مجلة جامعة حمص

سلسلة العلوم الهندسية الميكانيكية والكهربائية والمعلوماتية

مجلة علمية محكمة دورية

المجلد 48 . العدد 6

1448 هـ - 2026 م

الأستاذ الدكتور طارق حسام الدين رئيس جامعة حمص **المدير المسؤول عن المجلة**

أ. د. وليد حمادة	**رئيس تحرير مجلة جامعة حمص للعلوم الإنسانية**
د.نعيمة عجيب	**رئيس تحرير مجلة جامعة حمص للعلوم الطبية والهندسية والأساسية والتطبيقية**

د.محمد فراس رمضان	عضو هيئة التحرير
د. مضر سعود	عضو هيئة التحرير
د. ممدوح عبارة	عضو هيئة التحرير
د. موفق تلاوي	عضو هيئة التحرير
د. طلال رزوق	عضو هيئة التحرير
د. أحمد الجاعور	عضو هيئة التحرير
د. الياس خلف	عضو هيئة التحرير
د. روعة الفقس	عضو هيئة التحرير
د. محمد الجاسم	عضو هيئة التحرير
د. خليل الحسن	عضو هيئة التحرير
د. هيثم حسن	عضو هيئة التحرير
د. أحمد حاج موسى	عضو هيئة التحرير

تهدف المجلة إلى نشر البحوث العلمية الأصيلة، ويمكن للراغبين في طلبها الاتصال بالعنوان التالي:

رئيس تحرير مجلة جامعة حمص

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

. هاتف / فاكس : 2138071 31 963 ++

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

. البريد الالكتروني : journal.homs-univ.edu.sy

ISSN: 1022-467X

شروط النشر في مجلة جامعة حمص

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.
- **اذا كان الباحث طالب دراسات عليا:**

يجب إرفاق قرار تسجيل الدكتوراه / ماجستير + كتاب من الدكتور المشرف بموافقته على النشر في المجلة.

- **اذا كان الباحث عضو هيئة تدريسية:**

يجب إرفاق قرار المجلس المختص بإنجاز البحث أو قرار قسم بالموافقة على اعتماده حسب الحال.

- **اذا 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.

- **اذا 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 بالنسـبة لكليات (الآداب – الاقتصـاد– 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 17.5×25 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

ـ كتابة النص Simplified Arabic قياس 13 عادي ـ 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 للنشـر في المجلة يدل ضـمناً على عدم نشـره 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 ـ الحرف الأول من الاسم تتبعه فاصلة ـ سنة النشر ـ وتتبعها معترضة (–) عنوان الكتاب ويوضع تحته خط وتتبعه نقطة ـ دار النشر وتتبعها فاصلة ـ 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:

ـــ بعد الكنية والاسم وسنة النشر يضاف عنوان البحث وتتبعه فاصلة، اسم المجلد ويوضع تحته خط وتتبعه فاصلة ـــ المجلد والعدد (كتابة مختزلة) وبعدها فاصلة ـــ 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 حمص

1. **دفع رسم نشر (600) ل.س ستمئة ليرة سورية عن كل بحث لكل باحث يريد نشره في مجلة جامعة البعث.**
2. **دفع رسم نشر (2000) ل.س الفا 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 (150) ل.س مئة وخمسون ليرة سورية رسم موافقة على النشر من كافة الباحثين.**

المحتوى

اسم البحث	اسم الباحث	الصفحة
تصميم نظام تحكم ذكي باستخدام المنطق العائم لضبط ضغط الغاز المورد إلى العنفة الغازية في معمل الغاز	د. م. أوس ناصيف عثمان	42-11
دراسة نمذجة و محاكاة المحرك التحريضي الثلاثي الطور و تحليل نتائج اختباراته باستخدام أدوات الذكاء الاصطناعي	د. م.تامر عبد الجليل شتور	38-43
تطوير نظام ذكي للكشف المبكر عن مرض التوحد	ريمان الحاج أحمد د. خالد عمر	68-39
تطوير خوارزمية لموازنة حمل الخوادم في بيئة الشبكات المعرفة برمجياً باستخدام التعلم الآلي	ميساء الضاهر د. ماهر عباس د. محسن عبود	101-69

تصميم نظام تحكم ذكي باستخدام المنطق العائم لضبط ضغط الغاز المورد إلى العنفة الغازية في معمل الغاز

الدكتور المهندس أوس ناصيف عثمان

الملخص

يُستخدم غاز الميثان والإيثان في المعامل الغازية ومحطات توليد الطاقة الكهربائية من أجل تحويل الطاقة الحرارية الناتجة عن حرق هذه المركبات إلى طاقة ميكانيكية ومنها لتوليد الكهرباء. يتم بشكل دائم في المعامل الغازية تطوير وتحديث دارات التحكم ومعالجة المشاكل التي تواجه المشغلين في أثناء عمليات التشغيل، الإقلاع، والإيقاف.

تستخدم العنفة الغازية في معمل غاز جنوب الوسطى لتوليد الطاقة الكهربائية اللازمة لتشغيل وحدات المعمل كأبراج التقطير، غرفة التحكم، نظام التحكم والمراقبة، نظام الاتصالات وغيرها من الوحدات الرئيسة والمساعدة واللازمة لضمان استمرار إنتاج الغاز ومعالجته.

يتميز التيار الكهربائي الذي تولّدُه العنفة الغازية بتردد محدد تعمل عليه جميع القطع الكهربائية في المعمل وفي حال وجود ذبذبات في التردد يؤدي ذلك إلى فصل المعدة وتوقفها عن العمل، لذا يعتبر من الأهمية القصوى تشغيل العنفة ومراقبتها والحفاظ على استقرارها. ويتم ذلك من خلال منظومة تحكم خاصة بالعنفة متصلة مع نظام التحكم والمراقبة الأساسي (DCS) في المعمل. من أهم الدارات التحكمية هي دارة التحكم بضغط الغاز الذي يغذي العنفة الغازية والذي يجب أن يكون (20 بار) وفي حال تفاوت قيم الضغط لفترات زمنية طويلة يؤدي ذلك إلى توقف العنفة عن العمل وخاصة في مرحلة الإقلاع.

تم في هذا البحث بناء نموذج رياضي لدارة التحكم بضغط الغاز المورد للعنفة الغازية ومحاكاة عمل صمام التحكم وإضافة متحكم تقليدي (PID) ومتحكم عائم Fuzzy–PI ومقارنة أداء كل منها.

الكلمات المفتاحية: العنفة الغازية، نظام التحكم بالضغط، النموذج الرياضي، التحكم العائم، PID, Fuzzy PI، MATLAB.

Design of an Intelligent Control System Using Fuzzy Logic to Regulate the Gas Pressure Supplied to the Gas Turbine in a Gas Processing Plant

Abstract

Methane and ethane gases are used in gas plants and electric power generation stations to convert the thermal energy resulting from the combustion of these compounds into mechanical energy, which is then used to generate electricity.

In gas plants, control systems are continuously developed and updated, and operational issues faced by operators during startup, shutdown, and normal operation are addressed.

The gas turbine at the South Central Gas Plant is used to generate the electrical energy required to operate the plant's units, such as distillation towers, the control room, the control and monitoring system, the communication system, and other main and auxiliary units necessary to ensure continuous gas production and processing.

The electrical current generated by the gas turbine operates at a specific frequency that powers all electrical equipment in the plant. Fluctuations in frequency can cause equipment to trip and cease operation. Therefore, operating, monitoring, and maintaining the stability of the turbine is of utmost importance. This is achieved through a dedicated turbine control system connected to the plant's main Distributed Control System (DCS).

One of the most critical control circuits is the gas pressure control circuit that supplies the gas turbine, which must be maintained at 20 bar. Prolonged deviations in pressure values can cause the turbine to shut down, especially during startup stage.

In this research, a mathematical model of the gas pressure control circuit for the gas turbine was constructed. The operation of the control valve was simulated, and both a conventional PID controller and a Fuzzy-PI controller were implemented and their performance compared.

Keywords: Gas turbine, pressure control system, mathematical model, fuzzy control, PID, Fuzzy PI, MATLAB.

1ـ مـقـــدمـــــــة:

تُعد معامل الغاز من المنشآت الصناعية الحيوية التي تتألف عادةً من عدة وحدات تشغيلية مترابطة، تعمل بشكل متكامل لضمان استمرارية الإنتاج وكفاءة المعالجة. ويُعتبر تأمين مصدر كهرباء موثوق لهذه الوحدات شرطًا أساسيًا للحفاظ على استقرار العمليات التشغيلية وضمان جودة المخرجات.

في المعمل موضوع هذا البحث، يتم تزويد جميع الوحدات بالطاقة الكهربائية عبر عنفة غازية رئيسية، الموضحة في الشكل (1)، والتي تُحوِّل الطاقة الحرارية الناتجة عن احتراق الغاز الطبيعي إلى طاقة ميكانيكية ثم كهربائية. وتتميز هذه المنظومة بقدرتها على توفير الكهرباء بشكل مباشر ومستمر، بما يتناسب مع متطلبات الأحمال الصناعية المختلفة.

تُغذَّى العنفة الغازية بالغاز الطبيعي عند ضغط محدد ومدروس، يضمن تحقيق الاستقرار في عملية الاحتراق وكفاءة تحويل الطاقة. إن التحكم في ضغط الغاز المغذي يُعد من العوامل الجوهرية التي تؤثر على أداء العنفة، حيث يرتبط بشكل مباشر بمستوى القدرة الكهربائية المنتجة، وبمدى موثوقية التزويد للطاقة داخل المعمل.

من هنا، تأتي أهمية دراسة العلاقة بين ضغط الغاز المغذي وأداء العنفة الغازية، وتأثير ذلك على استمرارية تزويد الوحدات المختلفة في المعمل بالكهرباء. إذ يُسهم هذا البحث في تقديم رؤية علمية حول كيفية تحسين كفاءة التشغيل وضمان الاعتمادية في منظومات توليد الطاقة داخل معامل الغاز.



الشكل (1) العنفة الغازية في معمل غاز الفرقلس

يتم تشغيل العنفة الغازية في المعمل عن طريق تزويدها بغاز طبيعي بضغط (20 بار)، إن عملية ضبط ضغط الغاز الداخل إلى العنفة ليست مجرد إجراء تشغيلي روتيني، بل هي شرط أساسي لنجاح مرحلة الإقلاع .ففي هذه المرحلة الحرجة، يجب أن يتم تخفيض الضغط من 40 بار إلى القيمة التشغيلية المثلى (20 بار) خلال زمن قصير جدًا لا يتجاوز بضع ثوانٍ. أي تأخير أو تجاوز في الضغط قد يؤدي إلى:

- فشل الإقلاع بسبب عدم استقرار اللهب داخل غرفة الاحتراق.
- توليد اهتزازات ميكانيكية تؤثر على شفرات العنفة.
- تفعيل أنظمة الحماية التلقائية وإيقاف التشغيل.
- خسائر تشغيلية وزمن توقف غير مرغوب فيه.

لذلك، فإن التحكم الدقيق والسريع في ضغط الغاز خلال مرحلة الإقلاع يُعد من أكثر المتطلبات حساسية في تشغيل العنفات الغازية، ويعتمد بشكل مباشر على أداء صمام التحكم بالضغط.

تشير التجارب العملية في معمل غاز جنوب الوسطى إلى أن استجابة صمام التحكم يجب أن تكون لحظية ومضبوطة، خاصة في مراحل الإقلاع والتحميل السريع، حيث يكون النظام في حالة غير مستقرة حراريًا وهيدروليكيًا.

يبين الشكل (2) خط الغاز المزود للعنفة الغازية ومركب عليه صمام التحكم بالضغط مع المقاييس الخاصة بالضغط.



الشكل (2) صمام التحكم بتدفق الغاز للعنفة مع منظومة قياس ضغط الغاز

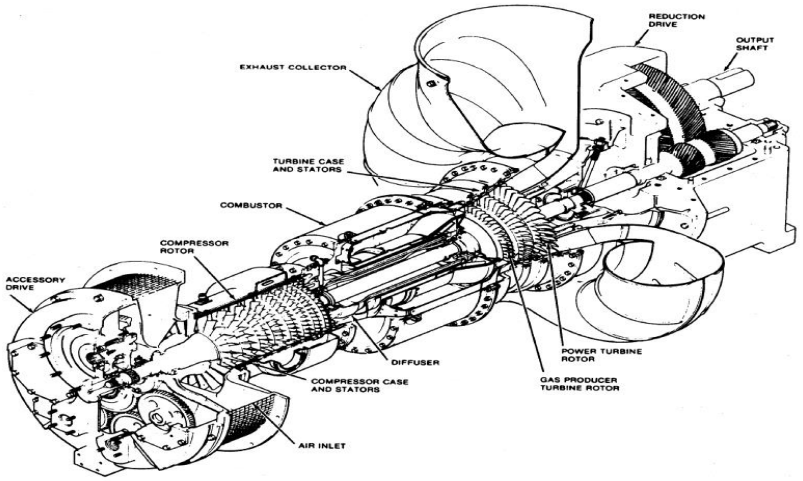
- **العنفة الغازية [5]:**

العنفة الغازية تعمل وفق دورة برايتون المفتوحة، حيث يتحول الهواء الخارجي إلى طاقة ميكانيكية عبر ثلاث مراحل رئيسية:

1. الضغط :يدخل الهواء من الجو عبر مدخل الهواء، ثم يُضغط بواسطة دوّار الضاغط والريش الثابتة داخل غلاف الضاغط، مما يرفع ضغطه ودرجة حرارته.

2. الاحتراق : يُرسل الهواء المضغوط إلى غرفة الاحتراق، حيث يُحقن الوقود (مثل الغاز الطبيعي) ويُشعل، مما ينتج غازات ذات حرارة وضغط عاليين.
3. التمدد وتوليد الطاقة :تمر الغازات الساخنة عبر دوّار عنفة إنتاج الغاز ثم دوّار عنفة القدرة، حيث تتمدد وتدير هذه الدوارات، مولدة طاقة ميكانيكية تُنقل عبر عمود الخرج إلى الحمل (مولد كهربائي أو مروحة دفع).

يبين الشكل (3) رسم توضيحي للعنفة الغازية [5]:



الشكل (3) رسم توضيحي لأجزاء العنفة الغازية

2-الدراسات المرجعية:

بمراجعة الأبحاث المنشورة في هذا المجال نجد أنه في **في عام 2026** قام الباحثون بتطوير استراتيجية تحكم هجين تعتمد على المنطق الضبابي بهدف تعزيز استقرار أنظمة القدرة الكهربائية متعددة المناطق، خصوصًا مع التوسع في استخدام مصادر الطاقة المتجددة. جاءت هذه الدراسة لمعالجة المشكلات الناتجة عن اللاخطية والاضطرابات السريعة التي تؤثر على دقة التحكم في التردد والجهد عند الاعتماد

على المتحكمات التقليدية. اعتمد الفريق البحثي على دمج متحكم PID متقدم مع نظام ضبابي من نوع Mamdani لتوفير استجابة أكثر ثباتًا تحت ظروف تشغيل متغيرة. وأظهرت نتائج المحاكاة أن النموذج الهجين قدّم أداءً أفضل من PID التقليدي من حيث سرعة الاستجابة وتقليل التجاوز وتحسين التخميد. وتشير النتائج إلى أن دمج المنطق الضبابي مع تقنيات التحكم الكلاسيكية يمكن أن يرفع موثوقية الشبكات الكهربائية الحديثة بشكل ملحوظ.[1]

عام (2025) قام الباحثون بإجراء دراسة لمنظومة التحكم بدرجة الحرارة في وحدة التكسير التحفيزي للسوائل في مصفاة النفط، حيث تم تصميم متحكمين للتحكم في درجة الحرارة في المفاعل (riser) وفي وحدة المجدد(ReGenerator) ، المتحكم الأول هو متحكم تقليدي من نوع PI والثاني متحكم ضبابي (Fuzzy Logic)ذو خمس مجموعات و25 قاعدة تحكم.

تم إجراء المحاكاة باستخدام برنامج MATLAB، وأظهرت النتائج تفوق المتحكم الضبابي بشكل واضح على المتحكم التقليدي من حيث تحقيق استجابة أكثر استقراراً وزمن الوصول إلى استقرار المنظومة أقصر وسرعة التعامل مع الاضطرابات.**[2]**

في عام (2024) ناقش الباحث تطوير خوارزمية PID ثنائية الدرجات للتحكم بسرعة وضغط التوربينات الغازية البحرية. ويوضح أن التحكم التقليدي فعال في ظروف التشغيل المستقرة، لكنه يحتاج إلى ضبط دقيق للمعاملات لتجنب التذبذبات أثناء الإقلاع أو تغير الحمل [3].

- **أُجري في عام (2021)** تصميم هياكل مختلفة لمتحكمات العنفات الغازية باستخدام المنطق العائم. حيث يوضح الباحث أن التحكم العائم أكثر مرونة منPID ، ويستجيب بسرعة للتغيرات المفاجئة في ضغط الغاز، مما يجعله مناسبًا جدًا لمراحل الإقلاع [4] .
- **قدم الباحث في عام (2023)** حلاً عملياً للتحكم التكيفي في ضغط الوقود خلال الإقلاع والتشغيل. يوضح البحث أن التحكم التكيفي يُقلل من احتمالية فشل الإقلاع أو توقف العنفة، عبر تعديل الضغط بشكل ديناميكي وفق ظروف التشغيل الفعلية [5] .
- **وفي عام (2018) ناقش الباحث** تطبيق متحكم PID قوي على نظام توربين غازي يعمل بخلايا وقود صلبة ويوضح أن التحكم التقليدي PID يمكنه التعامل مع تأخيرات زمنية وعدم يقين في الكسب، مما يجعله مناسبًا لضبط ضغط الغاز وتدفقه بشكل مستقر في ظروف تشغيل مختلفة.[6]

3-مشكلة البحث:

تؤكد الأبحاث منشورة أن أي تذبذب في ضغط الغاز خلال الإقلاع يؤدي إلى اضطراب في معدل التدفق والاحتراق، مما يمنع العنفة من الوصول إلى سرعة التشغيل المطلوبة. وبالتالي تظهر في مثل هذه المنظومات أهمية استخدام وتطوير أنظمة التحكم المستخدمة في عمليات الضبط.

حيث يتم حاليا استخدام متحكم تقليدي (PID) لضبط صمام التحكم بالضغط المركب على خط الغاز للعنفة الغازية، إلا أن استخدام المتحكم التقليدي أظهر بعض المشاكل التشغيلية المتكررة عند عملية إقلاع العنفة الغازية نتيجة المدة الزمنية اللازمة لضبط ضغط الغاز عند القيمة المثالية للإقلاع، وانطلاقاً من هذه المشكلة تم إجراء هذا البحث لدراسة تصميم نظام تحكم ذكي للتحكم بضغط الغاز خلال الفترة الزمنية المسموح بها دون حدوث مشاكل الإقلاع والتشغيل.

4-هدف البحث:

الهدف الرئيس للبحث هو **تصميم منظومة تحكم ذكية** باستخدام المنطق العائم لضبط ضغط الغاز المورد إلى العنفة الغازية خلال زمن قصير جدًا، بما يضمن:

- استقرار عملية الاحتراق.
- تحسين كفاءة تحويل الطاقة الحرارية إلى ميكانيكية.
- حماية المعدات من الإجهادات الميكانيكية والحرارية.
- تقليل زمن التوقف وتحقيق تشغيل آمن ومستمر.

كما يسعى البحث إلى **مقارنة أساليب التحكم التقليدي** (PID) مع **أساليب التحكم الحديثة** (Fuzzy control) في تنظيم ضغط الغاز، لتحديد الأنسب منها في ظروف التشغيل المختلفة، وخاصة في مرحلة الإقلاع التي تتطلب استجابة لحظية ومرونة عالية.

5-مواد وطرق البحث: تم إنجاز هذا البحث عن طريق استخدام برنامج MATLAB/Simulink لمحاكاة عمل منظومة التحكم بضغط الغاز الحقيقية في معمل غاز الفرقلس حيث تم محاكاة عمل كل من:

- **منظومة توريد الغاز** :خط أنابيب رئيسي يورد الغاز الطبيعي بضغط يصل إلى 40 بار.

- **صمام التحكم بالضغط** :(Gas Control Valve) صمام تخفيض ضغط عالي الكفاءة، مزود بمشغل كهربائي–ميكانيكي يسمح بالاستجابة السريعة لتغيرات الحمل.
- **أجهزة القياس:**
- حساسات ضغط (Pressure Transducers) لقياس الضغط قبل وبعد الصمام.
- حساسات تدفق (Flow Meters) لمراقبة معدل الغاز الداخل.
- نظام تسجيل بيانات (Data Acquisition System) لتخزين وتحليل القراءات الزمنية.
- **وحدة التحكم الإلكترونية:**(Controller)
- متحكم تقليدي (PID Controller) لضبط الضغط وفق معادلات التناسبية والتكاملية والتفاضلية.
- متحكم عائم (Fuzzy Logic Controller) يعتمد على قواعد منطقية للتعامل مع التغيرات المفاجئة واللاخطية.

6–خطة ومنهج البحث:

- **المرحلة الأولى: جمع البيانات التشغيلية**
  - تسجيل قيم الضغط الداخل (40 بار) والضغط المطلوب عند مدخل العنفة (20 بار).
  - مراقبة زمن الاستجابة خلال مرحلة الإقلاع، حيث يجب أن يتم تخفيض الضغط خلال ثوانٍ معدودة.
- **المرحلة الثانية: النمذجة الرياضية**
  - صياغة نموذج رياضي يمثل دارة تدفق الغاز إلى العنفة الغازية مع الصمام ومصدر الغاز المضغوط والحساسات مع إضافة المتحكم اللازم للتحكم بتدفق الغاز.
- **المرحلة الثالثة: المحاكاة والتحليل**
  - إدخال معاملات التحكم التقليدي(PID)
  - تصميم متحكم عائم (Fuzzy) للتحكم بضغط الغاز
  - تشغيل النموذج تحت ظروف مختلفة (إقلاع، حمل ثابت، تغير مفاجئ في أحد البارمترات).
  - تقييم أداء كل نظام تحكم من حيث:
  - زمن الاستجابة.(Response Time)
  - استقرار الضغط.(Stability)

- منع تجاوز الضغط المسموح به.(Overshoot)

- **المرحلة الرابعة: التحقق العملي:**
- مقارنة النتائج النظرية مع البيانات التشغيلية الحقيقية من معمل غاز جنوب الوسطى.

منهجية المقارنة:

- **التحكم التقليدي** :(PID) يُختبر في ظروف تشغيل مستقرة لمعرفة مدى دقته في ضبط الضغط.
- **التحكم العائم** :(Fuzzy) يُختبر في ظروف الإقلاع والتغيرات المفاجئة لمعرفة قدرته على التعامل مع اللاخطية.
- **بارمترات تقييم الأداء:** زمن الاستجابة، نسبة الخطأ، الاستقرار الديناميكي، وكفاءة التشغيل.

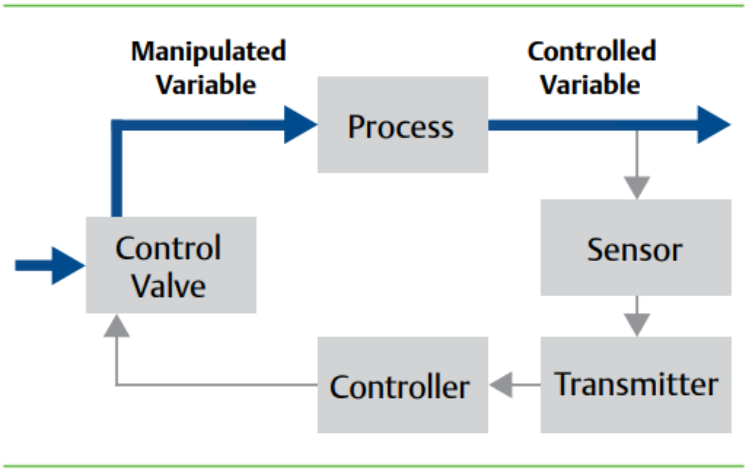
تُعد العنفات الغازية من نوع **MAN Turbo** من أهم المعدات التشغيلية في معامل الغاز، حيث تُستخدم لتوليد الطاقة الكهربائية اللازمة لتشغيل وحدات المعمل المختلفة مثل الضواغط، أنظمة التحكم، ووحدات المعالجة. تعتمد هذه العنفات على الغاز الطبيعي كمصدر رئيسي للطاقة، والذي يُورّد بضغط مرتفع يصل إلى 40 بار، ثم يُخفض عبر صمام تحكمي إلى الضغط التشغيلي المناسب (20 بار) قبل دخوله إلى غرفة الاحتراق.

- تتم عملية التشغيل وفق تسلسل محدد يبدأ بتوريد الغاز والهواء المضغوط إلى غرفة الاحتراق، حيث يحدث المزج والاشتعال لتوليد غازات ساخنة ذات ضغط وسرعة عاليين. هذه الغازات تمر عبر شفرات التوربين فتدفعها، محوّلة الطاقة الحرارية إلى طاقة ميكانيكية، ثم تُستخدم هذه الطاقة في تدوير عمود متصل بمولد كهربائي، لينتج الكهرباء اللازمة لتشغيل المعمل بشكل مستقل وموثوق [7].
- إن نجاح هذه العملية يعتمد بشكل مباشر على ضبط ضغط الغاز خلال مرحلة الإقلاع، حيث يجب أن يتم تخفيض الضغط بسرعة ودقة لتفادي أي تجاوز يؤدي إلى فشل الإقلاع أو اضطراب الاحتراق. لذلك، يُعتبر التحكم في ضغط الغاز عبر صمام التحكم التنظيمي من أهم عناصر ضمان التشغيل الآمن والكفء للعنفات الغازية [8].

الصمام التحكمي [9][10] :

تستخدم محطات المعالجة الحديثة شبكة واسعة من الحلقات التحكمية لضبط متغيرات العملية مثل الضغط، التدفق، المنسوب، ودرجة الحرارة ضمن نطاق تشغيل محدد يضمن جودة المنتج النهائي. هذه

الحلقات تتعرض لاضطرابات داخلية وخارجية تؤثر على المتغيرات المُراقبة، مما يستدعي وجود آلية فعّالة لإعادة المتغير إلى القيمة المرجعية المطلوبة.



الشكل (7) حلقة التحكم المغلقة المستخدمة في تنظيم ضغط الغاز في منظومة التشغيل.

يقوم المتحكم بمعالجة المعلومات القادمة من المستشعرات والمرسلات، ويحدد الاستراتيجية المناسبة للتعويض عن الاضطرابات. وعند اكتمال عملية القياس والمقارنة والحساب، يتولى عنصر التحكم النهائي تنفيذ هذه الاستراتيجية. يُعتبر صمام التحكم (Control Valve) أكثر عناصر التحكم النهائية شيوعًا في الصناعات، حيث يقوم بتنظيم تدفق المائع (غاز، بخار، ماء، أو مركبات كيميائية) لتعويض تأثير الاضطرابات والتي قد تكون زيادة أو نقصان في أحد البارمترات كالحرارة، الضغط، التدفق والحفاظ على المتغير المُراقب قريبًا من القيمة المرجعية.

- **آلية عمل الصمام التحكمي:**

يعتمد الصمام على فتحة متغيرة القطر، عند تقليص الفتحة :يزداد فقدان الضغط عبر الصمام، فينخفض الضغط عند المخرج، عند توسيع الفتحة يزداد التدفق ويرتفع الضغط عند المخرج. يتم التحكم بالفتحة عبر مشغل (Actuator) كهربائي أو هيدروليكي يستجيب لإشارة من وحدة التحكم. وبالتالي فإن جوهر عملية التحكم بضغط الغاز تعتمد على التحكم بتدفق الغاز المار عبر الصمام، أي أنه في

حالة زيادة فتحة الصمام وبالتالي زيادة تدفق الغاز يؤدي ذلك إلى انخفاض الضغط والعكس صحيح، أي أن العملية يجب أن تكون دقيقة بحيث يتم تزويد العنفة الغازية بكمية الغاز اللازمة للتشغيل مع الحفاظ على الضغط ضمن القيم المطلوبة. بناءً عليه ستكون عملية النمذجة الرياضية للحصول على معادلة تربط بين تدفق الغاز وضغط الغاز.

- **المرحلة الثانية: بناء النموذج الرياضي [11]:**

في حالتنا الخليط الغازي المستخدم هو غاز طبيعي وفق النسب التالية:

C1=96.24(غاز الميتان)

C2=2.66 (غاز الإيتان)

C3=0.81 (غاز البروبان)

C4=0.29 (غاز البوتان)

في حالة جريان الغاز عبر صمام تخفيض ضغط نميز نوعين من التدفق. التدفق الحرج والتدفق غير الحرج ولمعرفة نوع تدفق الغاز في حالتنا هذه:

- **درجة حرارة الغاز**

$$T=25℃ = 298.15\ (K)$$

خواص الخليط الغازي المار عبر الصمام وهو خليط غاز من غازات الإيتان والميتان والبروبان والبوتان وغازات أخرى بنسب ضئيلة وبالتالي لحساب **الوزن الجزيئي المتوسط** (Molecular Weight) لخليط غازي، نستخدم العلاقة التالية:

$$MW_{mix} = \sum y_i * MW_i \qquad [11].....(1)$$

حيث:

y_i الكسر المولي لكل مكوّن.

MW_i الوزن الجزيئي للمكوّن.

ونبين في الجدول أدناه قيم الكسر المولي و الوزن الجزيئي لكل مركب من مركبات الغاز الطبيعي:

جدول (1) نسب و قيم الكسر المولي والوزن الجزيئي لمركبات الغاز الطبيعي

المركب الغازي	النسبة المئوية في الخليط	الكسر المولي	الوزن الجزيئي
C1 (الميثان CH_4)	93.28 %	y=0.9328	MW=16.04 g/mol
C2 (الإيثان $C_2\ H_6$)	2.66%	y=0.0266	MW=30.07 g/mol

C3 (البروبان $C_3 H_8$)	0.81%	y=0.0081	MW=44.10 g/mol
C4 (البيوتان $C_4 H_{10}$)	0.29%	y=0.0029	MW=58.12 g/mol

$$MW_{mix} = 16.29 \frac{g}{mol}$$

- **الكثافة النسبية للخليط:**

$$G_{air} = 28.97$$

$$G_{g-mix} = \frac{\mathrm{MW}mix}{G_{air}} = \frac{16.29}{28.97} = 0.562 \quad \ldots\ldots\ldots(2)$$

- **النسبة الحرارية النوعية للخليط الغازي (K)**

باستخدام المتوسط التقريبي للنسبة الحرارية النوعية لكل غاز بحسب نسبه المولية في الخليط، يمكن إيجاد النسبة الحرارية النوعية للخليط الغازي وفق المعادلة:

$$\mathrm{k_{mix}} = \sum_{i=1}^{n} y_i \cdot \mathrm{k_i} \quad \ldots\ldots\ldots(3)$$

حيث:

$\mathrm{k_{mix}}$ النسبة الحرارية النوعية للخليط.

y_i الكسر المولي (أو الكتلي) للمكوّن

$\mathrm{k_i}$ النسبة الحرارية النوعية لكل غاز منفرد.

