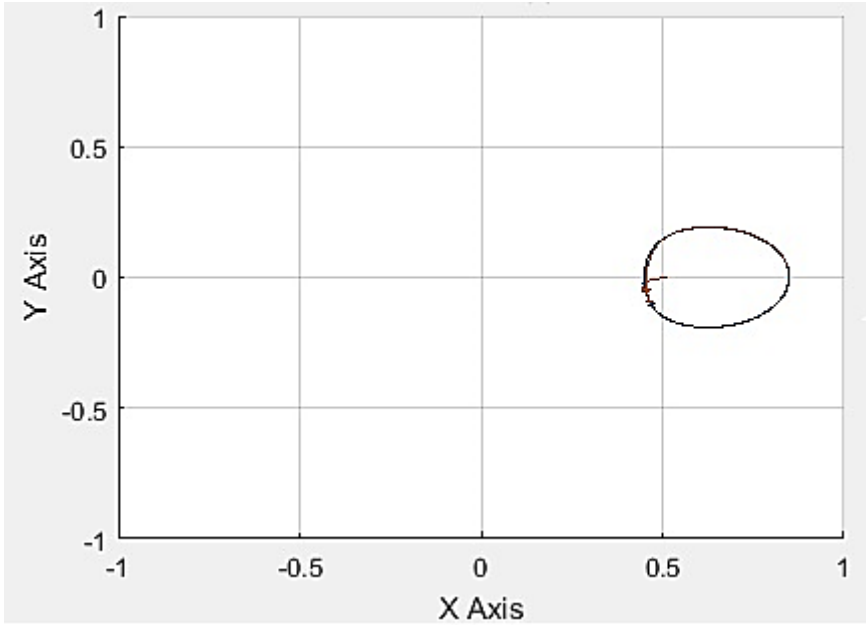
يوضح الشكل 18 المسار الدائري الناتج عند استخدام المتحكم PID ويلاحظ أن مركز الدائرة يساوي (0.65) على محور X ويساوي 0 على محور Y كما تم فرضه ضمن المعطيات.



الشكل (18): المسار الدائري باستخدام PID



الشكل (19): المسار الناتج في Joint Space ,Task Space باستخدام FSC.



الشكل (20): المسار الدائري باستخدام FSC

من الأشكال (17-18-19-20) نجد أن دقة تتبع المسار باستخدام المتحكم الإشرافي الضبابي أفضل من المتحكم PID في مستوي المسار (q_1, q_2, q_3) ومستوي احداثيات موقع النهاية على الدائرة ($x-y-z$).

التوصيات:

قدم البحث طريقة لإيجاد الزمن الأمثل لحركة ذراع روبوت وفق مسار دائري أفقي محدد مسبقاً مع تحقيق تتبع فعال للمسار حيث أظهرت النتائج أن طرق التحكم المستخدمة في

البحث تعطي زمن أقل مقارنة مع الزمن الذي وضعت الشركة الصانعة (ABB) كما

أظهرت النتائج أفضلية المتحكم الإشرافي الضبابي على المتحكم PID سواء في

الحصول على تتبع أدق للمسار أو الحصول على زمن حركة أقل.

يمكن استخدام خوارزمية حساب الزمن الأمثل لمسار مقيد في حساب الطاقة الأمثل وفق

العلاقة (18):

$$E = \int_{t_0}^{t_e} \frac{T^2}{\theta} d\theta \quad (18)$$

حيث يعبر T عن العزم

يمكن تضمين حالات إضافية مثل التشويش الخارجي أو الحمولة ودراسة تأثيرها على

أداء المتحكمات، كما يمكن إضافة عوائق على المسار المدرس أو دراسة المسار الدائري

في الحالة العمودية أو المائلة.

تعتبر مكتبة Simscape Multibody مناسبة للعمل مع الروبوتات ومحاكاتها وهي

توفر عدد كبير من الحساسات و المشغلات كما يمكنها محاكاة خلية تصنيع مصغرة.

المراجع

- [1] Yingjie T, Xinwen L, (2018)“Simulation Research of Manipulator Control System Based on Solidworks and Simmechanics” Academic Journal of Computing & Information Science. 19–27.
- [2] Stepan S, Pchelkin , Anton S, (2013) “Integrated Time–Optimal Trajectory Planning and Control Design for Industrial Robot Manipulator”. International Conference on Intelligent Robots and Systems (IROS). November 3–7, Tokyo, Japan.
- [3] John W. (2000). “Smooth and Time–Optimal Trajectory Planning for Industrial Manipulators along Specified Paths”. Journal of Robotic Systems s 17 5 , 233 .
- [4] Nasr A.,(2017) “Novel PID Tracking Controller for 2DOF Robotic Manipulator System Based on Artificial Bee Colony Algorithm” Electrical, Control and Communication Engineering. vol. 13, pp. 55–62.

[5] Bang C, Jae M, (2004) "Time optimal trajectory planning for a robot system Under torque and impulse constraints". EEE Industrial Electronics Society.

[6] Chen M, (2013) "On the time-optimal trajectory planning and control of robotic manipulators along predefined paths" American Control Conference, Washington, DC, USA, pp. 371–377.

[7] Liu H, (2013) "Time-optimal and jerk-continuous trajectory planning for robot manipulators with kinematic constraints", Rob. Comput.-Integr. Manuf. 29 309–317

[8] ABB Group. IRB 140 CAD models.

<http://new.abb.com/products/robotics/industrialrobots/irb-140/irb-140-cad>, 2014.

[9] Mohammed A, Omar I, (2017) "FORWARD AND INVERSE KINEMATICS ANALYSIS AND VALIDATION OF THE ABB IRB 140 INDUSTRIAL ROBOT", Journal of Mechanical Engineering and Technology, Vol. 9 No.2 July.

[10] Xiaodiao H, Liting S, (2006) "Simulation on a Fuzzy-PID Position Controller of the CNC Servo System". IEEE Xplore . Sixth International Conference on Intelligent Systems Design and Applications, 305-309.

[11] Omar M. Ali, Aous Y, (2015) "Comparison between the Effects of Different Types of Membership Functions on Fuzzy Logic Controller Performance". International Journal of Emerging Engineering Research and Technology. 76-83.

[12] Reza S, (2008) "Performance Comparison of PD-type Fuzzy Logic Controller of USBM Simplified Model". The 2nd International Power Engineering and Optimization Conference. 217-221.

إغناء نظام NeuMF بكامل ميزات المعطيات باستخدام نماذج التعلم العميق المعتمدة على الانتباه لتحسين التنبؤ بالتقييمات

م. محمد ديب¹، أ.د. ناصر أبو صالح²
كلية الهندسة المعلوماتية - جامعة البعث

الملخص

تستخدم أنظمة التوصية طرقات معتمدة على ميزات المعطيات المتعلقة بكل من المستخدمين والمنتجات والتفاعلات السابقة فيما بينهم بهدف تقديم أفضل التوصيات من المنتجات للمستخدم. نظام التوصية التحليل العاملي للمصفوفة العصبونية (NeuMF) المعتمد على الفترة التعاونية يستخدم فقط معرفات المستخدمين والمنتجات في حساب تقييمات المنتجات من أجل تقديم التوصيات المناسبة للمستخدمين الهدف، ولا يستخدم كامل ميزات المعطيات المتعلقة بالمستخدم والمنتج والتفاعلات فيما بينهم. في هذه الدراسة، نقوم بتحسين NeuMF بتسخير جميع ميزات المعطيات باستخدام التعلم العميق للاستفادة من العلاقات غير الخطية بين ميزات المعطيات والاستفادة من الميزات النصية، ونستخدم أيضاً نموذج XGBoost لتجميع خرج طبقات الشبكات العصبونية العميقة المستخدمة. تم تطبيق التجارب والمقارنات على مجموعات المعطيات الثلاث التالية: Amazon Gift Cards، Shopify App Store، Book Crossing. يتفوق النموذج المقترح المحسن على أنظمة التوصية الأساس قبل استخدام الميزات النصية بنسبة تخفيض خطأ تصل إلى 20%، وبعد استخدام الميزات النصية NeuMF-XT بنسبة تصل إلى 60% بالنسبة لمقاييس الخطأ MAE و RMSE.

الكلمات المفتاحية: التعلم العميق، الفترة التعاونية، تضمين الكلمات، الانتباه، المعالجة المسبقة.

¹ طالب دكتوراه - قسم هندسة البرمجيات ونظم المعلومات - كلية الهندسة المعلوماتية - جامعة البعث.

² أستاذ دكتور - قسم هندسة البرمجيات ونظم المعلومات - كلية الهندسة المعلوماتية - جامعة البعث.

Enriching NeuMF System with Full Data Features Using Attention-Based Deep Learning Models to Improve Ratings Prediction

Eng. Mohammed Deeb³, Dr. Nasser Abu Saleh⁴

Faculty of Informatics Engineering, Al-Baath University

Abstract

Recommendation systems use methods based on data features related to users, products, and previous interactions between them to provide the best products recommendations to the user. The collaborative filtering-based recommendation system, Neural Matrix Factorization (NeuMF) only uses users and products identifiers in calculating products ratings to provide appropriate recommendations to the target users, and does not use the full data features related to the user, product, and interactions between them. In this study, we improve NeuMF by harnessing all data features using deep learning to take advantage of the non-linear relationships between the data features and taking advantage of the textual features. We also use the XGBoost model to aggregate the output of the deep neural networks' layers. Experiments and comparisons were applied to the following three datasets: Book Crossing, Shopify App Store, and Amazon Gift Cards. The proposed improved model outperforms the baseline recommendation systems before using the textual features with an error reduction of up to -20%, and after using textual features NeuMF-XT by up to -60% for MAE and RMSE error metrics.

Keywords— Deep Learning || Collaborative Filtering || Word Embedding || Attention || Preprocessing.

³ PhD Student - Department of Software Engineering and Information Systems, Faculty of Informatics Engineering.

⁴ Professor Dr. - Department of Software Engineering and Information Systems, Faculty of Informatics Engineering.

1- المقدمة

تلعب أنظمة التوصية دوراً مهماً في تسهيل عمليات البحث واختيار المنتجات والخدمات المناسبة للمستخدمين لتوفر عليهم الوقت والجهد في البحث ضمن أعداد ضخمة من تلك المنتجات المتوفرة في مختلف أنواع المواقع الخدمية، وهذا الدور مهم باعتبار أن أكثر من نصف سكان العالم (تقريباً 67.9%) يستخدمون الإنترنت في معظم أنشطتهم اليومية⁵.

تستخدم أنظمة التوصية معطيات المستخدمين والمنتجات لإجراء العمليات عليها بهدف إيجاد وتقديم أفضل التوصيات بالمنتجات للمستخدمين [24]، وتقسّم إلى 3 أصناف: الفلتر التعاونية التي تعتمد على تفاعلات مستخدم-عنصر، والفلتر المعتمدة على المحتوى التي تعتمد على معطيات المستخدم أو العنصر، ومزيج هجين من التصنيفين السابقين [38]. التحليل العاملي للمصفوفة MF [24] هو نظام توصية معتمد على الفلتر التعاونية يقوم بتمثيل كل مستخدم وعنصر بمتجه من الميزات الكامنة ويسقطها على مصفوفة من المتجهات الكامنة، ينتج من جدائها داخلياً مصفوفة تفاعل عنصر-مستخدم تمثل قيمها تفضيلات المستخدم لذلك العنصر (تقييمات). إنّ MF تعتمد فقط على العلاقات الخطية بين تقييمات المستخدم والعناصر مما يجعل أداؤها التنبؤي غير جيد كفاية. طُبقت العديد من الدراسات لتطوير أنظمة MF للاستفادة من العلاقات غير الخطية بين ميزات المعطيات، من ضمنها المتعلقة بالتعلم العميق مثل نظام التحليل العاملي للمصفوفة العصبوني NeMF [14]. يُستخدم نظام NeMF بنيتين عصبونيتين وهما: GMF للتعلم من العلاقات الخطية وMLP للتعلم من العلاقات غير الخطية في تفاعلات مستخدم-عنصر [14]. مع ذلك تعاني NeMF من نفس مشاكل أنظمة الفلتر التعاونية CF، إذ أنّ عدد التقييمات المقدمة من قبل المستخدمين قليل جداً بالنسبة للأعداد الهائلة المتوفرة من المنتجات وهذا ما يطرح مشاكل مثل تبعثر

⁵ احصائيات الإنترنت العالمي، في 12 آذار 2024: <http://www.internetworldstats.com/stats.htm>

المعطيات والاقلاع البارد التي تؤثر سلباً على الأداء التنبؤي لأنظمة CF [33]. أُجريت العديد من الأبحاث من أجل حل تلك المشاكل من خلال استخدام نماذج تعلم الآلة وشبكات التعلم العميق العصبونية وذلك باستخدام كامل ميزات المعطيات المتعلقة بالمستخدم والعنصر [13، 27، 33]. إنّ ميزات المعطيات تملك معلومات مهمة تمثل خصائص المستخدم والعنصر، ويمكن الاستفادة منها في زيادة الدقة التنبؤية لأنظمة CF. تحمل الميزات النصية العديد من المعلومات المهمة التي توصف المستخدم والعنصر وأهمها التي تعبر عن مشاعر المستخدم تجاه العنصر ومدى تفضيله لها [7، 45]. يوجد العديد من الطرق التقليدية لتمثيل النصوص مثل BOW، TF-IDF، ولكنها لا تمثل مشاعر وأهمية الكلمات في النصوص ومراجعات المستخدمين [21، 45]. طُوّرت العديد من الطرق والنماذج لتحليل المشاعر وتصنيفها، إذ تم استخدام نماذج الشبكات العصبونية العميقة في تحليل المشاعر والآراء وقدمت تنبؤات بالتقييمات للمراجعات النصية بأداء عالي عند استخدامها نماذج مدربة مسبقاً لتضمين الكلمات [7، 21، 45]. بالإضافة لمشكلتي التبعرث والإقلاع البارد لدى نموذج NeuMF فإنّ دخله متبعرث عبارة عن أصفار تمثل مواضع معرفات المستخدمين أو العناصر (one-hot-encodings)، وتعتمد فقط على ميزة معرفات المستخدم والعنصر وهي لا تمثل سوى أنّ المستخدم قام بتفضيل العنصر [14]، وهذا غير كافي لتقديم أداء تنبؤي جيد.

في هذه الدراسة، سنقوم بالاستفادة من كامل ميزات المعطيات وخاصة الميزات النصية وذلك بتمكين النموذج من استخدام جميع ميزات المعطيات في طبقة الدخل، وتجنب التلاوم الزائد (Overfitting) والحصول على أداء جيد باستخدام نموذج تعلم الآلة XGBoost [4] كمكدس لنموذجي GMF، MLP ودمجها مع نموذج عصبوني نصي. تم تدريب واختبار 20 نموذج نصي من البنى العصبونية MLP [1، 14]، CNN [22، 25]، BiLSTM [12، 40، 42]، ونموذج هجين منها مع آلية الانتباه [26، 29، 41، 44]، بالإضافة إلى استخدام عدة نماذج مدربة مسبقاً لتضمين الكلمات Word2Vec [31]، FastText [20]، Glove [34]. تقدم الدراسة نموذجاً مقترحاً

NeuMF-XT يتفوق على جميع النماذج المقترحة، النموذج الأصلي NeuMF، وأنظمة الأساس بتطبيق التجارب عليها وإجراء المقارنات بينها بالنسبة لمعايير تقييم الدقة التنبؤية، مقياسي الخطأ MAE و RMSE وعلى 3 مجموعات للمعطيات Book Crossing [47]، Amazon Gift Cards [32]، Shopify App Store [36].

باقي البحث منسق كالتالي: الفقرة 2 تتحدث عن هدف البحث، الفقرة 3 تتحدث عن الأعمال السابقة المتعلقة بموضوع الدراسة، الفقرة 4 تشرح الخوارزميات والطرق المستخدمة في البحث، الفقرة 5 تعرض منهجية البحث وخطوات العمل المتبعة في معالجة المعطيات وبناء النماذج المقترحة، الفقرة 6 تعرض التجارب، أدوات البحث، مجموعات المعطيات، معايير التقييم، أنظمة الأساس، والتجارب والمقارنات للنماذج المقترحة لكل مرحلة، وأخيراً النتائج ومناقشتها في الفقرة 7 والتي تعرض ما تم التوصل إليه في هذه الدراسة.

2- هدف البحث

تعاني أنظمة CF من مشكلتي تبعثر المعطيات والاقلاع البارد بسبب قلة التقييمات التي تعتمد عليها في تفاعلات مستخدم-عنصر، ودخل NeuMF متبعثر جداً إذ يعتمد على طريقة One-hot-encoding لبناء متجهات معرفات المستخدمين بحجم العدد الكلي لهم ولا يحمل أي معلومات مفيدة سوى معرف المستخدم والعنصر. ونموذج MLP لا يحوي أي نوع من التنظيم في طبقاته والتي ستحسن من جودة النظام في التنبؤ. تقوم هذه الدراسة على تحسين وتمكين نظام NeuMF من استخدام كامل ميزات المعطيات بما فيها النصية لتحسين الدقة التنبؤية بالتقييمات من خلال تطوير بنية طبقات النموذج للحصول على أفضل النتائج، واستخدام نموذج تعلم الآلة XGBoost كطبقة لربط خرج طبقات النموذج المقترح، واستخدام بنى الشبكات العصبونية العميقة للاستفادة من الميزات النصية، وتمثيلاتها من خلال استخدام نماذج لتضمين الكلمات مدربة مسبقاً، والاستفادة من آلية الانتباه لزيادة الدقة التنبؤية للنموذج المقترح النهائي.

3- الأعمال ذات الصلة

استخدمت العديد من الدراسات نظام NeuMF كقالب في بناء أنظمة توصية جديدة تحل مشاكل النماذج والأنظمة مثل تبعثر المعطيات والإقلاع البارد بتطبيق مجموعة من خوارزميات تعلّم الآلة والتعلّم العميق مما يحسن الدقة التنبؤية لها. قدّم الباحثون في [13] نموذجاً جديداً يعتمد على نموذج NeuMF بتبديل البنية العصبونية MLP ببنية عصبونية مكررة LSTM ويدعى النموذج المقترح بـ G-LSTM. أجريت المقارنات مع نماذج عصبونية LSTM، RNN، BPR، وذلك بالنسبة لمعايير التقييم HR و NDGC على مجموعتي معطيات من موقع تعليم صيني "أكاديمية جوني"، وقد تفوّق النموذج المقترح عليها من ناحية الدقة والفعالية. قام الباحثون في [27] باستبدال بنية النموذج MLP في النظام NeuMF ببنية عصبونية CNN لنمذجة تفاعلات مستخدم-عنصر بشكل مباشر، حيث استُخدمت GMF لنمذجة الميزات الضمنية باستخدام الطريقة الخطية و CNN لنمذجة التفاعلات بالطريقة غير الخطية. تم استخدام مجموعة المعطيات MovieLens ومقارنة النتائج مع الأنظمة الأساس NeuMF، BPR، ItemKNN، GMF، eALS، إذ تفوّق النموذج المقترح على تلك الأنظمة بقيم 0.7068 و 0.4259 لمعايير التقييم HR و NDCG. قدمت الدراسة [7] نموذجاً جديداً InterSentiment للتنبؤ بتقييمات المراجعات من خلال ربط نموذج لتفاعلات مستخدم-عنصر مع نموذج لتحليل المشاعر للمراجعات النصية. يقوم النموذج باستخدام طبقة GMF لدمج بنية MLP مع بنية CNN بحيث يكون دخل MLP هو المعارف الفريدة للمستخدم والعنصر أما دخل بنية CNN فهو الميزة النصية للمراجعات. تم استخدام 3 مجموعات معطيات: IMDB، Yelp-2013، Yelp-2014، واستخدام مقياس الخطأ RMSE كمعيار لمقارنة الدقة التنبؤية مع كل من النماذج MF، SVM، MF، TFM، إذ أظهرت المقارنات تفوّق InterSentiment على تلك النماذج. من أجل تقليل

مشكلتي التبعر والإقلاع البارد التي تعاني منها أنظمة الفلتر التعاونية CF وبالأخص NeuMF، قدّمت الدراسة [33] نموذجاً هجيناً NeuMF++ يستخدم شبكات الترميز التلقائي لإزالة الضوضاء Denoising Autoencoders للحصول على تمثيلات كامنة لميزات المستخدمين والعناصر لتستخدم كدخل لنظام NeuMF للتعلم من تلك الميزات. تمت المقارنات مع NeuMF، GMF، MLP، على مجموعة معطيات MovieLens وتفوق النموذج بقيمة خطأ $RMSE=0.8681$.