وبالتالي بالنسبة للخليط الغازي المستخدم، نبين في الجدول أدناه السعة الحرارية والسعة الحجمية من أجل حساب السعة الحرارية النوعية لكل مركب:

جدول (2) خصائص المركبات الغازية المكونة للخليط			
الغاز	السعة الحرارية	السعة الحجمية	السعة الحرارية النوعية
	(C_p) $[J/mol \cdot K]$	$(C_v)[J/mol \cdot K]$	(K)
CH_4	35.7	27.0	1.31
C_2 H_6	52.5	44.0	1.19
C_3 H_8	73.6	65.1	1.13
C_4 $H_{1\ 0}$	97.5	89.0	1.09

k_{mix}=1.292

- **حساب نسبة انخفاض الضغط x:**

من العلاقة:

$$x = \frac{\Delta P}{P_1} \quad \text{.....(4)}$$

$$\Delta P = P_1 - P_2 \quad \text{.....(5)}$$

$$\Delta P = 40 - 20 = 20\ bar$$

$$x = 0.5$$

- **حساب معامل النسبة الحرارية النوعية للخليط الغازي** F_k:

$$F_k = \frac{k}{1.4} \quad \text{.....(6)}$$

الرقم (1.4) هو القيمة المرجعية للهواء الجاف عند الظروف القياسية.

$$F_k = \frac{1.292}{1.4} = 0.9229$$

يمكن تحديد حالة التدفق من خلال حساب الجداء $F_k . x_t$ حيث أن x_t **معامل الضغط الحرج للصمام** وهو معامل خاص بكل صمام تحكمي، يُعطى عادةً من الشركة المصنّعة، ويعتمد على **تصميم الصمام**

للصمام التحكمي المستخدم يكون $x_t = 0.75$

$$F_k . x_t = 0.9229 \,.\, 0.75 = 0.6922 \qquad .....(7)$$

وبما أن: $x = 0.5 < 0.6922$

فإن التدفق الغازي عبر الصمام غير حرج والمعادلة المستخدمة في حالة تدفق غير حرج:[12]

$$Q = N_1 . c_v . f_b . P_1 . y . \sqrt{\frac{x}{G_g . T . z}} \qquad .....(8)$$

وفي حال استخدام التدفق الكتلي للغاز بدلا من التدفق الحجمي تصبح المعادلة السابقة بالشكل التالي:

$$m = N_6 . c_v . f_b . y \sqrt{x . P_1 . \rho_1} \qquad .....(9)$$

وبتصحيح المعادلة للحصول على الضغط بدلالة التدفق الحجمي:

$$P_2 = P_1 - \frac{1}{\rho_1} . \left(\frac{m}{N . c_v . f_b . y}\right)^2 \qquad .....(10)$$

حيث أن ρ_1 الكثافة النوعية للخليط الغازي عند الشروط الابتدائية(الضغط الأولي) و التي يمكن إيجادها من العلاقة:

$$\rho_1 = \frac{P_1 . Mw_{mix}}{Z . R . T_1} \qquad .....(11)$$

Z=0.94 للخليط الغازي من غازي الميتان والإيتان .

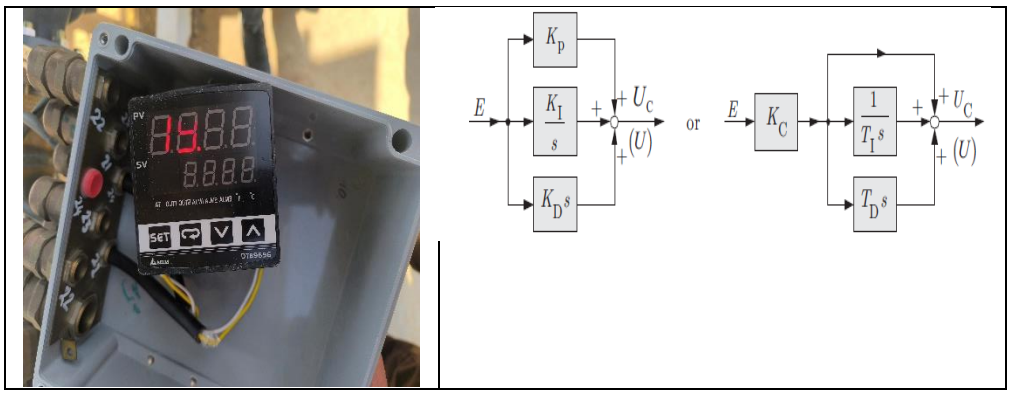
y : عامل التمدد، هو قيمة تعتمد على ضغط الخرج و بذلك فإن أفضل طريقة لإيجاد قيمة (y) هي طريقة التكرار العددية للحصول على قيمة توافق قيمة الضغط النهائي و نقوم باستخدام هذه القيمة في النموذج الرياضي

$$y = 1 - \frac{x}{3.F_k.x_t} \quad \text{.....(12)}$$

المرحلة الثالثة: محاكاة النموذج الرياضي:

المتحكم التقليدي (PID):[13]

يوضح الشكل (8) بنية المتحكم التناسبي التكاملي التفاضلي، والمتحكم التقليدي المستخدم في تنظيم ضغط الغاز للعنفة الغازية



الشكل (8) المخطط الصندوقي للمتحكم التناسبي التكاملي التفاضلي

معادلة عمل هذا المتحكم [13]:

$$u(t) = K_p e(t) + \frac{K_p}{T_i}\int_0^t e(t)dt + K_p T_d \frac{de(t)}{dt} \quad \text{..... (13)}$$

التابع التحويلي للمتحكم:

$$\frac{U(s)}{E(s)} = K_p\left[1+\frac{1}{T_i s}+T_d s\right] \quad \text{.....(14)}$$

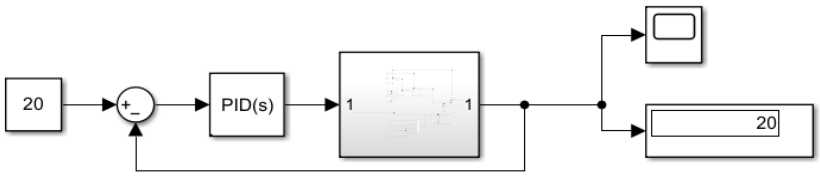
نطلق اسم متغيرات المتحكم على البارامترات المراد ضبطها أو توليفها حتى نحصل على استقرار النظام الصناعي المراد التحكم به وتكون بارامترات التوليف بالنسبة للمتحكم هي:

الكسب أو الربح: $K_c = K_P$

زمن الفعل التكاملي: $T_I = \frac{K_P}{K_I}$

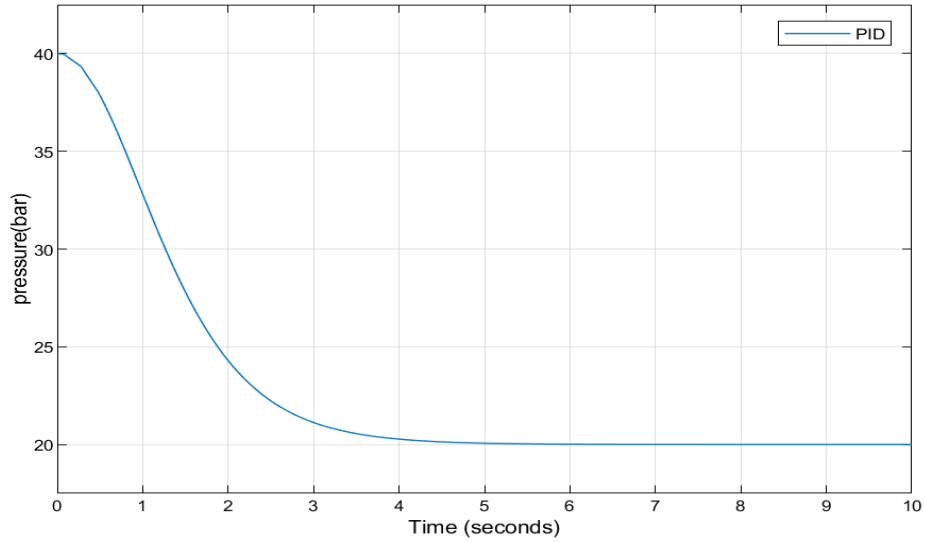
زمن الفعل التفاضلي: $T_D = \frac{K_D}{K_P}$

باستخدام برنامج MatLab، تم بناء نموذج رياضي يحاكي عمل الدارة التحكمية لصمام الغاز في بيئة Simulinkكما هو موضح في الشكل (9):



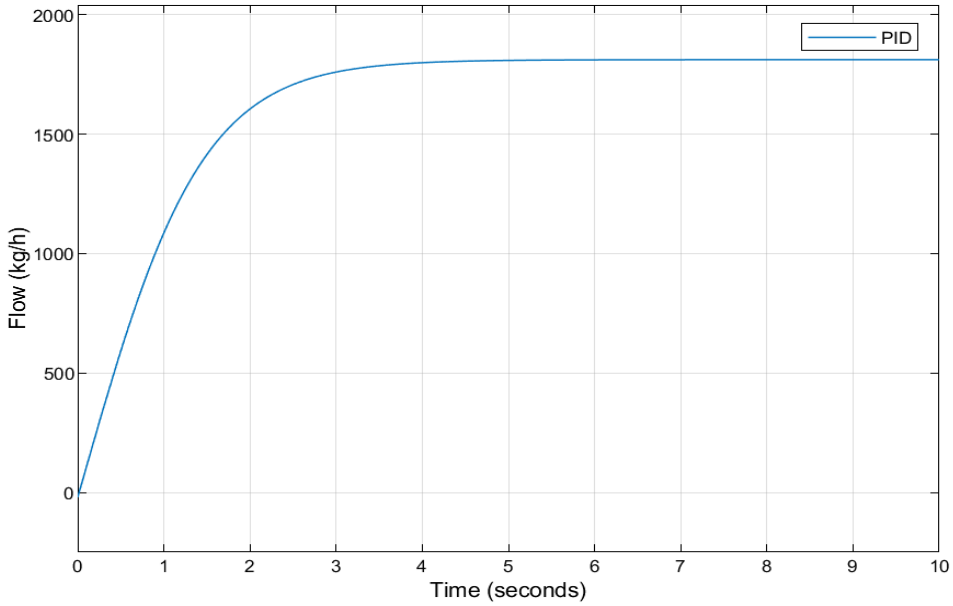
الشكل (9) النموذج الرياضي للدارة التحكمية لصمام تنظيم ضغط الغاز

ويبين الشكل (10) نتائج تطبيق المتحكم التقليدي على النموذج الرياضي:



الشكل (10) ضغط الغاز باستخدام المتحكم (PID)

ويبين الشكل (11) التدفق الكتلي عبر الصمام التحكمي باستخدام المتحكم التقليدي:



الشكل (11) التدفق الكتلي عبر الصمام التحكمي باستخدام المتحكم PID

- من الأشكال السابقة يتبين لنا أن المتحكم PID يعمل بكفاءة في تقليل الخطأ بسرعة دون تذبذب. والاستجابة تشير إلى تخميد جيد، أي أن النظام لا يعاني من اهتزازات أو تأرجح. ولا يوجد Overshoot إيجابي، بل هبوط مباشر نحو القيمة المرجوة، مما يناسب أنظمة الضغط التي تتطلب استقرارًا سريعًا

تحليل منحني الاستجابة:

- المرحلة الأولى (0–3 ثوانٍ):
  - استجابة هبوطية مفرطة التخميد أي أن المتحكم يطبّق جهدًا متوازنًا بين P و او Dلتقليل الخطأ دون تذبذب.
  - قوة التصحيح :متوسطة؛ لا يوجد قفزات حادة.
  - سلامة التشغيل :مناسبة للأنظمة الحساسة ميكانيكيًا.
- المرحلة الثانية (3–7 ثوانٍ):
  - اقتراب تدريجي من نقطة الضبط—المركّب التكاملي I يزيل الخطأ المتبقي ببطء.
  - مزايا :استقرار جيد، مقاومة للضجيج.
  - عيوب :زمن استقرار أطول، طاقة تصحيح موزعة على زمن أطول.
- المرحلة النهائية (7–10 ثوانٍ):
  - استقرار عند 20 بار—الخطأ في الحالة المستقرة يقارب الصفر.

القيم التشغيلية في المعمل:

تم في هذه المرحلة تجريب عدة قيم لبارامترات المتحكم التقليدي نبين بعضها في الجدول أدناه (الشكل (12):

الجدول (3) قيم تجريبية للمتحكم التقليدي (PID)				
الضغط النهائي	D	I	P	البارامتر
19.7	0	-55	1	تجربة (1)
19.6	0	-50	1	تجربة (2)
20	0	-63.3	1	تجربة (3)

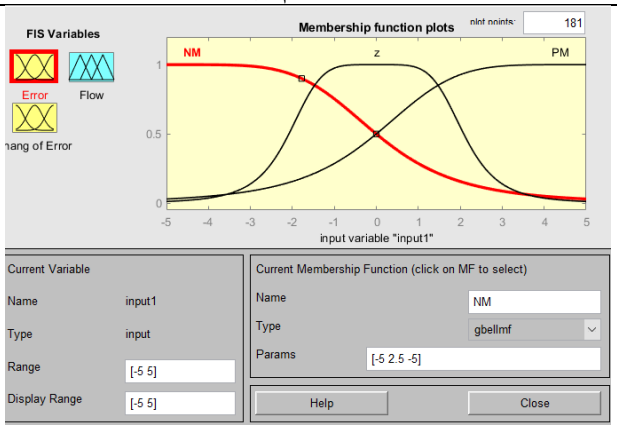
حيث أظهرت التجارب الأولية أن إضافة المركبة التفاضلية في متحكم PID أدّى إلى تضخيم الضوضاء وظهور اهتزازات غير مرغوبة في إشارة التحكم، مما انعكس سلباً على استقرار النظام، لذلك تم الاستغناء عن الجزء التفاضلي والاكتفاء بالمركبتين التناسبية والتكاملية لتحقيق استجابة أكثر ثباتًا ونعومة.



الشكل (12) قيم الضغط المقاسة وفق بارامترات مختلفة للمتحكم التقليدي

- **تصميم متحكم (Fuzzy-Pi) للتحكم بضغط الغاز:**

تم تحديد مداخل المتحكم بأنها الخطأ $(e(t))$ (الفرق بين القيمة المرجعية والقيمة الناتجة للضغط) بمجال عددي [-5,5] وتغير الخطأ ($\Delta(t)$) بمجال عددي [-5,5] والخرج (إشارة التحكم $u(t)$) هو تدفق الغاز المار عبر الصمام وبمجال عددي [-5,5]، وتم اعتماد متحكم عائم بثلاث توابع انتماء من نوع (g_ball) كما هو موضح في الشكل (13).



الشكل (13) توابع انتماء من شكل (**g_ball**)

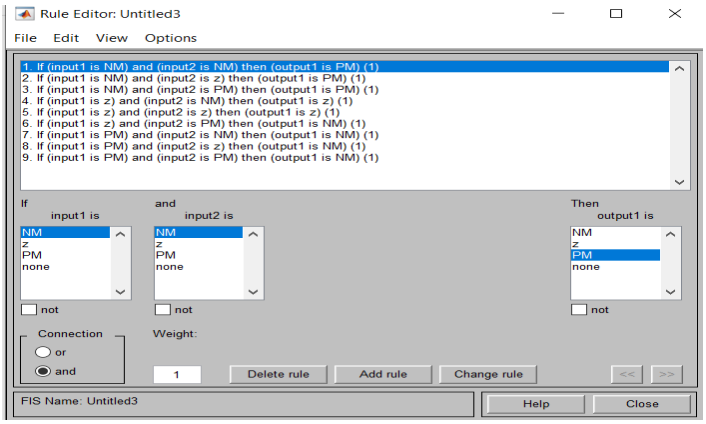
تحتاج عملية تصميم قواعد المتحكم العائم إلى معرفة جيدة بالعملية التشغيلية المراد التحكم بها، فالقواعد تمثل خبرة المراقب أو المشغل في صياغة ردود فعل النظام تجاه الحالات المختلفة[14] ، فمثلا في حالتنا هذه في حال كان الخطأ موجب وبالتالي فإن الضغط بعد عملية التحكم أصغر من القيمة المرجعية وبالتالي نحتاج إلى زيادة التدفق لتعديل القيمة ومن هذا الأساس تم بناء تسع قواعد للمتحكم المصمم **كما هو موضح في الجدول أدناه:**

جدول قواعد الخبرة للمتحكم الضبابي			
E(t) / $\Delta(t)$	**NM**	**Zero**	**PM**
NM	PM	Zero	NM
Zero	PM	Zero	NM
PM	PM	NM	NM

يمثّل العمود الأول في الجدول القيمَ اللغوية لتغيّر الخطأ، بينما يمثّل الصفّ الأول القيمَ اللغوية للخطأ نفسه. ويعبّر كل عنصر داخل الجدول عن القيمة اللغوية لخرج المتحكم الناتجة عن تقاطع قيمة الخطأ مع قيمة تغيّر الخطأ، كما يمكننا كتابة القواعد بطريقة أخرى، فنكتب القاعدة الأولى كالتالي

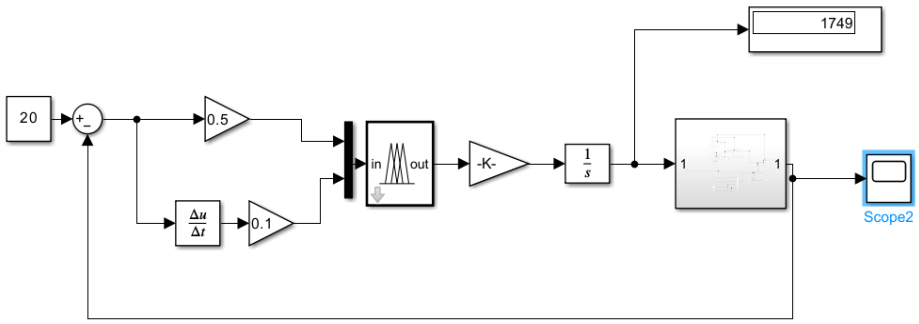
1- إذا كان الخطأ (دخل المتحكم الأول) سالب وتغيير الخطأ (دخل المتحكم الثاني) سالب فإن خرج المتحكم (إشارة التحكم) ستكون موجبة

ويوضح الشكل (14) قواعد الخبرة التي تم اعتمادها لتصميم المتحكم:



الشكل (14) قواعد الخبرة المستخدم في تصميم المتحكم العائم

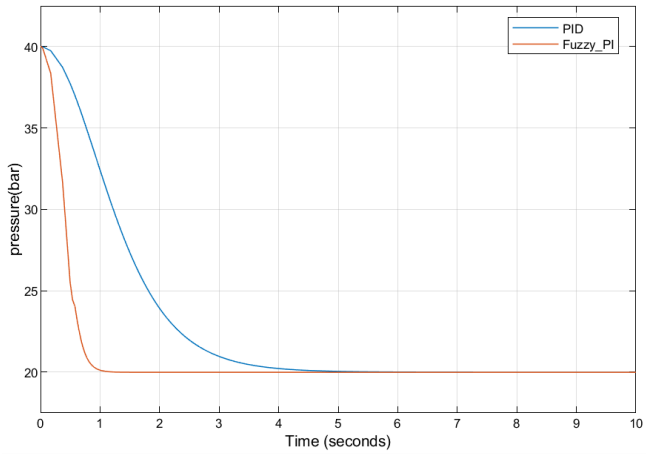
ويبين الشكل (15) محاكاة النموذج الرياضي للصمام التحكم باستخدام متحكم Fuzzy_PI:



الشكل (15) المتحكم العام Fuzzy_PI

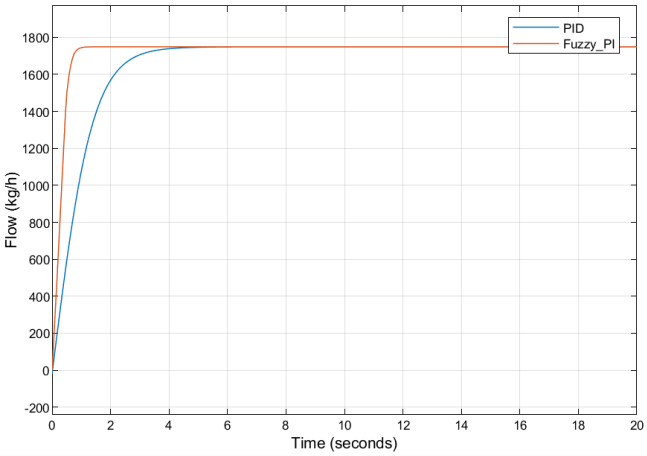
المقارنة:

أولاً: الحالة الأولى: التحكم بضغط الغاز دون وجود اضطراب: يبين الشكل (16) نتائج تطبيق كل من المتحكم التقليدي والمتحكم العائم:



الشكل (16) ضغط الغاز باستخدام المتحكم PID والمتحكم Fuzzy_PI

كما يبين الشكل (17) مقارنة بين تدفق الغاز في حالة استخدام متحكم تقليدي وفي حالة استخدام متحكم (Fuzzy_PI)



الشكل (17) تدفق الغاز باستخدام المتحكم PID والمتحكم Fuzzy_PI

تحليل منحنى الاستجابة:

- **المرحلة الأولى (0–1 ثانية):**
- هبوط حاد جدًا إلى نقطة الضبط—قواعد المنطق الضبابي تولّد جهد تصحيح كبير عند الخطأ العالي، مع كبح ذكي قرب نقطة الضبط.
- مزايا :زمن صعود شبه لحظي، تقليل الخطأ التكاملي بسرعة.
- مخاطر محتملة :إجهاد أعلى على المشغّل (Valve/Actuator) إن لم تُضبط حدود السرعة/التشبع.
- **المرحلة الثانية (1–2 ثانية):**
- تثبيت سريع دون تذبذب—المنطق الضبابي يخفّض الكسب تلقائيًا قرب الهدف.
- مزايا :عدم وجودOvershoot ، استقرار جيد.
- حساسية :قد يحتاج مرشحات للقياس إذا كان الضجيج عاليًا.
- **المرحلة النهائية (~2–10 ثوانٍ) :**
- ثبات عند 20 بار—الخطأ يقارب الصفر، لا انحرافات مرئية.
- مؤشر الأداء IAE/ITAE :منخفضان جدًا مقارنة بـ.PID

ونبين في الجدول (4) قيم مؤشرات الأداء لكل متحكم:

controller	RMSE	IAE	ITAE
PID	6.0901	27.6107	26.1743
Fuzzy	3.5307	8.3482	2.3137

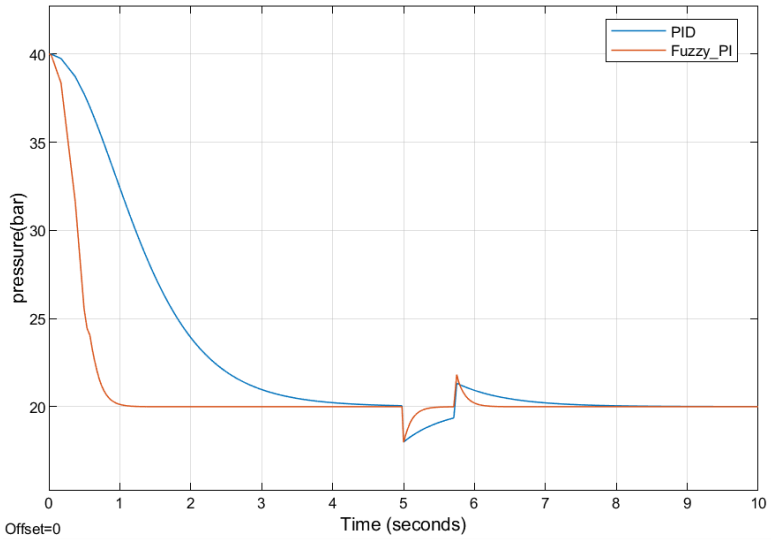
مقارنة الخصائص الأساسية للاستجابة مبينة في الجدول (5):

الجدول (5) الخصائص الأساسية للاستجابة لكل متحكم		
الخاصية	Fuzzy PI	PID
زمن الوصول إلى 20 بار	0.8–1.2 ثانية (هبوط سريع جدا)	3–7 ثوان (هبوط تدريجي)
زمن الاستقرار (Settling time)	1–2 ثانية	7–8ثوان

التذبذب/الاهتزاز	معدوم–استجابة حادة ومستقرة	معدوم تقريبًا–استجابة مفرطة التخميد
تجاوز القيمة(Overshoot)	لا يوجد تجاوز، تثبيت سريع	لا يوجد تجاوز إيجابي، هبوط مباشر
الخطأ في الحالة المستقرة	يقارب الصفر عند 20 بار	يقارب الصفر عند 20 بار
نعومة الإشارة	حادة وسريعة جدا	ناعمة لكن بطيئة
حساسية الضجيج	قد تكون أعلى إن لم تُرشّح الإشارة	أقل حساسية بسبب البطء

ثانياً: الحالة الثانية: التحكم بضغط الغاز في حالة وجود اضطراب:

قمنا بإجراء دراسة حالة وجود اضطراب يتمثل بزيادة مفاجئة بدرجة حرارة الغاز الوارد إلى العنفة الغازية ناتج عن ضعف في أداء المبادل الحراري الرئيس بزيادة مقدارها (30 k) عند زمن (t=5) من زمن المحاكاة، يبين الشكل (17) نتائج المحاكاة:



الشكل (17) ضغط الغاز في حال وجود اضطراب باستخدام المتحكمين

حيث نلاحظ أنه في حالة وجود الاضطراب فإن الزمن اللازم في حالة استخدام متحكم عائم لإعادة المنظومة لمرحلة الاستقرار أقل من الزمن اللازم باستخدام المتحكم التقليدي.
تبين نتائج المحاكاة أنه في حالة استخدام المتحكم التقليدي PID فإن الزمن اللازم لاستقرار المنظومة يقدر ب (7 ثواني) بينما في حالة استخدام المتحكم العائم فإن زمن الاستقرار لا يتجاوز (1.4 ثانية)، كما تبين النتائج عدم وجود تجاوز في القيمة المطلوبة (Overshoot) في حالة التشغيل المستقر.
أما في حالة وجود اضطراب فقد بلغت قيمة التجاوز في حالة استخدام المتحكم PID والمتحكم العائم نفس القيمة (18 Bar) بينما احتاج المتحكم PID إلى فترة زمنية قدرها (5 ثواني) للعودة إلى مرحلة الاستقرار، بينما احتاج المتحكم العائم إلى فترة أقل بكثير (1.3 ثواني) للعودة إلى مرحلة الاستقرار.

نبين في الجدول قيم مؤشرات الأداء لكل متحكم:

controller	RMSE	IAE	ITAE
PID	6.1050	29.3940	36.6326
Fuzzy	3.5385	8.8400	4.9960

حيث تظهر مؤشرات الأداء الثلاث تفوقاً واضحاً للمتحكم الضبابي مقارنة مع المتحكم التقليدي(PID)

فالمتحكم الضبابي حقق:

- **RMSE** أقل، مما يدل على دقة أعلى في تتبع الإشارة المرجعية وتقليل متوسط الخطأ الجذري.
- **IAE** أقل، وهو يعكس قدرة أفضل على تقليل مجموع الخطأ المطلق عبر الزمن.
- **ITAE** أقل بكثير، مما يعني أن المتحكم الضبابي يقلل الأخطاء المتأخرة بشكل كبير ويحقق استجابة أكثر استقرارًا ونعومة

وبشكل عام، تُظهر هذه النتائج أن المتحكم الضبابي يقدم **أداءً أدق، واستجابة أسرع، وخطأً تراكميًا أقل** مقارنة بمتحكمPID ، وهو ما ينسجم مع طبيعة المتحكمات الضبابية التي تتعامل بكفاءة مع اللاخطية وتغير ظروف التشغيل دون الحاجة إلى نموذج رياضي دقيق للنظام.

مقارنة خصائص الاستجابة:

نبين في الجدول (6) خصائص الاستجابة لكل متحكم:

الجدول (6) خصائص الاستجابة لكل متحكم في حال وجود اضطراب		
المعيار	Fuzzy PI	PID
سرعة الاستجابة	سريعة جدا	بطيئة نسبيا
الاستقرار	ممتاز وسريع	جيد لكن بعد وقت أطول
التعامل مع الاضطرابات	تصحيح سريع وفعال	تأخر في التصحيح
التذبذب	شبه معدوم	موجود بعد الاضطراب

7-الاستنتاجات:

1-يتضح لنا أن استقرار ضغط الغاز عند القيمة المرجعية خلال مرحلة الإقلاع أمر حاسم لنجاح تشغيل العنفة الغازية حيث أن أي تذبذب قد يؤدي إلى فشل الإقلاع أو توقف العنفة.

2-قصور المتحكم التقليدي (PID):

مع اختلاف ظروف التشغيل الحالية وعدم استقرار ضغط الشبكة الغازية لأسباب مختلفة مثل زيادة عدد آبار الغاز المستثمرة أو اختلاف تركيز الغازات ما يؤدي إلى اختلاف النسبة الحرارية النوعية للغاز أو غيرها من الظروف المختلفة قد يظهر المتحكم التقليدي بطء الاستجابة وصعوبة التكيف مع التغيرات المفاجئة مما يجعله غير مثالي خاصة لمراحل الإقلاع أو إعادة الإقلاع.

3-تفوق المتحكم العائم:

أظهر المتحكم العائم قدرة أعلى على التعامل مع اللاخطية والتغيرات السريعة والاضطراب، مما ساعد في تحسين زمن الاستجابة وتقليل التجاوزات في الضغط.

4-أهمية النمذجة الرياضية الدقيقة:

ساهم النموذج الرياضي المعتمد على خصائص الغاز الحقيقي في تحسين دقة المحاكاة مما أتاح تقييما واقعيا لأداء نظام التحكم.

5- تُظهر نتائج المحاكاة أن المتحكم الضبابي قدّم أداءً أفضل من متحكم PID في جميع مؤشرات التقييم المستخدمة، سواء من حيث قيمة الخطأ الجذري أو مجموع الخطأ المطلق أو الخطأ الموزون بالزمن. ويعود هذا التفوق بشكل أساسي إلى طبيعة المتحكمات الضبابية التي لا تعتمد على وجود نموذج رياضي دقيق للنظام، بل تستند إلى قواعد خبرة تسمح لها بالتعامل مع اللاخطية وتغيّر ظروف التشغيل بكفاءة أعلى.

8-التوصيات:

1-اعتماد المتحكم (Fuzzy-PI) للتحكم بضغط الغاز في العنفات الغازية نظرا لسرعة استجابته ومرونته العالية.

2-دمج أنظمة التحكم الذكية مع نظام التحكم والمراقبة (DCS): يجب تطوير تكامل المتحكمات الذكية مع أنظمة التحكم والمراقبة لضمان استجابة شاملة وسريعة.

3- إجراء اختبارات ميدانية موسعة: يوصى بتنفيذ تجارب ميدانية على الأنظمة الذكية في ظروف تشغيل مختلفة للتأكد من نتائج المحاكاة ومن فعالية النظام واستقراره على المدى الطويل.

9-الأبحاث المستقبلية:

تُظهر نتائج هذا البحث أن دمج تقنيات التحكم التقليدية مع تقنيات التحكم الذكية يفتح آفاقًا واسعة لتحسين أداء منظومات الضغط في العنفات الغازية. لذلك يُوصى بأن تتناول الدراسات المستقبلية ما يلي:

- تصميم متحكمات هجينة تجمع بين خصائص المتحكم PID واستجابة المتحكمات الضبابية (Fuzzy-PI)لتحقيق توازن بين سرعة الاستجابة والاستقرار طويل الأمد.
- تطبيق تقنيات التحكم التنبؤي والتحكم التكيفي لدراسة قدرة المنظومة على مواجهة ظروف تشغيلية أكثر تعقيدًا، مثل التغيرات المفاجئة في تركيب الغاز أو تقلبات الحمل الكهربائي.

- توسيع نطاق النمذجة والمحاكاة ليشمل سيناريوهات تشغيلية متعددة، بما في ذلك حالات الإقلاع والإيقاف، وذلك بهدف تحسين موثوقية الأداء تحت ظروف تشغيلية مختلفة.
- تحسين خوارزميات الضبط الذاتي لمعاملات المتحكمات بما يضمن سرعة التكيف مع التغيرات المستمرة في بيئة التشغيل.

إن التوجه نحو هذه المسارات البحثية سيسهم في رفع كفاءة منظومات التحكم الصناعي، ويعزز موثوقية تشغيل العنفات الغازية في المعامل ومحطات توليد الطاقة.

جدول (7) المصطلحات الخاصة بالشكل رقم (3) (أجزاء العنفة الغازية)	
الترجمة العربية	**المصطلح الإنجليزي**
وحدة القيادة الملحقة	ACCESSORY DRIVE
دوّار الضاغط	COMPRESSOR ROTOR
غلاف الضاغط والريش الثابتة	COMPRESSOR CASE AND STATORS
مدخل الهواء	AIR INLET
ناشر الهواء (موسع التدفق)	DIFFUSER
غرفة الاحتراق	COMBUSTOR
غلاف العنفة والريش الثابتة	TURBINE CASE AND STATORS
مجمع العادم	EXHAUST COLLECTOR
دوّار عنفة إنتاج الغاز	GAS PRODUCER TURBINE ROTOR
دوّار عنفة القدرة	POWER TURBINE ROTOR
وحدة تخفيض السرعة	REDUCTION DRIVE
عمود الخرج	OUTPUT SHAFT

الجدول (8) الرموز		
الرمز	**التعريف**	**الواحدة**
Q	معدل التدفق الحجمي	$\mathrm{Nm^3/h}$
$\dot{m}$	معدل التدفق الكتلي	$\mathrm{kg/h}$
C_v	معامل التدفق للصمام	بدون واحدة
P_1	ضغط الدخول المطلق	bar

P_2	ضغط الخروج المطلق	bar
ΔP	فرق الضغط	bar
x	نسبة انخفاض الضغط	بدون واحدة
T_1	درجة حرارة الدخول	K
G_g	الكثافة النسبية للغاز (الهواء = 1)	بدون واحدة
K	النسبة الحرارية النوعية cp/cv	بدون واحدة
Z	عامل الانضغاطية للغاز	بدون واحدة
x_t	نسبة انخفاض الضغط الحرجة للصمام	بدون واحدة
F_k	عامل تصحيح النسبة الحرارية	بدون واحدة
y	عامل التمدد للغاز	بدون واحدة
F_b	معامل تصحيح هندسة الأنابيب	بدون واحدة
N_1	ثابت تحويل الوحدات للتدفق الحجمي	بدون واحدة
N_6	ثابت تحويل الوحدات للتدفق الكتلي	بدون واحدة
ρ_1	كثافة الغاز عند ظروف الدخول	kg/m^3

[1]. Omar, M. H. T., Hamdy, R. A., & Kotb, H. (2026). A hybrid fuzzy-PIDD² control strategy for coordinated LFC and AVR in renewable-integrated multi-area power systems. Scientific Reports, 16, Article 3741

[2]. Atiyaha, S. K., Al-Timimi, B. A., Ali, A. Y., Ahmed, M. S., Albayati, T. M., Abdullah, G. H., & Mel, M. (2025). "Comparative Simulation of PI and Fuzzy Control for Fluid Catalytic Cracking Unit". Iranian Journal of Chemistry and Chemical Engineering (IJCCE), Vol. 44, Issue 3, pp. 846-857

[3] A Novel CEM-Based 2-DOF PID Controller for Low-Pressure Turbine Speed Control of Marine Gas Turbine Engines –Processes ،MDP,2024.

[4]. Fuzzy Controller Structures Investigation for Future Gas Turbine Aero-Engines –International Journal of Turbomachinery, Propulsion and Power ، MDPI.2021 .

[5]. OpFlex Sliding Fuel Pressure Control – GE Vernova .

[6]. Apply Robust Proportional Integral Derivative Controller to a Fuel Cell Gas Turbine – ASME Journal of Electrochemical Energy Conversion and Storage, 2018.

[7]. Boyce, M. P. (2012). Gas Turbine Engineering Handbook. Elsevier.

[8]. Kurz, R., & Brun, K. (2001). Gas Turbine Performance. ASME Press.

[9] . Holman, J. P. (2012). Experimental Methods for Engineers. McGraw-Hill.

[10]. Control Valve Handbook (5th Edition), Emerson Automation Solutions

[11]. Borden, G. (1998). Control Valves: Practical Guides for Measurement and Control. ISA.

[12]. "Industrial-process control valves - Part 2-1: Flow capacity - Sizing equations for fluid flow under installed conditions", International Society of Automation,(2007).

[13]. Borden, Control Valves: Practical Guides for Measurement and Control. Research Triangle Park, NC: ISA, 1998.

[14]. Carlos Dualibe.(2003) "Design Of Analog Fuzzy Logic Controllers In Cmos Technologies".Kluwer Academic Publishers 227p.

دراسة نمذجة و محاكاة المحرك التحريضي الثلاثي الطور و تحليل نتائج اختباراته باستخدام أدوات الذكاء الاصطناعي

د.م.تامر عبد الجليل شتور*

الملخص

إن دراسة نمذجة و محاكاة الآلات الكهربائية تمثل جسراً هاماً بين النظرية و التطبيق في التعليم الهندسي حيث تعتبر محاكاة الآلات الكهربائية خطوة ضرورية للمهندسين لتحليل و تحسين أدائها في بيئة افتراضية آمنة قابل للتعديل قبل الانتقال إلى النماذج الأولية المادية المصنعة المكلفة ، كما تلعب المحاكاة دوراً تعليمياً مهماً حيث توفر منصات تفاعلية لطلاب الهندسات لفهم مبادئ عمل الآلات الكهربائية و اختباراتها بشكل آمن وفعال و غير مكلف .

بدايةً تم اختيار المحرك التحريضي الثلاثي الطور الاكثر انتشاراً و أهميةً في الحياة العملية و تم الاعتماد على برامج متخصصة مثل **MATLAB/Simulink** لتطبيق منهجية علمية للمحاكاة بناء على نمذجة دقيقة و الأداة الحديثة المتطورة **Regression Learner** .

كما تم استعراض الأسس النظرية لنمذجة المحرك التحريضي الثلاثي الطور و من ثم الانتقال إلى استراتيجة البحث التي تمت من خلالها محاكاة الاختبارات الأساسية على المحرك : اللاحمل : باعطاء قيم مختلفة للتوتر من Un (0.5−1.1) مع بقاء العزم المطبق صفريا ثم قياس قيم التيار و الاستطاعة مع إنشاء جداول بالنتائج و رسم المنحنيات.

القصر: بإعطاء قيم مختلفة للتيار من(0 حتى Isc)حيث يكونIn=Iscمع تطبيق سرعة زاوية معدومة(ω=0)ثم قياس قيم التوتر والاستطاعة مع إنشاء جداول بالنتائج و رسم المنحنيات .

التحميل : بإعطاء قيم مختلفة للعزم الميكانيكي من (0 حتى Tn) مع تثبيت قيم التوتر و التردد ثم قياس قيم التيار والتوتر والسرعة مع إنشاء جداول بالنتائج و رسم منحنيات العمل.

تُستخدم نتائج المحاكاة، التي غالباً ما تُعرض على شكل منحنيات للأداء (العزم، السرعة، التيار)، لتقييم التصاميم المختلفة ومقارنتها وتحسين الكفاءة وتقليل التكاليف.

و أخيراً تم مناقشة النتائج اعتماداً على الأدوات الرائدة الحديثة للذكاء الاصطناعي لتحليل البيانات الناتجة ضمن الجداول و المنحنيات للاستفادة منها و مطابقتها للمعايير القياسية .

الكلمات المفتاحية:النمذجة و المحاكاة،الآلات الكهربائية،المحرك التحريضي الثلاثي الطور،الذكاء الاصطناعي

* دكتوراه في هندسة الطاقة الكهربائية–مدرس في كلية الهندسة المعلوماتية–الجامعة العربية الخاصة للعلوم و التكنولوجيا

Studying the modeling and simulation of a three-phase induction motor and analyzing the results of its tests using artificial intelligence tools.

Dr. E. Tamer Abduljalel Shattour*

Abstract

Simulating electrical machines is a crucial step for engineers and researchers to analyze and improve their performance and systems in a safe, customizable virtual environment before moving to costly, manufactured physical prototypes.

Simulation also plays a vital educational role, providing interactive platforms for engineering students to understand the operating principles of electrical machines and their testing safely, efficiently, and cost-effectively.

Initially, the most widespread and important three-phase induction motor in practical applications was chosen. Specialized software such as MATLAB/Simulink and Ansys Motor-CAD were used to implement a scientific simulation methodology

The theoretical foundations of three-phase induction motor modeling were reviewed, followed by the research strategy, which involved simulating the basic motor tests: No-load: applying different voltage values (0.5-1.1 Un) while keeping the applied torque at zero. Current and power values were then measured, and results were tabulated and curved. Short circuit simulation: By

assigning different current values from 0 to Isc (where Isc = In) and applying zero angular velocity ($\omega = 0$), the voltage and power values are measured, and tables of results are generated and curves plotted.Loading simulation: By assigning different torque values from 0 to Tn, while holding the voltage and frequency constant, the current, voltage, and velocity values are measured, and tables of results are generated .

The simulation results, often presented as performance curves (torque, velocity, current), are used to evaluate and compare different designs, improve efficiency .

Finally, the results are discussed using leading modern artificial intelligence tools to analyze the resulting data within the tables and curves, to ensure their relevance and compliance with standard criteria.

Keywords : Modeling and simulation , electrical machines , three- phase induction motor , artificial intelligence .

* Lecturer at the Arab Private University for Science and Technology.

1- المقدمة :

تعتبر المحركات التحريضية و خاصة الثلاثية الطور من أكثر أنواع الآلات الكهربائية انتشاراً في التطبيقات الصناعية حيث يشكل المحرك التحريضي الثلاثي الطور ذو القفص السنجابي ما يزيد عن 85 ٪ من الحمل الكهربائي في القطاع الصناعي عالمياً **[1]** .

تعتبر النمذجة والمحاكاة أداتان أساسيتان لا غنى عنهما لفهم سلوك المحرك حيث تأتي أهمية المحاكاة من قدرتها على تقليل دورات التطوير وتكاليفه بشكل كبير فبدلاً من بناء و اختبار نماذج مادية متعددة، يمكن للمهندسين إنشاء نماذج افتراضية وتقييمها عبر مجموعة كاملة من ظروف التشغيل . تتيح المحاكاة تحليلاً متعدد الجوانب يشمل الجوانب الكهرومغناطيسية والحرارية والميكانيكية، مما يؤدي إلى تصميمات مُحسَّنة من حيث الأداء والكفاءة والحجم .

تم في هذا البحث دراسة نمذجة و محاكاة المحرك التحريضي الثلاثي الطور انطلاقاً من إدخال المعطيات الأساسية من اللوحة الاسمية للمحرك و حتى الحصول على أدق المعلومات و المخططات النهائية للمحرك مروراً بكل اختباراته الأساسية .

2- مشكلة البحث :

يُعدّ المحرك التحريضيي آلة معقدة التصميم حيث تستخدم غالبية المؤسسات الصناعية برامج حاسوبية لمحاكاة الآلة قبل تنفيذ التصميم. و مع ذلك، يُنفَّذ النموذج الديناميكي للمحرك التحريضيي عادةً في محاور dq0 المباشرة، والمحور التربيعي، ومحور التسلسل الصفري. أما تنفيذ النموذج الساكن والديناميكي للمحرك فهو تمثيل رياضي؛ هذه الاستراتيجية تُزيل الخطأ البشري، وتُمكّن من تصميم محركات ذات أداء فائق، وتُوفّر محركات تحريضيية عالية الكفاءة. يُنفّذ هذا البحث نمذجة ساكنة وديناميكية لآلة تحريضيية ثلاثية الأطوار نظراً لاحتمالية حدوث أعطال ومتطلبات الأداء العالي للآلات التحريضية باستخدام طريقة المحور المباشر dq0، تم اشتقاق المعادلات التفاضلية للنموذج الديناميكي أولاً، ثم نُفِّذت في برنامج Matlab/Simulink؛ وتم تقييم أدائها في الاختبارات ضمن أدوات الذكاء الاصطناعي .

3- أهمية البحث :

1) التعلم التفاعلي : يتيح الواقع الافتراضي للباحثيين التعامل مع المعدات والأسلاك والمكونات الافتراضية حيث يُعزز هذا التفاعل العملي فهم المفاهيم التي قد يصعب استيعابها من خلال الدراسة النظرية وحدها، ويعزز قدرتهم على تذكرها .
2) التجريب الآمن : السلامة هي الأهم في مختبر الكهرباء حيث يُزيل الواقع الافتراضي المخاطر المرتبطة بالجهد العالي والدوائر الكهربائية النشطة مما يسمح بإجراء التجارب دون خوف من الحوادث أو الإصابات مما يساعد على التعلم من التجارب .
3) تطبيقات واقعية : يبدو مستقبل الواقع الافتراضي في مختبرات الكهرباء واعداً و ذلك مع استمرار تقدم التكنولوجيا حيث نتوقع رؤية محاكاة أكثر تطوراً، وتجارب تعليمية تفاعلية، وتكاملاً أفضل مع التقنيات التعليمية الأخرى. سيعزز هذا التطور طريقة تفاعل الباحثيين مع مفاهيم الهندسة

الكهربائية و يُحسّن الواقع الافتراضي تجارب مختبرات الكهرباء، مما يجعل التعلم أكثر جاذبية وفعالية .

4-الدراسات السابقة المرجعية عن البحث :

1) قدم شيترا و برابهاكار بحث عن محاكاة المحرك التحريضي باستخدام نهج المنطق الضبابي. من أجل تنظيم سرعة محرك التحريضي للحصول على عزم الدوران الأمثل بأقل قدر من الفقد. استخدما نهج التحكم الموجه للمجال لإنشاء وحدة تحكم منطقية ضبابية تتيح تحكماً مُحسَّناً في عزم دوران المحرك مع أداء متغير بشكل كبير **[2]** .
2) اقترح الناغي استخدام خوارزمية جينية لمعالجة الأحمال التجريبية على آلة تحريضية. وقد تم إثبات مبدأ التنبؤ ببيانات المحرك من بيانات الاختبار باستخدام تقنية تعتمد على الخوارزمية الجينية. وتم تحديد المواصفات باستخدام تجارب نموذجية بدون حمل وتجارب دوار مقيد**[3]** .
3) قدم جيردهي محاكاة لمحرك تحريضيي باستخدام شبكة عصبية اصطناعية (ANN) ونظام استدلال عصبي ضبابي تكيفي (ANFIS) لدراسة المتغيرات و قارن الباحثون نتائج المحاكاة وفق الأنظمة المقترحة مع النتائج العملية **[4]** .
4) تقترح الدراسة **[5]** المنشورة عام (2022) نهجاً مُدمجاً لنمذجة نظام تبريد المحرك التحريضي عالي الجهد ، الذي يتضمن دمج النموذج الكهربائي والحراري ونموذج المُبرّد باستخدام النموذج الرياضي ، تم تطوير نموذج حراري باستخدام نماذج رياضية ونماذج انحدار خطي (liner regression) مُدمجة ، تم دمج جميع النماذج المُثبتة في نموذج واحد ثم تُستخدم الإشارات الفعلية للتحقق من صحة البنية الكاملة للنموذج . أظهرت النتائج بوضوح دقة النموذج المقترح مع انخفاض كبير في متوسط الخطأ المطلق النسبي (MAPE) وجذر متوسط مربع الخطأ (RMSE).
5) تقترح الدراسة **[6]** المنشورة عام (2022) نموذجاً قائماً على الانحدار regression لتحليل أداء المحركات التحريضية حيث يتم استخدام شبكة (DBN) و هي نموذج متقدم من تعلم

الآلة (deep belief network)المكدسة مع عدة آلات بولتزمان (RBM) للتشخيص الدقيق من خلال اعتماد عملية التدريب للكشف عن الاعطال ، تم اقتراح نهج جديد قائم على التعلم العميق للتخفيف من الخسائر .

6) تقدم الدراسة **[7]** المنشورة عام (2023) نماذج محاكاة لإجراء اختبار التيار المستمر و اختبار اللاحمل واختبار الدوار المقفل على المحرك التحريضي الثلاثي الطور باستخدام MATLAB/Simulink تُعدّ هذه الاختبارات الثلاثة أساسية لتحديد خصائص الدائرة المكافئة للمحرك التحريضي الثلاثي الطور ، كما يستخدم البحث بيئة MATLAB لتحديد خصائص عزم الدوران والسرعة والتيار للمحرك ، وقد وُجد أن نتائج المحاكاة تتطابق بشكل كبير مع القيم التي تم الحصول عليها في التجارب العملية ، تم إجراء العديد من التجارب الافتراضية على المحركات التحريضية بدقة محسّنة باستخدام نماذج المحاكاة ، تم في اختبار اللاحمل تقييم تباين بنسبة 10% بين نتيجة النموذج والنتيجة المختبرية ، هذا التباين كبير و يتطلب البحث عن نموذج أكثر كفاءة لتقليل الخطأ إلى أقل قيمة ممكنة .

5-الهدف من البحث :

للمساهمة في تطوير نماذج محاكاة المحركات التحريضية ضمن المختبرات الكهربائية فكان الهدف من البحث يتضمن مجموعة نقاط أهمها :

1) تطبيق تقنية نمذجة إطار مرجعي للمحور dq0 لآلة دوارة وفق المعادلات الرياضية .
2) محاكاة محرك تحريضيي ثلاثي الأطوار باستخدام برنامج Matlab/Simulink .
3) تحليل الأداء الديناميكي :دراسة الاختبارات الرئيسية الثلاثة اللاحمل و القصر و التحميل.
4) استنتاج الجداول و رسم المنحنيات المميزة للاختبارات الرئيسية الثلاثة .
5) تقييم المحاكاة و تحسينها وفقاً لأدوات الذكاء الاصطناعي .

6- استراتيجية البحث :

أ : مواد و طرق البحث :

تم الاعتماد على المحرك التحريضي الثلاثي الطور **[8]** :

- ❖ لأنه أكثر المحركات انتشاراً وأهمها استخداماً في الحياة العملية .
- ❖ لأنه يتميز بموثوقية عالية و كفاءة العمل .
- ❖ لأنه يعتبر من المحركات الاقتصادية ذات المردود الجيد .
- ❖ لأنه يتميز بقلة أعطاله و سهولة صيانته و تواجده باستطاعات مختلفة .

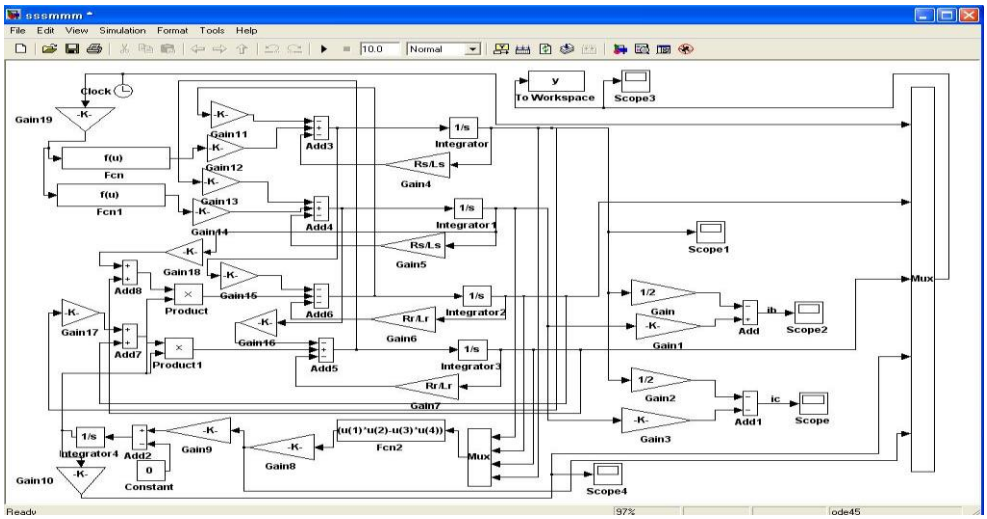
تم الاعتماد على MATLAB **[9]** :

- ❖ يعتبر MATLAB/Simulink الأداة الأكثر شيوعاً لنمذجة ومحاكاة الأنظمة الديناميكية .
- ❖ لأنه يعتبر لغة برمجة متطورة جداً و يتضمن البرمجة (GUI)والنمذجة (SIMULINK).
- ❖ لأنه يتمتع بمرونة عالية وقابلية للتعديل و التطور .
- ❖ لأنه يملك أضخم مكتبة لأنظمة الطاقة (simpower system) تحوي العديد من الأدوات و الوسائل المساعدة للنمذجة في النظم الكهربائية .

ب: نمذجة المحرك التحريضي الثلاثي الطور باستخدام معادلاته الرياضية :

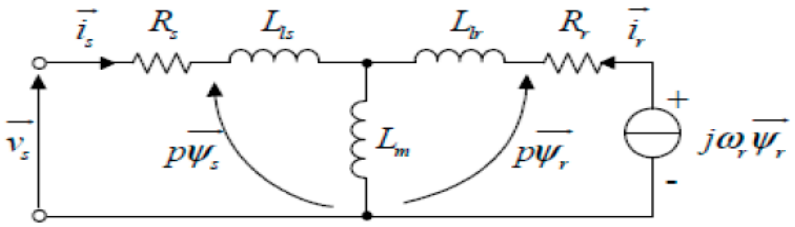
يحتوي MATLAB على (Block Diagrams) للمحرك التحريضي يتألف من عدة دارات ممثلة داخله حسب التمثيل الرياضي حيث يمكن تمثيل المحرك التحريضي بدارة يمثل فيها الثابت و الدائر بمعادلات رياضية خاصة به وتمثل هذه المعادلات في MATLAB بعناصر تمثيل المعادلات من مكاملات ومضخمات ومصفوفات و توابع رياضية وغيرها .

ويعبر الشكل عن تمثيل المحرك التحريضي وفق المعادلات الرياضية المميزة له :



الشكل (1) تمثيل المحرك التحريضي وفق المعادلات الرياضية في MATLAB

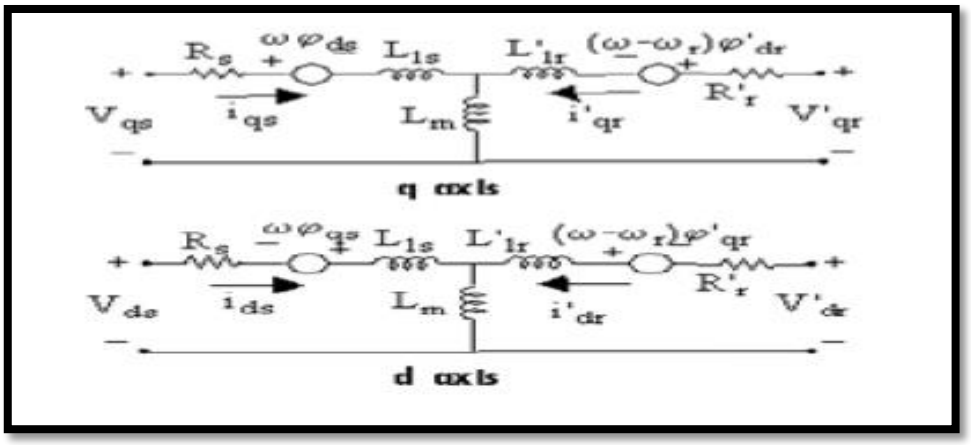
يتم تمثيل المحرك التحريضي بدارة مكافئة على شكل حرفTو يوضح الشكل التالي ذلك:



الشكل (2) تمثيل المحرك التحريضي بدارة على شكل حرف T [1]

وقد اعتُبر نموذج d–q للمحوريين المباشر و المتعامد مناسباً تماماً ليكون بمثابة تصميم أساسي

الذي يكافئ بالدارات التالية :



الشكل (3) تمثيل المحرك التحريضي بالمحوريين d-q [1]

حيث سيوضح : **الجدول (1) دلالة الرموز في تمثيل المحرك التحريضي بالمحورين d-q**

الرمز	الدلالة
R_s , L_{1s}	المقاومة و المحارضة التسريبية للثابت
L_s	المحارضة الكلية للثابت
V_{ds} , i_{ds}	توتر و تيار الثابت وفق المحور d
ω_m	السرعة الزاوية لمحرك كهربائي ثلاثي الطور
ω_r	السرعة الزاوية الكهربائية
P	عدد ازواج الاقطاب
T_m	العزم الميكانيكي لمحرك كهربائي ثلاثي الطور
H	معامل العطالة للحمولة و ممانعة المسار
R_r , L_{1r}	المقاومة و المحارضة التسريبية للدوار
V_{dr} , I_{dr}	توتر و تيار الدوار وفق المحور d
Lm	المحارضة المغناطيسية
Vqs , I_{qs}	توتر و تيار الثابت وفق المحور q
φ_{ds} , φ_{qs}	فيض الثابت وفق المحور d و q

Θ_m	زاوية موضع المحرك الكهربائي
Ω	السرعة الزاوية للإطار المرجعي
T_e	العزم الكهرومغناطيسي
F	معامل الإحتكاك
V_{qr} , I_{qr}	توتر و تيار الدوار وفق المحور q
φ_{dr} , φ_{qr}	فيض الدوار وفق المحور dو q
L_r	المحارضة الكلية للدوار

حيث إن أسلوب النمذجة المقترح لمحرك تحريضيي يتم بتزويد المحرك بجهد التغذية ثلاثي الأطوار ثم يتم تحويل الجهود باستخدام المحور dq0 لإنتاج المتجهين Vq و Vd ومن ثم يتم حساب تيارات وجهود الجزء الثابت، ثم تُؤخذ بيانات الجزء الدوار في الاعتبار .

سنوضح طريقة استنتاج المعادلات الرياضة وفق الدراسات المرجعية **[10]** كما يلي:

إن النموذج الرياضي للمحرك التحريضي ثلاثي الطور في الإطار المرجعي الثلاثي الطور (ABC) يُشتق مباشرة من قوانين كيرشوف للفولطية وقوانين فارادي للتحريضي حيث تتميز معادلاته بأنها شديدة الاقتران و غير خطية لذا يعد هذا النموذج معقد حسابياً .

لذا يعتمد على النموذج الرياضي للمحرك التحريضي في الإطار المرجعي الدوار (dq) – تحويل بارك : لتبسيط التحليل، يُطبق تحوير بارك (Park Transformation) لتحويل المتغيرات من الإطار الثلاثي الثابت (abc) إلى إطار مرجعي دوار (dq0) بمحوريه المباشر (d) والمتعامد (q) ، هذا التحويل يحول النظام إلى معادلات تفاضلية بمعاملات ثابتة **[10]**:

$$U_{1d} = R_{1d} i_{1d} + \frac{d_{\psi 1d}}{dt} \qquad U_{1q} = R_{1q} i_{1q} + \frac{d_{\psi 1q}}{dt} \qquad (1)$$

$$\Psi_{1d} = L_{1d} i_{1d} + M i_{2d} \qquad \Psi_{1q} = L_{1q} i_{1q} + M i_{2q}$$

يمكن بطريقة ثانية من العلاقتين الأخيرتين حساب ما يلي: $i_{1d} = \frac{\Psi_{1d} - M i_{2d}}{L_{1d}}$

و بنفس الأسلوب حيث تشير M إلى المحارضة المغناطيسية بين الثابت و الدوار :

$$U_{2d} = R_{2d} i_{2d} + \frac{d_{\psi_{2d}}}{dt} + W_r \psi_{2q}$$

$$U_{2q} = R_{2q} i_{2q} + \frac{d_{\psi_{2q}}}{dt} + W_r \psi_{2d} \qquad (2)$$

$$\Psi_{2d} = L_{2d} i_{2d} + M i_{1d} \qquad \Psi_{2q} = L_{2q} i_{2q} + M i_{1q}$$

أيضاً من المعادلتين الأخيرتين نجد أن: $i_{2d} = \frac{\Psi_{2d} - M i_{1d}}{L_{2d}}$

نستبدل العلاقة الأخيرة في العلاقة i_{1d} فنحصل على:

$$i_{1d} = \frac{\psi_{1d} - M\left[\left(\frac{\psi_{2d} - M i_{1d}}{L_{2d}}\right)\right]}{L_{1d}}$$

$$i_{1d} = \frac{L_{2d} \cdot \Psi_{1d} - M[\Psi_{2d} - M \cdot i_{1d}]}{L_{1d} \cdot L_{2d}} \quad \gg$$

$$i_{1d} = \frac{L_{2d} \cdot \Psi_{1d} - M\Psi_{2d} + M^2 \cdot i_{1d}}{L_{1d} \cdot L_{2d}} \quad \gg$$

$$i_{1d} \cdot L_{1d} \cdot L_{2d} = L_{2d} \cdot \Psi_{1d} - M \cdot \Psi_{2d} + M^2 \cdot i_{1d} \quad \gg$$

$$i_{1d} \cdot [L_{1d} \cdot L_{2d} - M^2] = L_{2d} \cdot \Psi_{1d} - M \cdot \Psi_{2d} \quad \gg$$

بالتالي بنفس الأسلوب يمكن حساب جميع التيارات كما يلي:

$$i_{1d} = \frac{L_{2d}\psi_{1d} - M\psi_{2d}}{L_{1d} . L_{2d} - M^2} \qquad (3)$$

$$i_{1q} = \frac{L_{2q}\psi_{1q} - M\psi_{2q}}{L_{1q}.L_{2q} - M^2} \quad (4)$$

$$i_{2d} = \frac{L_{1d}\psi_{2d} - M\psi_{1d}}{L_{1d}.L_{2d} - M^2} \quad (5)$$

$$i_{2q} = \frac{L_{1q}\psi_{2q} - M\psi_{1q}}{L_{1q}.L_{2q} - M^2} \quad (6)$$

بتبديل هذه القيم في معادلات الجهود نجد ما يلي:

$$U_{1d} = R_{1d}\left[\frac{L_{2d}\psi_{1d} - M\psi_{2d}}{L_{1d}.L_{2d} - M^2}\right] + \frac{d\psi_{1d}}{dt}$$

$$\frac{d\psi_{1d}}{dt} = U_{1d} - \frac{(R_{1d}L_{2d})\ \psi_{1d}}{L_{1d}.L_{2d} - M^2} + \frac{R_{1d}M\psi_{2d}}{L_{1d}.L_{2d} - M^2} \quad (7)$$

بنفس الطريقة يمكننا أن نوجد تفاضلات التحريض المغناطيسي بالنسبة لباقي الملفات عند المحورين المباشر و العكسي d – q كما يلي **[7]** :

$$\frac{d\psi_{1q}}{dt} = U_{1q} - \frac{(R_{1q}L_{2q})\ \psi_{1q}}{L_{1q}.L_{2q} - M^2} + \frac{(R_{1q}M)\psi_{2q}}{L_{1q}.L_{2q} - M^2} \quad (8)$$

$$\frac{d\psi_{2d}}{dt} = U_{2d} - \frac{(R_{2d}L_{1q})\ \psi_{2q}}{L_{1d}.L_{2d} - M^2} + \frac{(R_{2d}M)\psi_{1d}}{L_{1d}.L_{2d} - M^2} - W_r\psi_{2q} \quad (9)$$

$$\frac{d\psi_{2q}}{dt} = U_{2q} - \frac{\left(R_{2q}L_{1d}\right)\ \psi_{2q}}{L_{1q}.L_{2q} - M^{2}} + \frac{\left(R_{2q}M\right)\ \psi_{1q}}{L_{1q}.L_{2q} - M^{2}} - W_{r}\psi_{2d} \qquad (10)$$

لحل هذه المعادلات استخدمنا برنامج (Matlab) الذي يحتوي طريقة حل هذه المعادلات حيث يلزمنا

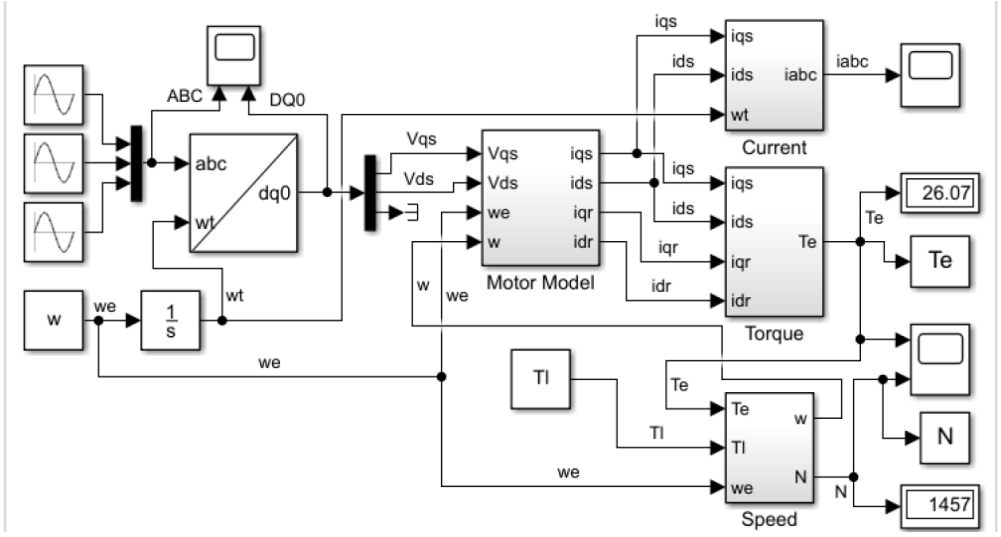
$$T_c = \frac{3}{2} MP^2 \left(i_{1d} i_{2q} - i_{2d} i_{1q}\right)$$

عندها أيضاً معادلة العزوم:

وكذلك معادلة الحركة الميكانيكية:

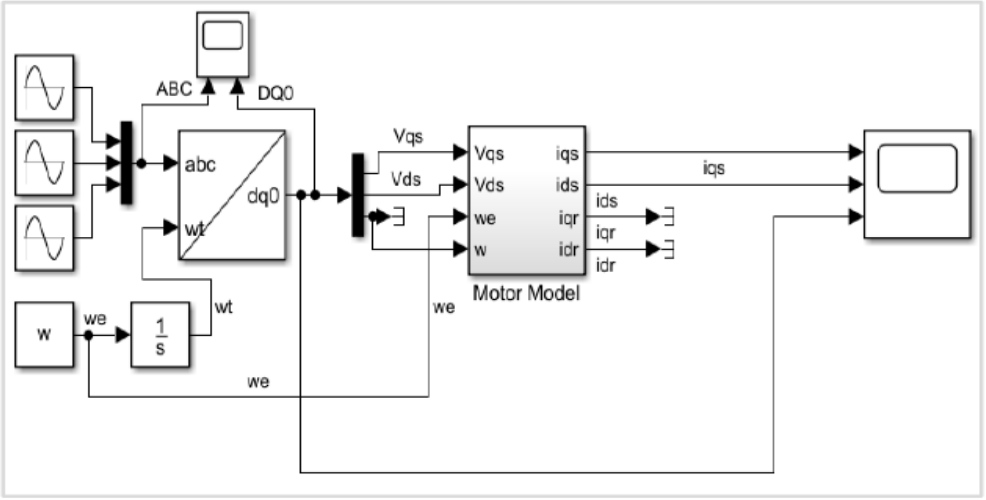
$$\frac{dW_r}{dt} = \frac{3}{2} MP^2 \left(i_{1d} i_{2q} - i_{2d} i_{1q}\right)$$

النموذج الديناميكي المقترح المتكامل مع معادلات العزوم و الاستطاعات **[11]** :



الشكل (4) النموذج الديناميكي للمحرك التحريضي

بينما يتحول النموذج للنموذج ستاتيكي ساكن عندما تكون السرعة و التسارع و العزوم المطبقة صفرية أي يصبح :



الشكل(5) النموذج الستاتيكي للمحرك التحريضي

ج : محاكاة المحرك التحريضي الثلاثي الطور و اختباراته :

يعتبر SIMULINK من أكثر برامج الحاسوب الهندسية شيوعاً و استخداماً في مجالات الأبحاث الأكاديمية و الصناعية لبناء نماذج تقليدية للأنظمة الديناميكية و تحليلها و محاكاتها يمكن للباحثين باستخدام هذا البرنامج في بناء نماذج للأنظمة الحقيقية و محاكاتها كما يمكن تعديل متغيرات هذه الأنظمة أثناء المحاكاة و ملاحظة التغيرات**[12]**.