إنّ طرق تصنيف وتحليل النصوص التقليدية بحاجة لتطوير بسبب طبيعة النصوص المعقدة والشعورية، مما دعت الحاجة إلى استخدام طرق أفضل للتنبؤ وتحليل المشاعر من الميزات النصية والمراجعات. قدّم الباحثون في الدراسة [45] نموذج الشبكة التلافيفية المكررة ثنائية الاتجاه المعتمدة على الانتباه (BRCAN) وهو نموذج ناتج عن دمج بنية BiLSTM وبنية CNN مع آلية الانتباه. تستخدم طريقة تضمين الكلمات Word2Vec للحصول على متجهات الكلمات ونموذج BiLSTM لاستخراج معلومات السياق والاعتماديات الطويلة للجمل. أما نموذج CNN يُستخدم لتحديد الكلمات التي لها دور أساسي في التصنيف وآلية الانتباه تعطي أوزان كبيرة للميزات المفتاحية من النص. أظهرت التجارب تفوق النموذج المقترح في دقة التصنيف على 4 مجموعات للمعطيات وهي Yahoo Answers، Sogou News، Yelp Reviews، Douba، بالمقارنة مع أنظمة شبكية وحيدة الطبقة، هجينة، معتمدة على الانتباه. أيضاً اقترح الباحثون في الدراسة [21] نموذجاً جديداً يستخدم بنية CNN لاستخراج واكتشاف الميزات السياقية وتقليل أبعاد الميزات، ويطبق الانتباه على خرج CNN للحصول على مستوى الانتباه لكل كلمة، وبنية BiLSTM للحفاظ على الاعتماديات الطويلة. بالنسبة لهيئة أوزان تضمين الكلمات تم استخدام TF-IDF و GloVe للحصول على تمثيلات معبرة للنصوص. تمت مقارنة النموذج المقترح مع نماذج تعلم آلة تقليدية تستخدم أوزان TF-

إغناء نظام NeuMF بكامل ميزات المعطيات باستخدام نماذج التعلّم العميق المعتمدة على الانتباه لتحسين التنبؤ بالتقييمات

IDF ونماذج عصبونية عميقة تستخدم أوزان TF-IDF و Glove، ومعيار التقييم هو دقة التصنيف على 4 مجموعات معطيات وهي US-airline، Sentiment140، SA4A، Sentiment140-MV.

في عمليات تصنيف النصوص وتحليل المشاعر، يتم استخدام الطبقات الكثيفة لربط نتائج الطبقات الخفية وإجراء عملية التصنيف النهائية للنموذج. هذه النماذج عرضة للتلاؤم الزائد بسبب تعلّم أوزان تلك الطبقة لكامل تعقيد مشكلة التصنيفات والتنبؤ. اقترح الباحثون في الدراسة [19] نموذجاً هجيناً يستخدم التعلّم العميق وتعلّم الآلة، إذ تتضمن بنية LSTM لتعلّم الاعتماديات الطويلة للسلاسل النصية وبنية RNN لاستخراج الميزات من تلك السلاسل. يتم معالجة خرج LSTM و RNN من خلال نموذج تعلّم الآلة XGBoost عوضاً عن الطبقات الكثيفة MLP من أجل عمليات التنبؤ النهائية. تفوّق النموذج على نماذج أساس CNN، RNN، CNN-LSTM، RNN-LSTM بمعايير تصنيف الدقة، الإصابة Precision، الاسترجاع Recall، قيمة F1 وذلك على مجموعة معطيات Twitter Airline Sentiment.

في هذه الدراسة، سنقوم بتطوير وتحسين نظام التوصية NeuMF باستخدام نموذج XGBoost كبديل لطبقة الربط بين GMF و MLP، وتمكين MLP من التعلّم من كامل ميزات المعطيات، بالإضافة إلى استخدام بنى عصبونية للتعلّم من الميزات النصية وتجربة أوزان تضمين للكلمات مختلفة ودمج تلك البنى مع NeuMF المحسّن ومقارنة النتائج.

4- الخوارزميات والطرق المستخدمة

يتكون نظام التوصية NeuMF من ربط بنيتين شبكيتين وهما GMF و MLP [14]، ومن أجل تحسين بنية نظام التوصية استخدمت هذه الدراسة مجموعة من الطرق

والنماذج النصية المدربة المسبقة وإضافة بنى شبكية عميقة بهدف تسخير جميع ميزات المعطيات المتوفرة وخاصة النصية من أجل تحسين الدقة التنبؤية لنظام NeuMF، وذلك وفق منهجيات مقترحة تم تطبيق نتائجها على مجموعات معطيات مختلفة لإجراء التجارب ومقارنة النتائج النهائية مع النظام الأساس NeuMF وعدد من أنظمة التوصية.

4-1- إطار عمل نظام توصية عصبوني معتمد على الفترة التعاونية (NCF)

إطار عمل يضم 3 أنظمة توصية CF، تستخدم المعارف الفريدة للمستخدمين والعناصر مع التفاعلات فيما بينهم (التقييمات) في إيجاد تنبؤات بالتقييمات، وتلك الأنظمة هي التحليل العاملي للمصفوفة المعمّم GMF، البيرسيترون متعدد الطبقات MLP، والتحليل العاملي للمصفوفة العصبوني NeuMF المكوّن من ضم البنيتين السابقتين [14].

4-1-1- التحليل العاملي للمصفوفة المعمّم (GMF)

GMF هو نظام توصية يُعتبر تعميم وامتداد لنظام التحليلي العاملي للمصفوفة Matrix Factorization (MF) [14]، GMF مكوّن من عدة طبقات شبكية عصبونية تتمثل بطبقة دخل لمتجهات المعارف الفريدة للمستخدمين والعناصر، الشكل (1)، يليها طبقة تضمين Embeddings تمثل أوزانها المتجهات الكامنة الخاصة بالمستخدمين p_u والعناصر q_i . بعد ذلك تأتي طبقة مسطحة Flatten تقوم بتسطيح مصفوفتي التضمين ثنائية الأبعاد إلى متجهة وحيدة البعد، بذلك نحصل على متجهتين تمثلان كل من المستخدم والعنصر. يأتي بعدها طبقة جداء عنصر بعنصر \odot ، المعادلة (1). ثم يتم إدخال المتجهة الناتجة من عملية الجداء إلى طبقة خرج متمثلة بطبقة كثيفة Dense ذات تابع تنشيط غير خطي sigmoid [5] مهينة أوزانها بطريقة التهيئة LeCun uniform، لكن تم استخدام ReLu كتابع تنشيط في الدراسة باعتبار أنّ مشكلة البحث

انحدر (هدف ذو قيم مستمرة - التقييمات Ratings). وتابع التحسين المستخدم هو هبوط التدرج العشوائي SGD. توضح المعادلة (2) خرج شبكة GMF (التقييم المتوقع (predicted rating):

$$\phi^{GMF} = p_u^{GMF} \odot q_i^{GMF} , \quad (1)$$

$$\hat{y}_{ui} = a_{out}(h^T(\phi^{GMF})) , \quad (2)$$

حيث h : متجهة أوزان طبقة الخرج، a_{out} : تابع التنشيط. يمكن الحصول على نظام MF من GMF باستخدام تابع تنشيط خطي Identity و h متجهة موحدة بقيم 1.

4-1-2- البيرسبيترون متعدد الطبقات (MLP)

MLP هي نوع من الشبكات العصبونية ذات التغذية الأمامية تتكون من طبقات متعددة كثيفة Dense متصلة بالكامل، تتمثل بطبقة الدخل، وأكثر من طبقة مخفية واحدة (تعلّم عميق)، وطبقة الخرج، الشكل (2). يتم حساب مجموع أوزان كل خلية عصبونية من الطبقات المذكورة باستخدام توابع تنشيط غير خطية. إنّ ضم الميزات الكامنة للمستخدم p_u والعنصر q_i غير كافي لنمذجة تأثير الفلتر التعاونية ولذلك يقترح الباحثون في الدراسة [14] استخدام MLP لتعلّم التفاعلات والروابط غير الخطية بين تلك الميزات الكامنة. تابع التنشيط المستخدم هو ReLU [10] لأن sigmoid و tanh يعانيان من مشكلة تلاشي التدرج Vanishing Gradient التي تحدث بسبب التدرجات الصغيرة جداً الناتجة أثناء عملية الانتشار الخلفي لتحديث أوزان خلايا طبقات الشبكة والتي ستلاشى بسبب عمق الشبكة ولن يتم تحديثها. استخدم الباحثون بنية هرمية تضيق نحو الخرج بنسبة 50% من عدد خلايا الطبقة السابقة. توضح المعادلة (3) خرج الشبكة MLP:

$$\phi^{MLP} = a_L(W_L^T(a_{L-1}(\dots a_2(W_2^T \begin{bmatrix} p_u^{MLP} \\ q_i^{MLP} \end{bmatrix} + b_1) \dots)) + b_L), \quad (3)$$

حيث W_x, b_x, a_x : مصفوفة الأوزان، الانحياز، وتابع تنشيط لخلية الطبقة x .

4-1-3- التحليل العاملي للمصفوفة العصبوني (NeuMF)

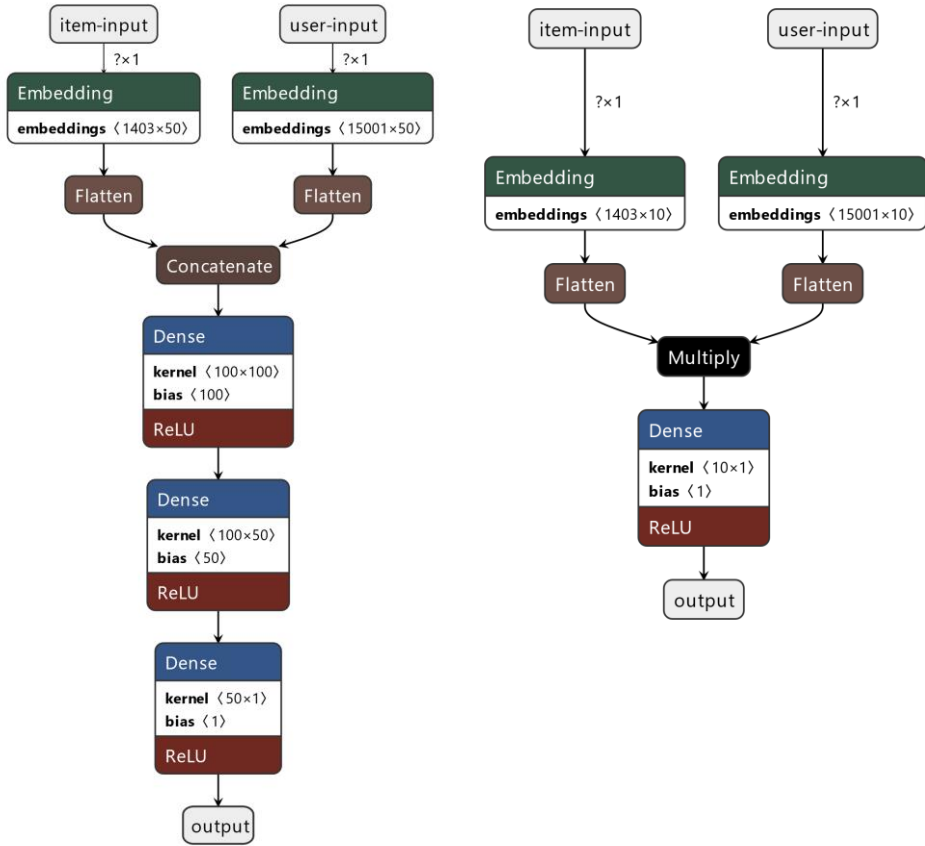
NeuMF هو نظام توصية CF مكون من دمج الطبقة المخفية الأخيرة لكل من GMF و MLP بطبقة ربط Concatenation، الشكل (3)، وبالتالي الاستفادة من العملية الخطية من نمذجة روابط الميزات الكامنة للمستخدمين والعناصر في نموذج GMF، والعملية غير الخطية من روابط الميزات من المعطيات في نموذج MLP [14].
توضح المعادلة (4) التقييم المتوقع للعنصر i من أجل المستخدم u :

$$\hat{y}_{ui} = \sigma \left(h^T \begin{bmatrix} \phi^{GMF} \\ \phi^{MLP} \end{bmatrix} \right), \quad (4)$$

حيث أن h : متجهة أوزان طبقة الربط، σ : تمثل تابع التنشيط.

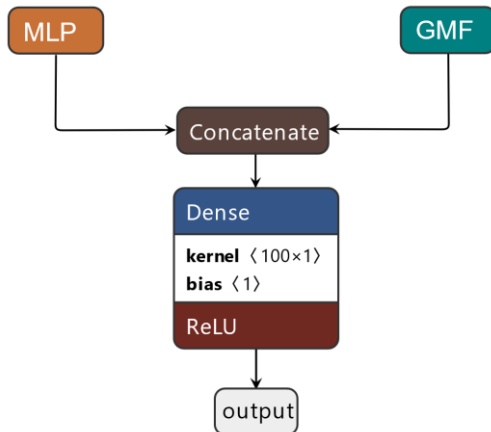
تابع التنشيط المستخدم هو ReLU وطريقة تهيئة الأوزان He_uniform. بالنسبة لتوابع التحسين Optimizers، كل من GMF و MLP تستخدم تابع التحسين Adam [23] لتحسين مقاييس الدقة والخطأ، أما NeuMF يستخدم تابع التحسين SGD، ومعدل التعلم يساوي 0.01. باعتبار أن النظام يقوم بالتنبؤ بالتقييمات التي تقع ضمن مجال بأعداد حقيقية مستمرة فإن المشكلة هي انحدار Regression وبالتالي سنستخدم مقاييس خطأ MAE و RMSE في تدريب واختبار النماذج.

إغناء نظام NeuMF بكامل ميزات المعطيات باستخدام نماذج التعلم العميق المعتمدة على الانتباه لتحسين التنبؤ بالتقييمات



الشكل (2): نموذج MLP.

الشكل (1): نموذج GMF.



الشكل (3): نموذج التحليل العامل للمصفوفة العصبوني NeuMF.

4-2- الشبكات العصبونية العميقة للميزات النصية

تستخدم الشبكات العصبونية العميقة مع مختلف أنواع المعطيات الرقمية، النصية، الصور والفيديو في مختلف المهام والمسائل، مثل: التصنيف والتنبؤ بالتقييمات، تحليل المشاعر، ترجمة النصوص، معالجة الصور والفيديو [1، 11]. تتناول الدراسة 3 أنواع للشبكات العصبونية بهدف الاستفادة من الميزات النصية في مجموعات المعطيات المستخدمة، وهي البيرسيترون متعدد الطبقات MLP [1، 14]، الشبكة العصبونية التلافيفية CNN [22، 25، 35، 43]، الشبكة المتكررة ذات الذاكرة الطويلة قصيرة المدى LSTM [8، 9، 15، 40]، بالإضافة إلى نموذج شبكي هجين مقترح يستخدم آلية الانتباه Attention في طبقاته.

بالنسبة للشبكات العصبونية المذكورة، إنّ طبقة الدخل عبارة عن سلاسل عددية تمثل الكلمات في الميزات النصية من مجموعات المعطيات المستخدمة. يليها طبقة تضمين Embedding لأوزان الكلمات E ذات حجم يساوي معجم الكلمات V و 300 بُعد لأوزان الطبقة d ، حيث $E \in \mathbb{R}^{d \times V}$. في البداية يتم تدريب الشبكات بدون أوزان تضمين للكلمات ومن ثم يتم تهيئتها بأوزان تضمين باستخدام أوزان لـ 3 نماذج من نماذج تضمين الكلمات المدربة مسبقاً، وهي Word2Vec، FastText، GloVe. بالنسبة لطبقات الشبكة، تم استخدام تابع التنشيط ReLU، ومقاييس خطأ MAE و RMSE لتدريب واختبار الأداء التنبؤي للشبكات، وتابع التحسين هو Adam.

4-2-1- البيرسيترون متعدد الطبقات (MLP)

MLP [11] هي نوع من الشبكات العصبونية ذات التغذية الأمامية، تتكون من طبقة مخفية أو أكثر من نوع الطبقة الكثيفة Dense المتصلة بالكامل ذات تابع تنشيط غير خطي. في هذه الدراسة، تم بناء الشبكة باستخدام 4 طبقات كثيفة Dense بعدد خلايا

إغناء نظام NeuMF بكامل ميزات المعطيات باستخدام نماذج التعلّم العميق المعتمدة على الانتباه لتحسين التنبؤ بالتقييمات

(64، 32، 5، 1). بالإضافة إلى استخدام الطبقة المسطحة Flatten، وطبقة الإسقاط Dropout [39] بمعدل 20% لخلايا كل طبقة مما يقلل من التعرض لمشكلة التلاؤم الزائد، الشكل (4).

4-2-2- الشبكات العصبونية التلافيفية (CNN)

CNN هي نوع من الشبكات العصبونية ذات التغذية الأمامية طوّرت من أجل مهام الرؤية الحاسوبية [25] وتستخدم في تصنيف النصوص [22] وتحليل المشاعر [43]. تتكون CNN من 3 مراحل: مرحلة الدخل (صورة ثنائية البعد، نصوص أحادية البعد)، مرحلة استخراج الميزات (على الأقل طبقة تلافيفية convolution وطبقة تجميع pooling)، ومرحلة التصنيف (على الأقل طبقة كثيفة Dense مثل شبكة MLP).

في هذه الدراسة، تم بناء شبكة CNN باستخدام اثنتين من الطبقات التلافيفية أحادية البعد Conv1D بعدد فلاتر 5 و 10، بعدها طبقة تجميع MaxPooling يليها طبقة تسوية الدفعة BatchNormalization [18] التي تحسن استقرار الشبكة بتسوية أوزان دخل كل طبقة على مستوى الميزة لكل العينات في الدفعة الصغرى mini-batch. يلي ذلك طبقة الإسقاط Dropout بمعدل 20% لخلايا الطبقة، يليها طبقتين Dense بحجم 5 و 1 من أجل عملية التنبؤ بالتقييمات وتحليل النصوص. تابع التنشيط المستخدم هو ReLU في كل من طبقتي Conv1D و Dense، الشكل (4).

4-2-3- الذاكرة الطويلة قصيرة المدى ثنائية الاتجاه (BiLSTM)

LSTM هي نوع من الشبكات العصبونية المتكررة طوّرت لحل مشكلة تلاشي التدرج (Vanishing Gradient) التي تعاني منها الشبكات العصبونية المتكررة RNN، بالإضافة إلى قدرتها على الاحتفاظ بالاعتماديات طويلة المدى [9، 15، 40]. تُستخدم

LSTM في المهام المتعلقة بالتسلسلات الزمنية من نصوص، صوت، فيديو، وتحليل المشاعر منها وتصنيفها، ترجمة اللغات، وأنظمة التوصية.

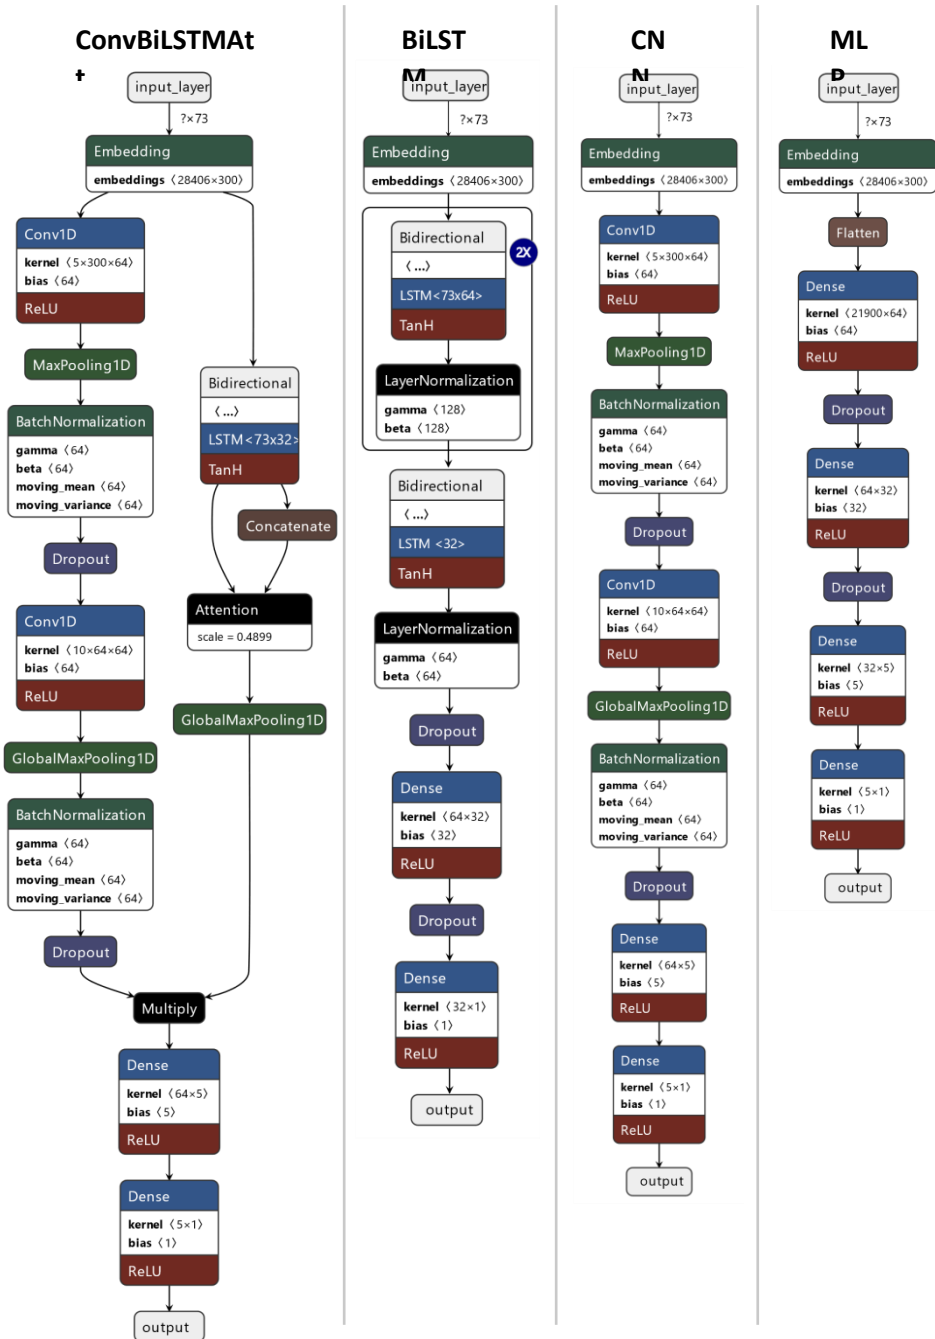
في هذه الدراسة، تم بناء شبكة BiLSTM باستخدام 3 طبقات BiLSTM بحجم 64، 64، 32، يلي كل منها طبقة تسوية الطبقة Layer Normalization [2] التي تحسن استقرار LSTM بتسوية أوزان دخل خلايا الطبقة بأكملها. يلي ذلك طبقة الإسقاط Dropout بمعدل 20% لخلايا الطبقة، يليها طبقتين Dense بحجم 32 و 1 من أجل عملية التنبؤ بالتقييمات وتحليل النصوص. تابع التنشيط المستخدم هو ReLU في طبقات Dense، tanh و sigmoid في طبقات LSTM، الشكل (4).

4-2-4- آلية الانتباه Attention

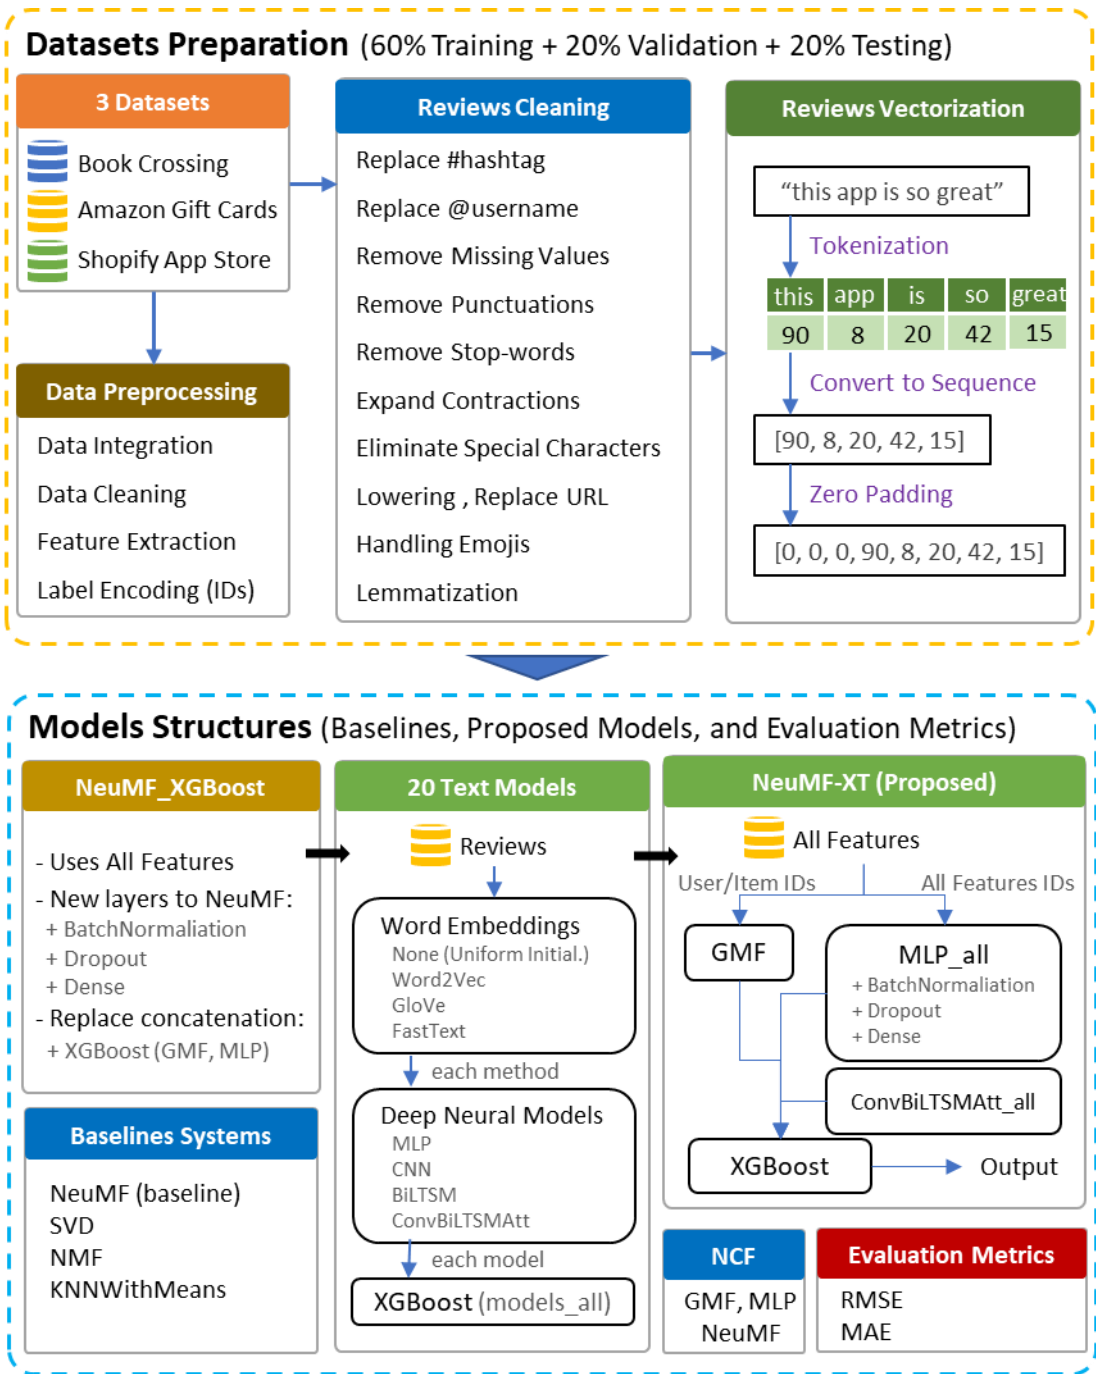
آلية الانتباه هي بنية تُستخدم في الشبكات العصبونية لنمذجة التفاعلات طويلة المدى، وهي تُقدم متجهة سياق تساعد الشبكة في التركيز على الأجزاء الأكثر صلة في سلسلة الدخل (مثل الكلمات والعبارات المفتاحية الممثلة لمشاعر النص) [3، 16، 26، 29، 41، 44-46].

في هذه الدراسة، تم بناء نموذج عصبي هجين مكون من فرعين، الأول طبقات تلافيفية، والثاني طبقة مكررة ثنائية الاتجاه مع الانتباه. بنية النموذج عبارة عن طبقتين تلافيفيتين بعدد فلاتر 64 وحجم 5، 10 وتابع التنشيط ReLU يتخللها طبقة تجميع وتسوية بالدفعة وإسقاط بمعدل 20%. طبقة BiLSTM بعدد خلايا 32 وتابع التنشيط tanh. طبقة انتباه تأخذ الحالة الأخيرة للطبقة المخفية من BiLSTM وإضافة الانتباه إلى خرج الطبقة الكلي. ثم يتم دمج الفرعين بطبقة جداء عنصر بعنصر Multiply، يليها طبقتين كثيفتين Dense بحجم 5 و 1 بتابع تنشيط ReLU، الشكل (4).

إغناء نظام NeuMF بكامل ميزات المعطيات باستخدام نماذج التعلّم العميق المعتمدة على الانتباه لتحسين التنبؤ بالتقييمات



الشكل (4): الشبكات العصبونية العميقة المبنية للتعامل مع الميزات النصية.



الشكل (5): منهجية البحث والطرق المستخدمة.

5- منهجية البحث

تتضمن منهجية البحث مرحلتين أساسيتين في إجراء هذه الدراسة لتطوير وتحسين نظام NeuMF، الشكل (5):

- مرحلة معالجة وإعداد مجموعات المعطيات التي يتم من خلالها إجراء التجارب والمقارنات بهدف اختيار النماذج ذات أفضل أداء تنبؤي (بأقل خطأ)، وتشمل عمليات المعالجة المسبقة لميزات المعطيات وعمليات تنظيف وتحويل للميزات النصية.
- مرحلة بناء النماذج المقترحة والمقارنات فيما بينها مع النظام الأساس NeuMF وأنظمة توصية CF أخرى، حيث تمت المقارنات على 3 مجموعات معطيات لشمولية النتائج واستخدام مقياسي الخطأ MAE و RMSE لمقارنة دقة التنبؤ.

5-1-1-5- مرحلة معالجة وإعداد مجموعات المعطيات

في هذه الدراسة قمنا باختيار مجموعات المعطيات الثلاث التالية: Book Crossing [47]، Amazon Gift Cards [32]، Shopify App Store [36]، وتطبيق مجموعة من عمليات المعالجة المسبقة عليها، ومعالجة الميزات النصية من خلال تنظيفها وتحويلها إلى سلاسل عديدة.

5-1-1-5- المعالجة المسبقة للمعطيات Data Preprocessing

تم التحقق من كمالية وصحة المعطيات من خلال تفقد القيم المفقودة والخطئة في ميزات مجموعات المعطيات وتصحيحها بإعطائها قيم تمثل العينة المنتمية لها وتشابه قيم العينات المشابهة لها. بعدها تم تنظيف المعطيات من العينات المكررة والميزات التي تحوي قيمة وحيدة فقط ولا تقدم أي أهمية في عملية التنبؤ، مثل: "Amazon Gift Cards(marketplace='us')"، إذ جميع قيم الميزة هي 'us' ولذلك تم حذف جميع الميزات المشابهة لها. تم حذف الميزات غير المهمة في إجراء الدراسة مثل عناوين الويب والصور للعناصر. قمنا باستخراج ميزات جديدة من خلال إيجاد معرفات فريدة لقيم

كل ميزة من مجموعات المعطيات المستخدمة من أجل النماذج الشبكية العصبونية والتي تتطلب قيم عددية كدخل لها.

بالنسبة للمجموعة Shopify App Store، فقد قمنا بدمج مجموعتي معطيات Apps.csv و reviews.csv للحصول عليها وإجراء عمليات التنظيف وضمان تكاملية المعطيات، بالإضافة إلى إعادة ترميز معرفات المستخدمين، المنتجات، والمراجعات لاحتوائها على قيم ذات طبيعة مختلفة (عددية ونصية) تُخل بإجراء العمليات عليها. من أجل الحصول على عينات معبرة وذات أهمية للتجارب اخترنا المستخدمين والمنتجات الذين لديهم أكثر من 3 مراجعات، إذ إنَّ اختيار قيمة أعلى ستقصي عدداً كبيراً من عينات التجربة. بالنسبة للمجموعة Book Crossing، قمنا باستخدام ميزاتها المستخرجة كما هي [6]، وقمنا باستخراج معرفات عددية فريدة لها كدخل للنماذج العصبونية العميقة.

يوضح كل من الجدول (1)، الجدول (2)، الجدول (3) الميزات المستخدمة والمستخرجة في استخراج معرفات فريدة لميزاتها (باستثناء rating) تمثيلها كدخل في نماذج الدراسة.

جدول (1): الميزات المستخدمة لمجموعة معطيات Book Crossing

الميزات المستخدمة	التوصيف
user_Age	عمر المستخدم
rating	تقييم المستخدم للكتاب
book_year_of_publication	تاريخ نشر الكتاب
book_num_pages	عدد الصفحات
user_ratings_mean	معدل تقييمات المستخدم
book_title_length	طول عنوان الكتاب
book_word_counts	عدد الكلمات
w2v_lemmatized_title_100_e	الميزة الأولى لتحليل المكون الأساسي ذو 100 بعد لعناوين
phocs_PCA_1	الكتب المطبق عليها عملية lemmatization
w2v_lemmatized_title_100_e	الميزة الثانية لتحليل المكون الأساسي ذو 100 بعد لعناوين
phocs_PCA_2	الكتب المطبق عليها عملية lemmatization
book_isbn_mean_ratings	معدل تقييمات الكتب
book_isbn_counts_ratings	عدد التقييمات الكتب
book_author_mean_rating	معدل تقييمات لكل مؤلف
book_author_count_rating	عدد تقييمات لكل مؤلف

جدول (2): الميزات المستخدمة والمستخرجة لمجموعة معطيات Amazon Gift Cards

الميزات المستخدمة والمستخرجة	التوصيف
customerID	رقم تعريف الزبون
reviewID	رقم تعريف المراجعة
productID	رقم تعريف المنتج
product_parent	صنف المنتج
product_title	اسم المنتج
rating	تقييم الزبون للمنتج
helpful_votes	عدد الزبائن الذين أعجبهم المراجعة
total_votes	العدد الكلي للزبائن الذين قيموا المراجعة
verified_purchase	تأكيد الشراء للمنتج من قبل الزبون
review_headline	عنوان المراجعة
review_body	جسم المراجعة النصية
review_date	تاريخ المراجعة

جدول (3): الميزات المستخدمة والمستخرجة لمجموعة معطيات Shopify App Store

الميزات المستخدمة والمستخرجة	التوصيف
appId	رقم تعريف التطبيق
reviewId	رقم تعريف المراجعة
title	اسم التطبيق
developer	الشركة المُطوّرة
site_rating	تقييم الموقع
author	المستخدم الذي كتب المراجعة
body	جسم المراجعة النصية
rating	تقييم المستخدم للتطبيق

5-1-2- تنظيف الميزات النصية Reviews Cleaning

بالنسبة للميزات النصية في مجموعات المعطيات المستخدمة، فقد قمنا بتطبيق مجموعة من عمليات تنظيف النصوص، مثل: حذف العينات ذات القيم المفقودة، حذف علامات التعجب والاستفهام وتبديلها بنقطة، حذف كلمات التوقف والمحارف الخاصة، تبديل الهاشتاج واسم المستخدم وعناوين URLs بقيمها فقط (حذف #، @)، توسيع

الاختصارات (“She should’ve” → “she should have”)، تصغير حالة الأحرف، تحويل الرموز التعبيرية emojis إلى نص معبر عنها (😊): grinning face with smiling eyes).

تم تطبيق تلك العمليات على الميزة النصية مراجعات المستخدمين (reviews) لكل من مجموعتي المعطيات Amazon Gift Cards، Shopify App Store، بالإضافة إلى إجراء عملية Lemmatization لإعادة الكلمات لمصادرها لتوحيد المعنى الخاص بها في مجموعة معطيات Book Crossing للميزات النصية الممثلة للكتاب (عنوان الكتاب، تصنيفه، تصنيفه الفرعي، ملخص الكتاب).

5-1-3- تحويل المراجعات إلى سلاسل عددية Reviews Vectorization

بعد إجراء عمليات تنظيف النصوص على الميزات النصية يجب تحويلها إلى قيم عددية تمثلها لتكون مناسبة كدخل للشبكات العصبونية. في البداية، نقوم بتحويل نص المراجعات إلى متجهات من كلمات النص وتمثيلها بمعرفات فريدة ترمز لها في معجم الكلمات الخاص باستخدام عملية الترميز Tokenization لنحصل على سلسلة عددية تمثل قيمها المعرفات الخاصة بكل كلمة، وفي النهاية نقوم بحشو تلك السلاسل الناتجة بأصفار لتصبح بحجم متساوي ثابت لتكون دخلاً لنماذج الشبكات العصبونية المستخدمة في الدراسة.

قمنا باستخدام متوسط طول كلمات المراجعات مضافاً إليها الانحراف المعياري لتوزيعها الطبيعي للحصول على الطول الأعظمي الثابت للسلاسل العددية المستخدمة كدخل للنماذج، جدول (4).

إغناء نظام NeuMF بكامل ميزات المعطيات باستخدام نماذج التعلّم العميق المعتمدة على الانتباه لتحسين التنبؤ بالتقييمات

جدول (4): حجم معجم الكلمات والطول الأعظمي لسلسلة الدخل مقاسة بعدد الكلمات

Shopify App Store	Amazon Gift Cards	Book Crossing	مجموعة المعطيات
73	54	264	الطول الأعظمي للدخل
28,405	31,516	12,755	حجم معجم الكلمات

بالنسبة لتقسيمات مجموعات المعطيات الثلاث، فقد قمنا بتقسيمها إلى 60% كمجموعة تدريب، 20% كمجموعة تحقق، 20% كمجموعة اختبار، أما حجم الدفعة=32 [30]. واستخدمنا مقياس الخطأ RMSE و MAE لقياس دقة التنبؤ بالتقييمات لنماذج الدراسة.

5-2-2- مرحلة بناء النماذج المقترحة

يشرح هذا القسم التعديلات على نظام NeuMF لتسخير كامل ميزات المعطيات، والنماذج العصبونية العميقة للتعامل مع الميزات النصية وتحليل المشاعر منها. بالإضافة إلى شرح النموذج المقترح النهائي الناتج من جمع العمليات السابقة، الشكل (5).

5-2-1- نموذج التحليل العاملي للمصفوفة كامل الميزات NeuMF_XGBoost

النموذج الأساس NeuMF يتكون من ربط نموذجي GMF و MLP بطبقة ربط Concatenation. من أجل تمكين استخدام كامل ميزات المعطيات، قمنا بتعديل طبقة الدخل لتشمل كامل الميزات (معرفاتها IDs). ومن أجل تنظيم خرج نموذج MLP استخدمنا طبقة Batch Normalization لتسوية أوزان دخل طبقات النموذج لتسهيل تهيئة الأوزان وتسريع عملية التدريب واستقرار الشبكة للحصول على دقة أفضل. من أجل تقليل مشكلة التلاؤم الزائد استخدمنا طبقة الإسقاط Dropout بمعدل 20% من خلايا الطبقة.

إنّ نموذج الأساس NeuMF يستخدم طريقة Lecun uniform لتهيئة الأوزان مع تابع التنشيط ReLU ولكن في دراسة لاحقة [5] وجد الباحثون أنّ استخدام طريقة تهيئة الأوزان He_uniform تقدم أداءً أفضل للنماذج ولذلك استخدمنا تلك الطريقة في تهيئة أوزان النموذج لنحصل في النهاية على نموذج MLP_all. قمنا بتبديل طبقة الربط Concatenation بنموذج تعلم الآلة المكدمس XGBoost لتكديس خرج طبقة GMF و MLP_all لنحصل على النموذج المقترح الأولي NeuMF_XGBoost. إنّ استخدام نموذج XGBoost سيساعد في إضافة نماذج أخرى مما يساهم في توسيع وظيفة النموذج.

5-2-2- النماذج العصبونية العميقة للتعامل مع الميزات النصية

بالنسبة للميزات النصية، فقد استخدمنا مجموعة من الشبكات العصبونية ذات طبقة التضمين Embedding لتحويل سلاسل النصوص إلى أوزان قابلة للتدريب لتعطي كل كلمة متجهات أوزان تُمثل مشاعر ومعنى كل كلمة في سياق النصوص (مراجعات المستخدمين، عناوين وتوصيفات الكتب). أولاً، قمنا ببناء 3 نماذج شبكية MLP، CNN، BiLSTM، الشكل (4)، وتهيئة أوزان طبقة التضمين بقيم عشوائية بدون استخدام أوزان نموذج تضمين كلمات مدربة مسبقاً مثل GloVe. ثانياً، بعد تدريب النماذج الثلاث بدون أوزان نماذج تضمين قمنا باستخدام 3 نماذج لتضمين الكلمات مدربة مسبقاً لتهيئة أوزان طبقات تضمين النماذج الشبكية، وهي Word2Vec، GloVe، FastText، جدول (5). هذه النماذج تقدم متجهات ذات 300 بُعد للكلمات تُمثل المعنى الدلالي وتموضعها في سياق النصوص. ثم تم تدريب النماذج العصبونية عليها في التنبؤ بالتقييمات Ratings.

جدول (5): نماذج تضمين الكلمات المدربة مسبقاً المستخدمة في الدراسة

الباحثون	عدد عينات التدريب	مجموعة المعطيات المدربة عليها	النماذج المدربة مسبقاً المستخدمة	المطورون	الخوارزميات والطرق في تمثيل الكلمات
(Mikolov et al., 2013) [31]	3 million words	Google News dataset (100 billion words)	GoogleNews-vectors-negative300.bin	Google	Word2Vec Word 2 Vector
(Joulin et al., 2017) [20]	1 million words	Wikipedia 2017, UMBC corpus and statmt.org news dataset (16B tokens)	wiki-news-300d-1M.vec	Facebook AI Research (FAIR) Lab	FastText
(Pennington et al., 2014) [34]	6 billion words	Wikipedia 2014 and Gigaword 5	glove.6B.300d.txt	Stanford University	GloVe Global Vectors

ثالثاً، في مرحلة لاحقة خلال إجراء الدراسة وجدنا أنه يمكن الاستفادة من فوائد شبكات CNN، BiLSTM، وتسخير آلية الانتباه لتحسين دقة تنبؤ النموذج. قمنا ببناء نموذج عصبوني هجين مكون من فرعين، الأول يعتمد على CNN، والثاني يعتمد على كل من BiLSTM وآلية الانتباه، الشكل (4). لنحصل بذلك على نموذج ConvBiLSTMAtt يستخدم قدرة الطبقات التلافيفية لـ CNN على استخراج واكتشاف الميزات الدلالية المحلية في كلمات ميزة الدخل النصية، وقدرة BiLSTM على الاحتفاظ بالاعتماديات طويلة المدى بين ميزات الدخل النصية والتعلم منها. بالإضافة إلى طبقة الانتباه Attention التي تقدم أوزان الانتباه إلى خرج BiLSTM للتركيز على أهم الميزات التي تعبر عن مشاعر السياق المتمثلة بالتقييمات. رابعاً، قمنا باستخدام نموذج

تعلم الآلة XGBoost لتكديس خرج كل من النماذج الشبكية على حدا مع مقابلاتها من نماذج تضمين الكلمات المدربة مسبقاً بحيث نحصل على نموذج يكسب خرج 4 نماذج شبكية لنفس النوع مستخدمةً 4 طرق لتهيئة أوزان طبقة التضمين None، Word2Vec، Glove، FastText. مثلاً، نموذج CNN_all هو نموذج نصي يكسب 4 نتائج معتمدة على كل من None، Word2Vec، Glove، FastText، و"all" ترمز إلى استخدام جميع طرق تهيئة الأوزان.