في هذا البحث تتم عملية بناء النماذج باستخدام المخططات الصندوقية المخزنة فيه على عكس البرامج الأخرى و التي تستهلك جهد ووقت الباحث في كتابة برامج طويلة و معقدة .

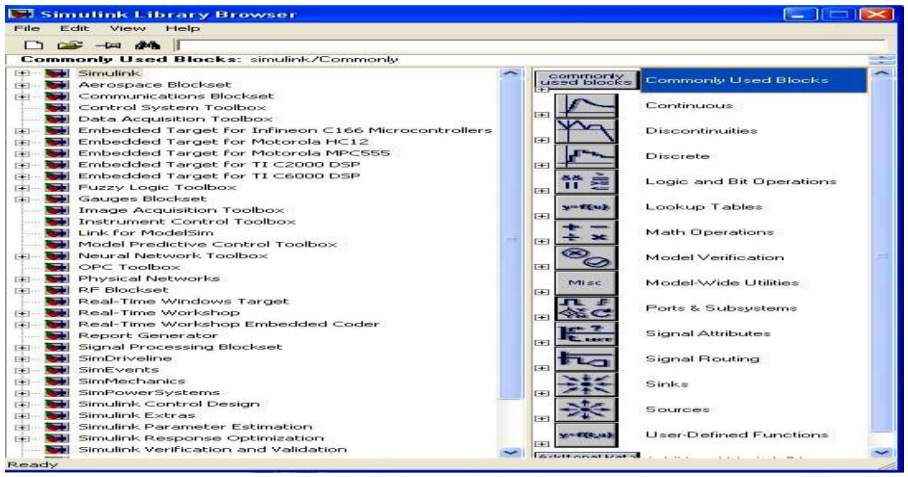
عند اكتمال بناء نموذج للمنظومة تبدأ عملية المحاكاة و ذلك باختيار طريقة التكامل المناسبة في SIMULINK يحتوي على عدة طرق لإنجاز عملية التكامل (Integration) .

و يمكن مشاهدة النتائج أثناء عملية المحاكاة على هيئة منحنيات و ذلك باستخدام راسم الإشارات الموجود أصلاً في SIMULINK أو على هيئة قيم تعطيها المقاييس الموجودة ضمن البرنامج .

و بعد بناء النموذج نقوم بتشغيل النموذج لعمل الـ simulation ويمكننا اختيار خصائص الـ simulation وطريقة التكامل وهذا يكون في non-real time كما يمكننا أيضا عمل محاكاة للنماذج في الـ real time وهذا باستخدام مجموعة Blocks الموجودة في باسم Xpc Target و Real Time Workshop

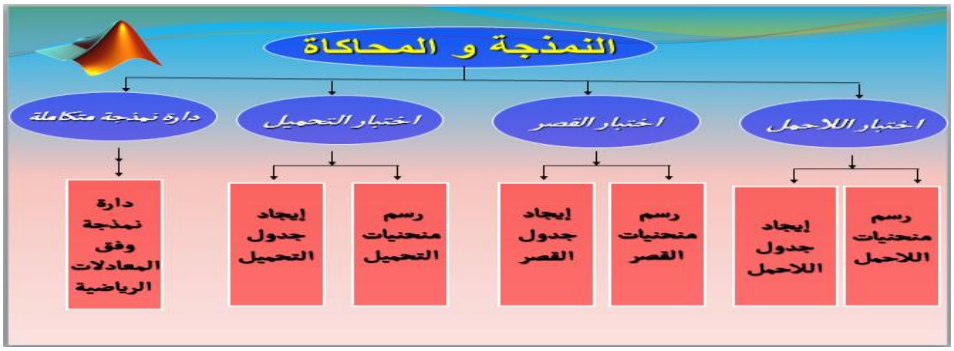
ويمكننا التحكم في الـ Simulation من خلال سطر أوامر MATLAB وهذا يكون مفيد جداً في حالة الرغبة لعمل Simulation لأكثر من نموذج ويمكن تخزين النتائج و استخدامها مع الـ Toolboxs الموجودة في MATLAB.

يمكن فتح برنامج المحاكاة من خلال الأيقونة الموجودة في شريط الأدوات أو من خلال كتابة كلمة Simulink في نافذة الـCommand window فتظهر الصورة الآتية توضح الواجهة الرئيسية :



الشكل (6) الواجهة الرئيسية لـ simulink

تم تصميم المخطط الصندوقي العام للبحث الذي يتضمن الاختبارات الثلاثة و نتائجها :



الشكل (7) المخطط الصندوقي العام للبحث

فيما يلي سنبين طريقة تشكيل الدارة في البحث وتحديد خصائص عناصرها وتنفيذها ولنأخذ **الدارة الأولى على سبيل المثال وهي اختبار اللاحمل للمحرك التحريضي :**

الغاية من الدارة محاكاة عمل المحرك التحريضي في حالة اللاحمل وتحديد تيار اللاحمل واستطاعة اللاحمل وعامل الاستطاعة ورسم المنحنيات المميزة للمحرك في هذه الحالة وهي

$$Po,Io,COS(\varphi o)=f(Uo)$$

يتم في هذه التجربة قياس استطاعة اللاحمل وتيار اللاحمل عند قيم مختلفة للتوتر المطبق .

سنبدأ بكيفية جلب Blocks المطلوبة إلى ساحة العمل فبعد طلب SIMULINK يتم فتح نافذة عمل جديدة لكي يتم العمل ضمن هذه النافذة :

1.منبع ثلاثي الطور متغير (Three-Phase Programmable Voltage Source):

وهذا المنبع موجود في مكتبة أنظمة الطاقة (SimPowerSystems) وفي صفحة المنابع الكهربائية (Sources Electrical)حيث يتم التحكم ببارامترات العناصر من خلال تعليمة الربط بين الـ GUI وال SIMULINK وقد غيرنا التوتر بـ المطال والزاوية وأيضا التردد.

2.المحرك التحريضي (Asynchronous Machine) :

وهو موجود في نفس المكتبة السابقة وفي صفحة الآلات الكهربائية (Machines) ويتم التحكم ببارامترات هذا العنصر الاسمية من توتر وتردد واستطاعة كما يتم تحديد نوع المحرك قفص سنجابي أو دائر ملفوف ونوع الوصل نجمي مثلثي من خلال الواجهة الأساسية .

3.قضيب القياس (Bus Selector) :

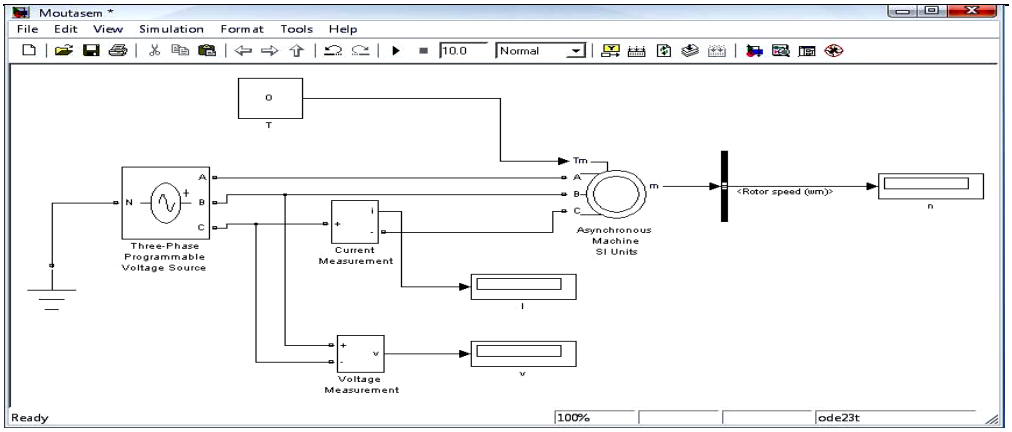
وهو موجود في القائمة الأكثر استخداماًCommonly Used Blocks حيث نستطيع من خلاله أخذ المقاييس التي نريدها للثابت والدائر (سرعة، تيار،عزم،توتر...).

4.حمولة معدومة ممثلة بعزم قيمته صفر .

5. مقاييس للتيار والتوتر المطبقين على الثابت .

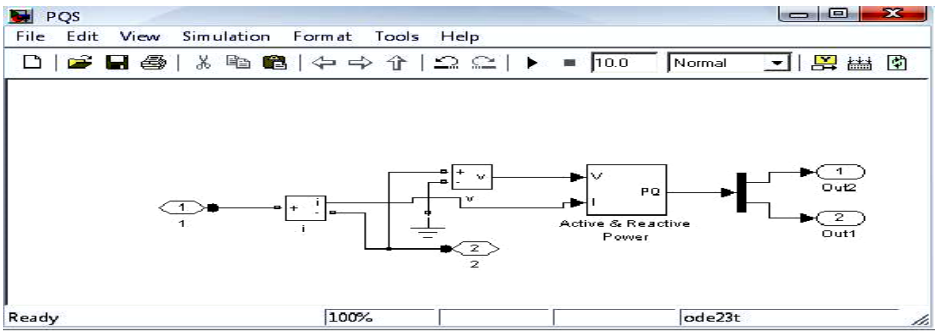
6.وصلة تأريض للمنبع الثلاثي .

7.شاشات إظهار المقاييس (Display) .



الشكل (8) الدارة الأولية للاختبارات

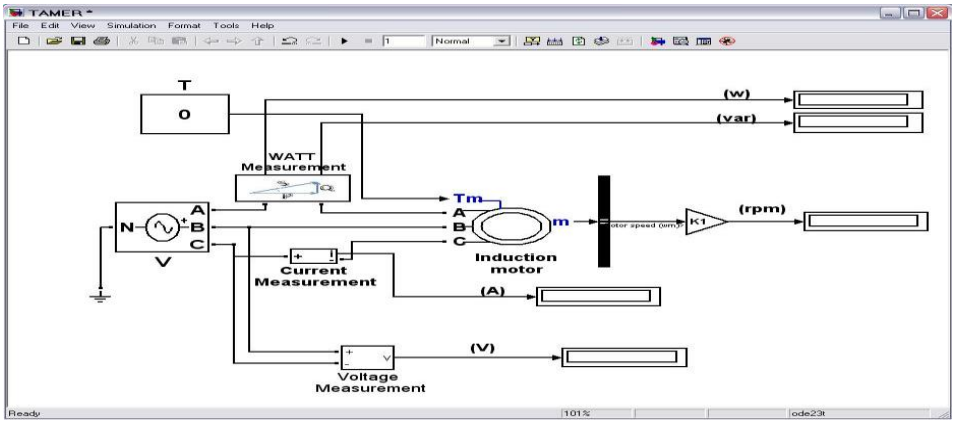
ولحساب الاستطاعة قمنا بإنشاءBlock لقياس الاستطاعة يتألف من: مقياس للتيار و مقياس للتوتر و مقياس الاستطاعة و قيمتان للخرج تعبران عن كل من الاستطاعتين الفعلية و الردية ولجعل هذه Blocks عبارة عن Block واحدة نختار منها الخيار (Craete Subsystem)



الشكل (9) مقياس الاستطاعة المصمم للاختبارات

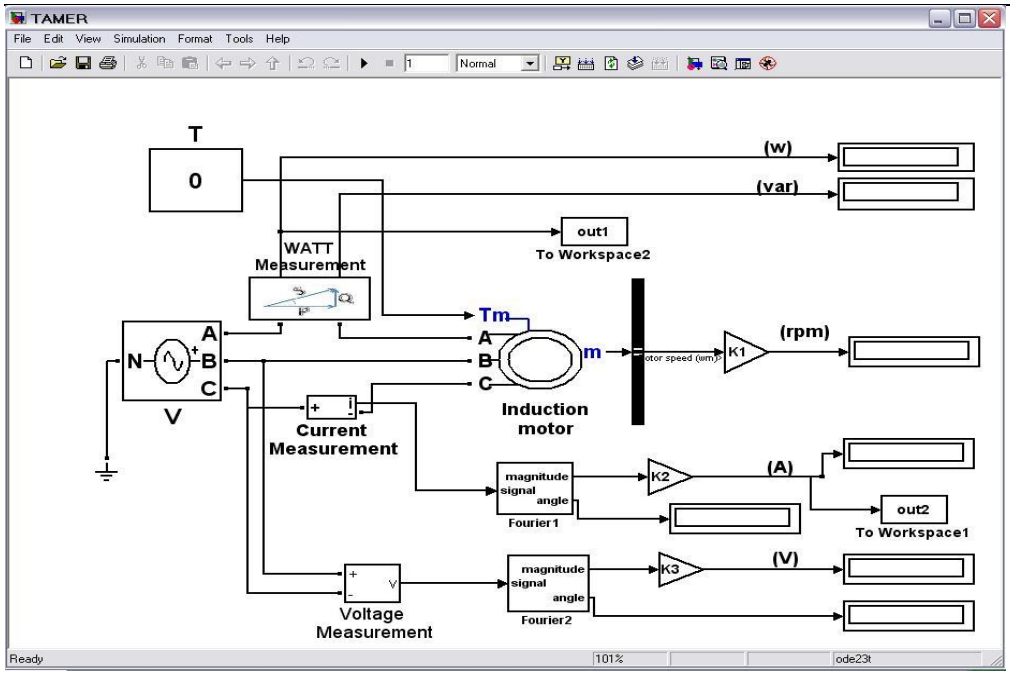
وتصبح عندها هذه الدارة كأنهاBlock واحد له قيمتين للدخل وهما التيار والتوتر وقيمتين للخرج وهما الاستطاعة الفعلية والاستطاعة الرد فعلية أو الرديّة .

وعند إضافة Block حساب الاستطاعة إلى الدارة الرئيسية تصبح الدارة على الشكل التالي :



الشكل (10) الدراة الرئيسية للاختبارات

ولكي نستطيع رسم المنحنيات المميزة لحالة العمل على فراغ قمنا بإضافة صندوق لسحب القيم التي نريد استخدامها إلى (work space) وهو موجود في مكتبة (Simulink) في (Skins) ونغير في إعداداته بحيث تكون القيم التي يسجلها على شكل مصفوفات .ولكي تكون القيم التي يعطيها كل من مقياسي التيار والتوتر قيم فعالة دقيقة و متوافقة مع توازن الأطوار و نظام ODE23T اللاخطي ونظام الإستمرار للقيمة مع الزمن حتى الاستقرار "continous" يوضع صندوق فوريه **[13]**ويوجد هذا الصندوق في مكتبة أنظمة الطاقة (SimPowerSystems) وفي صفحة مكتبات إضافية ضمن أدوات القياس وهذا الصندوق يقوم بتحليل القيم إلى طويلة وزاوية وعلى خرجه نقسم على ($\sqrt{3}$) فيصبح شكل الدارة كما :



الشكل (11) التصميم النهائي لدارة الاختبارات

وقد قمنا برسم بقية الدارات التي استخدمت في بحثنا بطريقة مماثلة للطريقة السابقة مع الأخذ بعين الإعتبار الخصائص المميزة لكل دارة طبقاً لعملها المطلوب .المعلومات التي يجب على الباحث أن يدخلها هي المعلومات التي توجد على اللوحة الاسمية لأي محرك تحريضي: التوتر الاسمي ، التيار الاسمي ،السرعة الاسمية ، التردد الاسمي ،الاستطاعة الاسمية ، عامل الاستطاعة ، نوع المحرك التحريضي وطريقة توصيل ملفات الثابت للمحرك .

وقد قمنا بتزويد البرنامج بعدد من هذه اللوحات المأخوذة من لوحات اسمية لمحركات تحريضية لكي يستطيع من يستخدم البرنامج لأول مرة أن يتعرف عليه بحيث تكون المنحنيات والقيم التي يظهرها البرنامج صحيحة ومتناسقة بالنسبة لهذه المحركات .

لتغيير بارامترات أي عنصر موجود في SIMULINK إلى قيم يريدها المبرمج أو المستخدم نستخدم التعليمة التالية :set_param('اسم العنصر','القيم المطلوب تغييرها',[القيم الجديدة])

بعد تشغيل البرنامج نختار ملف – فتح ونختار ملف (محاكاة)فتظهر النافذة بالشكل التالي بعد إدخال القيم الافتراضية المأخوذة من لوحة اسمية للمحرك المراد اختباره من الملف :



الشكل (12) الواجهة الرئيسية لإدخال بارامترات اللوحة الاسمية

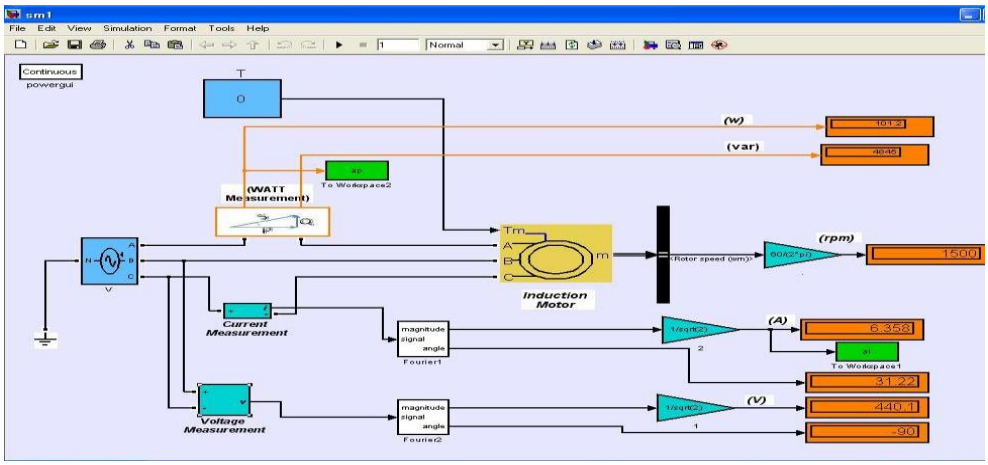
عند الضغط على زر نمذجة المحرك التحريضي ننتقل للصفحة التالية :



الشكل (13) واجهة محاكاة الاختبارات الرئيسية الثلاثة

أولاً:اختبار اللاحمل:

نضغط على"محاكاة اختبار اللاحمل" فتظهر الدارة التالي و بالضغط على "Enter" تعمل :



الشكل (14) دارة اختبار اللاحمل

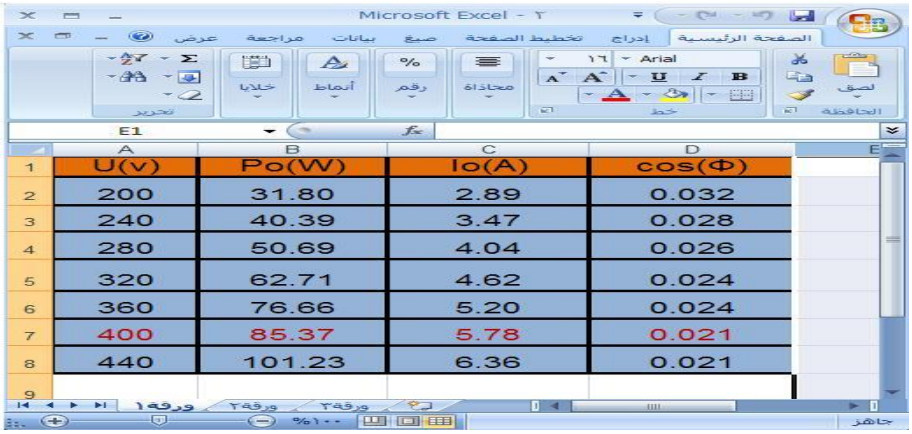
عند تنفيذ (عمل) الدارة نلاحظ أن البرنامج يقوم في كل خطوة بإعطاء قيمة للتوتر وهي من 0.5- Un (1.1) ويحاكي الدارة مع بقاء قيمة العزم المطبق مساوية للصفر (أي بدون حمل) في كل مرحلة و يقيس بالمقابل قيم التيار و الاستطاعة ويحفظها بذاكرته وذلك لاستدعائها عند حساب العلاقات و رسم المنحنيات ، وبعد الانتهاء من عمل الدارة نضغط على "نتائج الاختبار" فتظهر لنا النتائج الأولية من التجربة وهي عناصر الدارة الفرعية للدارة المكافئة :



الشكل (15) نتائج محاكاة دارة اللاحمل

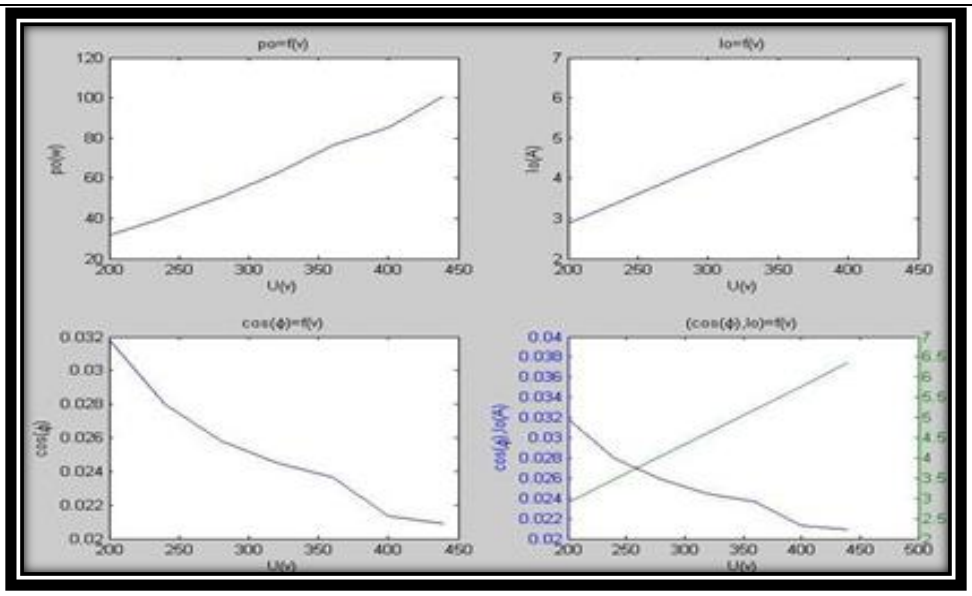
ويمكن إظهار جدول النتائج بالضغط على "جدول اللاحمل" فيظهر الجدول التالي :

الجدول (2) جدول نتائج محاكاة دارة اللاحمل



U(v)	Po(W)	Io(A)	cos(Φ)
200	31.80	2.89	0.032
240	40.39	3.47	0.028
280	50.69	4.04	0.026
320	62.71	4.62	0.024
360	76.66	5.20	0.024
400	85.37	5.78	0.021
440	101.23	6.36	0.021

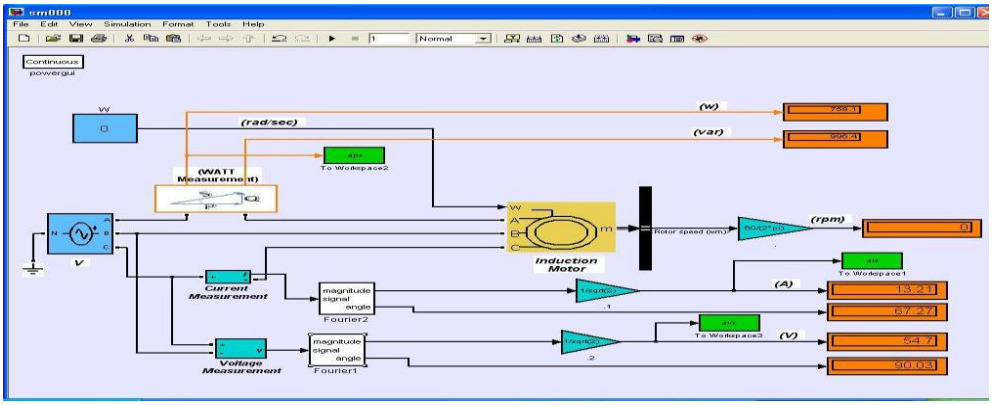
ويمكن إظهار منحنيات اللاحمل بالضغط على "منحنيات اللاحمل" فيقوم البرنامج برسم المنحنيات تبعاً لقيم نتائج الدارة حيث نلاحظ ازدياد تيار اللاحمل مع زيادة التوتر المطبق:



الشكل (16) منحنيات نتائج دارة اللاحمل

ثانياً :اختبار القصر (Short Circuit Test) :

الغرض من الاختبار تحديد الممانعات التسريبية (Leakage Reactances) والمقاومات :



الشكل (17) دارة اختبار القصر

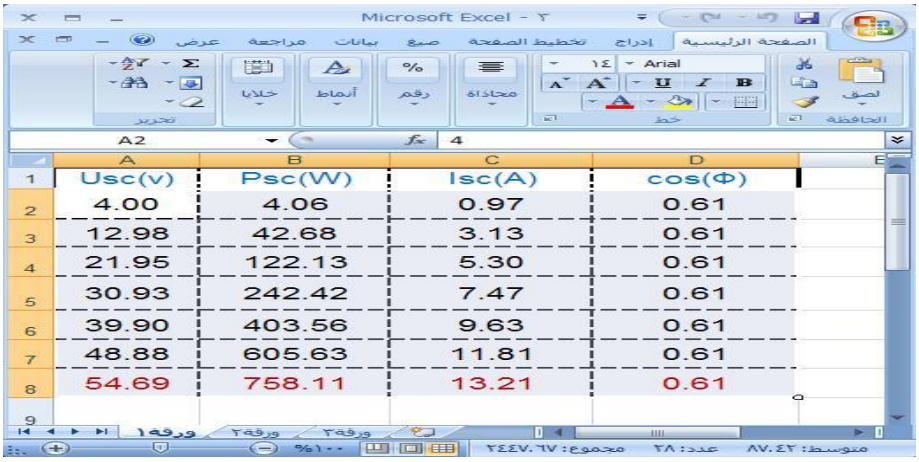
يتم تنفيذ الاختبار والمحرك في حالة كبح حيث طبقنا عليه سرعة زاوية معدومة ($\omega = 0$) و يتم في كل خطوة إعطاء قيمة للتيار وهي من (0 وحتى Isc)حيث يكون($Isc = In$) فقط لتجنب الاجهادات الحرارية و يقيس بالمقابل قيم التوتر والتيار و الاستطاعة ويحفظها بذاكرته وذلك لاستدعائها عند حساب العلاقات و رسم المنحنيات ، و بعد الانتهاء من عمل الدارة نضغط على زر "نتائج الاختبار" فتظهر لنا النتائج الأولية :



الشكل (18) نتائج محاكاة دارة القصر

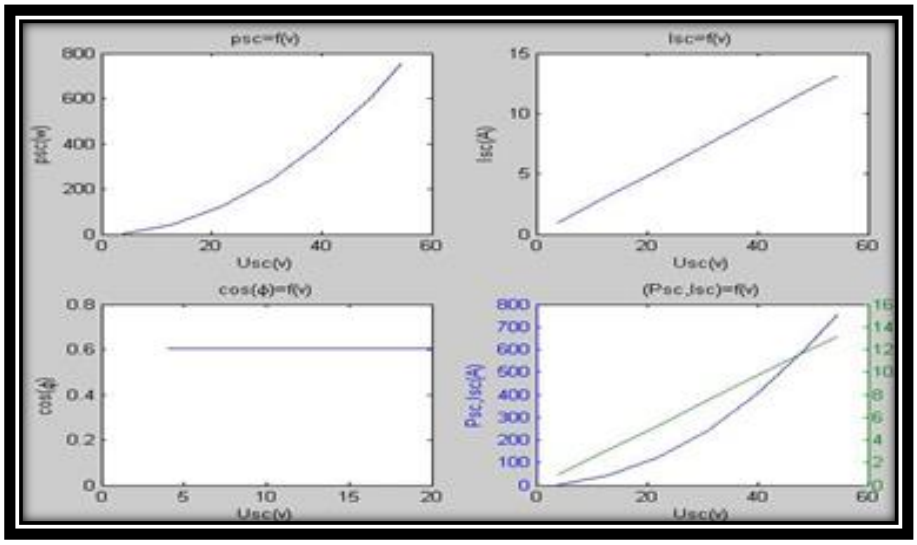
ويمكن إظهار جدول النتائج بالضغط على "جدول القصر" فيظهر الجدول التالي :

الجدول (3) جدول نتائج محاكاة اختبار القصر



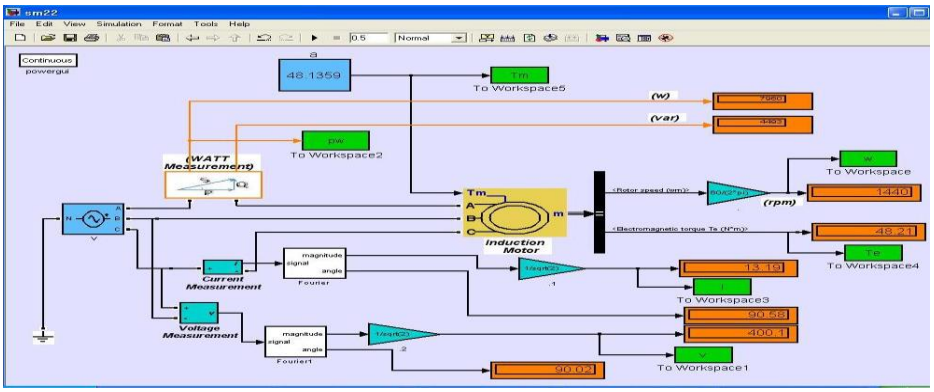
Usc(v)	Psc(W)	Isc(A)	cos(Φ)
4.00	4.06	0.97	0.61
12.98	42.68	3.13	0.61
21.95	122.13	5.30	0.61
30.93	242.42	7.47	0.61
39.90	403.56	9.63	0.61
48.88	605.63	11.81	0.61
54.69	758.11	13.21	0.61

ويمكن إظهار منحنيات القصر بالضغط على "منحنيات القصر" فيقوم البرنامج برسم المنحنيات تبعاً لقيم نتائج الدارة حيث نلاحظ ثبات عامل الاستطاعة مع زيادة تيار القصر:



الشكل (19) منحنيات نتائج محاكاة دارة القصر

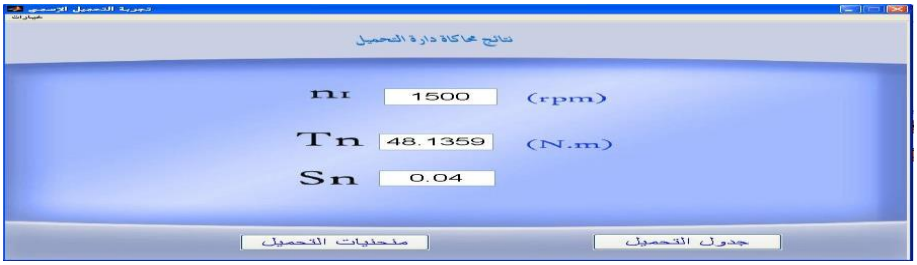
ثالثاً :اختبار التحميل (Load Test) :



الغرض من الاختبار قياس الأداء الكامل للمحرك تحت ظروف التشغيل الفعلية :

الشكل (20) دارة اختبار التحميل

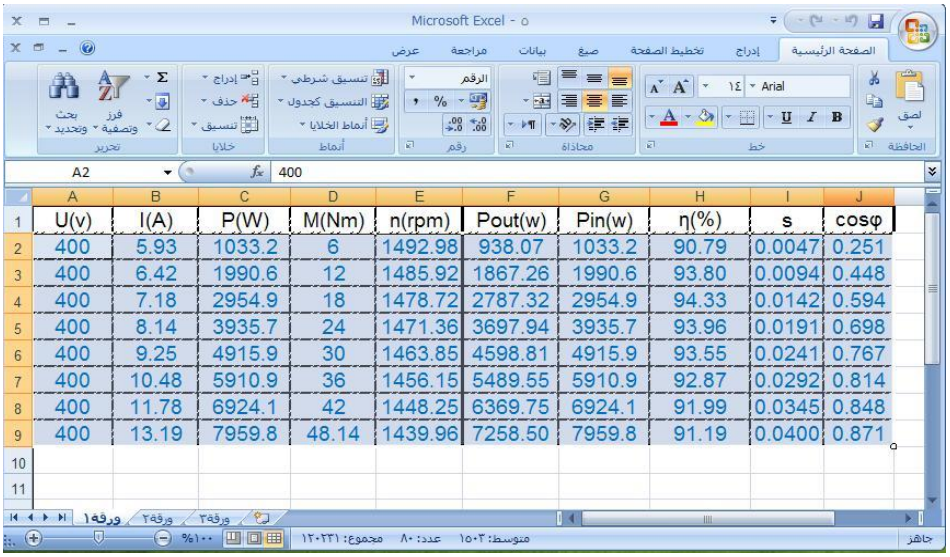
ونقوم بتنفيذ هذا الاختبار بتغيير حمولة المحرك وتثبيت قيم التوتر والتردد وذلك من خلال تغيير العزم المطبق على المحرك من (0 وحتى Tn) وفي كل مرة يقوم البرنامج بقياس التيار والتوتر والسرعة وعزم الخرج (العزم الميكانيكي) ويسجل القيم في ذاكرته ليستفيد منها في رسم المنحنيات المميزة لحالة عمل المحرك ، وبعد الانتهاء من عمل الدارة نضغط على زر "نتائج الاختبار" فتظهر لنا النتائج الأولية :



الشكل (21) نتائج محاكاة دارة التحميل

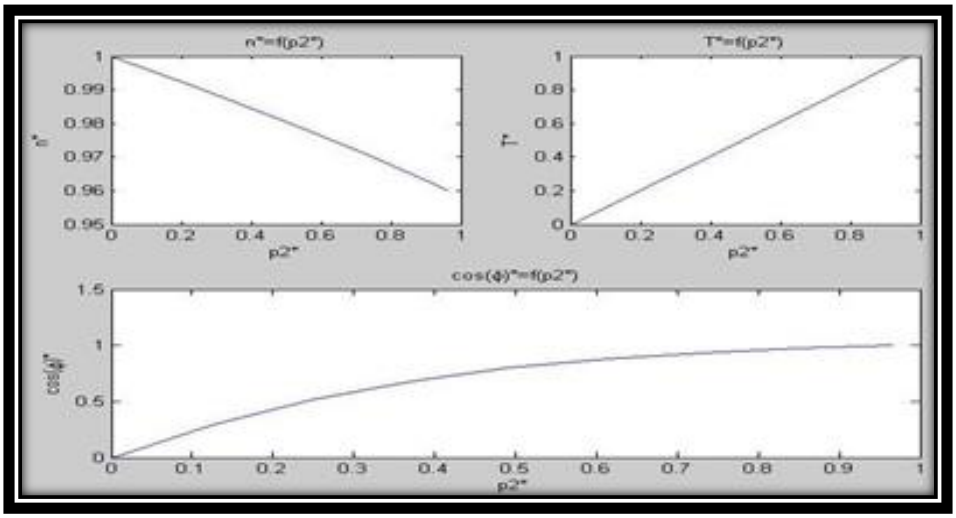
ويمكن إظهار جدول النتائج بالضغط على "جدول القصر" فيظهر الجدول التالي :

الجدول (4) جدول نتائج محاكاة دارة التحميل



U(v)	I(A)	P(W)	M(Nm)	n(rpm)	Pout(w)	Pin(w)	η(%)	s	cosφ
400	5.93	1033.2	6	1492.98	938.07	1033.2	90.79	0.0047	0.251
400	6.42	1990.6	12	1485.92	1867.26	1990.6	93.80	0.0094	0.448
400	7.18	2954.9	18	1478.72	2787.32	2954.9	94.33	0.0142	0.594
400	8.14	3935.7	24	1471.36	3697.94	3935.7	93.96	0.0191	0.698
400	9.25	4915.9	30	1463.85	4598.81	4915.9	93.55	0.0241	0.767
400	10.48	5910.9	36	1456.15	5489.55	5910.9	92.87	0.0292	0.814
400	11.78	6924.1	42	1448.25	6369.75	6924.1	91.99	0.0345	0.848
400	13.19	7959.8	48.14	1439.96	7258.50	7959.8	91.19	0.0400	0.871

ويمكن إظهار منحنيات التحميل فيقوم البرنامج برسم المنحنيات تبعاً لقيم نتائج الدارة :



الشكل (22) منحنيات نتائج محاكاة دارة التحميل

حيث نلاحظ مع زيادة العزم المطبق على الخرج يزداد سحب التيار و تنخفض السرعة

7-تحليل نتائج اختبارات المحاكاة باستخدام أدوات الذكاء الاصطناعي :

يعتبر دمج الذكاء الاصطناعي مع محاكاة المحرك التحريضي من أحدث الأبحاث في الهندسة الكهربائية و يسمى التوأم الرقمي المعزز بالذكاء الاصطناعي .

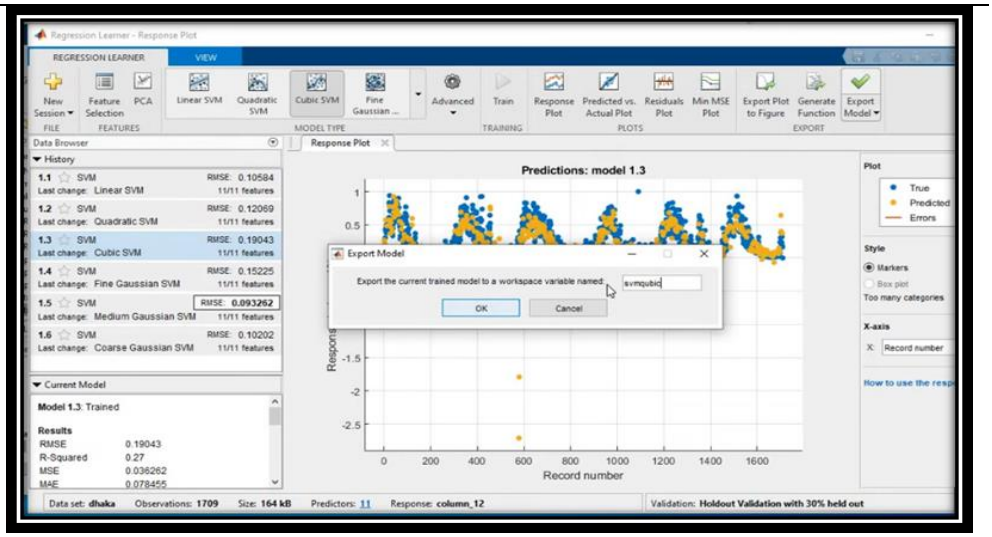
الهدف من استخدم أدوات الذكاء الاصطناعي هو فهم الكميات الهائلة من بيانات المحاكاة و استخلاص العلاقات بين التصميم و الأداء و التنبؤ بسلوك المحرك في ظروف لم تتم محاكاتها بعد كما يمكن تحليل الأعطال و تحسين التصميم (optimization) بتحقيق افضل موازنة بين (أعلى عزم بأقل حرارة و أقل وزن و اقل تكلفة) **[16]**.

بعد تصميم النموذج و اجراء المحاكاة نقوم بتنظم المخرجات في قاعدة البيانات حيث أن المدخلات هي بارمترات التصميم للوحة الاسمية و المخرجات هي نتائج المحاكاة من تيار و عزم و معامل قدرة و....**[14]** **[15]**.

لاختيار أداة الذكاء الاصطناعي لتحليل البيانات حيث سنحتاج إلى بيئة برمجية تستطيع قراءة بيانات المحاكاة و تطبيق خوارزميات الذكاء الاصطناعي عليها نجد أن الأداة **Regression Learner** الأقوى و الأكثر مرونة سواء بمقارنته مع أدوات الذكاء الاصطناعي للمحادثة العامة أو أدوات الذكاء الاصطناعي المختصة بتحليل البيانات و الاحصاءات للأرقام العامة لذا تم اعتماده في هذا البحث .

Regression Learner : تتيح لنا هذه الأداة استرداد البيانات مباشر من Excel أو Workspace كما يمكن تجربة العشرات من النماذج بنقرة زر و مقارنة أدائها بشكل تلقائي كما تصور النتائج برسوم بيانية تفاعلية و يتم تصدير النموذج النهائي إلى كود**[17]**.

نقوم باستيراد جداول البيانات التي تعبر عن برامترات التصميم من Predictors و نأخذ النتيجة المرجوة من Response لنحصل على نمذج ذكاء اصطناعي يتنبأ بكفاءة التصميم في أجزاء من الثانية .



الشكل (23) أداة الذكاء الاصطناعي Regression Learner

تم تقديم النموذج الاولي للأداة Regression Learner في الاصدار MATLAB R2017 لذا فإنها غير متوفرة في الإصدارات القديمة كما يجب تثبيت Statistics and Machine Learning Toolbox لضرورة التشغيل **[18]**.

كما يمكننا استخدام Response plot و predicted vs Actual لمعرفة أي بارمتر في تصميم المحرك هو الأكثر تأثيراً على الأداء ، كما يمكن اجراء تدريب تلقائي لجميع النماذج مع جدول مقارنة لاختيار الأفضل من خلال TRAIN ALL . Scatter Plot : لبيان مدى دقة التنبؤات مقارنة بالمحاكاة الحقيقية حيث كلما اقتربت النقاط المرسومة من الخط البياني كان النموذج أفضل . Residuals Plot : يوضح لنا بالضبط أخطاء النموذج المقترح .

أخيراً نقوم بالتصدير إلى workspace لاستخدام الفوري أو إلى Simulink للمحاكاة كما يمكن انشاء كود برمجي في MATLAB . الخطوات العملية للبحث :

1) نجهز البيانات في ملف Excelو نفتحMATLABو نكتب regression Learner
2) نسترد البيانات بالظغط على New Session و نختر الجداول مع تحديد متغيرات الادخال و متغيرات الإخراج .

3) نختر مجموعة نماذج (مثلاً All Trees) ثم نضغط Train .
4) نقارن بجدول الدقة RMSE , R-squared في القائمة اليمنى .
5) نحسن من الاعدادات بتجريب نماذج أخرى غير خطية مثلاً .
6) بعد اختيار أفضل نموذج نضغط على Export Model .

```
% استيراد البيانات
data = readtable('نتائج_محاكاة_المحرك.xlsx');
% تحديد المدخلات والمخرجات
predictors = data{:, {'تيار_التغذية' ,'عدد_اللفات' ,'
response = data.كفاءة_المحرك;
% تدريب نموذج (Bagged Trees = Random Forest)
model = fitrensemble(predictors, response, 'Me
% تقييم النموذج
predictions = predict(model, predictors);
plot(response, predictions, 'o');
xlabel('القيم الحقيقية'); ylabel('القيم المتوقعة');
```

إن قيم RMSE و R-squared تعتبران مقاييس إحصائية تستخدم لتقييم أداء النماذج :

1- **RMSE** هو متوسط حجم أخطاء النموذج Root Mean Square Error أي مقدار الاختلاف بين توقعات النموذج و القيم الفعلية في المتوسط و في بحثنا وصلنا لقيم صغيرة تتراوح بين 1.0 إلى 1.5 من وحدات القيم المقاسة في مختلف نماذج اختبارات المحرك الاحمل و القصر و التحميل أي قريبة جداً من القيم الحقيقية بدون قيم شاذة.

2- **R-squared** : هو مقياس لنسبة التباين في القيم الحقيقية التي يفسرها النموذج و في بحثنا وصلنا لقيم مرتفعة تصل إلى 0.92 أي تفسر أكثر من 92 % لمعظم القيم .

و بالتالي تعتبر النماذج المستنتجة ضمن البحث جيد و يمكن الاعتماد عليها بناءاً على قيم RMSE المنخفضة المعبرة عن حجم الخطأ بالوحدات الملموسة و قيم R-squared المرتفعة المعبرة عن الكفاءة ، و بمقارنتها مع الأبحاث السابقة **[5]** و **[6]** و **[7]** الحديثة نجدها أفضل و

أحسن مع امكانية التطوير و التوسع المستقبلي، و كمثال عن النتائج يوضح الجدول التالي (5) مقارنة بين قيمة Req المحاكاة و المخبرية في اختبار اللاحمل :

اختبار اللاحمل	simulation	experiment	Error %
Req	1.44 Ω	1.43 Ω	0.70 %

8-مجال الذكاء الاصطناعي المعتمد في البحث و الخوارزمية المستخدمة لتحليل النتائج :

إن من أهم التحديات الحديثة التي تواجه النمذجة والمحاكاة هي التكامل مع الذكاء الاصطناعي لذا تم الاعتماد على الأداة **Regression Learner** في مجال التعلم الآلي "**خوارزمية تعلم الانحدار**" التي تنسجم مع بيئات البرمجة مثلMATLAB و تستخدم لتدريب ومقارنة نماذج الانحدار حيث أنها مصممة لتبسيط عملية تعلم الآلة بدلاً من كتابة أكواد معقدة ، يمكننا من خلالها استيراد البيانات و تدريب النماذج و مقارنتها و تحسينها حيث أن :

- **الانحدار :(Regression)** هي تقنية إحصائية تُستخدم للتنبؤ بقيمة عددية مستمرة بناءاً على بيانات وعلاقات سابقة.
- **المتعلم :(Learner)** في التعلم الآلي(Machine Learning) ، تعني "الخوارزمية" أو "النموذج" الذي يتعلم من البيانات لإجراء هذه التنبؤات .

أهم ميزات هذه الاداة : واجهة سهلة – تدريب تلقائي – تقييم النماذج و مقارنتها عبر جزر متوسط مربع الخطأ RMSE و معامل التحديد R-squared – التحسين optimization

كما يمكن تصدير النموذج بإرساله إلى ساحة العمل و إنشاء كود برمجي في الماتلاب مع إمكانية النشر في Simulink .

لذا تعتمد هذه الأداة على تقنيات تعلم الآلة **Machine Learning** بهدف التنبؤ بالقيم المستمرة بناءاً على مجموعة مدخلات حيث تتعلم النماذج العلاقة بين هذه المتغيرات .

سنوضح بالجدول التالي (6) مقارنة بين الخوارزميات المختلفة حسب المعيار :

المعيار	تعلم الآلة Regression Learner	الأنظمة الخبيرة Expert Systems	التحكم الضبابي Fuzzy logic	الشبكات العصبونية Neural networks
مصدر المعرفة	البيانات الرقمية	خبرة الإنسان	معرفة غامضة	البيانات

طبيعة المعرفة	تعلم ضمني	منطق ثنائي	منطق متعدد	صندوق أسود
الشفافية و التفسير	متوسطة إلى عالية	عالية جداً	عالية جداً	منخفضة جداً
المرونة و التعلم	قوية جداً	ضعيفة جداً	متوسطة	قوية جداً جداً
متطلبات التشغيل	بيانات كثيرة	خبراء	معرفة مهندس	بيانات ضخمة جداً

كما توفر لنا هذه الأداة مجموعة واسعة من الخوارزميات الجاهزة أهمها :

- الانحدار الخطي(Linear Regression):التنبؤ بقيم مستمرة باستخدام علاقة خط مستقيم .
- **أشجار القرار للانحدار (Regression Trees):**توقع القيم عبر تقسيم البيانات إلى بنية هرمية تشبه الشجرة وهي الخوارزمية التي تم اعتمادها ضمن نماذج الاختبارات في بحثنا.

الفكرة الأساسية هي تقسيم مساحة البيانات إلى مناطق أصغر فأصغر بحيث تصبح البيانات في كل منطقة متجانسة من حيث قيمة المخرج ، لتتنبأ الخوارزمية بقيمة رقم مستمر مثل عزم المحرك تسير الخوارزمية في الشجرة من الجزر إلى أقرب ورقة بناءاً على قيم المدخلات ثم تخرج القيمة المخزنة في تلك الورقة و هي غالباً متوسط قيم جميع نقاط التدريب التي وصلت إلى تلك الورقة ، كما تعتمد أشجار القرار على خوارزمية CART (CLASSIFICATION AND REGRESSION TREES) تعمل على قياس النقاء باستخدام التباين و تختار أفضل تقسيم عند الانتقال من العقدة الأم إلى عقد الأبناء .

يكمن دور الخوارزمية في تحليل نتائج المحاكاة بما يلي :

1) تقدير بارامترات النموذج MODEL PARAMETER ESTIMATION :يتم تدرب الشجرة على قاعدة بيانات ضخمة لمحركات حقيقية تربط بين بيانات بسيطة من كتالوج المصنع (استطاعة ، السرعة ، معامل القدرة ، .....) و بين البارامترات الدقيقة للنموذج و هذه الطريقة تكون أسرع و أقل حساسية لأخطاء القياس .
2) التحقق من صحة النموذج MODEL VALIDATION : يتم تدريب شجدرة القرار على بناء نموذج بديل باستخدام بيانات مأخوذة من محاكاة مرجعية معروفة الدقة أو من قياسات

مخبرية فعلية على محرك حقيقي (تيار ، جهد ، ...) و يصبح هذا النموذج المدرب هو المقياس الأساسي المرجعي .

من خلال استخدامنا لهذه الأداة تم تحسين المحاكاة عن طريق تحديد أفضل المتغيرات حيث توفر لنا رسوم بيانية لمدى تأثير كل متغير (جهد ، عزم ، ...)على المخرج ،كما تم فهم القرارات حيث يمكننا رؤية شجرة القرار كمخطط انسيابي يمنحنا الثقة في منطق النموذج بعكس الشبكات العصبونية ،كما تم اختيار النموذج المناسب اعتماداً على مقياس RMSE .

عند التطبيق العملي جمعنا البيانات ضمن جداول وجعلنا أعمدة المدخلات تمثل ظروف التشغيل حسب نوح الاختبار و أعمدة المخرجات القيم المستهدفة ثم بعد فتح الأداة من تبويب APPs قمنا باستيراد البيانات و حددنا المخرجات كـ Respone و الباقي كـ predictors ، و في التدريب و الاختيار قمنا باختيار عدة نماذج Trees و قارن بينها بمقياس RMSE .

9-النتائج و مناقشتها :

1) أثبت هذا البحث أن النمذجة الرياضية و المحاكاة الحاسوبية ليستا مجرد أدوات نظرية بل هما عمودا التصميم الحديث لأنظمة القيادة الكهربائية. تبدأ الرحلة بنموذج دقيق ومعقد في الإطار الطبيعي ABC، ثم يتم تبسيطه عبر تحويل بارك إلى نموذج dq القابل للتحكم، وأخيراً يتم اختبار وتنقيح هذا النموذج وأي خوارزميات تحكم مصممة له في بيئة محاكاة آمنة ومرنة مثل Simulinkولضرورة تحقيق أقصى كفاءة ستستمر النمذجة والمحاكاة في التطور نحو مزيد من الدقة و السرعة والتكامل بين التخصصات .
2) أظهرت النتائج أن محاكاة اختبارات المحرك التحريضي في MATLAB يوفر الوقت ويقلل من الجهد المطلوب من الباحث ، مما يجعل المنصة المقترحة أكثر كفاءة . علاوة على ذلك، أظهر المحرك التحريضي أداءً مستقراً فيما يتعلق بالتيار و الطاقة الفعالة و الغير الفعالة و معامل القدرة ، أخيراً قورنت نتائج التقنية المقترحة بنتائج المعايير المقاسة وتبين أنها توفر تقديرات دقيقة بانحراف لا يتجاوز ±2% عن المعايير المقاسة.
3) أوضحت نتائج محاكاة اختبار اللاحمل قيم تيار العمل على فراغ و الضياعات الأساسية بالإضافة لجدول اللاحمل و منحنيات العمل على فراغ .

4) أوضحت نتائج محاكاة اختبار القصر الممانعات والمقاومات التسريبية بالإضافة إلى جدول القصر و منحنيات العمل على القصر .
5) أوضحت نتائج محاكاة اختبار التحميل العزم و الانزلاق و السرعة الإسمية بالإضافة إلى جدول التحميل و منحنيات العمل عند حالات مختلفة .
6) أظهر تحليل نتائج محاكاة الاختبارات عن طريق أداة الذكاء الاصطناعي Regression Learner مرونة علية و انسيابية كبير في التعديل و المقارنة ، مما يحفز الباحثيين على استخدام هذه الأداة بشكل دائم مع أي عملية محاكاة مستقبلية .
7) لربط الأسس النظرية بالتطبيق العملي وفرت المحاكاة المقترحة للاختبارات الافتراضية بيئة آمنة وفعالة للطلاب لتعلم طرق الاختبارات و تحليل النتائج في الآلات الكهربائية .

10-الاستنتاجات و التوصيات :

1) مع توافر أدوات الذكاء الاصطناعي Artificial Intelligence Tools المجانية و المدفوعة و توافر البرامج الهندسة التخصصية المدعومة من AI أصبح من الممكن التوسع في نمذجة و محاكاة أي نوع من أنواع الآلات الكهربائية و بطريقة الذي يريدها البحث عن طريق تصميم برنامج عام وشامل مع ضمان نتائج دقيقة للمخرجات و سرعة عالية في المحاكاة إضافة لسهولة التعامل وحسن الإظهار .
2) بالطرق التقليدية الباحث مُحكم بعدد المقايس و الأجهزة ومنصة التجارب أما بالبرنامج فيوجد مرونة أكبر حيث يمكننا إضافة أو حذف أي مقياس أو جهاز بكل سهولة .
3) بالطرق التقليدية النتائج تقريبية وليست دقيقة بسبب عمر التجهيزات و كفاءتها ، أما بالبرنامج فالنتائج ذات دقة عالية جداً وحساسة لأي تغير بسيط (خاصة simulink)
4) بالطرق التقليدية يوجد خطورة على المستخدم لتماسه المباشر مع الآلة و الضغط على الأزرار و القواطع الكهربائية و أي خطأ بالتوصيل يمكن أن يسبب خطورة كبيرة على الأجهزة و المستخدم

، أما بالبرنامج فيكتفي بالضغط على زر لوحة المفاتيح لإنجاز أي عملية فالأمور أكثر أماناً و أسهل تعاملاً .

5) بالطرق التقليدية هناك كلفة عالية جداً ثمن الآلات و الأجهزة و المقاييس وهذا يتناسب مع كفاءتها ، أما بالبرنامج فالجانب الإقتصادي واضح ...

6) نوصي بتطبيق مختلف طرق الإقلاع بدارات محاكاة بـ(SIMULINK) و استخلاص القيم من المحاكاة و وضعها ضمن جدول ومن ثم رسم منحنيات الإقلاع(w=f(T,I)).

7) نوصي بتطبيق مختلف أنظمة الكبح بدارات محاكاة بـ(SIMULINK) و استخلاص القيم من المحاكاة و وضعها ضمن جدول ومن ثم رسم منحنيات الكبح المختلفة (w=f(T,I)).

8) نوصي بزيادة عدد الأبحاث المستقبلية المتعلقة بالاستفادة من أدوات الذكاء الاصطناعي و تطبيقاته في النمذجة والمحاكاة لمختلف أنواع الآلات الكهربائية .

المراجع (References)

1) الدكتور المهندس جرجس سليم سعادة . الآلات الكهربائية 4 الآلات التحريضية . جامعة حمص

2) Chitra, V.; Prabhakar, R. (**2006**) – **Induction motor speed control using fuzzy logic controller** – World Acad. Sci. Eng. Technol. 17–22.

3) Elnaghi, B.E.; (**2019**) – **Load test of induction motors based on PWM technique using genetic algorithm**– Int. J. Eng. Manuf.

4) Jirdehi, M.A.; Rezaei, A. (**2016**) – **Parameters estimation of squirrel**–**cage induction motors using ANN and ANFIS**– Alex. Eng. J357–368.

5) Nurfatihah Syalwiah Rosli , Rosdiazli Ibrahim , Idris Ismail , Madiah Omar (**2022**)– **Modeling of high voltage induction motor cooling system using linear regression mathematical models** – research article/plos one/Malaysia–p.24

6) Pradeep Katta , Karunanithi Kandasamy , Ramesh Subramanian and Chandrasekar Perumal (2022)- **Regression Based Performance Analysis and Fault Detection in Induction Motors by Using Deep Learning Technique** - Vol. 11 N. 3 / India .

7) Kehinde Adeleye Makinde , Mutiu Shola Bakare , Uthman Oluwatosin Zubair (2023) - **Simulation based testing and performance investigation of induction motor drives using matlab Simulink** -SN Applied Sciences/journal p.14 .

8) Wang, H.; Chau, K.; Lee, C.H.; Cao, L.; Lam, W.H. (2020) - **Design, Analysis, and Implementation of Wireless Shaded-Pole Induction Motors IEEE Trans** - Ind. Electron. 6493–6503.

9) Rahaman, N.; Govindraju, H. (2014) -**Modeling and Simulation of a Three-Phase Electric Traction Induction Motor Using MATLAB/ Simulink**- Int. J. Electr. Electron. Comput.

10) Rajput, S.; Bender, E.; Averbukh, M. (2020) - **Simplified algorithm for assessment equivalent circuit parameters of induction motors**- IET Elec. Power Appl. 14, 426–432.

11) Maleki, M.G.; Chabanloo, R.M.; Farrokhifar, M. (2019) -**Accurate coordination method based on the dynamic model of overcurrent relay for industrial power networks taking contribution of induction motors into account**- IET Gener. Transm. Distrib., 645–655.

12) Duan, N.; Ma, X.; Lu, S.;Wang, S.; Wang, S. (2021) -**Simulation Calculation of Loss of Induction Traction Motor**- In The Proceedings of the 9th Frontier Academic Forum of Electrical Engineering; Springer: Berlin/Heidelberg, Germany, pp. 599–606.

13) Elnaghi, B.E.; Mohammed, R.H.; Dessouky, S.S.; Shehata, M.K. (2019) –**Load test of induction motors based on PWM technique using genetic algorithm**– Int. J. Eng. Manuf. 9, 1.

14) Iegorova; Miroshnyk ; Savchenko. (2020) –**Improving the accuracy of determining the parameters of induction motors in transient starting modes**– Energetika 66, 15–23.

15) Chen, J.; Severson, E.L. (2019) –**Design and modeling of the bearingless induction motor**– In Proceedings of the IEEE International Electric Machines Conference (IEMDC), San Diego, USA, pp. 343–350.

16) Goolak, S.; Gubarevych, O.; Yermolenko, E.; Slobodyanyuk, M.; Gorobchenko, O.(2020) – **Mathematical modeling of an induction motor for vehicles**– East. J. Enterp. Technol. 2, 104.

17) Hameed H. S., Al Azze Q., and Hasan M. S., (2023)–**Speed control of switched reluctance motors based on fuzzy logic controller by MATLAB / Simulink**– vol. 31, no. 2, pp. 647–657,doi:10.11591/ijeecs.

18) Giuseppe Ciaburro , (2024) **– MATLAB for Machine Learning –** part 4 , from classic methods to deep learning , new verision .

تطوير نظام ذكي للكشف المبكر عن مرض التوحد

[1]ريمان الحاج أحمد [2]د.خالد عمر

الملخص

يُعد اضطراب طيف التوحد (Autism Spectrum Disorder – ASD) من الاضطرابات النمائية العصبية المعقدة التي تؤثر على وظائف الدماغ والسلوك، ولا سيما مهارات التواصل والتفاعل الاجتماعي. ونظرا لأهمية الكشف المبكر في تحسين فرص التدخل العلاجي ورفع جودة الحياة لدى الأطفال المصابين، شهدت الأبحاث الحديثة توجها متزايدا نحو توظيف تقنيات الذكاء الاصطناعي والتعلم العميق في دعم عمليات التشخيص الطبي. يهدف هذا البحث إلى تطوير نظام ذكي للكشف المبكر عن اضطراب طيف التوحد اعتماداً على تحليل صور الوجه باستخدام نموذج Xception العميق. ركزت الدراسة على تحسين مراحل المعالجة المسبقة للبيانات وتصميم البنية المعمارية للنموذج من أجل تعزيز الأداء التشخيصي. تم تدريب النموذج باستخدام مجموعة بيانات حقيقية تضم صور أطفال بخصائص متنوعة، مع تطبيق تقنيات تحسين إضافية أثناء عملية التدريب. جرى تقييم أداء النموذج باستخدام عدة مؤشرات، من بينها الدقة والحساسية والقدرة التمييزية. أظهرت النتائج كفاءة عالية للنظام المقترح في التمييز بين الفئات، مما يؤكد إمكانيته كأداة داعمة للكشف المبكر عن التوحد والمساهمة في تحسين التدخل العلاجي وفهم السمات الوجهية المرتبطة بهذا الاضطراب.

الكلمات المفتاحية: اضطراب طيف التوحد، الأنظمة الذكية، الشبكات العصبية العميقة، التعلم العميق.

1 ريمان الحاج احمد طالبة ماجستير دراسات عليا في الجامعة الافتراضية، برنامج علوم الويب .
2 د. خالد عمر رئيس قسم الذكاء الإصطناعي في كلية الهندسة المعلوماتية، جامعة دمشق.

Developing an intelligent system for early detection of autism

Reman Alhaj Ahmad1, Dr. Khaled Omar2
[1] Master Student, Web Science Academic Program, Syrian Virtual University SVU, Syria (E-mail: reman_206339@svuonline.org).
[2] Head of the Artificial Intelligence Department at the Faculty of Informatics Engineering, Damascus University, Syria (E-mail: kh.om.mail@gmail.com)

Abstract

Autism Spectrum Disorder (ASD) is a complex neurodevelopmental disorder that affects brain function and behavior, particularly social communication and interaction skills. Given the importance of early detection in improving therapeutic interventions and enhancing the quality of life of affected children, recent research has increasingly focused on the use of artificial intelligence and deep learning techniques to support medical diagnostic processes. This study aims to develop an intelligent system for the early detection of Autism Spectrum Disorder based on facial image analysis using the deep Xception model. The research emphasizes improving data preprocessing stages and optimizing the model's architectural design to enhance diagnostic performance. The model was trained using a real-world dataset comprising facial images of children with diverse characteristics, with additional optimization techniques applied during the training process. The system's performance was evaluated using multiple metrics, including accuracy, sensitivity, and discriminative ability. The results demonstrate high effectiveness of the proposed system in distinguishing between classes, confirming its potential as a supportive tool for early autism detection and for improving therapeutic intervention and understanding facial features associated with Autism Spectrum Disorder.