بالنسبة لبارامترات النماذج، فقد قمنا بمعايرة معدل التعلم للمُحسن Adam لكل النماذج وعدد الخلايا لطبقات MLP و BiLSTM وعدد وحجم فلاتر CNN لاختيار أفضل القيم لها، جدول (6). يبين الجدول (7) قيم البارامترات الخاصة لكل نموذج عصبوني نصي، والجدول (8) يبين قيم البارامترات العامة المشتركة بين النماذج.

جدول (6): معايرة البارامترات المستخدمة في النماذج العصبونية النصية

النماذج	البارامترات	مجال القيم	الأفضل
MLP	units	(64, 128, 256)	64
	learning_rate	(0.001, 0.01, 0.1)	0.01
CNN	filters	(32, 64, 128)	64
	kernel_size	(3, 5, 10)	5
	learning_rate	(0.001, 0.01, 0.1)	0.01
BiLSTM	units	(16, 32, 64)	64
	learning_rate	(0.001, 0.01, 0.1)	0.001

جدول (7): قيم البارامترات الخاصة للنماذج العميقة النصية المستخدمة في الدراسة

البارامترات	البارامترات المستخدمة	النماذج
units= (64, 32, 5, 1) rate=0.2 activation='relu'	عدد الخلايا في طبقات Dense معدل الإسقاط تابع التنشيط في Dense	MLP
filters= (64, 64) units= (5, 1) rate=0.2 activation='relu' activation='relu' padding='same'	عدد الخلايا في طبقات Conv1D عدد الخلايا في طبقات Dense معدل الإسقاط تابع التنشيط في Conv1D تابع التنشيط في Dense نوع الحشو	CNN
units= (64, 64, 32) units= (32, 1) rate=0.2 activation='relu'	عدد الخلايا في طبقات BiLSTM عدد الخلايا في طبقات Dense معدل الإسقاط تابع التنشيط في Dense	BiLSTM
filters= (64, 64) kernel_size = (5, 10) rate=0.2 activation='relu' activation='relu' padding='same' units= 32 score_mode='dot' use_scale=True units= 5, 1	عدد الخلايا في طبقات Conv1D حجم الفلاتر معدل الإسقاط تابع التنشيط في Conv1D تابع التنشيط في Dense نوع الحشو عدد الخلايا في طبقات BiLSTM نمط التسجيل في طبقة Attention استخدام مُقياس في طبقة Attention عدد الخلايا في طبقات Dense	ConvBiLSTMAtt

جدول (8): قيم البارامترات العامة المشتركة للنماذج العميقة النصية المستخدمة

البارامترات العامة في النماذج	قيم البارامترات
طريقة التحسين	optimizer='adam'
تابع الخسارة	loss='mse'
معيار الخطأ	metrics=['mae']
تقسيمات مجموعة المعطيات	60% training, 20% validation, 20% testing
حجم الدفعة	batch_size=32
عدد دورات التدريب	epochs=10
حجم طبقة التضمين	embed_dim=300
أوزان طبقة التضمين	None, Word2Vec, FastText, GloVe
الطول الأعظمي لدخل طبقة التضمين	متوسط أطوال المراجعات + انحرافها المعياري

5-2-3- النموذج المقترح NeuMF-XT

إنّ ناتج المرحلة السابقة هو 20 نموذج عصبوني نصي (4 نماذج شبكية \times 4 نماذج تضمين + 4 نماذج شبكية مكدسة). قمنا بدمج كل نموذج نصي على حدا مع نموذج NeuMF_XGBoost لتمكينه من الاستفادة من كامل ميزات المعطيات العددية والفئوية والنصية. قمنا بإجراء عملية الدمج باستخدام نموذج XGBoost الخاص بنموذج NeuMF_XGBoost نفسه، لنحصل على نموذج ذو دقة تنبؤية أعلى. من خلال إجراء المقارنات واعتماد مقاييس الخطأ RMSE، MAE لمقارنة دقة أداء التنبؤ بالتقييمات لكل من النماذج الناتجة وجدنا أنّ النموذج الذي يربط NeuMF_XGBoost مع النموذج النصي ConvBiLSTMAAtt_all قدّم أفضل النتائج، ويدعى NeuMF-XT، الشكل (5).

6- التجارب

6-1- أدوات البحث

تم تطبيق تجارب الدراسة على بيئتي عمل محلية وسحابية، وهما:

- حاسب محمول بنظام Windows 11 Home 64bit ومعالج Intel Core i5 بسرعة 2.6GHz وذاكرة RAM 8GB، بطاقة الفيديو المستخدمة NVIDIA GeForce RTX 3050 Ti 4GB وCUDA 11.2.

- بيئة عمل سحابية Google Collaboratory بنظام Ubuntu 22.04.3 LTS ومعالج Xeon بسرعة 2.3GHz وذاكرة RAM 12.7GB، بطاقة الفيديو المستخدمة NVIDIA Tesla T4 16GB وCUDA 12.2.

استخدمنا لغة بايثون 3.10.9 ومكتباتها NumPy, Pandas, Matplotlib, Sklearn في إجراء عمليات المعالجة على مجموعات المعطيات وعرض الأشكال لمقارنة النتائج، ومكتبات re، contractions، emoji، nltk لمعالجة النصوص. واستخدمنا مكتبة Tensorflow 2.10.1 لبناء وتدريب النماذج المقترحة واختبارها ومقارنة النتائج. استخدمنا بيئة عمل Anaconda Jupyter Notebook لكتابة وتوثيق الأكواد البرمجية.

6-2- مجموعات المعطيات

قمنا باستخدام مجموعات المعطيات الثلاثة التالية في الدراسة: Book Crossing، Amazon Gift Cards، Shopify App Store. قمنا باستخدام Book Crossing [6، 47] لاحتوائها على ميزات عديدة ومفيدة في عمليات التنبؤ بالتقييمات، مثل: الميزات الإحصائية، التمثيلات النصية، ميزات توصف الكتاب بأكثر قدر ممكن. واستخدمنا مجموعتي معطيات Amazon Gift Cards [32]، Shopify App Store [36] لاحتوائهما على الميزة النصية مراجعات المستخدمين للمنتجات والتي تعبر عن

مدى تفضيل المستخدم للمنتج، ومجموعة الكتب لا تحوي ميزة نصية معبرة عن تفضيلات المستخدم، إنما تحوي ميزات نصية تُمثل الكتاب فقط (عنوانه، تصنيفه، تصنيفه الرئيسي، ملخص شامل). أجرينا مجموعة من عمليات المعالجة المسبقة والتنظيف على كامل الميزات واستخلص معرفات فريدة لقيم الميزات ما عدا ميزة التقييمات Rating وهي هدف التنبؤ.

تم تقسيم المجموعات إلى 60% للتدريب، 20% للتحقق، و20% اختبار. يوضح الجدول (9) خصائص مجموعات المعطيات الإحصائية ومجال التقييمات قبل وبعد معالجتها.

جدول (9): خصائص مجموعات المعطيات قبل وبعد معالجتها للدراسة

Shopify App Store		Amazon Gift Cards		Book Crossing		مجموعة المعطيات
بعد	قبل	بعد	قبل	بعد	قبل	
الخصائص						
77,538	287,467	-	148,310	14,239	1,149,780	عدد العينات
1,402	179,656	-	142,467	1,091	278,858	عدد المستخدمين
15,000	2,169	-	1,776	603	271,379	عدد العناصر
76,155	283,864	-	148,310	603	271,379	عدد النصوص
لا يوجد	المؤلف: 151 الجسم: 186	لا يوجد	عنوان: 3 جسم: 2 تاريخ: 1	لا يوجد	العمر: 110,762 المؤلف: 1 الناشر: 2	القيم المفقودة
0.369%	0.074%	-	0.059%	2.164%	0.002%	كثافة التقييمات
-	(1, 5)	-	(1, 5)	-	(1, 10)	مجال التقييمات
19	22	23	15	69	14	عدد الميزات

6-3- معايير تقييم دقة التنبؤ

من أجل اختبار جودة النماذج ومقارنة الدقة التنبؤية لكل منها مع النظام الأساس NeuMF استخدمنا مقاييس الخطأ MAE متوسط الخطأ المطلق و RMSE جذر متوسط مربع الخطأ [37]، إذ كلما صغرت قيمها كانت دقة التنبؤ أفضل.

$$MAE = \frac{\sum_{j=1}^N |\hat{r}_j - r_j|}{N} \quad (6) \quad \left| \quad RMSE = \sqrt{\frac{\sum_{j=1}^N (\hat{r}_j - r_j)^2}{N}} \quad (5)$$

ونسبة التخفيض [7] في الخطأ RMSE أو MAE فتحسب من المعادلة (7):

$$\text{Reduction\%} = \frac{[RMSE|MAE]_{\text{model}} - [RMSE|MAE]_{\text{baseline}}}{[RMSE|MAE]_{\text{baseline}}} * 100, \quad (7)$$

6-4- أنظمة الأساس Baselines

من أجل مقارنة النموذج المقترح مع أنظمة CF مختلفة عن الأساس NeuMF استخدمنا مكتبة بايثون Surprise [17] والتي تقدم مجموعة من الأنظمة التي يمكن اختبار المعطيات عليها ومقارنة نتائجها مع النموذج المقترح. استخدمنا الأنظمة التالية: KNNWithMeans، [28] Non-negative Matrix Factorization (NMF)، [38] Singular Value Decomposition (SVD).

6-5- التجارب والمقارنات خلال مراحل منهجية الدراسة

يُقدّم هذا القسم مجموعة من المقارنات وفقاً لمراحل بناء النماذج المقترحة، وذلك بالنسبة لمعايير دقة التنبؤ، مقاييس الخطأ RMSE و MAE ومقارنتها مع NeuMF الأساس.

في الجدول (10)، قمنا بمقارنة النموذج المحسن NeuMF_XGBoost مع النظام الأساس NeuMF وذلك على مجموعتي معطيات Book Crossing و Amazon Gift Cards بالنسبة لقيمتي الخطأ RMSE و MAE، إذ حقق النموذج المحسن قيم MAE = 0.4049 و RMSE = 0.8715 بنسبة تخفيض 66.24% و 46.87% بالترتيب من أجل Book Crossing بالمقارنة مع قيم الأساس NeuMF. بالمثل من أجل Amazon Gift Cards، حقق النموذج المحسن قيم MAE = 0.3189

و $RMSE=0.6659$ بنسبة تخفيض 9.15% و 22.88% بالترتيب. بعدها قمنا بتوسيع النموذج المحسن بنموذج شبكي نصي CNN بدون أوزان تضمين كلمات مدربة مسبقاً لنحصل نموذج NeuMF_XGBoost_CNN والذي حقق نتائج أفضل من الأساس والنموذج المحسن بقيم $MAE=0.3133$ و $RMSE=0.8283$ بنسبة تخفيض 73.88% و 49.50% بالترتيب لـ Book Crossing، وقيم $MAE=0.1750$ و $RMSE=0.4240$ بنسبة تخفيض 50.14% و 50.90% بالترتيب لـ Amazon Gift Cards. قمنا بعدها باستخدام مجموعة معطيات Shopify App Store والحصول على نفس النتائج.

جدول (10): مقارنة دقة تنبؤ النماذج المقترحة ونسبة تخفيض الخطأ مع الأساس NeuMF

Shopify App Store		Amazon Gift Cards		Book Crossing		مجموعة المعطيات
RMSE	MAE	RMSE	MAE	RMSE	MAE	
0.8104	0.4111	0.8635	0.3510	1.6402	1.1993	NeuMF (الأساس)
0.5960 (-26.46 %)	0.2670 (-35.05 %)	0.6659 (-22.88 %)	0.3189 (-9.15 %)	0.8715 (-46.87 %)	0.4049 (-66.24 %)	NeuMF_XGBoost
0.3333 (-58.87 %)	0.1374 (-66.58 %)	0.4240 (-50.90 %)	0.1750 (-50.14 %)	0.8283 (-49.50 %)	0.3133 (-73.88 %)	NeuMF_XGBoost_CNN

من المقارنة السابقة وجدنا أنّ استخدام نموذج شبكي CNN للتعامل مع النصوص قدم أداءً تنبؤياً أفضل من النموذج الأساس والنموذج المحسن من NeuMF، لذلك قمنا ببناء مجموعة من النماذج العصبونية واستخدمنا عدة طرق لتهيئة أوزان تضمين الكلمات ودمجها مع النموذج المحسن NeuMF_XGBoost، ومن ثم قمنا بإجراء المقارنات عليها بالنسبة لقيم RMSE و MAE على كل من مجموعتي المعطيات Amazon Gift Cards و Shopify App Store، جدول (11) و جدول (12). من الجدولين وجدنا أنّ النموذج المقترح NeuMF_XGBoost+ConvBiLSTMAtt حقق أفضل دقة تنبؤ

إغناء نظام NeuMF بكامل ميزات المعطيات باستخدام نماذج التعلّم العميق المعتمدة على الانتباه لتحسين التنبؤ بالتقييمات

على مقاييس الخطأ MAE و RMSE بالنسبة لمعظم طرق تضمين الكلمات وكان أفضل نموذج هو النموذج NeuMF_XGBoost+ConvBiLSTMAAtt_all والذي يكس نتائج النماذج النصية الأربعة المعتمدة على كل طريقة تضمين على النموذج ConvBiLSTMAAtt، وكاختصار للنموذج المقترح أشرنا إليه بـ NeuMF_XT وهو أفضل نموذج في الدراسة، إذ حقق قيم MAE=0.1080 و RMSE=0.3297 لمجموعة معطيات Amazon Gift Cards، وقيم MAE=0.0585 و RMSE=0.2824 لمجموعة معطيات Shopify App Store.

جدول (11): مقارنة دقة تنبؤ النماذج المقترحة بحسب النماذج النصية لكل من أوزان تضمين الكلمات المدربة مسبقاً لمجموعة المعطيات Amazon Gift Cards

All		Word2Vec		Glove		FastText		No Weights		أوزان تضمين الكلمات
RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	
0.3663	0.1202	0.4459	0.1846	0.4521	0.1874	0.4519	0.1847	0.4488	0.1864	النماذج MLP
0.3407	0.1088	0.4192	0.1697	0.4266	0.1759	0.4279	0.1732	0.4338	0.1773	LSTM
0.3396	0.1101	0.4231	0.1740	0.4210	0.1754	0.4163	0.1722	0.4240	0.1750	CNN
0.3297	0.1080	0.4094	0.1659	0.4103	0.1673	0.4159	0.1707	0.4244	0.1751	ConvBiLSTMAAtt
-	-	-	-	-	-	-	-	0.8635	0.3510	NeuMF (الأساس)

جدول (12): مقارنة دقة تنبؤ النماذج المقترحة بحسب النماذج النصية لكل من أوزان تضمين الكلمات المدربة مسبقاً لمجموعة المعطيات Shopify App Store

All		Word2Vec		Glove		FastText		No Weights		أوزان تضمين الكلمات
RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	
0.3170	0.0708	0.3514	0.1411	0.3525	0.1419	0.3493	0.1417	0.3595	0.1521	النماذج MLP
0.2971	0.0635	0.3281	0.1310	0.3322	0.1321	0.3281	0.1294	0.3314	0.1310	LSTM
0.2841	0.0595	0.3243	0.1284	0.3231	0.1307	0.3314	0.1286	0.3333	0.1374	CNN
0.2824	0.0585	0.3189	0.1286	0.3293	0.1304	0.3108	0.1255	0.3199	0.1263	ConvBiLSTMAAtt
-	-	-	-	-	-	-	-	0.8104	0.4111	NeuMF (الأساس)

بعد الانتهاء من إجراء التجارب والمقارنات والحصول على أفضل نموذج وهو NeuMF_XT (والذي يتألف من دمج النموذج المحسن NeuMF_XGBoost مع نموذج الشبكة العصبونية النصي ConvBiLSTMatt_all والذي بدوره يدمج 4 نماذج لـ ConvBiLSTMatt معتمدة على كل طريقة تضمين) قمنا بإجراء مقارنات بين النموذج المقترح وعدة أنظمة CF، ولاحظنا تفوق NeuMF_XT على تلك الأنظمة، جدول (13). حيث قدم نسب تخفيض تصل إلى 60% لقيم RMSE و MAE على المجموعات الثلاث.

جدول (13): مقارنة دقة تنبؤ النموذج المقترح ونسبة تخفيض الخطأ مع أنظمة التوصية CF

Shopify App Store		Amazon Gift Cards		Book Crossing		مجموعة المعطيات
RMSE	MAE	RMSE	MAE	RMSE	MAE	
0.8104	0.4111	0.8635	0.3510	1.6402	1.1993	NeuMF (الأساس)
0.9762 (+20.46 %)	0.7103 (+72.79 %)	0.8517 (-1.36 %)	0.4948 (+40.98 %)	2.6152 (+59.45 %)	2.2970 (+91.53 %)	NMF
0.8287 (+2.25 %)	0.3798 (-7.61 %)	0.8289 (-4 %)	0.4638 (+32.15 %)	1.6399 (-0.02 %)	1.2004 (+0.09 %)	KNNWithMeans
0.7522 (-7.18 %)	0.3852 (-6.31 %)	0.8224 (-4.76 %)	0.4543 (+29.43 %)	1.4868 (-9.35 %)	1.1333 (-5.50 %)	SVD
0.2824 (-65.15 %)	0.0585 (-85.77 %)	0.3297 (-61.82 %)	0.1080 (-69.23 %)	0.9451 (-42.38 %)	0.3297 (-72.51 %)	NeuMF_XT (النموذج المقترح)

7- النتائج ومناقشتها

من نتائج المقارنات السابقة، بملاحظة نسب التخفيض في خطأ MAE و RMSE للنموذج الأساس في الجدول (10)، فقد وجدنا أنّ النموذج المحسن NeuFM_XGBoost تفوّق على الأساس بنسبة تخفيض جيدة لكل من قيمتي الخطأ MAE و RMSE على مجموعات المعطيات الثلاث، وذلك بسبب إضافة طبقات التسوية بالدفعات BatchNormaliztion، الإسقاط Dropout إلى بنية MLP في NeuMF والتي تمنع مشكلة التلاؤم الزائد وتزيد من استقرار النموذج، وتمكيننا للنموذج من إدخال كامل معرفات ميزات مجموعة معطيات التجربة، بالإضافة إلى استخدام مكس XGBoost الذي يدمج خرج كل من MLP_all و GMF معاً للحصول على نتائج أفضل من الأساس NeuMF. وجدنا أيضاً أنّ استخدام النموذج NeuFM_XGBoost_CNN (النموذج النصي CNN + النموذج المحسن) يتفوّق على كل من النموذج الأساس والمحسن وينسب تخفيض جيداً تفوق 50% لكل من MAE و RMSE على مجموعات المعطيات الثلاث. وهذا ما شجعنا إلى متابعة بناء نماذج شبكية نصية مختلفة لمقارنة أدائها في تحسين الأداء التنبؤي للأساس NeuMF. وأيضاً لاحظنا أنّ النموذج المحسن في مجموعة Book Crossing قدم نسب تخفيض أعلى بالمقارنة مع نسب التخفيض بالنسبة لمجموعتي المعطيات الثانية والثالثة وذلك لأن المجموعة الأولى Book Crossing تحوي على ميزات ممثلة أكثر للعناصر (الكتب) والمستخدمين، وبالمثل نلاحظ أنّ النموذج المقترح NeuFM_XGBoost_CNN الذي يُمكن الأساس من الاستفادة من الميزات النصية قد حقق نسب تخفيض لمقاييس الخطأ MAE و RMSE لكل من مجموعتي المعطيات Amazon Gift Cards و Shopify و App Store أفضل من نسبة التخفيض لمجموعة المعطيات Book Crossing بالمقارنة مع النموذج المحسن وذلك لأنّ Book Crossing يحوي ميزات نصية لا تعبر

عن مشاعر وآراء المستخدم حول المنتج، بينما Amazon Gift Cards و Shopify App Store يحويان الميزة النصية (مراجعات المستخدم) والتي تعبر عن آراء المستخدم وتُقدّم معلومات مفيدة لتحسين الدقة التنبؤية.