KEYWORDS: Autism Spectrum Disorder, Intelligent Systems, Deep Neural Networks, Deep Learning.

1. المقدمة:

في ظل التطورات المتسارعة في قطاع الرعاية الصحية الحديثة، أصبح الكشف المبكر عن اضطرابات النمو العصبية، وعلى رأسها اضطراب طيف التوحد (ASD)، ضرورة ملحة لما له من دور أساسي في تحسين جودة حياة الأطفال المصابين وتعزيز فرص التدخل العلاجي الفعال على المدى الطويل. يُعد اضطراب طيف التوحد من أكثر الاضطرابات النمائية العصبية تعقيداً وانتشاراً، إذ يؤثر بشكل مباشر على مهارات التواصل الاجتماعي والسلوك والقدرات الإدراكية [1]. وغالبا ما يُظهر الأطفال المصابون بالتوحد أنماطا سلوكية وتعلمية غير نمطية، مثل السلوكيات المتكررة أو الاهتمام المفرط بأشياء محددة. وتشير الإحصاءات الحديثة الصادرة عن مركز السيطرة على الأمراض والوقاية منها (CDC) إلى تزايد ملحوظ في انتشار الاضطراب، حيث سُجّلت حالة واحدة من كل 36 طفلا بعمر 8 سنوات في الولايات المتحدة [2]. كما تؤكد بيانات شبكة رصد التوحد والإعاقات النمائية (ADDM) تضاعف معدلات التشخيص بين عامي 2000 و2021 [3]. وعلى الرغم من هذا الانتشار المتزايد، لا يزال التشخيص المبكر يمثل تحدياً بسبب دقة الأعراض الأولية وتباين مظاهرها، فضلًا عن اعتماد الطرق التقليدية على التقييمات السريرية السلوكية. ومع التقدم في تقنيات الذكاء الاصطناعي والتعلم العميق، برزت إمكانات واعدة لتحليل البيانات البصرية، ولا سيما صور الوجه، باعتبارها مصدراً غنياً بالمؤشرات المرتبطة باضطراب طيف التوحد. وفي هذا السياق، يسعى هذا البحث إلى تطوير نظام ذكي يعتمد على تحليل صور الوجه لدعم الكشف المبكر عن اضطراب طيف التوحد وتحسين دقة وموضوعية التشخيص مقارنة بالأساليب التقليدية.

2. هدف البحث:

يهدف هذا البحث إلى تطوير نظام ذكي للكشف المبكر عن اضطراب طيف التوحد اعتماداً على تحليل صور الوجه باستخدام تقنيات الذكاء الاصطناعي والتعلم العميق. يعتمد النظام على نموذج Xception كشبكة أساسية مع دمج وحدة الانتباه CBAM لاستخلاص السمات الوجهية الدقيقة ذات الدلالة التشخيصية. كما تم تحسين جودة البيانات وتطبيق تقنيات تدريب متقدمة لضمان استقرار النموذج ورفع

دقته. جرى تقييم النظام باستخدام مقاييس إحصائية شاملة على مجموعة اختبار مستقلة للتحقق من موثوقية الأداء.

3. مواد وطرق البحث:

اعتمدت هذه الدراسة على لغة البرمجة Python لتطوير النظام المقترح، نظراً لمرونتها وانتشارها الواسع في تطبيقات الذكاء الاصطناعي والتعلم العميق. تم تنفيذ النموذج باستخدام بيئة Google Colab، لما توفره من بنية حوسبة سحابية تفاعلية ودعم لوحدات المعالجة الرسومية (GPU) لتسريع تدريب النماذج العميقة. استُخدم إطارا TensorFlow و Keras لبناء وتدريب نموذج Xception ودمج وحدة الانتباه CBAM وضبط خوارزميات التحسين. كما تم توظيف مكتبات OpenCV و PIL لمعالجة الصور وتنفيذ مراحل المعالجة المسبقة، إلى جانب NumPy و Pandas للمعالجة العددية وإدارة البيانات. أُجري تحليل النتائج وتمثيلها بصرياً باستخدام Matplotlib، مع ضمان التوافق بين جميع الأدوات لتحقيق الاستقرار وقابلية إعادة التجربة.

4. الدراسات السابقة:

قام الباحثون في الدراسة [4] بالاستفادة من خصائص وجوه الأطفال المصابين باضطراب طيف التوحد والأطفال الطبيعيين للكشف عن التوحد باستخدام نماذج التعلم العميق VGG16 و Xception القائمة على التعلم بالنقل. اعتمدت المنهجية على مجموعة بيانات من منصة Kaggle تضم 2940 صورة وجه، تم تقسيمها إلى مجموعات تدريب وتحقق واختبار بعد تطبيق المعالجة المسبقة والتقييس. استُخدمت الشبكات العصبية التلافيفية (CNN) لاستخلاص السمات الوجهية الدقيقة تلقائياً عبر طبقات الالتفاف والتجميع والاتصال الكامل. تم تحسين التدريب باستخدام Batch Normalization والإيقاف المبكر ومُحسن RMSprop مع استخدام دالة التنشيط Softmax في طبقة الإخراج لأغراض التصنيف. أظهرت نتائج التقييم تفوق نموذج Xception بدقة بلغت 91% مقارنة بنموذج VGG16 الذي حقق دقة قدرها 78%.

في الورقة البحثية [5] تم تطوير نموذج يعتمد على التعلم بالنقل مبني على معمارية AlexNet لتشخيص اضطراب طيف التوحد من خلال تحليل ملامح الوجه باستخدام صور أطفال مصابين وغير مصابين

بالتوحد من منصة Kaggle. استُخدم نموذج AlexNet المدرب مسبقاً على ImageNet مع إعادة تدريب طبقاته الأخيرة لتلائم مهمة تصنيف التوحد، مع الإبقاء على الطبقات الأولى لاستخلاص السمات العامة. تم تدريب النموذج باستخدام 80% من البيانات والتحقق باستخدام 20%، مع اعتماد خوارزمية SGDM ومعدل تعلم قدره 0.0001 .أظهرت النتائج أداء مرتفعاً للنموذج بدقة وصلت إلى 91%، متفوقا على أساليب تقليدية مثل PCA و CNN التقليدي..

في الدراسة [6] ركز الباحثون على توظيف تقنيات التعلم الآلي في تحليل اضطراب طيف التوحد باستخدام بيانات ديموغرافية وطبية وتصويرية، مع مقارنة عدة خوارزميات تصنيف. استُخدمت خوارزميات مثل SVM و Random Forest و Decision Tree والانحدار اللوجستي، إلى جانب تقنيات التعلم العميق لتحليل بيانات التصوير بالرنين المغناطيسي. تم تطبيق اختيار الميزات وتحليل المكونات الرئيسية (PCA) مع استخدام أسلوب الموازنة العشوائية للبيانات لتحسين أداء المصنفات. أظهرت النتائج تفوق مصنف الفضاء المتجه (SVM) بدقة تصنيف بلغت 96% مقارنة ببقية الخوارزميات. كما بينت الدراسة أن الجنس والعمر واليرقان تُعد من العوامل المؤثرة في اضطراب طيف التوحد، مؤكدة فعالية التعلم الآلي في دعم التشخيص المبكر.

في [7] يقترح هذا البحث أداة فحص إلكترونية سريعة عبر الإنترنت للكشف المبدئي عن اضطراب طيف التوحد اعتماداً على صور وجوه الأطفال.

تعتمد الأداة على نموذج DenseNet من الشبكات العصبية الالتفافية، والمُدرب باستخدام خوارزمية التدرج الفرعي المتحكم به (CSA) لتحسين معدل التعلم ورفع دقة التصنيف.

تم تطوير النظام باستخدام إطار Django بلغة بايثون واستضافته سحابيا، مع آلية بسيطة لرفع الصور ومعالجتها ثم عرض نتيجة التنبؤ ونسبة الثقة.

أظهرت النتائج أداءً مرتفعاً للنموذج بدقة اختبار بلغت 98%، مع قيم متوازنة لمقاييس Precision و Recall و F1 لكلتا الفئتين.

يخلص البحث إلى أن الأداة تمثل وسيلة عملية داعمة للتشخيص المبكر، مع التأكيد على أنها لا تغني عن التقييم الطبي المتخصص.

5. الشبكات العصبية:

1.5 الشبكات العصبية الاصطناعية (ANN):

تُعرف الشبكات العصبية الاصطناعية بأنها نماذج حسابية تحاكي – إلى حدٍ ما – آلية عمل الدماغ البشري من خلال عصبونات مترابطة تعالج المعلومات بصورة مشابهة للخلايا العصبية [8] .

تتكون هذه الشبكات من طبقة إدخال تستقبل البيانات الأولية، وطبقات مخفية مسـؤولة عن معالجة البيانات واستخلاص الأنماط، وطبقة إخراج تُنتج التنبؤ النهائي.

تعتمد الشبكات العصبية على دوال تنشـيط مثل Sigmoid و Tanhو ReLUلإضفاء خاصية اللاخطية وتمكين النموذج من تمثيل العلاقات بين المدخلات والمخرجات.

2.5 الشبكات العصبية العميقة DNN والتعلم العميق Deep Learning :

الشبكات العصبية العميقة هي امتداد للشبكات العصبية الاصطناعية التقليدية، حيث تحتوي على عدد كبير من الطبقات المخفية، مما يسمح لها بتمثيل العلاقات المعقدة داخل البيانات.

يُعد التعلم العميق أحد الفروع المتقدمة للتعلم الآلي، ويعتمد على استخدام الشبكات العصبية الاصطناعية العميقة .

يتميز التعلم العميق بقدرته العالية على التعامل مع كميات ضخمة من البيانات غير المهيكلة مثل الصور،الصوت، والنصوص، وقد أدى ذلك إلى تطور كبير في تطبيقات الذكاء الاصطناعي، خاصة في مجالات الرؤية الحاسوبية ومعالجة اللغة الطبيعية.

بخلاف خوارزميات التعلم الآلي التقليدية التي تعتمد على هندسة الميزات يدوياً، تقوم نماذج التعلم العميق باستخلاص الميزات تلقائياً من البيانات الخام، حيث تتعلم الطبقات الأولى الخصائص البسيطة بينما تتعلم الطبقات العميقة الأنماط الأكثر تعقيداً [9] [20].

3.5 الشبكات العصبية التلافيفية CNNs :

تُعد الشبكات العصبية التلافيفية من أهم نماذج التعلم العميق المستخدمة في مجال الرؤية الحاسوبية Computer Vision ، حيث صُممت خصيصاً لمعالجة البيانات ذات البنية الشبكية مثل الصور والفيديو[9] [10]، وهو ما يجعلها محور هذه الدراسة .

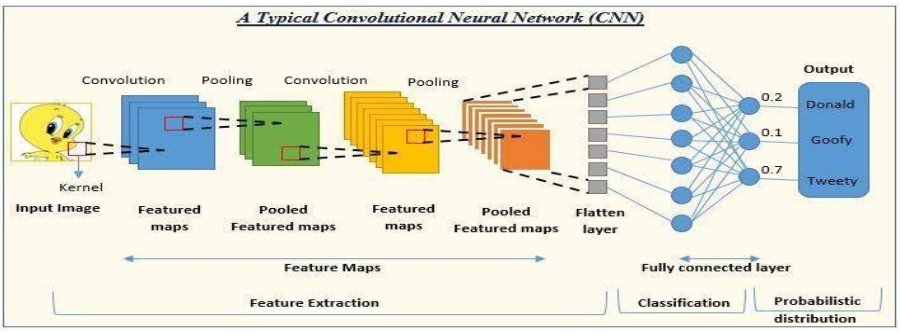
1.3.5 المدخلات والفلاتر في الشبكات العصبية التلافيفية :

تُمثَّل الصور المدخلة إلى الشبكة العصبية التلافيفية على شكل مصفوفات رقمية، حيث تعبر كل قيمة عن شدة بكسل لونية، وتُطبق عليها عمليات رياضية متتالية لاستخلاص الخصائص المهمة.

تُستخدم الفلاتر (Filters) وهي مصفوفات صغيرة الحجم مثل 3×3 أو 5×5تتحرك فوق الصورة لإجراء عمليات الالتفاف، بهدف استخراج الميزات الأساسية كالحواف، الزوايا، والأنماط المتكررة، والتي تُعد مدخلات أساسية لمرحلة التصنيف اللاحقة .

2.3.5 الطبقات الرئيسية في الشبكات العصبية التلافيفية CNN:

تتكون CNN من عدة طبقات أساسية، أبرزها طبقة الالتفاف (Convolutional Layer) التي تُعد جوهر الشبكة، حيث تطبق فلاتر متعددة على البيانات المدخلة. تليها طبقة التجميع (Pooling Layer) التي تُستخدم لتقليل الأبعاد المكانية لخرائط الميزات، مما يقلل التعقيد الحسابي ويحد من الإفراط في التعلم مع الحفاظ على الخصائص المهمة[11]، ومن أشهر أنواعها Max Pooling و Average Pooling. أما الطبقات الكثيفة (Fully Connected Layer) فتقع في نهاية الشبكة، حيث يتم ربط جميع العقد معا لاتخاذ القرار النهائي للتصنيف [12] وفقا للشكل (1) :



الشكل(1) : بنية شبكة عصبية تلافيفية CNN

3.3.5 آلية تدريب الشبكات العصبية التلافيفية CNN:

تتم عملية تدريب الشبكات العصبية التلافيفية من خلال تغذية الشبكة بصور مُسماة (Labeled Images) [8]، حيث تمر الصور عبر طبقات الالتفاف والتجميع لاستخراج الميزات والأنماط المهمة. بعد ذلك، يتم حساب الفرق بين المخرجات المتوقعة والمخرجات الحقيقية باستخدام دالة الخسارة وبالاعتماد على خوارزمية الانتشار العكسي (Backpropagation) وخوارزميات التحسين المبنية على مبدأ الانحدار المتدرج (Gradient Descent) ، يتم تحديث الأوزان والفلاتر تدريجياً بهدف تقليل قيمة الخطأ وتحسين أداء النموذج.

4.5 نماذج التعلم العميق المتقدمة:

مع تطور تقنيات التعلم العميق، ظهرت نماذج متقدمة مثل Xception المعتمدة على مبدأ الالتفاف القابل للفصل[13] (Depthwise Separable Convolutions) ، والذي يفصل بين الالتفاف المكاني والالتفاف عبر القنوات، مما يقلل عدد المعاملات والتعقيد الحسابي مع الحفاظ على دقة عالية. وقد أثبت هذا النموذج كفاءة كبيرة في مهام تصنيف الصور عالية الدقة، لذلك تم اعتماده في هذه الدراسة كعمود فقري للنموذج المقترح لقدراته العالية على استخلاص السمات البصرية الدقيقة المرتبطة بالمؤشرات التشخيصية لاضطراب طيف التوحد، مع تحقيق توازن مناسب بين الدقة والاستقرار الحسابي.

6. منهجية العمل:

يعتمد النظام المقترح على بنية متكاملة لأتمتة الكشف المبكر عن اضطراب طيف التوحد عبر تحليل السمات الوجهية الدقيقة باستخدام التعلم العميق. تبدأ العملية بإدخال صور الأطفال الخام، ثم تمر الصور بمرحلة معالجة مسبقة تشمل اكتشاف الوجه، مواءمته، توحيد الأبعاد، وتحسين الجودة البصرية لتقليل العوامل غير المهمة وتعزيز السمات التشخيصية. بعد ذلك، تُمرر الصور إلى نموذج Xception لاستخلاص السمات الوجهية العميقة تلقائياً، مع دمج وحدة الانتباه CBAM لإعطاء أولوية للمناطق الأكثر دلالة. تُستخدم طبقات النموذج النهائية مع دالة Softmax لإجراء التصنيف الثنائي وتحديد احتمالية انتماء الطفل لفئة المصابين أو غير المصابين.

1.6 مجموعة البيانات (Dataset):

تُعد مجموعة البيانات عنصراً أساسياً في أنظمة التعلم العميق، خاصة في التطبيقات الطبية التي تتطلب دقة ووثوقية عاليتين، إذ يرتبط أداء النموذج المقترح بشكل مباشر بجودة البيانات وتنوعها وطريقة معالجتها. لذلك، تم اختيار مجموعة بيانات مناسبة للكشف المبكر عن اضطراب طيف التوحد اعتماداً على تحليل صور الوجه.



الشكل(2) : عينة من مجموعة البيانات (– سليم، – مصاب)

وهي بيانات حقيقية منشورة عبر منصة Kaggle، مما يعزز قابلية إعادة إنتاج النتائج والشفافية العلمية، حيث تتضمن صور وجوه لأطفال مصنفين إلى فئتين: أطفال مصابون باضطراب طيف التوحد (Autistic) وأطفال غير مصابين (Typical) وقد استُخدم الترميز الثنائي لتمثيل الفئات، بما يتوافق مع مهام التصنيف الثنائي.

ولضمان تقييم موثوق لأداء النموذج، قُسمت البيانات إلى ثلاث مجموعات مستقلة: التدريب، التحقق، والاختبار، مع اعتماد التقسيم الطبقي (Stratified Splitting) للحفاظ على التوزيع النسبي للفئات في جميع المجموعات. تم تحميل البيانات وتنظيمها مباشرة داخل بيئة Google Colab باستخدام Kaggle API، ثم إخضاعها لعمليات المعالجة المسبقة قبل إدخالها إلى نموذج التعلم العميق.

رابط مجموعة البيانات على Kaggle :

https://www.kaggle.com/datasets/remoha/autismdataset

2.6 المعالجة المسبقة للبيانات (Data Preprocessing):

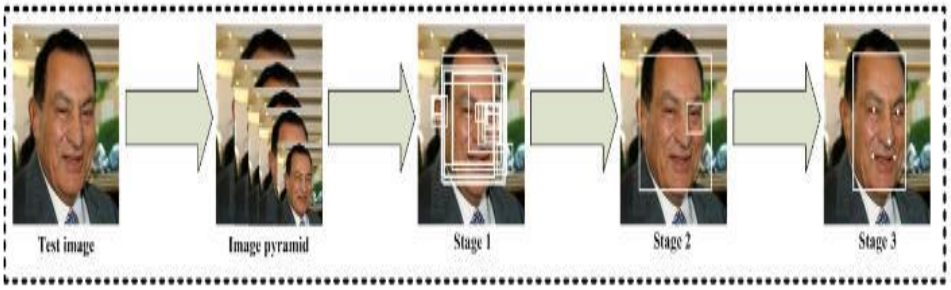
تُعد مرحلة المعالجة المسبقة للبيانات من أهم المراحل في أنظمة التعلم العميق المعتمدة على الصور [14]، إذ تؤثر بشكل مباشر على جودة السمات المستخرجة وعلى الأداء النهائي للنموذج. ونظراً لدقة الفروقات الوجهية المرتبطة باضطراب طيف التوحد، فقد تم تنفيذ سلسلة من الخطوات المنهجية لتحويل الصور الخام إلى مدخلات معيارية مناسبة لنموذج Xception المستخدم في هذه الدراسة، بما يضمن استقرار عملية التعلم وتحسين دقة التصنيف.

في البداية، تم تحميل الصور من المجلدات المخصصة لكل فئة Autistic و Typical، ومن ثم تطبيق خطوات المعالجة المسبقة عليها.

1.2.6 اكتشاف الوجه ومواءمته:

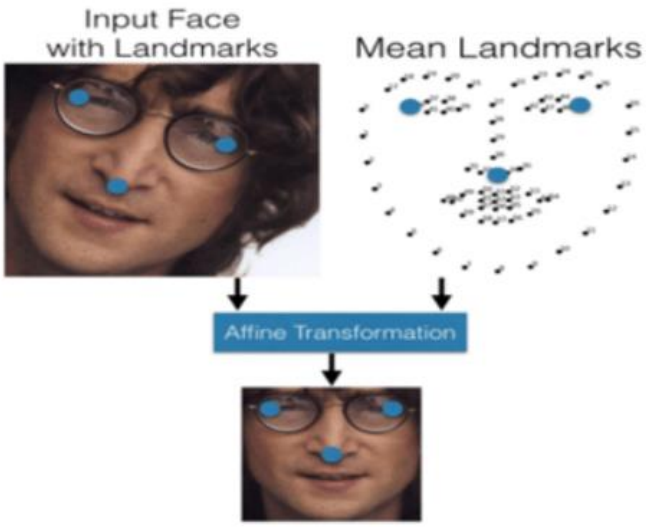
نظراً لاحتمال احتواء الصور الأصلية على خلفيات أو عناصر غير ذات صلة، تم تطبيق مرحلة اكتشاف الوجه ومواءمته كخطوة أساسية في المعالجة المسبقة، لضمان تركيز النموذج على الملامح الوجهية فقط. ولتحقيق ذلك، تم اعتماد خوارزمية MTCNN (Multi-Task Cascaded Convolutional Neural Network)، والتي تُعد من أكثر الخوارزميات دقة وانتشاراً في مجال اكتشاف الوجوه وتحديد المعالم الوجهية الأساسية [15]، مثل مواضع العينين، الأنف، الفم وحدود الوجه. تعتمد خوارزمية MTCNN على بنية متعددة المراحل تتكون من ثلاث شبكات عصبية تلافيفية متتابعة تعمل بشكل تسلسلي. في المرحلة الأولى، تقوم شبكة P-Net بتوليد مقترحات أولية لمواضع الوجوه المحتملة داخل الصورة باستخدام نوافذ منزلقة وعلى مقاييس متعددة، مما يسمح باكتشاف الوجوه الصغيرة والكبيرة. وفي المرحلة الثانية، تتولى شبكة R-Net تصفية هذه المقترحات من خلال استبعاد

المربعات الخاطئة وتحسين دقة تحديد موضع الوجه. أما في المرحلة الثالثة، فتقوم شبكة O–Net بإجراء التحديد النهائي لمواضع الوجوه إلى جانب استخراج المعالم الوجهية الأساسية بدقة عالية وفقاً للشكل (2):



الشكل(3) آلية عمل خوارزمية MTCNN

بعد استخراج المعالم الوجهية، تم تطبيق عملية مواءمة الوجه (Face Alignment) باستخدام تحويل تآلفي (Affine Transformation) ، وذلك من خلال الاستفادة من إحداثيات المعالم الوجهية المكتشفة. تهدف هذه العملية إلى تصحيح ميلان الوجه داخل الصورة، بحيث يتم تدوير الوجه rotation ، تحجيمه scaling وإزاحته translation ليصبح موضع العينين على خط أفقي ثابت وبمواقع نسبية متقاربة بين جميع الصور وفقاً للشكل (3). يساهم ذلك في تقليل الاختلافات الناتجة عن زاوية التصوير أو ميلان الرأس، مما يؤدي إلى توحيد التمثيل الهندسي للوجوه وتحسين اتساق المدخلات قبل تمريرها إلى نموذج Xception ، مما ينعكس إيجاباً على دقة السمات المستخرجة وأداء النظام ككل.



الشكل(4) مواءمة الوجه باستخدام تحويل تآلفي

2.2.6 توحيد أبعاد الصور:

بعد إتمام مرحلة مواءمة الوجه، تم توحيد أبعاد جميع الصور لتتوافق مع متطلبات نموذج Xception، حيث يستقبل النموذج مدخلات بحجم 299×299 بكسل. ممايضمن توافق الصور مع بنية النموذج، وتوحيد شكل المدخلات، ومنع الأخطاء البرمجية أثناء التدريب.

3.2.6 تقييس قيم البكسل (Normalization):

تعد عملية تقييس قيم البكسل خطوة أساسية لتحسين استقرار عملية التعلم. لم يُستخدم في هذه الدراسة التقييس التقليدي بتحويل القيم إلى المجال[0–1] ، بل تم اعتماد دالة preprocess_input الخاصة بنموذج Xception ، التي تقوم بتحويل قيم البكسل من المجال [0–255] إلى [−1,+1] بما يتوافق

مع آلية التقييس المعتمدة أثناء التدريب المسبق للنموذج على مجموعة بيانات ImageNet ، مما يضمن الاستفادة المثلى من الأوزان المسبقة وتحسين سرعة التقارب ودقة النموذج.

4.2.6 زيادة البيانات (Data Augmentation):

نظراً لمحدودية حجم البيانات في التطبيقات الطبية، تم اعتماد تقنيات زيادة البيانات بهدف تعزيز قدرة النموذج على التعميم وتقليل مشكلة فرط التعلم. وقد طُبقت هذه التقنيات حصرياً على بيانات التدريب، مع الإبقاء على بيانات التحقق والاختبار دون أي تحويلات لضمان نزاهة التقييم. شملت الزيادة التقليدية عمليات مثل الانعكاس الأفقي، التدوير المحدود، الإزاحات البسيطة، والتغيير الطفيف في المقياس، وذلك لمحاكاة التنوع الواقعي في ظروف التصوير دون التأثير على السمات الوجهية التشخيصية الأساسية.

إضافة إلى ذلك، تم اعتماد تقنيات زيادة بيانات متقدمة على مستوى الدفعات التدريبية، تمثلت في MixUp و CutMix [16] .

تعتمد **تقنية MixUp** على المزج الخطي بين عينتين عشوائيتين داخل الدفعة نفسها مع دمج تسمياتهما وفق معامل عشوائي λ مستمد من توزيع Beta كما هو موضح في الشكل (4) ، مما يؤدي إلى إنشاء عينات هجينة وتوسيع فضاء البيانات بشكل فعال، يساهم هذا الاسلوب في تقليل فرط التعلم وتنعيم حدود القرار.

الصياغة الرياضية :

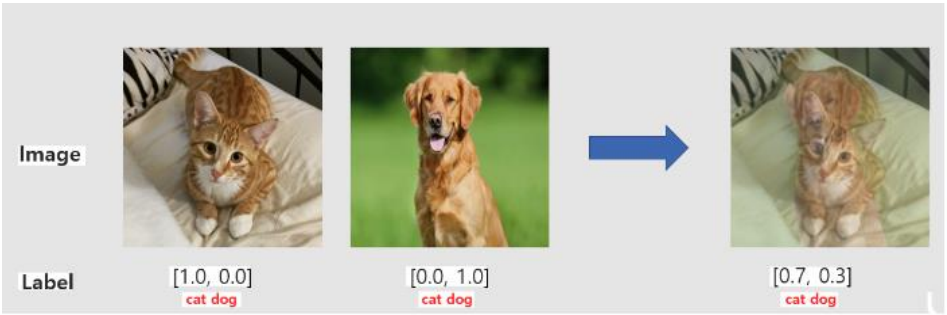
لتكن : $(xi,yi),(xj,yj)$ عينتين عشوائيتين مأخوذتين من نفس الدفعة التدريبية، حيث x تمثل الصورة و y تمثل التسمية المقابلة لها.

يتم توليد معامل المزج: $\lambda \sim Beta(\alpha,\alpha), \lambda \in [0,1]$

ثم تُحسب العينة الجديدة كما يلي:

$$x\sim = \lambda xi + (1-\lambda)xj$$

$$y\sim=\lambda yi+(1-\lambda)yj$$



الشكل (5): عينة جديدة باستخدام تقنية MixUp

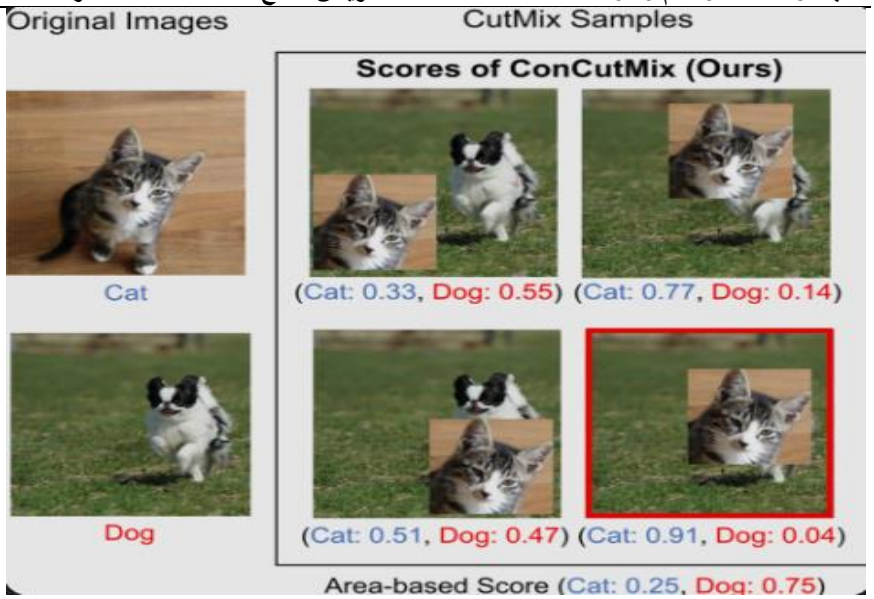
أما **تقنية CutMix** فتعتمد على الدمج الموضعي، حيث يتم استبدال جزء من صورة تدريبية بجزء من صورة أخرى مع تعديل التسمية وفق نسبة المساحة المستبدلة، الأمر الذي يدفع النموذج للتركيز على السمات الجزئية المهمة ويزيد من متانته.

الصياغة الرياضية : لتكن: (xi,yi),(xj,yj) صورتان تدريبيتان

يتم قص منطقة مستطيلة من الصورة xi واستبدالها بمنطقة من الصورة xj كما هو موضح في الشكل (5)، حيث يتم حساب معامل المزج λ وفق نسبة المساحة غير المستبدلة كما يلي:

$$\lambda = 1 - \frac{\text{مساحة الجزء المستبدل}}{\text{المساحة الكلية للصورة}}$$

ثم يتم تعريف التسمية الجديدة وفق المعادلة : $y\sim=\lambda yi+(1-\lambda)yj$



الشكل (6): توليد عينات جديدة للبيانات باستخدام تقنية CutMix

في نهاية مرحلة المعالجة المسبقة، تصبح الصور مكتشفة الوجه، مواءَمة هندسياً، موحدة الأبعاد، ومطبعة القيم، وجاهزة بالكامل للإدخال إلى نموذج Xception وقد أسهم الدمج بين الزيادة التقليدية والمتقدمة في تحسين استقرار عملية التعلم وتعزيز قدرة النموذج على استخلاص السمات الوجهية المرتبطة باضطراب طيف التوحد، مع الحفاظ على دقة ووثوقية التقييم.

3.6 بنية النموذج العميق المقترح:

تم اختيار نموذج Xception كأساس للنظام المقترح للكشف المبكر عن اضطراب طيف التوحد نظراً لقدرته العالية على استخلاص السمات الوجهية الدقيقة اعتماداً على الالتفافات القابلة للفصل عمقياً، مع كفاءة حسابية مناسبة.

يتكون النموذج من ثلاث مراحل رئيسية هي : مرحلة الإدخال(Entry Flow) ، المرحلة الوسطى (Middle Flow)، ومرحلة الإخراج (Exit Flow) .

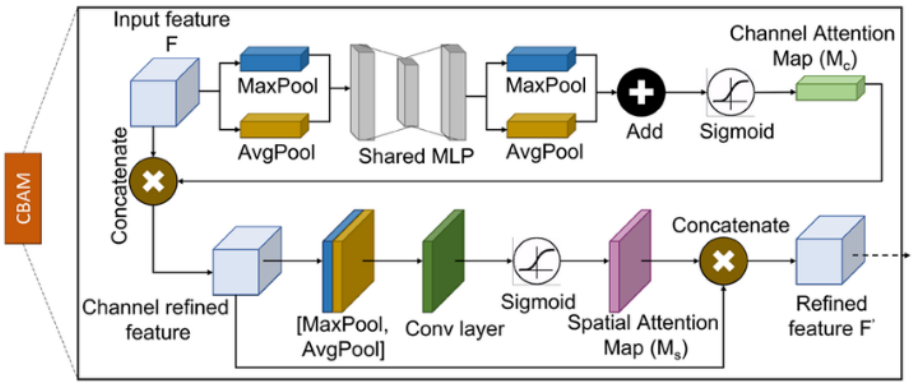
في مرحلة الإدخال، يتم استخلاص السمات الأولية للصورة، مثل الحواف والأنماط البسيطة، والتي تمثل الأساس لفهم البنية العامة للوجه. أما المرحلة الوسطى، فتتكرر فيها وحدات التلافيف القابلة للفصل عدة مرات، مما يسمح بتعلم سمات أكثر تعقيداً، مثل العلاقات المكانية وتوزيع الملامح الوجهية. في حين تركز مرحلة الإخراج على دمج السمات المستخرجة وتحويلها إلى تمثيل عالي المستوى غني بالمعلومات، يُستخدم لاحقاً في عملية التصنيف.