بالنسبة للنماذج المقترحة المعتمدة على النماذج العصبونية النصية، وجدنا من نتائج المقارنات السابقة في الجدول (11) والجدول (12) أنّ جميع النماذج حققت قيم خطأ MAE و RMSE أقل من النموذج الأساس، وأفضلها كان النموذج المعتمد على ConvBiLSTMatt والذي حقق أدنى خطأ في معظم التجارب لكل من نماذج تضمين الكلمات، إذ أنّ ConvBiLSTMatt يعتمد على قدرة الطبقات التلافيفية في استخراج واكتشاف الميزات الدلالية المحلية (المعبّرة عن المشاعر) في كلمات السياق للدخل، وقدرة BiLSTM على الاحتفاظ بالاعتماديات الطويلة بين ميزات الدخل النصية، بالإضافة إلى قدرة الانتباه Attention في تقديم أوزان الانتباه إلى خرج BiLSTM للتركيز على أهم الميزات المفتاحية التي تعبر عن مشاعر السياق المتمثلة بالتقييمات. بالنسبة لمجموعي المعطيات Amazon Gift Cards و Shopify App Store وجدنا أنّ أفضل نموذج مقترح من هذه المقارنات هو النموذج NeuMF-XT الذي يضم النموذج المحسن NeuFM_XGBoost مع النموذج العصبوني النصي المكسب ConvBiLSTMatt_all. وقد حقق النموذج قيمة NSE [37] جيدة جداً تساوي 84% لـ Amazon Gift Cards و 88% لـ Shopify App Store، إذ أنّ القيمة تدل على مقدار تشابه التنبؤات مع التقييمات الحقيقية وقيمها بين $-\infty$ و 100%، القيمة 0% أي النموذج يشابه متوسط قيم الهدف أما 100% أي النموذج يقدم تنبؤات مماثلة تماماً للهدف.

من المقارنات في الجدول (13) وجدنا أنّ النموذج المقترح NeuMF-XT تفوّق على كل من أنظمة التوصية CF: NeuMF، NMF، KNNWithMeans، SVD بالنسبة

لقيم الخطأ MAE و RMSE، وحقق أفضل نسب تخفيض للخطأ بالنسبة للنموذج الأساس على مجموعات المعطيات الثلاث. بما أنّ نسب التخفيض الخاصة بالنموذج المقترح جيدة جداً وهي أفضل بكثير من أنظمة التوصية CF فإننا نقترح استخدام هذه المنهجية التي تقوم على استخدام نموذج مكس XGBoost لتحسين نتائج NeuMF وتوسيع مهام النظام الأساس ليتمكن إضافة نماذج عصبونية نصية تمكن النظام من الاستفادة من الميزات النصية المعبرة عن آراء المستخدمين مثل نموذج ConvBiLSTMAtt_all الذي يعتمد على خصائص كل من CNN و BiLSTM والانتباه لزيادة الدقة التنبؤية بتقييمات العناصر (كتاب، بطاقة هدية، تطبيق).

8- الاستنتاجات والتوصيات

في هذه الدراسة قمنا بتطوير بنية نظام NeuMF للحصول على نموذج ذو أداء تنبؤي أفضل من النظام الأساس NeuMF بأقل قيم ممكنة للخطأ MAE و RMSE في التنبؤ بالتقييمات. اقترحنا في هذه الدراسة نموذج NeuMF-XT والذي قمنا فيه بتعديل بنية نظام NeuMF بإضافة طبقات التسوية بالدفعات والإسقاط واستخدام نموذج تعلّم الآلة XGBoost لتكديس كل من MLP_all و GMF للحصول على نموذج محسن NeuMF_XGBoost والذي قمنا أيضاً بربطه مع نموذج عصبوني نصي ConvBiLSTMAtt_all والذي يستفيد من قدرة الطبقات التلافيفية في استخراج واكتشاف الميزات الدلالية المحلية وقدرة BiLSTM على الاحتفاظ بالاعتماديات الطويلة بين ميزات الدخل النصية، وقدرة الانتباه في تقديم أوزان الانتباه إلى خرج BiLSTM للتركيز على أهم الميزات المفتاحية التي تعبر عن مشاعر السياق المتمثلة بالتقييمات. تُمكن المنهجية المقترحة النظام NeuMF من استخدام كامل ميزات المعطيات وخاصة النصية منها للحصول على نتائج جيدة بأفضل أداء تنبؤي بالتقييمات. أظهرت النتائج تفوق النماذج المقترحة بالنسبة لمجموعات المعطيات الثلاث Book Crossing،

Shopify App Store، Amazon Gift Cards بنسب تخفيض للخطأ تصل بين - 60% و -70%.

بالنسبة للأعمال المستقبلية، النموذج المقترح قابل للتوسيع ليستفيد من ميزات غير النصية مثل: ميزات السلاسل الزمنية، ميزات الصور، الفيديو، الصوت وذلك بحسب المهام المطلوبة. يمكن استخدام نماذج لتضمين اللغات مثل BERT والشبكات العصبونية الصورية GNN وشبكات الخصومة التوليدية GAN مع الانتباه واختبار تأثيرها على الأداء التنبؤي للنموذج. استخدام النموذج المقترح في بناء أنظمة توصية تعتمد على طرق الترتيب Ranking لتقديم أفضل التوصيات. يمكن تطبيق النموذج المقترح على أنواع مختلفة من المهام ومجموعات المعطيات وإجراء التجارب والمقارنات عليها.

إغناء نظام NeuMF بكامل ميزات المعطيات باستخدام نماذج التعلّم العميق المعتمدة على الانتباه لتحسين التنبؤ بالتقييمات

جدول (14): اختصارات لأسماء النماذج والتوابع المستخدمة في البحث

الاختصار	المعنى الكامل
NCF	Neural Collaborative Filtering
GMF	Generalized Matrix Factorization
MLP	Multi-Layer Perceptron
MLP_all	MLP تستخدم جميع ميزات المعطيات all features.
NeuMF	Neural Matrix Factorization
XGBoost	eXtreme Gradient Boosting
ReLU	Rectified Linear Unit
Adam	Adaptive Moments
CNN	Convolutional Neural Network
BiLSTM	Bidirectional
RNN	Recurrent Neural Network
ConvBiLSTMAtt	CNN+BiLSTM+Attention
(TextModelName)_all	نموذج نصي يستخدم XGBoost لتكديس 4 نماذج من أجل كل طريقة تضمين كلمات مدربة مسبقاً بالنسبة لكل نموذج عصبوني نصي، مثال: CNN_all هو نموذج نصي يكس 4 نتائج معتمدة على كل من None, Word2vec, FastText, Glove.
NeuMF-XT	نموذج مقترح يتألف من نموذج NeuMF معدّل بطبقات شبكية ونموذج مكس XGBoost لربط نتائج GMF و MLP، بالإضافة لنموذج عميق نصي Text model، والأفضل كان نموذج ConvBiLSTMAtt_all للتعامل مع الميزات النصية.
RMSE	Root Mean Square Error
MAE	Mean Absolute Error
NSE	Nash-Sutcliffe Model Efficiency

المراجع References

- [1] Aggarwal CC, 2023 - "**Neural Networks and Deep Learning: A Textbook**". Cham: Springer International Publishingp.
- [2] Ba JL, Kiros JR, and Hinton GE, 2016. "**Layer Normalization**".
- [3] Bahdanau D, Cho K, and Bengio Y, 2014. "**Neural Machine Translation by Jointly Learning to Align and Translate**".
- [4] Chen T and Guestrin C, 2016. "**XGBoost: A Scalable Tree Boosting System**", *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '16*, pp. 785-794.
- [5] Datta L, 2020. "**A Survey on Activation Functions and their relation with Xavier and He Normal Initialization**", *ArXiv*, vol. abs/2004.06632.
- [6] Deeb M and Abu Saleh N, 2019. "**Performance Evaluation of Learning Models in Comparison with Recommendation Systems by Studying Data Features**", *Journal of Al-Baath University*, vol. 41, no. 51, pp. 11-52.
- [7] Feng S, Song K, Wang D, Gao W, and Zhang Y, 2021. "**InterSentiment: combining deep neural models on interaction and sentiment for review rating prediction**", *International Journal of Machine Learning and Cybernetics*, vol. 12, no. 2, pp. 477-488.
- [8] Gers FA, Schmidhuber J, and Cummins F, 2000. "**Learning to forget: continual prediction with LSTM**", *Neural Comput.*, vol. 12, no. 10, pp. 2451-71.
- [9] Gers FA, Schraudolph NN, and Schmidhuber J, 2003. "**Learning precise timing with lstm recurrent networks**", *J. Mach. Learn. Res.*, vol. 3, no. null, pp. 115–143.

- [10] Glorot X, Bordes A, and Bengio Y, 2011. "**Deep Sparse Rectifier Neural Networks**".
- [11] Goodfellow I, Bengio Y, and Courville A, 2016 - "***Deep learning***". Cambridge, Massachusetts: The MIT Pressp.
- [12] Graves A and Schmidhuber J, 2005. "**Frame-wise phoneme classification with bidirectional LSTM and other neural network architectures**", *Neural Networks*, vol. 18, no. 5, pp. 602-610.
- [13] Guo T, Wen Y, Wang F, and Hou J, 2019. "**Learning Resource Recommendation Based on Generalized Matrix Factorization and Long Short-Term Memory Model**", in *2019 IEEE International Conference on Cloud Computing Technology and Science (CloudCom)*, pp. 217-222, Sydney, Australia: IEEE.
- [14] He X, Liao L, Zhang H, Nie L, Hu X, and Chua T-S, 2017. "**Neural Collaborative Filtering**", in *Proceedings of the 26th International Conference on World Wide Web*, pp. 173-182, Perth Australia: International World Wide Web Conferences Steering Committee.
- [15] Hochreiter S and Schmidhuber J, 1997. "**Long short-term memory**", *Neural Comput*, vol. 9, no. 8, pp. 1735-80.
- [16] Huang R, McIntyre S, Song M, E H, and Ou Z, 2018. "**An Attention-Based Recommender System to Predict Contextual Intent Based on Choice Histories across and within Sessions**", *Applied Sciences*, vol. 8, no. 12, p. 2426.
- [17] Hug N, 2020. "**Surprise: A Python library for recommender systems**", *Journal of Open Source Software*, vol. 5, no. 52.
- [18] Ioffe S and Szegedy C, 2015. "**Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift**".

- [19] James V and Alagarsamy S, 2022. "RNN LSTM-based Deep Hybrid Learning Model for Text Classification using Machine Learning Variant XGBoost", *International Journal of Performability Engineering*, vol. 18, no. 8, pp. 545-551.
- [20] Joulin A, Grave E, Bojanowski P, and Mikolov T, 2017 - "***Bag of Tricks for Efficient Text Classification***". Valencia, Spain: Association for Computational Linguistics, 427-431p.
- [21] Kamyab M, Liu G, and Adjeisah M, 2021. "Attention-Based CNN and Bi-LSTM Model Based on TF-IDF and GloVe Word Embedding for Sentiment Analysis", *Applied Sciences*, vol. 11, no. 23, p. 11255.
- [22] Kim Y, 2014. "Convolutional Neural Networks for Sentence Classification", in *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp. 1746-1751, Doha, Qatar: Association for Computational Linguistics.
- [23] Kingma DP and Ba J, 2014. "Adam: A Method for Stochastic Optimization".
- [24] Koren Y, Bell R, and Volinsky C, 2009. "Matrix Factorization Techniques for Recommender Systems", *Computer*, vol. 42, no. 8, pp. 30-37.
- [25] LeCun Y *et al.*, 1989. "Backpropagation Applied to Handwritten Zip Code Recognition", *Neural Computation*, vol. 1, no. 4, pp. 541-551.
- [26] Liu G and Guo J, 2019. "Bidirectional LSTM with attention mechanism and convolutional layer for text classification", *Neurocomputing*, vol. 337, pp. 325-338.
- [27] Low YH, Yap W-S, and Tee YK, 2019. "Convolutional Neural Network-Based Collaborative Filtering for Recommendation Systems", Singapore, pp. 117-131: Springer Singapore.

- [28] Luo X, Zhou M, Xia Y, and Zhu Q, 2014. "**An Efficient Non-Negative Matrix-Factorization-Based Approach to Collaborative Filtering for Recommender Systems**", *IEEE Transactions on Industrial Informatics*, vol. 10, no. 2, pp. 1273-1284.
- [29] Luong M-T, Pham H, and Manning CD, 2015. "**Effective Approaches to Attention-based Neural Machine Translation**".
- [30] Masters D and Luschi C, 2018. "**Revisiting Small Batch Training for Deep Neural Networks**".
- [31] Mikolov T, Sutskever I, Chen K, Corrado G, and Dean J, 2013. "**Distributed Representations of Words and Phrases and their Compositionality**".
- [32] Ni J, Li J, and McAuley J, 2019. "**Justifying Recommendations using Distantly-Labeled Reviews and Fine-Grained Aspects**", in *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, pp. 188-197, Hong Kong, China: Association for Computational Linguistics.
- [33] Ong K, Ng K-W, and Haw S-C, 2021. "**Neural matrix factorization++ based recommendation system**", *F1000Research*, vol. 10, p. 1079.
- [34] Pennington J, Socher R, and Manning C, 2014. "**Glove: Global Vectors for Word Representation**", in *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp. 1532-1543, Doha, Qatar: Association for Computational Linguistics.
- [35] Roy PK, 2020. "**Multilayer Convolutional Neural Network to Filter Low Quality Content from Quora**", *Neural Processing Letters*, vol. 52, no. 1, pp. 805-821.

- [36] Rustam F, Mehmood A, Ahmad M, Ullah S, Khan DM, and Choi GS, 2020. "**Classification of Shopify App User Reviews Using Novel Multi Text Features**", *IEEE Access*, vol. 8, pp. 30234-30244.
- [37] Shan S, Ni H, Wang D, Chen G, and Sang X, "A Deep Learning Model with Attention-BiLSTM Networks Combining XGBoost Residual Correction for Short-Term Water Demand Forecast," In Review, preprint 2022, Accessed on: 2024-03-15 14:00:58.
- [38] Sharma R, Gopalani D, and Meena Y, 2017. "**Collaborative filtering-based recommender system: Approaches and research challenges**", in *2017 3rd International Conference on Computational Intelligence & Communication Technology (CICCT)*, pp. 1-6, Ghaziabad, India: IEEE.
- [39] Srivastava N, Hinton GE, Krizhevsky A, Sutskever I, and Salakhutdinov R, 2014. "**Dropout: a simple way to prevent neural networks from overfitting**", *J. Mach. Learn. Res.*, vol. 15, pp. 1929-1958.
- [40] Van Houdt G, Mosquera C, and Nápoles G, 2020. "**A review on the long short-term memory model**", *Artificial Intelligence Review*, vol. 53, no. 8, pp. 5929-5955.
- [41] Vaswani A *et al.*, 2017. "**Attention Is All You Need**".
- [42] Wang H *et al.*, 2021. "**A Stock Closing Price Prediction Model Based on CNN-BiSLSTM**", *Complexity*, vol. 2021, pp. 1-12.
- [43] Xiaoyan L, Raga RC, and Xuemei S, 2022. "**GloVe-CNN-BiLSTM Model for Sentiment Analysis on Text Reviews**", *Journal of Sensors*, vol. 2022, pp. 1-12.
- [44] Yao X, 2018. "**Attention-based BiLSTM Neural Networks for Sentiment Classification of Short Texts**", in *Proceedings of Information Science and Cloud Computing*

— *PoS(ISCC 2017)*, p. 014, Guangzhou, China: Sissa Medialab.

- [45] Zheng J and Zheng L, 2019. "A **Hybrid Bidirectional Recurrent Convolutional Neural Network Attention-Based Model for Text Classification**", *IEEE Access*, vol. 7, pp. 106673-106685.
- [46] Zhou P *et al.*, 2016. "Attention-Based Bidirectional Long Short-Term Memory Networks for Relation Classification", in *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers)*, pp. 207-212, Berlin, Germany: Association for Computational Linguistics.
- [47] Ziegler C-N, McNee SM, Konstan JA, and Lausen G, 2005. "Improving recommendation lists through topic diversification", in *Proceedings of the 14th international conference on World Wide Web - WWW '05*, p. 22, Chiba, Japan: ACM Press.

مقارنة دقة كشف الاختراقات الأمنية في مجموعتي البيانات NSL-KDD و UNSWNB15 باستخدام خوارزميات الذكاء الصناعي

م. ريم مالك إبراهيم

ماجستير في هندسة تكنولوجيا المعلومات، كلية هندسة تكنولوجيا المعلومات
والاتصالات، جامعة طرطوس

ملخص البحث: نظراً للتوسع السريع في استخدام تكنولوجيا الإنترنت والشبكات، وازدياد الطلب على أنظمة الشبكات، يعد تأمين البيانات الحساسة والخاصة وحماية الشبكات من الاختراقات أمراً بالغ الأهمية في الوقت الحالي. تواجه الشبكات الآلاف من الهجمات بمختلف أنواعها لذلك لا يكفي حل مشكلة الهجمات باستخدام برنامج فيروسي أو جدار حماية، إذ كان لابد من وجود تقنية فعالة للكشف عن عمليات الاختراق. يعد الكشف عن الهجمات في الشبكة وتحليلها بشكل دقيق أمر بالغ الأهمية لتشغيل النظام بأكمله وحماية الشبكة من الاختراقات التي قد تتعرض لها. تنوعت طرق كشف الاختراقات في الشبكات الحاسوبية، استخدمت بعض الأبحاث الأنظمة الخبيرة القائمة على القواعد Rule Based Expert System في عملية كشف الاختراقات ولكن أظهرت هذه الأنظمة نتائج غير دقيقة عند استخدامها مع مجموعات البيانات ذات عدد السجلات الكبير لذلك تم استخدام تقنيات تعلم الآلة في عملية كشف الهجمات، يمكن لتعلم الآلة اكتشاف الارتباط بين الميزات والفئات الموجودة في بيانات التدريب عن طريق استخلاص الميزات

مقارنة دقة كشف الاختراقات الأمنية في مجموعتي البيانات UNSWNB15 و NSL-KDD باستخدام خوارزميات الذكاء الصناعي

وتقليل الأبعاد ثم استخدام نتيجة هذه الطرق من أجل بناء نموذج قادر على التصنيف والتنبؤ.

تم في هذا البحث استخدام تقنيات تعلم الآلة والتعلم العميق لاكتشاف وتصنيف أنواع مختلفة من تدفقات مرور الشبكة. وانطلاقاً من أن اختيار الميزة يعد عامل مهم وأساسي في نجاح التصنيف تم استخدام معامل الارتباط والتباين لتحديد السمات الأكثر ارتباطاً بالهدف. تم استخدام أداة التعلم الآلي WEKA لتصنيف الهجمات بالإضافة إلى برنامج الماتلاب في عملية استخلاص الميزات.

توصل البحث إلى أن خوارزمية الغابة العشوائية RF أعطت أعلى دقة من أجل مجموعة البيانات UNSWNB15 وأن تقنية التعلم العميق MLP أعطت أعلى دقة تصنيف من أجل مجموعة البيانات NSL مقارنة مع تقنيات تعلم الآلة الأخرى. تعتمد خوارزمية RF على التعلم الجماعي إذ أنه عند استخدام نهج المجموعة بدلاً من نموذج شجرة القرار الفردي، تكون الدقة أعلى عادةً، كما أن MLP تسمح بتمثيل البيانات بشكل مرن من خلال دمج طبقات مخفية متعددة مما يحسن قدرتها التنبؤية. وفي هذا البحث أعطت كل من التقنيتين السابقتين نجاح ملحوظ في عملية التصنيف.

كلمات مفتاحية: كشف الاختراقات، تعلم الآلة، دقة الكشف، الشبكات الحاسوبية، قواعد البيانات، التصنيف.

Comparing the accuracy of detecting security breaches on the NSL–KDD and UNSWNB15 datasets using Artificial Intelligence algorithms

Eng.Reem Malek Ibrahim

Master of Information Technology Engineering

Department, Information and Communication Technology

Engineering, Tartous University

Abstract: Due to the rapid expansion in the use of Internet and network technology, and the increasing demand for network systems, securing sensitive and private data and protecting networks from hacking is extremely important at the present time. Networks face thousands of attacks of various types, so it is not enough to solve the problem of attacks using a virus program or a firewall, as there must be an effective technology to detect intrusions. Detecting and accurately analyzing attacks in the network is crucial to the operation of the entire system and protecting the network from intrusions that may be exposed to it. Methods for detecting intrusions in computer networks have varied. Some research has used rule-based expert systems in the process of detecting intrusions, but these systems showed inaccurate results when used with data sets with a large number of records, so machine learning techniques were used in the process of detecting attacks. Machine learning can discover the association between features and categories in training data by

extracting features and reducing dimensions, and then using the result of these methods to build a model capable of classification and prediction.

In this research, machine learning and deep learning techniques were used to detect and classify different types of network traffic flows. Based on the fact that feature selection is an important and fundamental factor in the success of classification, the correlation and variance coefficient were used to determine the features most closely related to the target. The machine learning tool, WEKA, was used to classify the attacks, in addition to the MATLAB program in the feature extraction process.

The research found that the RF random forest algorithm gave the highest accuracy for the UNSWNB15 dataset, and that the MLP deep learning technique gave the highest classification accuracy for the NSL dataset compared to other machine learning techniques. The RF algorithm relies on group learning, as when using the group approach instead Than a single decision tree model, the accuracy is usually higher, and MLP allows for flexible data representation by incorporating multiple hidden layers which improves its predictive power. In this research, both of the previous techniques gave remarkable success in the classification process.

Key words: Intrusions detection, Machine Learning, Detection Accuracy, Computer Networks, Databases, Classification.

1. مقدمة:

أدى التطور السريع في البيانات والتقنيات والأجهزة الذكية إلى زيادة الاعتماد على أجهزة الإنترنت بالإضافة إلى أن استخدام الإنترنت أصبح مهم جدا في العديد من مجالات الحياة، لذلك تعتبر سرية البيانات وتكاملها بالإضافة إلى أمن البيانات من المهام الأساسية التي يجب الحفاظ عليها في أي نظام يعتمد على الإنترنت.

بينما يحاول مسؤولو الشبكة تلبية الاحتياجات المتزايدة والمحافظة على أمن وأمان الشبكة يحاول المتسللون والبرامج الضارة من جهة أخرى التسلل إلى أنظمة الشبكات وتدمير المعلومات وتغييرها أو سرقتها.

ومع ازدياد طرق وتقنيات التسلل ومحاولات الاختراق كان لابد من تطوير أنظمة شبكات تحافظ على السرية والنزاهة وسهولة الاستخدام وإعطاء الأولوية لأمن المعلومات.

يمكن أن تكون عمليات تسجيل الدخول على الشبكات مشبوهة، إذ يمكن أن تكون على شكل برامج أو أجهزة أو مزيج من الاثنين معا.

يمكن اكتشاف الاختراقات الأمنية بعدة طرق منها تتبع واجهات الشبكات ومكوناتها للجهاز المستهدف ويتطلب ذلك إعدادات معينة متوافقة مع الخادم، تحتاج قواعد البيانات مع ازدياد عدد الهجمات ونوعها وانتشارها بشكل كبير إلى التحديث باستمرار كما أنها تتطلب خبرة متخصصة لاكتشاف عمليات التطفل وكشف الاختراقات الأمنية.

يمكن استخدام الذكاء الاصطناعي بسهولة لأن اكتشاف مثل هذه الحالات الشاذة يمثل مشكلة تصنيف. ولهذا السبب، تم إنشاء العديد من مجموعات البيانات للتحكم في كشف

التسلل [1]

من أهم مجموعات البيانات المستخدمة لهذا الغرض NSL-KDD, UNSW- NB15, KDDCUP99, CICICS2017، إذ تستخدم خوارزميات تعلم الآلة مع مجموعات البيانات هذه وتقدم أفكارا مهمة للغاية من أجل كشف الاختراقات ضمن قواعد البيانات.

من الممكن استخلاص الميزات واختيار الميزات المناسبة باستخدام عدة طرق منها خوارزميات التعلم الآلي أو طرق التصفية أو الأساليب القائمة على التعلم بالإضافة إلى أساليب التعلم الجماعي Ensemble learning methods.

تعتبر خوارزميات التعلم الجماعي Ensemble algorithm في التعلم الآلي تقنية تهدف إلى تحقيق أداء أعلى من خلال الجمع بين خوارزميات التعلم المتعددة، يمكنها الجمع بين تنبؤات خوارزميات التعلم المختلفة للحصول على نتائج أكثر دقة.

أحيانا يتفوق استخدام مزيج من التعلم الآلي وخوارزميات التعلم العميق على مشاكل التصنيف، وبالتالي من المهم في هذه المرحلة تحديد النماذج التي سيتم استخدامها ونقاط القوة والضعف في النماذج.

تم تصميم العديد من أنظمة كشف الاختراقات الحاسوبية من خلال الجمع بين مكونات الأجهزة والبرامج التي تكشف المحاولات الضارة أو الخبيثة في الشبكة إذ يمكن لهذه الأنظمة مراقبة جميع أنشطة الشبكة واكتشاف أي اختراق يمكن أن تتعرض له وإبلاغ مسؤول النظام بحدوث أي نشاط مشكوك به. [2]

عند تصميم أي نظام خاص بكشف الاختراقات هناك أربع خطوات أساسية يتم العمل عليها: [3]

1- جمع البيانات: يجب جمع معلومات عن حركة مرور شبكة مثل نوع حركة المرور والمضيف والبروتوكول المستخدم وتفاصيله والعديد من المعلومات الأخرى.

2- استخلاص الميزات: نحتاج إلى استخراج الميزات من الكميات الكبيرة من البيانات التي تم جمعها بحيث يتم استخدام الميزات التي نحتاجها فقط.

3- تحليل البيانات: الهدف من هذه المرحلة تحليل بيانات الميزات المختارة لمعرفة

ما إذا كانت البيانات تدل على هجوم أم أنها بيانات حركة مرور طبيعية.

4- تنفيذ الإجراء المطلوب وفقا للنتائج: يمكن إصدار إنذار أو تنبيه بواسطة مسؤول

الشبكة يخبر من خلاله بحصول هجوم ويحدد نوع هذا الهجوم كما يمكن

للأنظمة من المشاركة في السيطرة على الهجمات من خلال إغلاق منفذ الشبكة

وإيقاف العمليات ضمن الشبكة لحين حل المشكلة.

2. هدف البحث:

الهدف من هذا البحث هو كشف الاختراقات الأمنية في الشبكات الحاسوبية باستخدام

مجموعتين من مجموعات قواعد البيانات وذلك من خلال كشف السلوكيات غير الطبيعية

في الشبكات وتحديد نوع هذه السلوكيات، تكمن أهمية هذا البحث في عملية معالجة

مجموعات البيانات الأولية قبل البدء بالتصنيف واستخدام تقنيات استخلاص الميزات

بهدف زيادة دقة الكشف وتخفيف عبء العمل. بالإضافة إلى استخدام عدة تقنيات من

تقنيات تعلم الآلة والتعلم العميق من أجل مجموعتي البيانات بهدف المقارنة.

3. أهمية البحث:

أصبحت مسألة أمن الشبكات من أهم الأمور التي تشغل المؤسسات والشركات وخاصة مع

ازدياد معرفة وذكاء المهاجمين والمخترقين الذين تمكنوا من تنفيذ العديد من المحاولات الناجحة

لتعطيل الشبكات وإيقاف مواقع ويب مهمة.

تزداد أهمية أنظمة كشف الاختراقات مع ازدياد تطور الهجمات وخبرة المهاجمين، ومن هذا

المنطلق تكمن أهمية البحث، يقدم البحث مساهمة جديدة في مجال كشف الاختراقات الهدف

منها مقارنة خوارزميات تعلم الآلة التقليدية مع خوارزميات التعلم العميق.

مقارنة دقة كشف الاختراقات الأمنية في مجموعتي البيانات UNSWNB15 و NSL-KDD باستخدام خوارزميات الذكاء الصناعي

كما تم استخدام مجموعتين من البيانات المعيارية بهدف توسيع مجال المقارنة، تكمن أهمية البحث بشكل أساسي في مرحلة المعالجة الأولية لقاعدة البيانات التي انعكست إيجاباً على دقة الكشف.

زادت المعالجة الأولية للبيانات من دقة الكشف بالمقارنة مع الدراسات السابقة، وتعد دقة الكشف العالية عامل مهم جداً في مجال أمن الشبكات يزيد من موثوقية النظام ويجعله أكثر كفاءة في حال تعرضه لهجوم جديد أو متطور.

كما يمكن نمذجة النظام المقترح على شكل تطبيق برمجي واستخدامه مع مختلف قواعد البيانات من أجل أي مؤسسة أو شركة مما يساهم في حماية شبكات هذه المؤسسات وكشف الاختراقات في حال تعرضها للهجوم.

3. الدراسات المرجعية:

قامت العديد من الأبحاث باستخدام تقنيات الذكاء الاصطناعي في عملية كشف الاختراقات على مجموعات مختلفة من قواعد البيانات.

اقترح Gowthul et al نموذج DEHO قائم على SVM للكشف عن هجمات DDos في بيئة الحوسبة السحابية، تم فحص النموذج المقترح مع أربع مجموعات من البيانات وأظهرت النتائج أن النموذج المقترح في عملية كشف الاختراقات أعطى أعلى لأداء مقارنة بالطرق الأخرى. [4]

قام Mushtaq et al بتصميم بنية LSTM تعتمد على التشفير التلقائي على مرحلتين، وأظهرت النتائج أن النموذج المقترح يحوي أخطاء تتبؤ أقل مقارنة بتقنيات التعلم الآلي والتعلم العميق. [5]

قام كل من الباحثون Taher et al بكشف اختراقات الشبكة باستخدام الشبكات العصبونية تم تطبيق النموذج المقترح على مجموعة البيانات NSL-KDD، وتوصل البحث إلى أن الشبكات العصبونية أعطت أعلى دقة مقارنة مع تقنيات تعلم الآلة الأخرى. [6]

اقترح Injadat and Nassif إطار عمل ثنائي المراحل لكشف الاختراقات الأمنية في الشبكات، تم استخدام مجموعة البيانات 2017 CICID وخوارزمية أشجار القرار في عملية التصنيف، توصل البحث إلى أن الإطار المقترح باستخدام أشجار القرار أعطى دقة تصنيف عالية مقارنة بالدراسات الأخرى.[7]

قام Magan et al بمقارنة وتقييم أنظمة كشف الاختراقات الأمنية بالاعتماد على تقنيات تعلم الآلة، تم استخدام أشجار القرار في عملية التصنيف ومجموعة البيانات UGR'16، أعطت خوارزمية أشجار القرار دقة تصنيف عالية مقارنة بالتقنيات والدراسات السابقة.[8]

تم في هذا البحث مقارنة دقة كشف الاختراقات الأمنية باستخدام تقنيات الذكاء الصناعي، وتم تطبيق هذه التقنيات على مجموعتين من البيانات، تم استخدام أكبر عدد ممكن من التقنيات بهدف التجريب والمقارنة إذ تم استخدام تقنيات تعلم الآلة التقليدية بالإضافة إلى تقنيات التعلم العميق بهدف توسيع مجال المقارنة، اعتمدت الدراسات السابقة على عدد محدد من التقنيات وفي بعض الدراسات تم استخدام تقنية تصنيف واحدة، في حين أن البحث الحالي استخدم تقنيات تعلم الآلة التقليدية بالإضافة إلى تقنيتين من تقنيات التعلم العميق بهدف تحديد التقنية الأكثر دقة في الكشف، ويهدف المقارنة تم استخدام مجموعتين من البيانات على عكس أغلب الدراسات السابقة التي استخدمت مجموعة بيانات واحدة.

تفرد البحث الحالي في عملية المعالجة الأولية لقواعد البيانات إذ تم تطبيق عدة مراحل من المعالجة الأولية منها ترميز البيانات وحساب التباين ومعامل الارتباط على عكس الدراسات السابقة التي لم تتوسع في موضوع المعالجة الأولية، مما انعكس على دقة الكشف إذ توصل البحث إلى دقة كشف أعلى مقارنة بالدراسات السابقة التي لم تستخدم تقنيات معالجة أولية لقاعدة البيانات.

4. مواد وطرائق البحث:

تم في هذا البحث مقارنة دقة كشف الاختراقات باستخدام مجموعتين من البيانات تختلفان عن بعضهما البعض بالحجم وعدد السجلات، لكن كلاهما مستخدم في مجال أمن الشبكات ويضم حركة مرور لشبكة محلية.

1.4 مجموعة البيانات:

تم في هذا البحث استخدام مجموعتين من البيانات بهدف مقارنة دقة كشف الاختراقات الأمنية باستخدام عدة خوارزميات من تعلم الآلة والتعلم العميق.

قاعدتي البيانات المستخدمتين هما NSL-KDD و UNSWNB15 ، نستعرض فيما يلي كل منهما:

1.1.4 مجموعة البيانات: UNSWNB15

الهدف الرئيسي من مجموعة البيانات هو الحصول على مزيج من الأنشطة العادية الحقيقية وسلوك الهجوم.[2][3]

تتكون مجموعة البيانات هذه من حوالي 2 مليون سجل مع 49 ميزة، يمكن تقسيم مجموعة البيانات إلى طبيعية وغير طبيعية مندرجة ضمن ثمانية أنواع من الهجمات هي:

- 1- Fuzzer attacks: هي أنواع من الهجمات يتم الحصول عليها باستخدام البيانات التي تم إنشاؤها عشوائيا والتي تحاول اختراق البرنامج أو الشبكة.
- 2- التحليل analysis: يحوي أنواع مختلفة من الهجمات بما في ذلك البرامج النصية للويب لفحص المنافذ والبريد الإلكتروني الشبيه بالبريد العشوائي.
- 3- الباب الخلفي Backdoor: أسلوب يستخدم فيه المهاجمون بوابة نظام قانونية للحصول على وصول غير قانوني.

- 4 - Dos: في هذا النوع من الهجوم يكون فيه الخادم مشغول بحيث لا يتمكن مستخدمو النظام من الوصول إليها ويتسبب ذلك في تداخلها مع خدمات المضيف على الإنترنت.
- 5 - عمليات الاستغلال Exploits: هجمات تستغل الثغرة الأمنية الناجمة عن أي خطأ وتحاول تعطيل السلوك الموثوق به على الشبكة.
- 6 - Generic: يمكن تطبيق هذا النوع لحظر كلمات المرور ورمز التحقق والبريد وإرسال الرسائل.
- 7 - الاستطلاع reconnaissance: في هذا النوع من الهجمات يتم جمع معلومات أولية عن أي شبكة عامة أو مضيف مستهدف واستنادا للمعلومات التي تم جمعها يتم استخدامها للتسلل إلى المضيف أو الشبكات المستهدفة.
- 8 - Worms: هي أنواع تتجدد وتتزايد لتبدأ على جهاز كمبيوتر وتنتشر إلى جهاز آخر.

يبين الجدول (1) النسبة المئوية لعدد السجلات وتوزيعها على طول قاعدة البيانات:

الجدول (1): النسبة المئوية لعدد السجلات في مجموعة البيانات UNSWNB15

UNSWNB15	النسبة المئوية لعدد السجلات
Normal	48.66%
Backdoor	24.01%
Fuzzers	19.94%
Analysis	2.10%
Reconnaissance	2.21%
Dos	0.69%
Exploits	2.13%
Generic	0.12%
Worms	0.14%

مقارنة دقة كشف الاختراقات الأمنية في مجموعتي البيانات NSL-KDD و UNSWNB15 باستخدام خوارزميات الذكاء الصناعي

تحتوي مجموعة البيانات هذه على 47 سمة بالإضافة إلى سمتين تساعدان في عملية التصنيف هما:

Attack-cat: تعبر عن اسم الهجوم و label تأخذ قيمتين 0 في حال كان السجل طبيعي و 1 في حال كان السجل يعبر عن هجوم. من أجل عملية التصنيف يمكن استخدام إحدى السمتين أو كلاهما، في هذا البحث سيتم التصنيف في حال كان السجل طبيعي أم هجوم (تصنيف ثنائي) وبالتالي السمة الأكثر إفادة في بحثنا هي سمة ال label.

الجدول (2) يوضح سمات مجموعة البيانات UNSWNB15:

الجدول (2): سمات مجموعة البيانات UNSWNB15

S. No:	Attribute Name	S. No:	Attribute Name
1	srcip	26	res_bdy_len
2	sport	27	Sjit
3	dstip	28	Djit
4	dsport	29	Sstime
5	proto	30	Ltime
6	state	31	Sintpkt
7	dur	32	Dintpkt
8	sbytes	33	tcprrt
9	dbytes	34	synack
10	sttl	35	ackdat
11	dttl	36	is_sm_ips_ports
12	sloss	37	ct_state_ttl
13	dloss	38	ct_flw_http_mthd
14	service	39	is_ftp_login
15	Sload	40	ct_ftp_cmd
16	Dload	41	ct_srv_src
17	Spkts	42	ct_srv_dst
18	Dpkts	43	ct_dst_ltm
19	swin	44	ct_src_ltm
20	dwin	45	ct_src_dport_ltm
21	stcpb	46	ct_dst_sport_ltm
22	dtcpb	47	ct_dst_src_ltm
22	smeansz	48	attack_cat
24	dmeansz	49	Label
25	trans_depth		

2.1.4 مجموعة البيانات NSL-KDD:

هي مجموعة بيانات عالمية شائعة، يمكن للباحثين تطبيق عدة نماذج لكشف الاختراقات الأمنية في الشبكات عليها. تعد NSL-KDD مجموعة بيانات مشتقة من مجموعة البيانات الأكثر شهرة والعالمية KDD-99، تتكون من سجلات تم تحديدها من مجموعة بيانات kdd الكاملة.

بما أن nsf تحوي سجلات بيانات أقل من مجموعة البيانات kdd فهي غير مكلفة من حيث عبء العمل لاستخدامها في تدريب نماذج التعلم الآلي.[9]

من أهم مميزاتا هو عدم احتوائها على سجلات مكررة وبالتالي لن تتحاز المصنفات التي تتأثر بالسجلات المكررة نحوها.

تصنف السجلات ضمنها إلى طبيعية وغير طبيعية كما هو الحال في مجموعة البيانات UNSWNB15

تحوي NSL-KDD على 41 سمة، بالإضافة إلى سمة ال class التي تعبر عن سجل الاتصال هل هو سجل طبيعي أم سجل هجوم، فيما يلي الجدول (3) يوضح النسبة المئوية لعدد السجلات ضمن قاعدة البيانات هذه:

الجدول (3): النسبة المئوية لعدد السجلات في مجموعة البيانات NSL-KDD

NSL-KDD	النسبة المئوية لعدد السجلات
Normal	53.46%
Dos	36.46%
Probe	0.79%
R2L	9.25%
U2R	0.04%

تتدرج جميع السجلات في مجموعة البيانات ضمن 4 أنواع أساسية موضحة كما يلي:

[10]

- 1- هجوم حجب الخدمة (Dos): محاولة جعل الجهاز غير متاح لمستخدميه.
- 2- هجوم التحقق (probe): الهدف منه تعريض النظام إلى الخطر من خلال قيام المهاجم بتحديد نقاط الضعف ضمن الشبكة لاستغلالها فيما بعد.

مقارنة دقة كشف الاختراقات الأمنية في مجموعتي البيانات NSL-KDD و UNSWNB15 باستخدام خوارزميات الذكاء الصناعي

3- هجوم مستخدم إلى جذر (U2R): يبدأ المهاجم باستغلال النظام من خلال الحصول على امتيازات مستخدم رئيسي وباستخدام حساب طبيعي ضمن الشبكة.

4- هجوم بعيد إلى محلي (R2L): يستغل المهاجم ميزات جهاز محلي من خلال إرسال حزم عبر الإنترنت إلى جهاز لا يملك الوصول إليه بهدف استغلال نقاط ضعف الأجهزة.

تحتوي مجموعتي البيانات على 41 سمة بالإضافة إلى سمة ال class موضحة ضمن الجدول (4):

الجدول (4): سمات مجموعة البيانات NSL-KDD

F#	Feature name	F#	Feature name	F#	Feature name
F1	Duration	F15	Su attempted	F29	Same srv rate
F2	Protocol type	F16	Num root	F30	Diff srv rate
F3	Service	F17	Num file creations	F31	Srv diff host rate
F4	Flag	F18	Num shells	F32	Dst host count
F5	Source bytes	F19	Num access files	F33	Dst host srv count
F6	Destination bytes	F20	Num outbound cmds	F34	Dst host same srv rate
F7	Land	F21	Is host login	F35	Dst host diff srv rate
F8	Wrong fragment	F22	Is guest login	F36	Dst host same src port rate
F9	Urgent	F23	Count	F37	Dst host srv diff host rate
F10	Hot	F24	Srv count	F38	Dst host serror rate
F11	Number failed logins	F25	Serror rate	F39	Dst host srv serror rate
F12	Logged in	F26	Srv serror rate	F40	Dst host rerror rate
F13	Num compromised	F27	Rerror rate	F41	Dst host srv rerror rate
F14	Root shell	F28	Srv rerror rate	F42	Class label

2.4 استخلاص الميزات:

استخلاص الميزات هو عملية تقليل عدد متغيرات الدخل عند تطوير نموذج تنبؤي توفر لنا طرق استخلاص الميزات طريقة لتقليل وقت الحساب، وتحسين أداء التنبؤ، وفهم أفضل للبيانات في التعلم الآلي أو التعرف على الأنماط.

تعتبر الميزة خاصية فريدة قابلة للقياس للعملية التي تتم ملاحظتها، باستخدام مجموعة من الميزات يمكن لأي خوارزمية من خوارزميات التعلم الآلي إجراء التصنيف [11]

[12]

يتم اختيار طرق استخلاص الميزات بالاعتماد على نوع التعلم المستخدم سواء كان رقابي أم تعلم غير رقابي، بالإضافة إلى أنه يتم أخذ نوع البيانات بعين الاعتبار.

تصنف طرق استخلاص الميزات إلى عدة فئات لكل منها ميزاته واستخداماته.

في هذا البحث سيتم استخدام التباين ومعامل الارتباط للحصول على السمات الأكثر ارتباطاً بالهدف في كل من مجموعتي البيانات المستخدمتين.

✓ التباين هو أحد مقاييس مقياس التشتت الإحصائي بين القيم لعينة ما، يقيس مقدار تشتت القيم عن الوسط الحسابي وعن بعضها البعض. إذا كانت قيمة التباين كبيرة يعني ذلك أن القيم متباعدة عن بعضها البعض وعن الوسط الحسابي وفي المقابل إذا كانت قيمته صغيرة هذا يعني أن القيم متقاربة من بعضها البعض ومن الوسط الحسابي.