دمج وحدة الانتباه CBAM:

لتعزيز قدرة النموذج على التركيز على المناطق الوجهية ذات الأهمية التشخيصية، تم دمج وحدة الانتباه CBAM (Convolutional Block Attention Module) بعد مخرجات نموذج Xception . تعتمد آليات الانتباه على توجيه تركيز النموذج نحو الأجزاء الأكثر أهمية في البيانات المدخلة بدل معالجة جميع المعلومات بنفس الدرجة[17] . وبالتالي تسهم في إبراز المناطق المرتبطة بالفروقات الدقيقة، مثل العينين والفم وتعابير الوجه، مما يعزز القدرة التمييزية للنموذج.

تتكون وحدة CBAM من مرحلتين متتاليتين تعملان بشكل تكاملي:

- الانتباه القنوي (Channel Attention) : يهدف إلى تحديد القنوات الأكثر أهمية في خريطة السمات، وذلك باستخدام تقنيتي Global Average Pooling و Global Max Pooling، يليهما شبكة عصبية صغيرة مشتركة. تم استخدام معامل تقليل الأبعاد (ratio = 8) لتحقيق توازن بين تقليل التعقيد الحسابي والحفاظ على القدرة التمثيلية للشبكة.
- الانتباه المكاني (Spatial Attention): يركز على تحديد المناطق المكانية الأكثر أهمية داخل الصورة، من خلال دمج خرائط المتوسط والقيمة العظمى عبر القنوات، ثم تطبيق طبقة التفاف بنواة 7×7 متبوعة بدالة Sigmoid لإنتاج خريطة انتباه مكانية وفقاً للشكل (6) :



الشكل (7):مكونات وحدة الانتباه CBAM

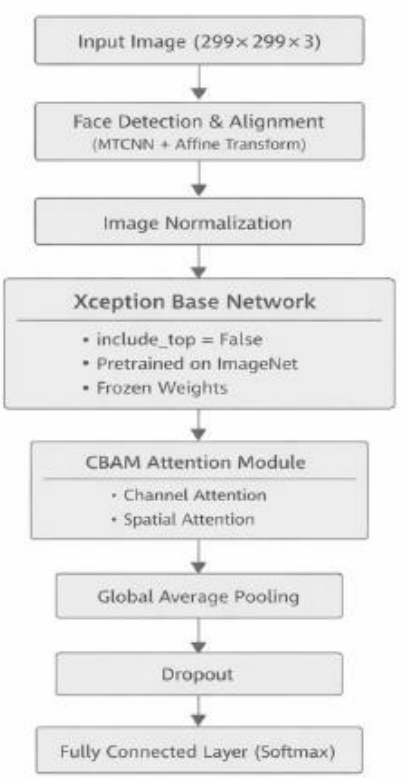
يسهم هذا التسلسل في تحسين جودة السمات المستخرجة، وزيادة حساسية النموذج للتفاصيل الدقيقة، وتقليل تأثير الاختلافات في الإضاءة والخلفيات، مما يدعم عملية التمييز بين الحالات المصابة باضطراب طيف التوحد وغير المصابة.

الطبقات النهائية للتصنيف(Classification Head)

بعد مرحلة استخلاص السمات وتعزيزها باستخدام وحدةCBAM ، يتم تمرير المخرجات إلى مجموعة من الطبقات النهائية المصممة خصيصاً لأغراض التصنيف. تبدأ هذه المرحلة باستخدام طبقة Global Average Poolingلتقليل الأبعاد المكانية لخريطة السمات وتحويلها إلى متجه سمات مضغوط يمثل المعلومات الجوهرية للصورة[18] .

بعد ذلك، تم تطبيق طبقة Dropout بهدف تقليل الاعتماد الزائد على السمات الفردية أثناء التدريب وتحسين قدرة النموذج على التعميم. وفي النهاية، استُخدمت طبقة كثيفة واحدة بعدد عقد يساوي عدد الفئات (عقدتين 2 Neurons)، مع دالة التفعيل Softmax لإجراء التصنيف الثنائي بين فئتي ASDو Non-ASD وفقا للشكل (7).

توفر دالة Softmax مخرجات احتمالية واضحة تسهل تفسير النتائج، وهو أمر بالغ الأهمية في التطبيقات الطبية، كما تتوافق مع دالة الخسارة Categorical Cross-Entropy المستخدمة أثناء التدريب.



الشكل(8) : البنية العامة للنموذج المقترح المعتمد على Xception مع آلية الانتباه CBAM

4.6 آلية تدريب النموذج وضبط المعاملات:

تم اعتماد تقنية **التعلم بالنقل** (Transfer Learning) في تدريب النموذج المقترح [19] من خلال استخدام نموذج Xception مُدرّب مسبقاً على مجموعة بيانات **ImageNet**، وذلك بهدف الاستفادة من المعرفة البصرية العامة التي تعلمها النموذج، مثل الحواف، والأنماط، والعلاقات المكانية، وهي سمات مناسبة بشكل خاص في ظل محدودية البيانات الطبية.

اعتمدت هذه الاستراتيجية على استبعاد الطبقات النهائية الأصلية الخاصة بالتصنيف ، وتحميل الأوزان المدربة مسبقاً، مع تجميد جميع طبقات النموذج الأساسية خلال المرحلة الأولى من التدريب. وقد أسهم

هذا الإجراء في تسريع عملية التدريب، وتحسين الاستقرار في المراحل الأولية، وتقليل خطر فرط التعلم، مع توجيه عملية التعلم نحو الطبقات المضافة الخاصة بالمهمة التشخيصية.

1.4.6 إعداد بيانات التدريب وخطوط البيانات:

تم تنظيم بيانات التدريب والتحقق باستخدام آليات تحميل ديناميكية تتيح قراءة الصور على دفعات أثناء التدريب. في المرحلة الأولى، تم تحميل الصور من مجلدات منظمة حسب الفئات مع تطبيق المعالجة المسبقة وزيادة البيانات الأساسية.

في المراحل المتقدمة، تم الاعتماد على واجهة tf.data.Dataset لإنشاء خطوط بيانات أكثر كفاءة، حيث أُتيح تطبيق الخلط العشوائي والتحميل المسبق، إضافة إلى تقنيات زيادة البيانات المتقدمة (Cutmix & Mixup). ساهم هذا الإجراء في تحسين كفاءة التنفيذ، تقليل استهلاك الذاكرة، وتعزيز قدرة النموذج على التعميم.

2.4.6 دالة الخسارة وخوارزمية التحسين :

تم استخدام دالة الخسارة Categorical Cross-Entropy بالتزامن مع طبقة Softmax في مخرج النموذج. كما تم تطبيق تقنية Label Smoothing بقيمة= ε (0.05).

ولتحديث أوزان النموذج أثناء التدريب تم اعتماد خوارزمية AdamW، وهي نسخة محسنة من Adam تدعم تطبيق Weight Decay بشكل صريح.

يسهم هذا الأسلوب التنظيمي في الحد من تضخم الأوزان، وتقليل فرط التعلم، وتحسين قدرة النموذج على التعميم، خاصة في البيئات الطبية الحساسة.

3.4.6 معدل التعلم :

نظرا لأهمية معدل التعلم في استقرار التدريب وجودة التقارب، تم اعتماد استراتيجية ديناميكية لضبطه. في مرحلة التدريب الأولي، استُخدمت جدولة Cosine Decay with Restarts مع بدء بمعدل تعلم منخفض نسبياً لضمان تقارب مستقر.

أما في مرحلة Fine-Tuning، فقد تم استخدام معدل تعلم صغير جداً (FT_LR = 8e-6) لتجنب إتلاف الأوزان المدربة مسبقاً وتحقيق تحسين دقيق في الأداء.

4.4.6 حجم الدفعة وعدد الحقب :

تم اعتماد حجم دفعة ثابت (Batch Size = 16) باستخدام واجهةtf.data ، بما يحقق توازنا بين كفاءة استخدام الذاكرة واستقرار التدريب، أما عدد الحقب(Epochs) ، فقد تم تحديده بشكل ديناميكي اعتماداً على أداء النموذج، مع استخدام آلية Early Stopping لمراقبة مقياس AUC على مجموعة التحقق واستعادة أفضل الأوزان المحققة تلقائياً.

5.4.6 آليات التحكم في التدريب:

تم استخدام مجموعة من آليات التحكم لضمان استقرار التدريب، شملت:

- Early Stopping
- Model Checkpoint
- Reduce Learning Rate on Plateau

وقد ساعدت هذه الآليات في تقليل زمن التدريب، منع التذبذب، والاحتفاظ بأفضل نسخة من النموذج بناءً على أعلى قيمة AUC .

6.4.6 تدريب رأس النموذج والضبط الدقيق(Fine-Tuning) :

خلال المرحلة الأولى، تم تدريب الطبقات المضافة فقط(CBAM ، Global Average Pooling، Dropout، وطبقة التصنيف النهائية)، بينما بقيت طبقات Xception الأساسية مجمدة.

بعد الوصول إلى استقرار مقبول، تم الانتقال إلى مرحلة Fine-Tuning من خلال فك تجميد عدد محدود من الطبقات العليا، مع تثبيت طبقات Batch Normalizationللحفاظ على الاستقرار الإحصائي وتقليل التذبذب في الأداء.

بعد الانتهاء من التدريب، تم اختبار النموذج على مجموعة بيانات مستقلة لم تُستخدم أثناء التدريب أو التحقق، دون تطبيق أي زيادة بيانات، وذلك لتقييم القدرة الحقيقية على التعميم والتأكد من أن إجراءات التحسين لم تؤدِّ إلى تحيز زائد.

7. مقاييس التقييم :

في التطبيقات الطبية، قد يؤدي أي خطأ تشخيصي إلى تبعات نفسية وسريرية كبيرة، لا سيما في الاضطرابات النمائية العصبية. لذا، لا يُعد الاعتماد على مقياس الدقة Accuracy وحده كافياً، بل يتطلب الأمر استخدام مقاييس متعددة تُبرز قدرة النموذج على اكتشاف الحالات المصابة فعلياً (الحساسية)، واستبعاد الحالات السليمة (النوعية)، وتحقيق توازن مناسب بين الاكتشاف الصحيح وتقليل الإنذارات الكاذبة.

- **إعداد التنبؤات باستخدام(Test–Time Augmentation (TTA**

يوضح الجدول (1) تأثير استخدام تقنية Test–Time Augmentation (TTA) على أداء النموذج. لوحظ أن تطبيق TTA باستخدام الانعكاس الأفقي أدى إلى تحسن ملحوظ في كل من AUC و F1–score مقارنة بالحالة بدون TTA، مما يشير إلى دور TTA في تعزيز استقرار التنبؤات وتحسين التعميم.

Setting	AUC	Best	Best Threshold
No TTA	0.921	0.853	0.50
TTA (Horizontal Flip)	0.9436	0.8787	0.44

الجدول (1) : تأثير استخدام TTA على اداء النمودج

- **مصفوفة الارتباك(Confusion Matrix)**

تُستخدم مصفوفة الارتباك لتحليل توزيع التنبؤات الصحيحة والخاطئة، وتحديد قيم (TN, FP) (TP FN, وتكتسب هذه الأداة أهمية سريرية خاصة، إذ تُعد الأخطاء من النوع الثاني (FN) أكثر خطورة في سياق التوحد، لأنها تعني عدم اكتشاف حالات مصابة وتأخير التدخل المبكر.

- **المقاييس المعتمدة لتقييم الأداء:**

- الدقة (Accuracy): تمثل النسبة الإجمالية للتنبؤات الصحيحة، إلا أنها قد تكون مضللة في حال عدم توازن البيانات.

$$\textbf{Accuracy= (TP+TN) / (FP+FN+TP+TN)}$$

- الحساسية (Sensitivity / Recall): تقيس قدرة النموذج على اكتشاف الحالات المصابة فعلياً، وتُعد من أهم المقاييس في هذه الدراسة نظراً لأولوية تقليل الحالات غير المكتشفة.

$$\textbf{Sensitivity} = \textbf{TP} / \textbf{FN+TP}$$

- النوعية (Specificity): تقيس قدرة النموذج على التعرف الصحيح على الحالات غير المصابة، وتسهم في تقليل القلق الناتج عن التشخيص الخاطئ.

$$\textbf{Specificity} = \textbf{TN} / \textbf{FP+TN}$$

- الدقة الإيجابية (Precision): تعكس مدى صحة التنبؤات الإيجابية، وتساعد في الحد من الإنذارات الكاذبة.

$$\textbf{Precision} = \textbf{TP} / \textbf{FP+TP}$$

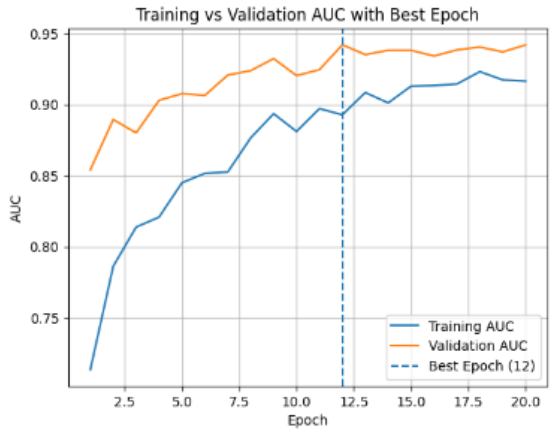
- مقياس F1−score : يجمع بين الحساسية والدقة الإيجابية في قيمة واحدة، ويُعد مناسباً بشكل خاص للبيانات الطبية غير المتوازنة.
- منحنى ROC والمساحة تحت المنحنى(AUC): يُستخدم منحنى ROC لتقييم العلاقة بين معدل الإيجابيات الحقيقية ومعدل الإيجابيات الكاذبة عبر مختلف عتبات القرار، بينما يعبر AUCعن القدرة التمييزية العامة للنموذج.

ويُعد مقياس AUC مناسباً بشكل خاص في تشخيص اضطراب طيف التوحد، لكونه غير متأثر بعدم توازن البيانات، ويقدم تقييماً شاملاً لأداء النموذج بغض النظر عن العتبة المختارة، مما يدعم الاعتماد عليه كنظام مساعد لاتخاذ القرار في التطبيقات الطبية الحساسة.

8. النتائج :

❖ نتائج التدريب والتحقق:

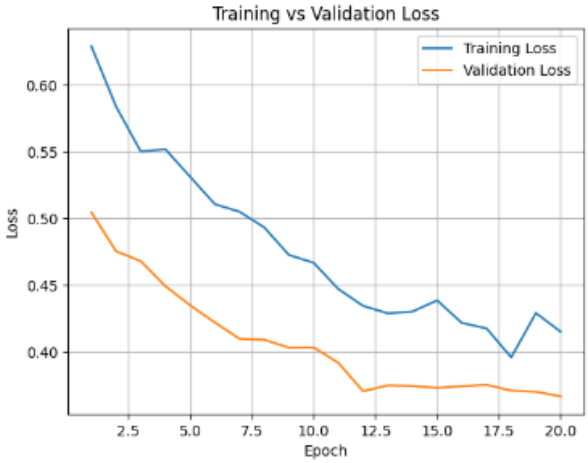
أظهرت نتائج التقييم أن النموذج المقترح يمتلك قدرة عالية على التمييز بين حالات اضطراب طيف التوحد (ASD) والحالات غير المصابة، مع تحقيق توازن مناسب بين الحساسية والنوعية. ويعكس هذا الأداء فعالية دمج نموذج Xception مع استراتيجيات المعالجة المسبقة المتقدمة وآليات التحسين المعتمدة خلال التدريب.



الشكل (9): منحنيات AUC للتدريب والتحقق

يوضح الشكل (8) تطور المساحة تحت منحنى (AUC) لكل من بيانات التدريب وبيانات التحقق. وقد سُجّل أفضل أداء على مجموعة التحقق عند الحقبة الثانية عشرة، حيث بلغت قيمة AUC 0.942، وذلك بالتزامن مع فك تجميد عدد محدود من الطبقات العليا في نموذج Xception بهدف تحسين تمثيل السمات عالية المستوى. ويشير هذا الارتفاع في قيمة AUC إلى قدرة النموذج على التمييز الجيد بين الفئتين، إضافة إلى فعالية آليتي ModelCheckpoint و ReduceLROnPlateau في تحسين الأداء.

بعد هذه الحقبة، لوحظ استقرار واضح في الأداء مع تقارب ملحوظ بين منحنيي التدريب والتحقق، مما يدل على استقرار عملية التعلم وقدرة النموذج على التعميم، ويؤكد فعالية استراتيجيات Fine-Tuning و Early Stopping المعتمدة في هذه الدراسة .



الشكل (10): منحنيات الخسارة loss للتدريب والتحقق

يوضح الشكل (9) منحنيات الخسارة لكل من بيانات التدريب والتحقق عبر 20 حقبة تدريبية. نلاحظ انخفاضاً تدريجياً في خسارة التدريب، يقابله انخفاض مستقر في خسارة التحقق، مما يشير إلى تحسن أداء النموذج وقدرته على التعميم. كما يُلاحظ استقرار خسارة التحقق بعد الحقبة الثانية عشرة، وهي الحقبة التي حقق عندها النموذج أفضل قيمة لمقياسAUC ، مما يبرر اعتماد آلية الإيقاف المبكر (Early Stopping) لتفادي فرط التعلم.

يعرض الجدول (2) أفضل نموذج تم اختياره اعتماداً على أعلى قيمة لمقياس AUC على مجموعة التحقق، وذلك باستخدام آلية الإيقاف المبكر وتخفيض معدل التعلم عند ثبات الأداء.

البند	القيمة	البند	القيمة
أفضل حقبة)	12	Training Loss	0.4344
Training AUC	0.8927	Validation Loss	0.3704
Validation AUC	**0.9420**	Learning Rate	8×10^{-6}
Training Accuracy	0.8860	Early Stopping	نعم
Validation Accuracy	0.8800	Reduce LR on	نعم

الجدول (2): ملخص أفضل أداء للنموذج

❖ **نتائج تقييم النموذج على مجموعة الاختبار:**

بعد تحديد أفضل نموذج بناءً على أداء مجموعة التحقق، تم تحميل الأوزان المحفوظة واختبار النموذج على مجموعة بيانات اختبار مستقلة تتكون من 300صورة موزعة بالتساوي بين الفئتين.

أظهرت نتائج التقييم أن النموذج حقق أداءً متميزاً على مختلف مقاييس التقييم الإحصائية، ويمكن تلخيصها كما يلي:

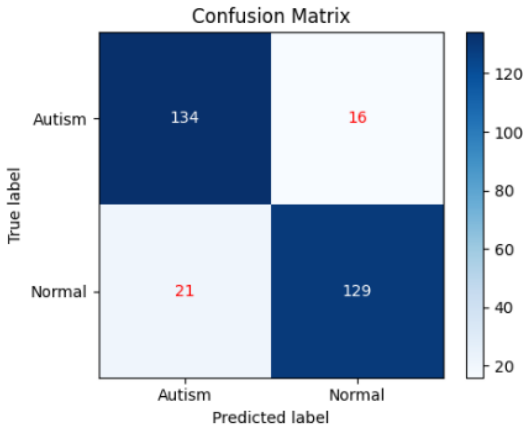
- **الدقة** : بلغت دقة التصنيف الإجمالية 87.67%، مما يدل على قدرة جيدة للنموذج على التنبؤ الصحيح عبر الفئتين.
- **المساحة تحت منحنى (AUC)**: حقق النموذج قيمة AUC = 0.9436، وهي قيمة مرتفعة تعكس قدرة قوية على التمييز بين الحالات المصابة وغير المصابة عبر مختلف قيم العتبة.
- **مقياس F1−score** : بلغ أفضل مقياس F1 قيمة 0.8787عند عتبة تصنيف مقدارها 0.44، وهو ما يعكس توازناً جيداً بين الحساسية والدقة الإيجابية، وهو أمر بالغ الأهمية في التطبيقات الطبية.

الفئة	Precision	Recall	F1-score
Non-ASD	0.8897	0.8600	0.8746
ASD	0.8645	0.8933	0.8787

الجدول (3) : مقاييس تقييم اداء النمودج المقترح حسب الفئات

تشير هذه النتائج إلى أن النموذج أظهر قدرة أعلى على اكتشاف الحالات المصابة فعلياً، وهو أمر بالغ الأهمية في السياق الطبي.

تحليل مصفوفة الارتباك:



الشكل(11): مصفوفة الارتباك

يوضح الشكل (10) مصفوفة الارتباك الخاصة بأفضل نموذج، حيث أسفرت النتائج عن:

- **(TP)** True Positives عددها **134** حالة، وتمثل الحالات المصابة التي صُنفت بشكل صحيح.
- **(TN)** True Negatives عددها **129** حالة، وتمثل الحالات غير المصابة التي صُنفت بشكل صحيح.
- **(FP)** False Positives عددها **21** حالة، وهي حالات غير مصابة صُنفت خطأ كمصابة.
- **(FN)** False Negatives عددها **16** حالة فقط لم يكتشفها النموذج وهو معدل منخفض نسبياً، ويُعد مؤشراً إيجابياً في سياق التشخيص الطبي حيث يُفضل تقليل الحالات غير المكتشفة.

مناقشة النتائج:

تعكس النتائج المحققة فعالية الدمج بين:

- القوة التمثيلية العميقة لنموذج Xception
- دقة آلية الانتباه CBAM في إبراز السمات التشخيصية المهمة
- تقنيات تحسين الأداء مثل Fine-Tuning ، ضبط العتبة، وTTA

كما أن تحقيق قيمة AUC مرتفعة (0.9436) يشير إلى أن النموذج لا يعتمد فقط على نمط واحد من السمات، بل يمتلك قدرة قوية على التعميم والتمييز.

علاوة على ذلك، فإن الأداء المتوازن بين الفئتين، وعدم انحياز النموذج نحو فئة دون أخرى، يعززان من موثوقيته في التطبيقات الطبية الواقعية.

9. التوصيات :

بناءً على نتائج هذه الدراسة، يُوصى بما يلي:

- اعتماد مقاييس مثل AUC و Recall كمؤشرات أساسية في تشخيص ASD
- عدم الاكتفاء بالدقة (Accuracy) وحدها
- استخدام TTA في أنظمة التشخيص المعتمدة على الصور
- التركيز على تقليل False Negatives في التطبيقات الطبية
- تحسين جودة وتوازن مجموعات البيانات الطبية

13. المراجع :

[1]. Autism spectrum disorder (2023). Retrieved from World Health Organization: https://www.who.int/news-room/fact-sheets/detail/autism-spectrum-disorders

[2]. Autism Spectrum Disorder (ASD) (2023). Retrieved from Centers for Disease Control and Prevention: https://www.cdc.gov/ncbddd/autism/facts.html

[3]. Autism and Developmental Disabilities Monitoring (ADDM) Network (2023).Retrieved from Centers for Disease Control and Prevention: https://www.cdc.gov/autism/about/?CDC_AAref_Val

[4] .A. F. Rashid and S. H. Shaker ،
"Autism Spectrum Disorder Detection Using Face Features Based on Deep Neural Network"،Wasit Journal of Computer and Mathematical Science، vol. 2, no. 1, pp. 112–120, 2023. [Online].
Available: https://doi.org/10.31185/wjcm.100

[5]. T. M. Ghazal, S. Munir, S. Abbas, A. Athar, H. Alrababah, and M. A. Khan,"Early Detection of Autism in Children Using Transfer Learning,"Intelligent Automation & Soft Computing, 2023.
[Online].Available: https://doi.org/10.32604/iasc.2023.030125

[6]. M. A. Mareeswaran and K. Selvarajan,
"A Computational Intelligent Analysis of Autism Spectrum Disorder Using Machine Learning Techniques," IAES International Journal of Artificial Intelligence (IJ-AI),
vol. 13, no. 1, pp. 807–816, 2024. [Online].
Available: https://doi.org/10.11591/ijai.v13.i1.pp807-816

[7]. M. Ikermane and A. El Mouatasim,
"Web-Based Autism Screening Using Facial Images and Convolutional Neural Network,"
Indonesian Journal of Electrical Engineering and Computer Science,
vol. 29, no. 2, pp. 1140–1147, 2023. [Online].
Available: https://doi.org/10.11591/ijeecs.v29.i2.pp1140-1147

[8]. Goodfellow, I., Bengio, Y., & Courville, A.
Deep Learning, 1st ed.Cambridge, MA: MIT Press, 2016.
[Online]. Available: https://www.deeplearningbook.org

[9]. LeCun, Y., Bengio, Y., & Hinton, G.
Deep learning. *Nature*, vol. 521, pp. 436–444, 2015.
[Online]. Available: https://doi.org/10.1038/nature14539

[10]. O'Shea, K., & Nash, R.
An introduction to convolutional neural networks.
arXiv preprint arXiv:1511.08458, 2015.
[Online]. Available: https://arxiv.org/abs/1511.08458

[11]. Deeb, M., et al. 2024- Enriching NeuMF System with Full Data Features Using Attention-Based Deep Learning Models to Improve Ratings Prediction, Journal of Homs University vol. 46, no. 9 , pp. 85-128 [In Arabic]. https://journal.homs-univ.edu.sy/index.php/Engineering/article/view/6012

[12]. Dumoulin, V., & Visin, F.
A guide to convolution arithmetic for deep learning.
arXiv preprint arXiv:1603.07285, 2016.
[Online]. Available: https://arxiv.org/abs/1603.07285

[13]. Chollet, F.
Xception: Deep learning with depthwise separable convolutions.
Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1251–1258, 2017.
[Online]. Available: https://doi.org/10.1109/CVPR.2017.195

[14]. Shorten, C., & Khoshgoftaar, T. M.
A survey on image data augmentation for deep learning.
Journal of Big Data, vol. 6, no. 1, pp. 1–48, 2019.
[Online]. Available: https://doi.org/10.1186/s40537-019-0197-0

[15]. Zhang, K., Zhang, Z., Li, Z., & Qiao, Y.
Joint face detection and alignment using multitask cascaded convolutional networks.
IEEE Signal Processing Letters, vol. 23, no. 10, pp. 1499–1503, 2016.
[Online]. Available: https://doi.org/10.1109/LSP.2016.2603342

[16]. Yun, S., Han, D., Oh, S. J., Chun, S., Choe, J., & Yoo, Y.
CutMix and MixUp: Data augmentation techniques for robust image classification. *arXiv preprint arXiv:1905.04899*, 2019
[Online]. Available: https://arxiv.org/abs/1905.04899

[17] .S. Woo, J. Park, J. Y. Lee, and I. S. Kweon, “CBAM: Convolutional Block Attention Module,” *Proceedings of the European Conference on*

Computer Vision (ECCV), pp. 3–19, 2018. [Online]. Available: https://doi.org/10.1007/978-3-030-01234-2_1

[18]. Lin, M., Chen, Q., & Yan, S.
Network in network.
arXiv preprint arXiv:1312.4400, 2013.
[Online]. Available: https://arxiv.org/abs/1312.4400

[19]. Tan, M., & Le, Q.
EfficientNet: Rethinking model scaling for convolutional neural networks.
Proceedings of the International Conference on Machine Learning (ICML), pp. 6105–6114, 2019.
[Online]. Available: https://arxiv.org/abs/1905.11946

[20]. Kessis, N., et al. 2025-Real-Time Arabic Sign Language Recognition Using Deep Learning, Journal of Homs University vol. 47, no. 3 , pp. 53-86 [In Arabic]. https://journal.homs-univ.edu.sy/index.php/Engineering/article/view/7397

تطوير خوارزمية لموازنة حمل الخوادم في بيئة الشبكات المعرفة برمجياً باستخدام التعلم الآلي

ميساء الضاهر[1] د. ماهر عباس[2] د. محسن عبود[3]

الملخص

تعد الشبكات المعرَفة بالبرمجيات (SDN) إطاراً مرناً وفعالاً لإدارة موارد الشبكة وتوجيه حركة البيانات، مما يجعلها بيئة مثالية لتطبيق استراتيجيات موازنة الحمل بين الخوادم، ومع تطور تقنيات الذكاء الاصطناعي أصبح دمج التعلم الآلي مع SDN خطوة متقدمة نحو تحسين القرارات الشبكية بشكل ذاتي وتنبؤي. هذا الدمج يفتح المجال لشبكات أكثر ذكاءً وتكيفاً قادرة على مواجهة التغيرات اللحظية في الحمل الشبكي. وانطلاقاً من ذلك، تقترح هذه الدراسة خوارزمية جديدة لموازنة الحمل بين الخوادم في بيئة SDN، تعتمد على التنبؤ بزمن استجابة الخوادم باستخدام تقنيات التعلم الآلي بناءً على مؤشرات أداء الخوادم النشطة، مثل استخدام وحدة المعالجة المركزية، استخدام الذاكرة، عرض النطاق الترددي، وعدد الاتصالات النشطة بهدف اختيار الخادم الأمثل الذي يُتوقع أن يقدم أقل زمن استجابة. تم تقييم أداء الخوارزمية المقترحة ضمن بيئة ديناميكية وباختبارات متنوعة ومقارنتها مع خوارزميات Traditional Least Response، Least Bandwidth، Round Robin، وخوارزمية Naive Bayes، ثم تم تحليل النتائج إحصائياً، وقد أظهرت النتائج تفوق الخوارزمية المقترحة على جميع الخوارزميات المُقارن معها.

الكلمات المفتاحية: الشبكات المعرَفة برمجياً، موازنة الحمل، أداء الخوارزميات، التعلم الآلي.

1 ميساء الضاهر طالبة دكتوراه في كلية الهندسة المعلوماتية، قسم هندسة الشبكات والنظم الحاسوبية، جامعة حمص.

2 د. ماهر عباس أستاذ مساعد في كلية الهندسة المعلوماتية، قسم هندسة الشبكات والنظم الحاسوبية، جامعة حمص.

3 د. محسن عبود مدرس في كلية الهندسة المعلوماتية، قسم هندسة الشبكات والنظم الحاسوبية، جامعة حمص.

Developing an Algorithm for Server Load Balancing in an SDN Environment Using Machine Learning

Mayssaa Aldaher1, Dr. Maher Abbas2, Dr. Mohssen Abboud3
[1] PhD Student, Department of Network Engineering and Computer Systems, Homs University, Syria (E-mail: maldaher@homs-univ.edu.sy).
[2] Assistant Professor, Department of Network Engineering and Computer Systems, Homs University, Syria (E-mail: mabbaas@homs-univ.edu.sy)
[3]Lecturer, Department of Network Engineering and Computer Systems, Homs University, Syria (E-mail: mabboud@homs-univ.edu.sy).

Abstract

Software-Defined Networking (SDN) is a flexible and efficient framework for managing network resources and routing data traffic, making it an ideal environment for implementing server load balancing strategies. With the advancement of artificial intelligence (AI) technologies, integrating machine learning with SDN has become a significant step towards improving network decisions autonomously and predictively. This integration paves the way for smarter and more adaptive networks capable of handling real-time changes in network load. Therefore, this study proposes a novel server load balancing algorithm in an SDN environment. This algorithm relies on predicting server response times using machine learning techniques based on active server performance metrics, such as CPU utilization, memory utilization, bandwidth, and the number of active connections. The goal is to select the optimal server expected to offer the lowest response time. The performance of the proposed algorithm was evaluated in a dynamic environment using various tests and compared with Traditional Least Response, Least Bandwidth, Round Robin, and Naive Bayes algorithms. The results were then statistically analyzed, and the results showed that the proposed algorithm was superior to all the algorithms compared with it.

KEYWORDS: SDN, Load Balancing, Algorithms performance, Machine Learning.