العلاقة الرياضية التي تعبر عن التباين

$$COV(x) = 1/n \sum_{i=0}^n (Xi - X)$$

حيث: X المتوسط الحسابي ل قيم X، n عدد العينات

✓ معامل الارتباط: هو مقياس للعلاقة الخطية بين اثنين أو أكثر من المتغيرات يمكن من خلاله التنبؤ بواحد من السمات من خلال السمة الأخرى. عند ارتباط متغيرين يمكن توقع أحدهما من الآخر وبالتالي إذا كانت السمات مترابطة يحتاج النموذج واحدة منهم فقط لأن السمة الثانية لا تضيف أي ميزات أو معلومات إضافية عن السمة الأولى.

يعبر عن معامل الارتباط بالعلاقة الرياضية التالية:

$$Corr (x, y) =Cov (x, y)/ax. ay$$

حيث ax هو الانحراف المعياري ل x ، الانحراف المعياري ل y ، $COV(x,y)$ التباين حيث أن الانحراف المعياري هو الجذر التربيعي للتباين.

يعد معامل الارتباط والتباين من أكثر التقنيات استخداما وخاصة فيما يتعلق بكشف الاختراقات الأمنية باستخدام تقنيات تعلم الآلة لما أبدت من دقة في الكشف وسرعة في الحساب وملائمة مع مصنفات تعلم الآلة.

3.4 خوارزميات تعلم الآلة والتعلم العميق:

يعد الذكاء الاصطناعي أحد فروع علوم الكمبيوتر الذي يهتم باستخدام تقنيات ذكية لإنجاز المهام التي تحتاج إلى الذكاء البشري لإتمامها، ومن أهم هذه التقنيات هي التعلم الآلي.

التعلم الآلي هو فرع من فروع الذكاء الاصطناعي الذي يسمح لأنظمة الكمبيوتر بالتعلم مباشرة من الأمثلة والبيانات والخبرة، يستخدم التعلم الآلي الخوارزميات المبرمجة التي تتلقى وتحلل بيانات الدخل للتنبؤ بقيم الخرج تتعلم هذه الخوارزميات وتحسن من عملياتها لتحسين الأداء وتطوير الذكاء مع مرور الوقت.[13]

فيما يلي بعض خوارزميات تعلم الآلة وشرح عن كل منها: [15] [14]

1- مصنف الجار الأقرب (KNN) K nearest Neighbor

تعد هذه الخوارزمية من خوارزميات تعلم الآلة الخاضعة للإشراف وهي بسيطة وسهلة التنفيذ وتستخدم لحل مشاكل التصنيف والانحدار يستند التصنيف باستخدام مصنف الجار الأقرب KNN إلى إيجاد عدد من عينات التدريب K الأقرب إلى عينة الاختبار، ثم تحديد الصنف الذي تنتمي إليه عينة الاختبار من خلال عملية الانتخاب والتي تتم بعدة طرق تعتمد إما مبدأ الأكثرية أو مبدأ المسافة الموزونة.

2- Random Forest: تعتبر خوارزمية تصنيف جماعي وخوارزمية انحدار

مناسبة لتجميع البيانات في فئات خلال مرحلة التدريب يتم إنشاء سلسلة من أشجار القرار التي يتم استخدامها بعد ذلك للتنبؤ بالفئة. في عملية الحساب يتم أخذ فئات جميع الأشجار الفردية بالاعتبار ويعتبر الصف الذي حصل على أعلى أصوات هو الناجح.

3- المصنف Naïve Bayes

يرتكز هذا المصنف إلى نظرية بيبز الاحتمالية Bayes' theorem القائمة على مبدأ الاحتمال الشرطي الذي يعمد لحساب احتمال وقوع أحد الأحداث الاحتمالية بناء على وقوع حدث آخر

4- أشجار القرار: Decision Tree

شجرة القرار هي بنية تشبه المخطط الانسيابي، حيث تمثل كل عقدة داخلية اختباراً على سمة، ويمثل كل فرع نتيجة الاختبار، وتمثل كل عقدة ورقة الفئة القرار المتخذ بعد حساب جميع السمات (. تمثل المسارات من الجذر إلى الورقة قواعد التصنيف تعتبر خوارزميات التعلم المعتمدة على الأشجار واحدة من أفضل طرق التعلم التي يتم الإشراف عليها بالإضافة إلى أن الأساليب المعتمدة على الشجرة تعطي نماذج تنبؤية للقرار بدقة عالية وثبات وسهولة في التفسير.

[16]


بالإضافة إلى خوارزميات التعلم الآلي التقليدية يمكن استخدام خوارزميات التعلم العميق لحل مشاكل التصنيف والتي سيتم توظيفها في هذا البحث في عملية كشف الاختراقات.

فيما يلي بعض خوارزميات التعلم العميق:

1- Multi-Layer Perception (MLP): تحوي الشبكة العصبية في هذه


الخوارزمية على وحدات مرتبة في طبقات في بنيتها الداخلية.

هذه الوحدات هي: طبقة الدخل وطبقة مخفية واحدة أو أكثر وطبقة الخرج. تقوم طبقة الدخل بنقل المدخلات إلى الطبقات التالية، كما تحوي العقد المخفية على توابع غير خطية بالإضافة إلى توابع خطية يمكن تمكينها عند الحاجة. بالنسبة لبنية MLP ثلاثي الطبقات ترتبط جميع المدخلات بشكل مباشر مع جميع المخرجات، يمكن توضيح بنية MLP كما في الشكل (1):



الشكل (1): بنية MLP

2- Long-Short-term Memory (LSTM): الذاكرة طويلة المدى تم تصميمها للتغلب على مشاكل التدفق العكسي للخطأ يمكن اعتبارها وحدة فرعية من أساليب التعلم الآلي. يمكن ل LSTM استخدام الذاكرة لتذكر المعلومات طويلة المدى ومراقبة السمات المختلفة للنص التي تتم معالجته حالياً. تتكون من خلية وبوابة دخل وبوابة خرج وبوابة النسيان Forget Gate، يمكن التعبير عن بوابة الخلية كذاكرة الشبكة التي تحمل المعلومات عبر الخلايا لأغراض التنبؤ. تقوم بوابة الدخل بتغيير وظيفة تحديث حالة الخلية، أما بوابة الخرج تقرر ما هو مدخل الخلية التالية كما أنها تستخدم في التنبؤ أما بوابة النسيان هي البوابة التي تقرر أي من المعلومات يجب الاحتفاظ بها أو نسيانها. فيما الهيكل المعماري ل LSTM موضحة بالشكل (2):



Forget Gate - Input Gate - Output Gate - Cell State

الشكل (2): الهيكل المعماري ل LSTM

4.4 تقييم الأداء:

إن قياس دقة التصنيف لا يكفي في حد ذاته لذلك سيتم حساب مؤشرات الأداء لكل فئة في مجموعة البيانات بناء على مصفوفة الارتباك (Confusion Matrix).

الجدول (5): مصفوفة الارتباك

Confusion Matrix	Predicted No	Predicted Yes	
Actual No	TN(True Negative)	FP(False Positive)	
Actual Yes	FN(False Negative)	TP(True Positive)	Recall
		Precision	Accuracy

تعد مصفوفة الارتباك من أهم الوسائل المستخدمة في تقييم المصنفات، إذ يتم تقييم المصنف من خلال قدرته على التصنيف الصحيح أي القدرة على تحديد نوع الصنف الذي تنتمي إليه العينة المدروسة.

وعند مقارنة نتيجة التصنيف مع الواقع الفعلي نجد أربع حالات مختلفة موضحة بالجدول (5):

- الإيجابيات الصحيحة (True Positive (TP): الحدث إيجابي وتم التنبؤ أن الحدث إيجابي. (صحيح)
- الإيجابيات الخاطئة (False Positive (FP): الحدث سلبى وتم التنبؤ أن الحدث إيجابي. (خطأ)
- السلبيات الخاطئة (False Negative (FN): الحدث إيجابي وتم التنبؤ أن الحدث سلبى. (خطأ)
- السلبيات الصحيحة (True Negative (TN): الحدث سلبى وتم التنبؤ أن الحدث سلبى. (الشواذ)

من خلال هذه الحالات يتم حساب القيم التالية:

1- الدقة Accuracy: المقياس الأكثر شيوعاً لتقييم المصنف، يقيم كامل الخوارزمية، يعطى بالعلاقة التالية:

$$Accuracy = \frac{TN + TP}{TN + TP + FN + FP}$$

2- Recall: يعبر عن النسبة المئوية الإيجابية من بين كل النتائج الإيجابية الفعلية، يعطى بالعلاقة التالية:

$$Recall = \frac{TP}{Total Actual Yes}$$

3- Precision: يعبر عن النسبة المئوية الإيجابية من بين كل النتائج الإيجابية المتوقعة، ويعطى بالعلاقة التالية:

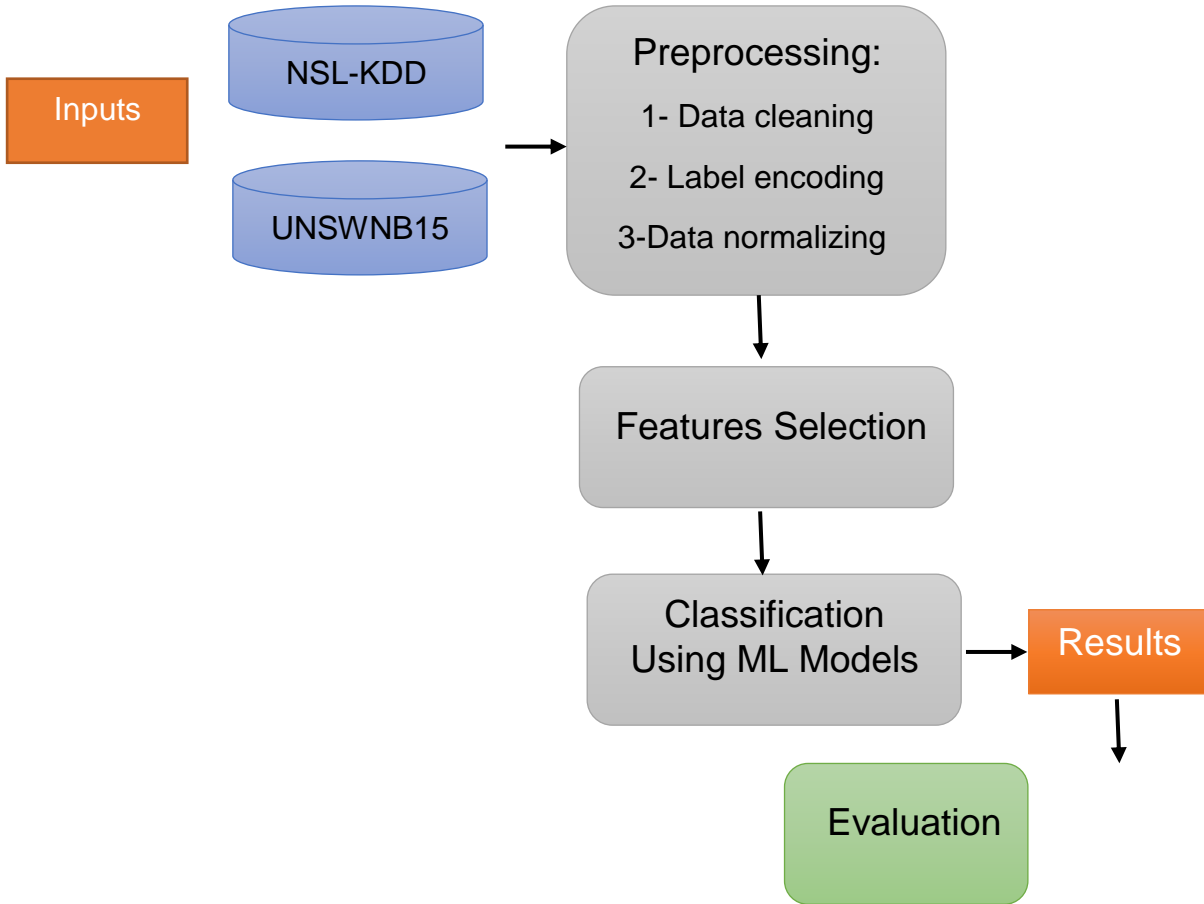
$$Precision = \frac{TP}{Total Predicted yes}$$

4- F1 Score: معيار يأخذ بالحسبان كل من السلبيات والإيجابيات الكاذبة، لذلك يعد مناسب مع مجموعات البيانات الغير متوازنة، يعطى بالعلاقة التالية:

$$F1\ Score = \frac{2 * Prec * Recall}{Prec + Recall}$$

5. المنهجية المقترحة:

فيما يلي مخطط صندوقي يبين مراحل العمل:



الشكل (3): المخطط الصندوقي لمراحل العمل

يظهر الشكل (3) مخطط مراحل العمل المتبعة في هذا البحث، إذ يتم في البداية تنظيف البيانات قبل تطبيق أي نوع من الخوارزميات لإصلاح عيوب قواعد البيانات بما

مقارنة دقة كشف الاختراقات الأمنية في مجموعتي البيانات UNSWNB15 و NSL-KDD باستخدام خوارزميات الذكاء الصناعي

فيها معالجة الأعمدة الفارغة وفقا لطبيعتها وتحويل القيم النصية إلى رقمية بهدف تقليل الحمل الحسابي.

عملية تطبيع البيانات عملية ضرورية يتم فيها قياس قيم السمات في النطاق [0,1] وتفيد في تقليل الحمل الحسابي.

تم استخدام مجموعتين من البيانات UNSWNB15 و NSL-Kdd في البداية تم استيراد ملف البيانات لكل من المجموعتين في برنامج الاكسل لاستعراض البيانات بشكل منظم وإجراء بعض عمليات التحليل والمعالجة البسيطة.

تمت معالجة النقص والسجلات المكررة لغاية عدم تأثر المصنف المستخدم بها أو الانحياز إليها.

في برنامج الاكسل تم ترميز أنواع الهجمات وتحويلها إلى رموز ليسهل تصنيفها باستخدام المصنفات المختارة.

عملية استخلاص الميزات عملية أساسية وخطوة مهمة في بناء نموذج الذكاء الاصطناعي والسبب الأساسي في ذلك أنه يلغي الأبعاد الناجمة عن مشكلة وجود العديد من الميزات كما أنه يقلل من عبء العمل مع العديد من الميزات ويحوطه إلى بنية بسيطة سهلة المعالجة. لذلك من الحكمة تبسيط نموذج العمل مع تأثير زيادة التعقيد ووقت التدريب والاختبار على دقة كشف الاختراقات.

تم اختيار السمات الأكثر صلة بالهدف باستخدام معامل الارتباط، تعد هاتان الخطوتان من خطوات المعالجة الأولية لقاعدة البيانات إذ تعد المعالجة الأولية مرحلة ضرورية قبل القيام بالتدريب الهدف منها تقليل زمن المعالجة وزمن التصنيف بالإضافة إلى زيادة دقة التصنيف كون السمات غير الهامة غالبا ما تؤثر على خوارزمية التصنيف.

بعد عملية اختيار الميزات تم استخدام خوارزميات التعلم الآلي والإدراك متعدد الطبقات Long-short Term و Multi-Layer perception وخوارزمية الذاكرة طويلة المدى

memory في عمليات التصنيف ثم مقارنة النتائج من حيث معايير التقييم مع الدراسات السابقة ومن أجل كل من مجموعتي البيانات.

تم ضبط المصنفات على قيم معينة قبل البدء بعملية التصنيف قابلة للتعديل تبعاً للنتائج والمقارنة، وفيما يلي الإعدادات المستخدمة في البحث:

عدد أشجار خوارزمية الغابة العشوائية = 120، معدل التعلم = 0.01، رقم تكرار الانحدار اللوجستي = 100 حالة، عتبة الحد الأقصى لشجرة القرار = افتراضية تابع تنشيط LSTM هو tanh

6. النتائج ومناقشتها:

نستعرض فيما يلي ملخص عن مراحل العمل والنتائج التي توصل إليها البحث، تم في هذا البحث مقارنة دقة كشف الاختراقات الأمنية في مجموعتي البيانات NSL-KDD و UNSWNB15 باستخدام خوارزميات تعلم الآلة والتعلم العميق.

تم استخدام برنامج Weka وبرنامج الماتلاب في بعض مراحل العمل في عملية التصنيف واستخلاص الميزات.

مرحلة المعالجة الأولية لمجموعتي البيانات:

تفيد المعالجة الأولية في برنامج الاكسل بتحويل البيانات إلى شكل موحد، وتعد هذه المرحلة ضرورة أساسية قبل القيام بعملية التصنيف الهدف منها تقليل زمن المعالجة وزمن التصنيف بالإضافة إلى زيادة دقة التصنيف كون السمات غير الهامة غالباً ما تؤثر على دقة التصنيف.

تضم هذه المرحلة ما يلي:

1- الترميز الرقمي لأنواع الهجمات:

إن تحويل أنواع الهجمات إلى ترميز رقمي يفيد في الحصول على نتائج التصنيف بشكل صحيح، تم في هذا البحث ترميز الهجمات على مرحلتين الأولى ترميز الهجمات الرئيسية والثانية ترميز الهجمات الفرعية بهدف تحديد نوع الهجوم بدقة.

تم في هذا البحث ترميز السجلات الطبيعية ب 0 وسجلات الهجوم ب 1 في كل من مجموعتي البيانات.

نوع التصنيف في هذا البحث ثنائي.

2- تخفيض السمات:

يمكن للسمات الإضافية أن تزيد من زمن الحساب كما يمكنها التأثير على دقة التصنيف وبالتالي عملية تخفيض السمات عملية ضرورية في مرحلة المعالجة الأولية، سنعمد في هذا البحث على علاقات رياضية تساعد في حساب الترابط بين السمات وإيجاد السمات غير المفيدة، تضم هذه المرحلة:

- إيجاد السمات غير المفيدة: من خلال حساب التباين، بهدف الاستغناء عن السمات ذات التباينات الصفرية أي السمات التي لم تبدي أي تغير على طول مجموعة البيانات ومن أجل كل السجلات.

تم ذلك بالاعتماد على علاقة التباين وفي بيئة الماتلاب من خلال التعليم البرمجية $var(i)$ حيث i هي العمود المعبر عن السمة المختارة في كل مرة.

من أجل مجموعة البيانات UNSWNB15 تم الحصول على نتائج التباين كما هو موضح بالجدول (6):

الجدول (6): نتائج التباين من أجل كل سمة في مجموعة البيانات UNSWNB15

Var(1)=0.3596	Var(2)= 1.5859	Var(3)=0.2516	Var(4)=4.357
Var(5)=0.5839	Var(6)=0.02548	Var(7)= 0.6987	Var(8)=0.0808
Var(9)=0.0171	Var(10)=0.0968	Var(11)=0.1202	Var(12)=0.8087
Var(13)=0.1322	Var(14)=5.2050	Var(15)=1.5889	Var(16)=5.2958
Var(17)=5.3695	Var(18)= 0.2547	Var(19)=0.2598	Var(20)=0.0256
Var(21)=0.2589	Var(22)=1.0259	Var(23)=0.0897	Var(24)=2.3698
Var(25)=8.3651	Var(26)=0.2203	Var(27)=0.5259	Var(28)=0.0023
Var(29)=0	Var(30)=0	Var(31)=0.0365	Var(32)=0.0027
Var(33)=5.2332	Var(34)=2.3658	Var(35)=0.3258	Var(36)=0.2581
Var(37)=0.6523	Var(38)=0.0968	Var(39)=0	Var(40)=0.0702
Var(41)=1.0056	Var(42)=0.1658	Var(43)=0.2365	Var(44)=0.8789
Var(45)=0.00364	Var(46)=1.2350	Var(47)=0.2587	

من الجدول (6) نجد أن السمات 29 و 30 و 39 لها تباين صفري، أي أن قيمتها لا تتغير على طول قاعدة البيانات وتأخذ قيمة واحدة من أجل كل السجلات وبالتالي يمكن الاستغناء عنها من أجل عملية التصنيف مما يقلل من الحمل الحسابي وزمن التصنيف.

السمة 29 تعبر عن زمن البدء والسمة 30 تعبر عن زمن الانتهاء والسمة 39 تأخذ قيمة 1 في حال تم تسجيل الدخول من قبل المستخدم و 0 فيما عدا ذلك. وبالتالي يصبح عدد السمات بعد هذه العملية 44 سمة بالإضافة إلى السمة label التي تعبر عن نوع السجل هل هو سجل طبيعي ام سجل هجوم. من أجل مجموعة البيانات NSL:

كانت نتائج مرحلة حساب التباين موضحة بالجدول (7):

مقارنة دقة كشف الاختراقات الأمنية في مجموعتي البيانات NSL-KDD و UNSWNB15 باستخدام خوارزميات الذكاء الصناعي

الجدول (7): نتائج التباين من أجل كل سمة في مجموعة البيانات NSL

Var(1)=1.98	Var(5)= 2.235	Var(6)=4.5026	Var(7)=3.1042
Var(8)=0.0203	Var(9)=0.0013	Var(10)= 0.862	Var(11)=0.0226
Var(12)=0.2467	Var(13)=52.8470	Var(14)=0.0024	Var(15)=4.4353
Var(16)=64.6676	Var(17)= 0.4581	Var(18)=0.0023	Var(19)=0.0046
Var(20)=0	Var(21)=0	Var(22)=0.0276	Var(23)=1.6522
Var(24)=7.9321	Var(25)=0.0872	Var(26)=0.0890	Var(27)=0.1732
Var(28)=0.1732	Var(29)=0.1702	Var(30)=0.0672	Var(31)=0.0643
Var(32)=8.84296	Var(33)=1.2496	Var(34)=0.1898	Var(35)=0.0487
Var(36)=0.938	Var(37)=0.0073	Var(38)=0.0746	Var(39)=0.0794
Var(40)=0.1499	Var(41)=0.1607		

من الجدول (7) نجد مما سبق نجد أن السمتين 20 و 21 لها تباين صفري أي لا تتغير قيمتها من أجل كل السجلات في قاعدة البيانات وبالتالي يمكن الاستغناء عنهما مما يقلل من حجم قاعدة البيانات دون التأثير على دقة التصنيف، وأصبح عدد السمات بعد هذه المرحلة 39 سمة.

السمة (20) هي عدد الأوامر الصادرة في جلسة بروتوكول ftp .

السمة (21) تأخذ قيمة 1 إذا تم تسجيل الدخول إلى hot list و 0 فيما عدا ذلك.

كلا السمتين قيمتهما صفر على طول قاعدة البيانات ومن أجل كل السجلات وبالتالي حذفهما لا يؤثر على عملية التصنيف.

- إيجاد السمات المرتبطة: من خلال حساب قيمة معامل الترابط لكل زوج من السمات، تتراوح قيم معامل الارتباط بين 1 و -1 وكلما كانت قيمته أقرب إلى الواحد كلما كان ارتباط زوج السمات أعلى، وبالتالي الهدف من هذه الخطوة

الاستغناء عن سمة واحدة من كل زوج من السمات ذات معامل الترابط الأعلى لأن وجود أحدهما يعوض عن وجود الأخرى.

بالاعتماد على علاقة معامل الارتباط الرياضية والتعليمية البرمجية $\text{corrcoef}(a,b)$ في بيئة الماتلاب تم حساب معامل الترابط لكل زوج من السمات.

فيما يلي جدول يوضح السمات الأكثر ارتباطاً أي السمات التي كان معامل الترابط لها أكبر من 0.9 لكل من مجموعتي البيانات:

من أجل مجموعة البيانات NSWBNB15:

كانت نتائج حساب معامل الترابط موضحة في الجدول (8):

الجدول (8): السمات الأكثر ارتباطاً في مجموعة البيانات UNSWNB15

$\text{Corrcoef}(10,31)=0.9015$	$\text{Corrcoef}(11,32)=0.9253$	$\text{Corrcoef}(8,17)=0.9906$
$\text{Corrcoef}(8,23)=0.9915$	$\text{Corrcoef}(9,18)=0.9934$	$\text{Corrcoef}(9,24)=0.9959$
$\text{Corrcoef}(44,45)=0.9742$	$\text{Corrcoef}(42,45)=0.9698$	$\text{Corrcoef}(41,46)=0.9936$
$\text{Corrcoef}(43,46)=0.9956$	$\text{Corrcoef}(46,47)=0.9041$	

من الجدول (8) نجد أن السمة 10 مرتبطة مع السمة 31، والسمة 11 مرتبطة مع السمة 32، والسمة 45 مرتبطة مع السمات 44 و42، أما السمة 46 مرتبطة مع السمات 43 و41 و47، والسمة 8 مرتبطة مع السمات 17 و23، والسمة 9 مرتبطة مع السمات 18 و24.

وبالتالي يمكن الاستغناء عن أحد السمات المرتبطة من كل زوج من السمات. إن السمة 45 تعبر عن عدد الاتصالات التي لها نفس عنوان المصدر ورقم خدمة الهدف نفسه، والسمة 44 تعبر عن عدد الاتصالات التي لها نفس عنوان

مقارنة دقة كشف الاختراقات الأمنية في مجموعتي البيانات UNSWNB15 و NSL-KDD باستخدام خوارزميات الذكاء الصناعي

المصدر، والسمة 42 تعبر عن عدد الاتصالات التي لها نفس رقم الخدمة في الهدف.

وبالتالي السمة 45 تمكنا من معرفة عدد الاتصالات التي لها نفس عنوان المصدر ورقم خدمة الهدف نفسه فهي تتوب عن السمتين 44 و 42 وبالتالي يمكن الاستغناء عنهم.

ونفس الأمر ينطبق على جميع السمات المرتبطة الأخرى.

بعد هذه العملية يصبح لدينا عدد السمات في مجموعة البيانات UNSWNB15 هو 33 بالإضافة إلى سمة ال label التي تعبر عن نوع السجل هل هو طبيعي أم غير طبيعي.

من أجل مجموعة البيانات NSL:

بعد حساب معامل الترابط بين السمات حصلنا على السمات الأكثر ترابطا كما هو موضح في الجدول (9):

الجدول (9): السمات الأكثر ارتباطا في مجموعة البيانات NSL

Corrcoef(13,16)=0.9960	Corrcoef(12,16)=0.9006	Corrcoef(25,26)=0.9664
Corrcoef(25,38)=0.9041	Corrcoef(25,39)=0.9008	Corrcoef(26,38)=0.9997
Corrcoef(26,39)=0.9210	Corrcoef(27,28)=0.9755	Corrcoef(27,40)=0.9852
Corrcoef(27,41)=0.9310	Corrcoef(28,40)=0.98	Corrcoef(28,41)=0.9478
Corrcoef(33,34)=0.9044	Corrcoef(38,39)=0.9450	Corrcoef(40,41)=0.9047

من الجدول (9) نجد أن السمة 16 من سمات قاعدة البيانات مرتبطة بشكل كبير مع السمتان 13,12 وبالتالي يمكن الاستغناء عن السمتين 12 و 13 والإبقاء على السمة 16، ونجد نفس الأمر من أجل السمة 25 التي تحل مكان السمات 26,38,39، والسمة 28 تحل مكان السمات 27,40,41 والسمة 33 تحل مكان ال سمة 34.

مثلا السمة 25 هي النسبة المئوية لعدد مرات إعادة الخطأ مرتبطة بشكل كبير مع السمة 26 التي تعبر عن النسبة المئوية لعدد الاتصالات لنفس الخدمة ونفس المضيف أي وجود قيمة لأحد هذه السماتان يغني عن وجود السمة الأخرى بمعرفة عدد مرات حصول فشل بالاتصال يمكننا من معرفة عدد مرات الاتصال الناجح، ونفس الأمر ينطبق على كل السمات المترابطة.

إذاً: نبقى على السمات الأربعة 16,25,28,33 ونحذف السمات التسعة المتبقية
13,12,26,38,39,27,40,41

وبالتالي يصبح عدد السمات بعد هذه المرحلة هو 30 سمة.

بعد عملية المعالجة الأولية للبيانات يمكن تطبيق خوارزميات التصنيف على مجموعتي البيانات ومقارنة النتائج تم تحميل مجموعتي البيانات كل منها على حدى على برنامج Weka .

فيما يلي جدول يوضح نتائج دقة الكشف وفق بارامترات مصفوفة الدقة من أجل كل من مجموعة البيانات.

من أجل UNSWNB15:

الجدول (10): بارامترات الأداء من أجل مجموعة البيانات UNSWNB15

UNSW	Accuracy	Recall	Precision	F1-score
NB	0.958	0.96	0.96	0.96
KNN	0.974	0.98	0.98	0.98
RF	0.997	0.99	0.99	0.99
DT	0.985	0.99	0.98	0.98
MLP	0.983	0.98	0.99	0.99
LSTM	0.987	0.97	0.99	0.98

مقارنة دقة كشف الاختراقات الأمنية في مجموعتي البيانات NSL-KDD و UNSWNB15 باستخدام خوارزميات الذكاء الصناعي

من الجدول (10) نجد أن نتائج التصنيف كانت عالية من أجل جميع الخوارزميات المستخدمة، لكن من أجل مجموعة البيانات UNSWNB15 أعطت تقنية الغابة العشوائية RF أعلى دقة وصلت إلى 99.7% وأعلى قيمة لبارامتر F1-score وصلت إلى 99%.

من أجل مجموعة البيانات NSL:

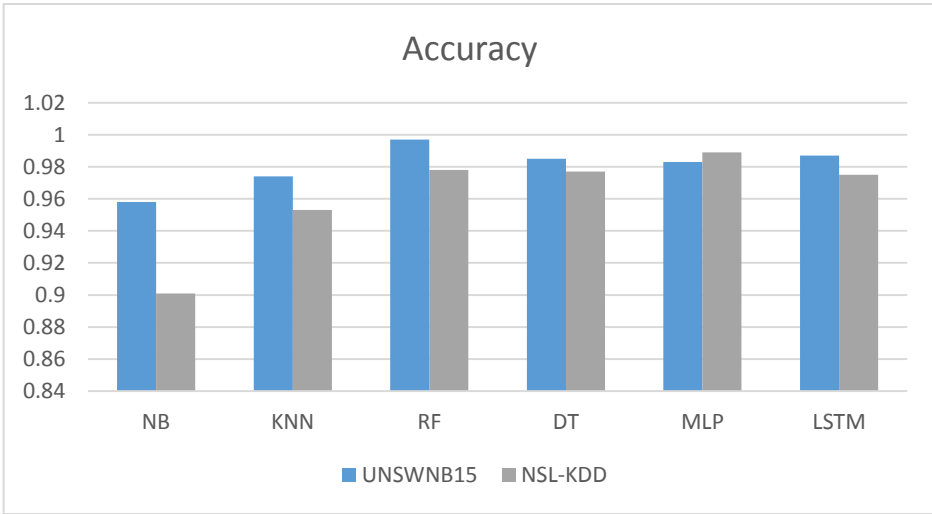
الجدول (11): بارامترات الأداء من أجل مجموعة البيانات NSL

NSL	Accuracy	Recall	Precision	F1-score
NB	0.901	0.90	0.90	0.90
KNN	0.953	0.95	0.95	0.95
RF	0.978	0.98	0.98	0.98
DT	0.977	0.98	0.98	0.98
MLP	0.989	0.99	0.98	0.99
LSTM	0.975	0.97	0.97	0.97


من الجدول (11) نجد أن تقنية التعلم العميق MLP أعطت أعلى القيم من أجل مجموعة الاختبار NSL-KDD وصلت دقة الكشف إلى 98.9% وكانت قيمة F1-score هي 99%.

كما أن نتائج التصنيف بشكل عام كانت عالية من أجل جميع خوارزميات التصنيف وأعطت قيم أعلى من 90%.

فيما يلي مخططات بيانية تظهر مقارنة بين بارامترات الأداء من أجل كل من مجموعتي البيانات:

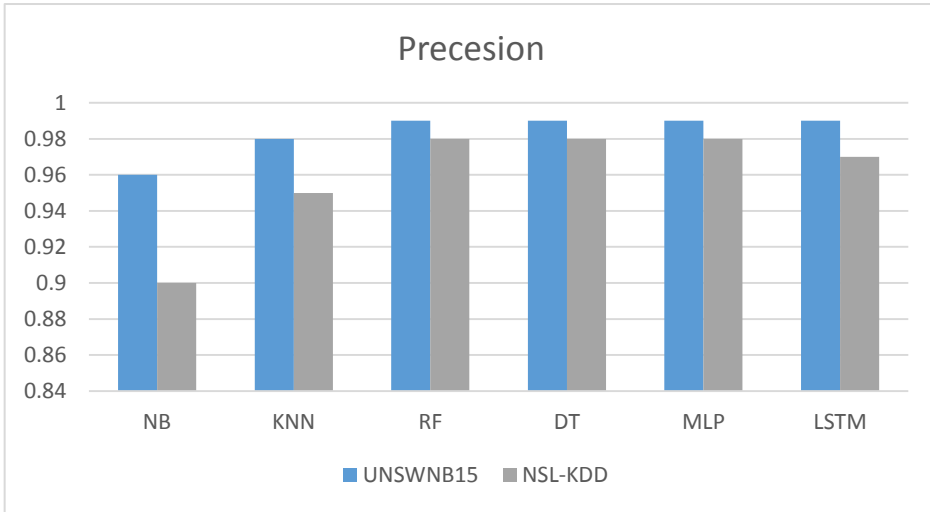


الشكل (4): مقارنة دقة الكشف




الشكل (5): مقارنة قيمة Recall

مقارنة دقة كشف الاختراقات الأمنية في مجموعتي البيانات UNSWNB15 و NSL-KDD باستخدام خوارزميات الذكاء الصناعي



الشكل (6): مقارنة قيمة Precision



الشكل (7): مقارنة قيمة F1-score

من الأشكال (4) (5) (6) (7) نجد أن دقة الكشف أعطت قيم عالية من أجل مجموعتي البيانات لكن كانت أعلى في مجموعة البيانات UNSWNB15 من أجل جميع الخوارزميات مقارنة مع نتائج دقة الكشف في مجموعة البيانات NSL، كما هو الحال من أجل بارامتر Precision و Recall.

أما من أجل F1-score كانت القيم أعلى منها من أجل مجموعة البيانات UNSWNB15 بالمقارنة مع مجموعة البيانات NSL من أجل جميع خوارزميات التصنيف ماعدا تقنية التعلم العميق MLP تساوت فيها القيمة من أجل مجموعتي البيانات ووصلت إلى 99%.

بالمقارنة مع عدة دراسات سابقة كانت النتائج موضحة كما في الجدول التالي:

الجدول (12): مقارنة مع الدراسات السابقة

دقة الكشف	خوارزمية التصنيف	قاعدة البيانات المستخدمة	الدراسة
95.00%	ANN	NSL-KDD	[6]
92.60%	DT	CICID 2017	[7]
94.00%	Random Forest	UGR'16	[8]
RF:99.7%	DT,RF,KNN,NB,MLP,LSTM	UNSWNB15	الدراسة
MLP: 98.9%	DT,RF,KNN,NB,MLP,LSTM	Nsl-Kdd	الحالية

من الجدول (12) نجد أن الدراسة الحالية أعطت دقة كشف أعلى بالمقارنة مع باقي الدراسات، قام الدراسة الأولى باستخدام الشبكات العصبونية في عملية التصنيف على قاعدة البيانات NSL وتوصلت إلى دقة كشف 95%، في حين أن الدراسة الثانية قامت

مقارنة دقة كشف الاختراقات الأمنية في مجموعتي البيانات NSL-KDD و UNSWNB15 باستخدام خوارزميات الذكاء الصناعي

باستخدام أشجار القرار فقط في عملية التصنيف واستخدمت مجموعة البيانات CICID وتوصلت إلى دقة كشف 92.60%، في حين أن الدراسة الثالثة استخدمت مجموعة البيانات UGR'16 مع خوارزمية Random Forest وتوصلت إلى دقة 94%.

قامت الدراسة الحالية باستخدام مجموعتين من البيانات UNSWNB15 و NSL واستخدمت عدة تقنيات تعلم آلة وتوصل البحث إلى أن RF أعطت أفضل دقة من أجل مجموعة البيانات UNSWNB15، في حين أن تقنية التعلم العميق MLP أعطت أعلى دقة كشف من أجل مجموعة البيانات NSL.

الاستنتاجات والتوصيات:

الاستنتاجات:

تم في هذا البحث كشف الاختراقات الأمنية في الشبكات الحاسوبية باستخدام عدة تقنيات من تقنيات تعلم الآلة والتعلم العميق ومقارنة النتائج، من خلال هذه الدراسة تم استنتاج ما يلي:

- أثبتت النتائج التي تم الحصول عليها من مجموعتين مختلفتين من البيانات نجاح خوارزميات التعلم الآلي في التصنيف، من أجل مجموعة البيانات NSL تم الحصول على أعلى دقة باستخدام تقنية التعلم العميق MLP في حين أعطت تقنية الغابة العشوائية RF أعلى دقة من أجل مجموعة البيانات UNSWNB15.
- جميع خوارزميات تعلم الآلة أعطت نتائج جيدة وعالية، كما أن هيكلية تقنيات التعلم العميق تمكنت من تقديم نتائج ناجحة، ومع ذلك يثبت هذا

البحث أن خوارزميات التعلم الآلي الكلاسيكية لا تزال بديل جيد لنماذج التعلم العميق.

- بفضل هذه البحث والدراسات السابقة يمكن تقديم خيار لاكتشاف نقاط الضعف والجوانب الضعيفة للخوارزميات وتطوير أنظمة هجينة جديدة وفقا للنتائج السابقة.

التوصيات:

في الدراسات المستقبلية يمكن تحسين مجموعات البيانات من حيث جعل الفئات المفقودة أكثر توازنا بالإضافة إلى تصميم نماذج جديدة باستخدام تقنيات تعلم آلة مختلفة.

كما أنه بالنظر إلى أن أنظمة الكشف عن الاختراقات تتعرض باستمرار للمزيد من الهجمات لابد من إجراء مثل هذه الدراسات على فترات زمنية قصيرة ومع مجموعات بيانات محدثة كما يمكن دعم هذه النماذج بواجهات ويب قادرة على العمل في الزمن الحقيقي.

جدول المصطلحات العلمية والمختصرات:

المعنى الكامل باللغة العربية	المعنى الكامل باللغة الانجليزية	المختصر
هجوم حجب الخدمة الموزع	Distributed Denial-of-Service	DDOS
هجوم حجب الخدمة	Denial-of-Service	DOS
أشجار القرار	Decision Tree	DT
السلبيات الخاطئة	False Negative	FN
الإيجابيات الخاطئة	False Positive	FP
مصنف الجار الأقرب	K nearest Neighbor	KNN
الذاكرة طويلة المدى	Long-Short-term Memory	LSTM
الشبكة العصبونية متعددة الطبقات	Multi-Layer Perception	MLP
هجوم بعيد الى محلي	Remote to Local	R2L
الغابة العشوائية	Random Forest	RF
السلبيات الصحيحة	True Negative	TN
الإيجابيات الصحيحة	True Positive	TP
هجوم مستخدم الى جذر	User To Root	U2R

المراجع:

- [1] Moualla.S, Khorzom.K, and Jafar.A,(2021). “Improving the Performance of Machine Learning–Based Network Intrusion Detection Systems on the UNSW–NB15 Dataset,” Comput Intell Neurosci, vol. 2021, pp. 5557577 .
- [2] Choudhary.S and Kesswani.N,(2020). “Analysis of KDD–Cup’99, NSL–KDD and UNSW–NB15 Datasets using Deep Learning in IoT,” Procedia Comput Sci, vol. 167, pp. 1561–1573.
- [3] Serinelli.B, Collen.A, and Nijdam.N,(2020), “Training Guidance with KDD Cup 1999 and NSL–KDD Data Sets of ANIDINR: Anomaly–Based Network Intrusion Detection System”, Procedia Comput Sci, vol. 175, pp. 560–565.
- [4] G. A. MM, J. N. K. S, U. M. R, and M. R. TF,(2022), “An efficient SVM based DEHO classifier to detect DDoS attack in cloud computing environment,” Computer Networks, vol. 215, p. 109138.

- [5] Mushtaq.E,Zameer.A,Umer.M, and Abbasi.A,(2022), “A two-stage intrusion detection system with autoencoder and LSTMs,” Appl Soft Comput, vol. 121, p. 108768.
- [6] K.A., Taher, B.M.Y., Jisan, and M.M. Rahman, (2019).“Network intrusion detection using supervised machine learning technique with feature selection,” In 2019 International conference on robotics, electrical and signal processing techniques, pp. 643–646.
- [7] Injadat.M, Moubayed.A, Nassif.A, Shami.A,(2020). “Multi-stage optimized machine learning framework for network intrusion detection,” IEEE Trans. Netw. Serv. Manag.
- [8] Magán–Carrión.R,Urda.D, Díaz–Cano.I, and Dorronsoro.B,(2020). “Towards a reliable comparison and evaluation of network intrusion detection systems based on machine learning approaches,” Applied Sciences, vol. 10, no. 5, p. 1775.
- [9] Choudhary.B and Kesswani.N,(2020). “Analysis of KDD–Cup’99, NSL–KDD and UNSW–NB15 Datasets using Deep

- Learning in IoT,” *Procedia Comput Sci*, vol. 167, pp. 1561–1573.
- [10] Cil.A, Yildiz.K, and Buldu.A,(2020). “Detection of DDoS attacks with feed forward based deep neural network model,” *Expert Syst Appl*, vol. 169, p. 114520.
- [11] Amaizu.G,Nwakanma.C, Bhardwaj.S, Lee.J, and Kim.D, (2021).“Composite and efficient DDoS attack detection framework for B5G networks,” *ComputerNetworks*,vol.188,p.107871.
- [12] Mushtaq.E, Zameer.A, Umer.M, and Abbasi.A,(2022). “A two-stage intrusion detection system with autoencoder and LSTMs,” *Appl Soft Comput*, vol. 121, p. 108768.
- [13] Basati.A and Faghih.M,(2022). “PDAE: Efficient network intrusion detection in IoT using parallel deep auto-encoders,” *Inf Sci (N Y)*, vol. 598, pp. 57–74.
- [14] Moualla.S, Khorzom.K, and Jafar.A,(2021). “Improving the Performance of Machine Learning-Based Network Intrusion Detection Systems on the UNSW-NB15 Dataset,” *Computational Intelligence and Neuroscience*, vol. 2021.

[15]Buyrukoğlu.S.(2021). “Promising cryptocurrency analysis using deep learning.” In 2021 5th International symposium on multidisciplinary studies and innovative technologies (ISMSIT),” pp. 372–376.

[16]TS.P and Shrinivasacharya.P,(2021). “Evaluating neural networks using Bi-Directional LSTM for network IDS (intrusion detection systems) in cyber security,” Global Transitions Proceedings, vol. 2, no. 2, pp. 448–454.