1. المقدمة

مع تزايد استخدام الشبكات المعرفة بالبرمجيات (SDN) في الشبكات الحديثة، أصبحت إدارة موارد الشبكة بكفاءة أمرًا بالغ الأهمية. وتُعدّ موازنة أحمال الخوادم أحد أبرز التحديات في هذه البيئات، إذ يؤثر بشكل مباشر على أداء الشبكة وسرعة استجابتها، كما يضمن الاستخدام الأمثل للموارد المتاحة. ونظرًا للطبيعة الديناميكية لشبكات SDN، تواجه العديد من تقنيات موازنة الأحمال التقليدية تحديات متزايدة في مواكبة تطور الشبكات الحديثة، لا سيما من حيث التكيف مع ظروف الشبكة المتغيرة [1].

يتأثر أداء الخوادم بمؤشرات تشغيلية متنوعة، مثل استخدام وحدة المعالجة المركزية والذاكرة، واستهلاك النطاق الترددي، وعدد الاتصالات النشطة. ورغم شيوع مراقبة هذه المؤشرات، إلا أن الطرق الحالية عادةً ما تتعامل معها بشكل منفصل أو تعتمد على خوارزميات مبسطة لا تعكس بدقة حجم العمل الفعلي على الخوادم. علاوة على ذلك، غالبًا ما يتم إغفال التأثير المُجتمع لهذه المؤشرات على سرعة استجابة الخادم الذي يعتبر مؤشر رئيسي لجودة الخدمة. توفر تقنيات التعلم الآلي منهجاً عملياً لنمذجة هذه التفاعلات المعقدة. مع ذلك، فإن الدراسات التي تُطبّق هذه التقنيات على موازنة أحمال الخوادم في بيئات الشبكات المعرفة بالبرمجيات (SDN) محدودة نسبيًا.

حثت الدراسات السابقة على التكامل بين الشبكات المعرفة بالبرمجيات والتعلم الآلي، حيث أبرزت أن هذا التقارب يمثل اتجاهاً تقدمياً في تحسين شبكات مراكز البيانات (DCNs) [2]. يتيح هذا التكامل بين المجالين الاستفادة من القدرات التنبؤية لنماذج التعلم الآلي إلى جانب التحكم المركزي الذي توفره SDN، مما يعد بتأثير تحويلي على قدرة الشبكة على التكيف وإدارة الموارد [3]. كما تؤكد هذه الدراسات أن هذا المجال لا يزال ناشئًا ويتطلب مزيدًا من الاستكشاف الشامل، فهو يحمل الإمكانات ليس فقط لرفع الكفاءة التشغيلية من خلال موازنة الحمل الذكية المتوقعة ولكن أيضًا لإحداث ثورة في نماذج الإدارة التي تحكم أنظمة مراكز البيانات على مستوى العالم [2].

2. هدف البحث

انطلاقاً من توصيات الدراسات السابقة بتقاطع التعلم الآلي وشبكات SDN في سياق موازنة الأحمال من أجل التحرك نحو أنظمة تكيفية مدفوعة بالذكاء تتقدم عدة خطوات على التدابير التقليدية التفاعلية، وبما أنَ معظم الأبحاث التي دمجت التعلم الالي في SDN ركزت على موازنة حمل المسارات، بينما لاتزال موازنة حمل الخوادم باستخدام التعلم الآلي أقل استكشافاً رغم أهميتها في تعزيز كفاءة مراكز البيانات، ومن هذا المنطلق اخترنا التركيز على موازنة حمل الخوادم نظراً لندرة الأبحاث في هذا المجال، وهذا ما يجعل دمج التعلم الآلي فيها خطوة تستحق التعمق والدراسة وفرصة بحثية واعدة لتقديم حلول ذكية قابلة للتطبيق في بيئات الشبكات الحديثة. بناء على ذلك سيكون هدف البحث اقتراح خوارزمية جديدة للتنبؤ بزمن استجابة الخوادم في بيئات الشبكات المعرفة بالبرمجيات اعتماداً على مجموعة من المؤشرات التشغيلية النشطة للخادم. يعتمد النموذج المقترح على خوارزمية الغابة العشوائية (Random Forest) لتحليل العلاقة بين مجموعة من العوامل الأساسية، مثل استخدام وحدة المعالجة المركزية، واستهلاك الذاكرة، وعرض النطاق الترددي، وعدد الاتصالات النشطة، بهدف بناء نموذج تنبؤي قادر على تقدير زمن الاستجابة بدقة أعلى، فالهدف من هذا النهج هو تحسين عملية اتخاذ القرار في موازنة الأحمال داخل بيئات SDN الديناميكية.

3. مواد وطرق البحث

سنستخدم في التجارب محاكي Mininet هو برنامج محاكاة يستند إلى Linux من أجل النمذجة السريعة للشبكات المعرفة برمجياً [4] يستخدم على نطاق واسع في أبحاث SDN ومنها الدراسة [5] . أيضاً سنستخدم Siege وهي أداة اختبار لحمل HTTP يمكن استخدامها لإرسال طلبات مئات الزبائن المتزامنين إلى مخدم الويب في وقت واحد للتحقق من كيفية أدائه تحت الضغط ومدى التوفر الذي يمكن أن يوفره الخادم، توفر بعد اكتمال الاختبار معلومات مفيدة مثل التوفر وعدد الطلبات الناجحة وعدد الطلبات الفاشلة والمزيد من المعلومات [6]. أيضاً سيتم استخدام Psutil لقياس إحصائيات الخادم ومراقبة أدائه خلال تنفيذ التجارب، وهي مكتبة متعددة المنصات تُستخدم لاسترجاع المعلومات حول العمليات الجارية واستخدام النظام [7]. كما سيتم استخدام أداة D-ITG [8] لتوليد traffic مغاير

عن http حيث سيتم تشغيلها بالتوازي مع أداة Siege التي تولد http traffic الذي سيُطَبق موازنة الحمل عليه، لمحاكاة بيئة شبكة واقعية، مما يسمح بتقييم أداء موازنة حمل http ضمن سياق عملي أقرب إلى الواقع.

4. الدراسات السابقة

حظيت مسألة موازنة حمل الخوادم باهتمام بحثي واسع في مجال الشبكات الحاسوبية. ومع ظهور الشبكات المعرَفة بالبرمجيات (SDN) أُعيدت صياغة هذه المسألة ضمن إطار أكثر مرونة، مستفيداً من الفصل بين مستوى التحكم ومستوى البيانات وما يتيحه ذلك من رؤية شاملة لحالة الشبكة وإدارتها مركزياً. ركزت بعض الأبحاث في هذا المجال على استخدام خوارزميات موازنة حمل تقليدية مثل Random [9]، Round Robin و Weighted Round Robin [10] بعد تكييفها للعمل ضمن بيئة SDN ورغم بساطة هذه الخوارزميات وسهولة تطبيقها إلا أنها غالباً ما تهمل الحالة الفعلية لموارد الخوادم أو ظروف الشبكة الديناميكية مما قد يؤدي إلى توزيع غير عادل للحمل. وهذا ما جعل بعض الباحثين يستخدم خوارزميات تعتمد على تحليل مؤشرات الأداء الفردية للخوادم لموازنة الحمل بينها. حيث اعتُبر في [11] أن عدد الاتصالات النشطة هو أحد العوامل الأساسية التي تُؤثر على أداء الخادم بينما في [12] تم الاعتماد على عرض النطاق الترددي للخوادم. في حين اعتمدت [13] على أوقات استجابة الخوادم لتوزيع الحمل وهنا لابدَ من الإشارة أنه تم قياس وقت الاستجابة بطريقة تقليدية بالاعتماد على إرسال وحدة التحكم لرزم packet out بفاصل زمني معين وتسجيل وقت الإرسال ثم انتظار الرد من الخادم وتسجيل وقت الاستلام. أما في [14] استُخدم خوارزمية Server Load Balancing والتي يتم فيها اختيار الخادم الذي لديه أقل قيمة لوحدة المعالجة المركزية. في [15] تم توزيع الحمل بين الخوادم في بيئة SDN باستخدام خوارزمية Least Packet Load حيث يتم توجيه الطلب إلى الخادم الذي يتلقى أقل عدد من الرزم. أحياناً الاعتماد على عامل واحد فقط قد لا يعكس الطبيعة المعقدة لأحمال الخادم خاصة تحت ظروف مرور متباينة. لتحسين دقة تقدير حمل الخادم قامت دراسات أخرى بدمج مؤشرين أو أكثر ففي [16] تم الاستناد إلى وقت استجابة الخادم ونوع محتوى الطلب لإجراء عملية الموازنة بين الخوادم. أما في [17] يتم اختيار الخادم الأفضل بناءً على إحصائيات وقت

الاستجابة وحجم المرور عبر منافذ المبدل. في [18] تم موازنة الحمل بين الخوادم في شبكة SDN باستخدام بارمترات استخدام المعالج، استخدام الذاكرة، استخدام I/O بالاعتماد على المنطق الضبابي. في [19] تم موازنة الحمل لكن في بيئة SDN هجينة بالاعتماد على مؤشرات CPU load، I/O read، I/O write، link upload، link download. من خلال النظر في عدة عوامل، توفر الأساليب السابقة صورة أكثر تمثيلاً لحمل الخادم. ومع ذلك، تعتمد هذه الطرق على قواعد ثابتة أو أوزان محددة مسبقاً، دون الاستفادة من تقنيات التعلم الآلي لفهم العلاقة الديناميكية بين هذه المؤشرات وتأثيرها الفعلي على أداء الخادم. في المقابل بدأت الأبحاث الحديثة بالاستفادة من تقنيات التعلم الآلي لتحسين موازنة الحمل في شبكات SDN. ففي [20] تم استخدام نموذج التعلم الآلي logistic regression للتنبؤ بنوع الطلب الأمثل الذي يمكن للخادم التعامل معه عند إعطائه الميزات، تم تدريبه على مجموعة بيانات تحوي 200 نقطة، كل نقطة بيانات عبارة عن مجموعة تحتوي على وقت الرحلة (trip time) واستخدام الذاكرة واستخدام المعالج والعلامة التي تكون إما 0 أو 1 المقابلة لنوع الطلب Media أو Text، لم يتم ذكر آلية توليد dataset. أما في [21] تم تنفيذ موازنة الحمل في SDN باستخدام الانحدار الخطي. تحتوي مجموعة البيانات الخاصة بنمذجة التابع الخطي على ثلاثين عينة، كل عينة تحتوي على معلومات وحدة المعالجة المركزية وذاكرة RAM وعدد الطلبات. يتم حساب الانحدار الخطي وفقاً لوحدة المعالجة المركزية وذاكرة الوصول العشوائي الخاصة بالخادم والنتيجة هي التنبؤ بعدد الطلبات من كل خادم. لم يتم تحديد آلية الحصول على الثلاثين عينة بدقة. في [22] تم تطبيق موازنة الحمل على شبكة معرفة بالبرمجيات باستخدام خوارزمية Naïve Bayes بناءً على البيانات الواردة من الخوادم (استخدام المعالج، استخدام الذاكرة، استخدام القرص) بعد ذلك يتم إجراء العمليات الحسابية عليها لتحويلها إلى شكل لغوي بناءً على مجموعة بيانات محددة مسبقاً مؤلفة من 27 حالة للحصول على حالة الخادم، وبعد الحصول على حالة الخادم يتم توزيع المرور بناءً على أقل استخدام للموارد من الخادم. بالرغم من استفادة الأبحاث السابقة من تقنيات التعلم الآلي لتحسين موازنة الحمل في شبكات SDN، مع ذلك لم تركز معظم هذه الدراسات على تأثير مؤشرات الموارد المختلفة على وقت استجابة الخادم باعتباره عامل أساسي لجودة الخدمة، أو اقتصرت على مجموعة محدودة

من المؤشرات. بناءً على ما سبق، يتضح أنّ هناك حاجة إلى نموذج تعلم آلي قادر على نمذجة العلاقات المعقدة للتأثير المشترك لمجموعة من مؤشرات موارد الخادم الأساسية للتنبؤ بوقت الاستجابة له بدقة عالية.

لابدَ من الإشارة إلى أنَ الدراسة رقم [23] تضمنت تحليلاً دقيقاً ومقارناً وشاملاً لأكثرية الجوانب التقنية للخوارزميات المستخدمة في مجال موازنة حمل الخوادم في شبكات SDN من حيث تصميم وآلية عمل كل خوارزمية، الطوبولوجيا المستخدمة، البارامترات المقاسة، محاكيات الشبكات وأدوات قياس الأداء المستخدمة، الخوارزميات المُقارن معها والافاق المستقبلية التي ذكرتها كل دراسة، وهذا ما وفر أساساً نظرياً قوياً وساهم في توجيه منهجية هذه الدراسة الحالية.

5. بنية الشبكات المعرفة برمجياً (SDN)

يتكون نموذج SDN من ثلاث طبقات، وهي طبقة البنية التحتية ويطلق عليها أيضاً طبقة البيانات، تتكون من أجهزة التبديل (مثل المبدلات، والموجهات، وما إلى ذلك). تتمثل وظائف أجهزة التبديل في أنها أولاً مسؤولة عن جمع حالة الشبكة وإرسالها إلى وحدات تحكم كما أنها مسؤولة عن معالجة الرزم استناداً إلى القواعد التي توفرها وحدة التحكم [24]. الطبقة الثانية هي طبقة التحكم والتي تمثل ذكاء الشبكة، تسمى العقد الموجودة في طبقة التحكم بوحدات التحكم. يسمح هذا الحل لوحدة التحكم بالحفاظ على رؤيا عامة للشبكة المتوضعة في طبقة البنية التحتية [25]. الطبقة الأخيرة هي طبقة التطبيق التي تحتوي على تطبيقات SDN مصممة لتلبية متطلبات المستخدم [24].

6. وحدة التحكم POX

يوجد حاليًا العديد من تطبيقات وحدات التحكم المتوفرة، وهي مفتوحة المصدر وتستند إلى لغات برمجة مختلفة. تم اختيار وحدة التحكم pox لإجراء التجارب في هذا البحث، والتي تم تطويرها بالكامل باستخدام Python، وبالتالي فهي تدعم Linux و Mac OS و Windows. هدفها الرئيسي هو تسريع عملية التطوير دون الحاجة إلى القلق بشأن مشاكل الأداء [26].

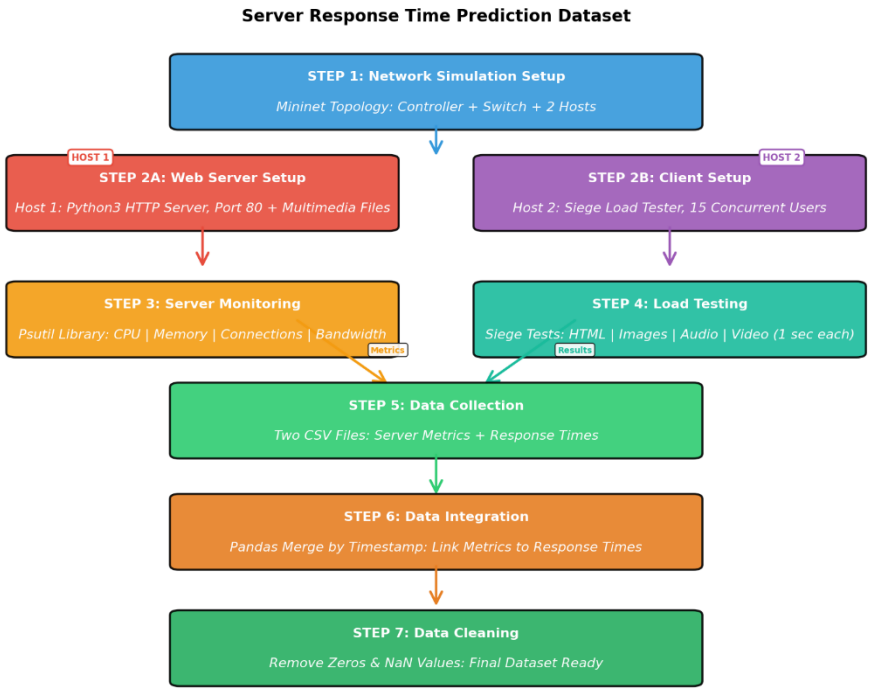
7. توليد مجموعة البيانات

تم توليد مجموعة بيانات تلبي احتياجات الدراسة للتنبؤ بوقت استجابة الخادم بناءً على المؤشرات النشطة للخادم. ولتوليد مجموعة البيانات تم القيام بالعديد من الخطوات:

- تم استخدام محاكي Mininet لتوليد طوبولوجيا شبكة وقد تم استخدام الطوبولوجيا الافتراضية المكونة من وحدة تحكم ومبدل ومضيفين.
- تم استخدام أحد المضيفين لتشغيل خادم ويب يستخدم بروتوكول HTTP على منفذ 80 باستخدام python3 على مجلد يحوي ملفات html وصور وفيديو وملفات صوتية بأحجام متنوعة حتى يقوم الخادم بتقديم جميع الملفات الموجودة في ذلك الدليل، كما تم كتابة وتشغيل برنامج بايثون على الخادم يقوم بحساب استخدام المعالج واستخدام الذاكرة وعدد الاتصالات وعرض النطاق الترددي للخادم كل ثانية باستخدام مكتبة Psutil وتوجيه هذه الإحصائيات وتخزينها بشكل مستمر في ملف CSV.
- أما المضيف الثاني في الطوبولوجيا تم استخدامه كعميل حيث تم تشغيل عدد من المستخدمين المتزامنين عليه بعدد 15 (العدد الافتراضي) يقومون بطلب الملفات التي يقوم الخادم بتقديمها وموجودة في الدليل كما هو موضح سابقاً، ومن أجل ذلك تم استخدام الأداة Siege لإرسال الطلبات واختبار حمل الخادم، تم تنفيذ الاختبارات بشكل متتابع وفوري واحد تلو الآخر مباشرة في وقت متقارب جداً، بهدف تمثيل حمل مستمر من جهة العملاء يعكس السلوك الواقعي للنظام ويرصد التأثيرات التراكمية على أداء الخادم. مدة كل اختبار ثانية واحدة لضمان تزامن موثوق مع مؤشرات أداء الخادم حيث توفر الأداة قياسات زمن استجابة على مستوى التجربة ككل، فالثانية الواحدة تحقق توازن منهجي بين دقة القياس وإمكانية التزامن مع مؤشرات الخادم فهي أقل وحدة زمنية تضمن تزامناً مقبولاً بين القياسات على العميل والسيرفر.
- تم توجيه نتائج اختبارات siege إلى ملف CSV. قسم من الاختبارات طُلب فيها الوصول إلى صفحة html، وفي قسم آخر طُلب الوصول إلى صورة وفي القسم الثالث من الاختبارات طُلب فيه الوصول إلى مقطع صوتي وفي القسم الأخير من الاختبارات طُلب فيه الوصول

إلى مقطع فيديو بهدف توفير محتوى متكامل للمستخدمين عبر HTTP حتى تكون الإحصائيات المخزنة في ملف CSV متنوعة.

- بعد ذلك تم دمج ملفي CSV السابقين الناتجين عن الاختبارات باستخدام مكتبة pandas بناءً على تطابق قيم حقل الطابع الزمني في ملف CSV جديد، ثم تم تنظيف ملف CSV الجديد عن طريق حذف القيم الصفرية وقيم nan وحذف الأعمدة غير الضرورية باستخدام مكتبة pandas. يوضح الشكل التالي خطوات توليد مجموعة البيانات بصورة موجزة:



الشكل (1) مخطط صندوقي يوضح خطوات توليد مجموعة البيانات.

وهذا جزء من ملف output.csv النهائي وقد احتوى هذا الملف على 882 سطر من البيانات:

timestamp	cpu_usage	memory_usage	connections	bandwidth_sent	bandwidth_recv	total_bandwidth	Resp Time
2025-01-24 10:55:39	10.6	25.1	41	9184	6714	15898	0.01
2025-01-24 10:55:41	21.5	25.1	57	11080	8254	19334	0.02
2025-01-24 10:55:43	6.5	25.1	62	3380	2430	5810	0.04
2025-01-24 10:55:45	5.1	25.1	69	4732	3402	8134	0.01
2025-01-24 10:55:55	10.9	25.4	110	7180	5280	12460	0.01
2025-01-24 10:55:57	13.8	25.6	131	8310	6030	14340	0.07
2025-01-24 10:55:59	15.8	25.2	145	10272	7554	17826	0.01
2025-01-24 10:56:01	8	25.2	157	8178	5898	14076	0.02
2025-01-24 10:56:03	6	25.2	160	2094	1524	3618	0.01
2025-01-24 10:56:13	9.1	25.3	223	10140	7290	17430	0.05
2025-01-24 10:56:15	4.5	25.2	234	8376	6096	14472	0.03
2025-01-24 10:56:17	12	25.3	245	6760	4860	11620	0.02
2025-01-24 10:56:19	19.3	25.5	268	15680	11524	27204	0.01
2025-01-24 10:56:21	10.7	25.3	278	7024	5470	12494	0.08

الشكل (2) جزء من مجموعة البيانات المولدة.

8. الخوارزمية المقترحة

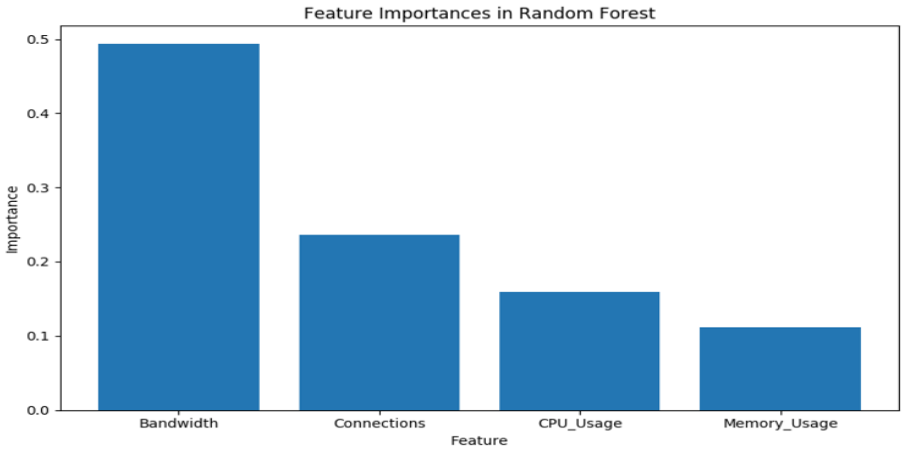
8-1 طريقة العمل

إنَ هدف البحث كما أُشير سابقاً هو تطوير خوارزمية تتنبأ بوقت الاستجابة بناءً على المؤشرات النشطة للخادم ولتحقيق هذا الهدف:

أولاً تم توليد مجموعة بيانات وهذا ما تم شرحه بالتفصيل في الفقرة السابقة، ثم تم إنشاء نموذج تعلم آلي باستخدام الغابة العشوائية (30 شجرة، عمق 10) وتدريبه على مجموعة البيانات المولدة. تم اعتماد تقسيم البيانات بنسبة 90:10 (90% للتدريب و10% للاختبار) استناداً إلى النتائج التجريبية الواردة في الدراسة [28]، والتي أثبتت أن هذا التقسيم حقق أعلى دقة أداء عند اختباره على مجموعة بيانات مكونة من 304 حالة؛ وهو ما يُعد نطاقاً قريباً من حجم البيانات المستخدم في هذا البحث المؤلف من 882 سجلّاً، فالهدف في هذا البحث هو تعظيم قدرة النموذج على التقاط الأنماط المعقدة والعلاقات غير الخطية بين موارد النظام المتمثلة في عرض النطاق الترددي، وعدد الاتصالات، واستخدام المعالج، واستخدام الذاكرة، من جهة، ووقت الاستجابة من جهة أخرى. وقد أثبتت النتائج العملية فيما بعد صحة هذا الاختيار، حيث حقق النموذج أداءً تنبؤياً دقيقاً ومتسقاً عند دمجه مع وحدة التحكم POX في بيئة التشغيل الفعلية، مما يُبرر اختيار هذه النسبة ويُؤكد ملاءمتها المثلى لهذا البحث.

تم حفظ النموذج ليتم استرجاعه في وحدة التحكم POX بحيث يتم تطبيقه على البيانات الجديدة للمحافظة على دقة واستقرار النتائج.

ولابدَ من الإشارة أنه تم تجربة عدة نماذج تحليلية، من بين جميع النماذج التي تم اختبارها، ظهر نموذج الغابة العشوائية كأفضل نموذج في تحقيق التوازن بين دقة التنبؤ وتفسير البيانات. حقق النموذج قيمة RMSE بلغت 0.0227 (5.27% من النطاق الكلي)، مما يدل على دقة تنبؤ عالية بفروق ضئيلة بين القيم المتنبأة والحقيقية. كما سجل معامل التحديد R^2 قيمة 0.7466، أي أنه يفسر حوالي 74.66% من التباين في البيانات، وهو أداء جيد في سياق تحليل البيانات المتعددة الأبعاد (استخدام المعالج، الذاكرة، عرض النطاق الترددي، وعدد الاتصالات). وبهدف الكشف عن العلاقات الكامنة وراء هذا الأداء، تم تقييم مساهمة كل متغير مستقل في ناتج النموذج عبر مقياس أهمية المتغيرات (Feature Importance) لفهم مدى تأثير كل ميزة على زمن الاستجابة في مجموعة البيانات المستخدمة في هذه الدراسة، وقد أظهرت النتائج أنَ تأثير موارد النظام الأربعة على وقت الاستجابة كان كما هو موضح في الشكل التالي:



الشكل (3) أهمية المتغيرات في نموذج الغابة العشوائية.

ثانياً تم تنفيذ برنامج بايثون على كل خادم يقوم بجمع وحساب إحصائيات الخادم (عرض النطاق الترددي، عدد الاتصالات، استخدام الذاكرة، استخدام المعالج) باستخدام أداة Psutil وإرسالها إلى وحدة التحكم POX بشكل مستمر كل خمس ثوانٍ عن طريق UDP Socket (وهي الطريقة المتبعة في جمع إحصائيات الخادم في الدراسة رقم [29]علماً أن الأكواد غير موجودة وتم تحقيقها). بعد ذلك،

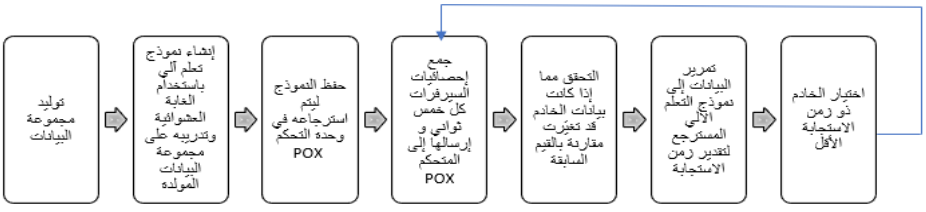
عندما تقوم وحدة التحكم باستقبال UDP Packet يتم معالجة هذه الرزمة كرزمة تحوي إحصائيات الخادم، لقد تم تخزين إحصائيات الخوادم ضمن dictionary، Keys لهذا dictionary هي عناوين IP الخاصة بالخوادم أما قيمة كل key هي قاموس داخلي يحتوي إحصائيات الخادم.

ثالثاً يتم التحقق مما إذا كانت بيانات الخادم قد تغيَرت مقارنة بالقيم السابقة وعند اكتشاف تغير في بيانات الخادم، يتم تحويلها إلى مصفوفة NumPy، بعد ذلك يتم تمرير هذه البيانات إلى نموذج التعلم الآلي الذي تم استيراده لتقدير زمن الاستجابة المتوقع لكل خادم، ثمّ يتم تخزين النتائج وربط كل IP خادم بزمن الاستجابة المتوقع. وهنا لابدّ من الإشارة إلى أنّ زمن التنبؤ لا يتجاوز بضعة مللي ثواني في الظروف العادية كون حجم النموذج نسبياً صغير (30 شجرة، عمق 10)، ويجري التنبؤ بشكل دوري كل 5 ثوانٍ عند استلام إحصائيات الخوادم، ويُخزَّن لاستخدامه لاحقاً. أما قرار اختيار الخادم الأمثل فيتم فوراً عند وصول رزمة من العميل باستخدام آخر التنبؤات المخزنة، حيث يبلغ متوسط زمن هذا القرار 0.08 مللي ثانية، فالنظام يفصل بين التنبؤ الدوري والقرار الفوري، التنبؤ يتم دورياً عند استلام الإحصائيات، والقرار يتم فوراً عند وصول الرزم باستخدام آخر التنبؤات المخزنة ولا يتأثر بزمن التنبؤ.

بناءً على ما سبق، عندما تأتي رزمة إلى موازن الحمل يتم اختيار الخادم ذو زمن الاستجابة الأقل وفقاً للتالي:

$$Best_server = Min(response_time(server_{(I)})) \quad where\ I=1, 2 \ldots n$$

يوضح الشكلان التاليان مراحل عمل الخوارزمية: الأول مخطط صندوقي للتسلسل العام، والثاني Pseudo-code للتفاصيل التنفيذية:



الشكل (4) مراحل تطوير الخوارزمية المقترحة.

```
ALGORITHM: توجيه الرزم إلى الخادم الأقل زمن استجابة
BEGIN
//==== المرحلة 1: التهيئة (مرة واحدة) ====
    dataset ← generateDataset()
    model ← train (RandomForest, dataset)
    save (model, "model.pkl")
    load (model, POX_Controller)

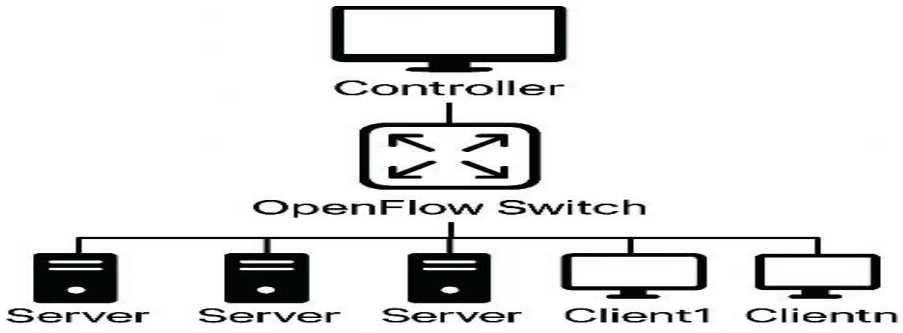
    predictions ← {} // Dictionary: {server_IP: زمن الاستجابة}
//==== المرحلة 2: تنبؤ دوري (كل 5 ثوانٍ) ====
    PROCEDURE PeriodicPrediction()
        WHILE systemRunning DO
            stats_dict ← POX.receiveStatsFromServers // الخوادم ترسل
        الإحصائيات، المتحكم يستلم هذه الإحصائيات
            FOR EACH (server_ip, server_stats) IN stats_dict.items() DO
                IF server_stats.changed() THEN
                    input ← convertToNumpy(server_stats)  // [[CPU, Memory,
Conn, BW]]
                    result ← model.predict(input) //  تقدير زمن الاستجابة
                    predictions[server_ip] ← result //  Dictionary  تحديث
القيمة بالـ
                END IF
```

```
        END FOR
      END WHILE
  END PROCEDURE
//==== المرحلة 3: قرار فوري (عند وصول رزمة من العميل) ====//
  PROCEDURE OnPacketArrival(packet)
      bestServer ← min(predictions, key=predictions.get) //  Dictionary
أقل قيمة بالـ
      forward(packet, bestServer) //          توجيه فوري
  END PROCEDURE
END
```

الشكل (5) Pseudo-code للخوارزمية المقترحة.

8-2 طوبولوجيا الاختبار والخوارزميات المُقارن معها

لاختبار أداء الخوارزمية المقترحة وفعاليتها تم استخدام طوبولوجيا SDN تم إنشاؤها باستخدام محاكي Mininet عن طريق برنامج نصي مكتوب بلغة python مؤلفة من وحدة تحكم POX تعمل كموازن للحمل ومبدل OpenFlow وثلاثة أجهزة مضيفة تعمل كخوادم ويب وعدد من الأجهزة المضيفة التي تعمل كعملاء كما في الشكل التالي:



الشكل (6) طوبولوجيا الاختبار.

المبررات لاختيار هذه الطوبولوجيا هي أنها الطوبولوجيا المستخدمة في أكثرية الدراسات السابقة [23] لأنه ما يهم هو المبدل المتصل مباشرة بالخوادم فهو المبدل الذي سيستقبل قواعد موازنة التدفق من وحدة التحكم ويقوم بناءً على هذه القواعد بتوزيع الطلبات بين الخوادم، وقد ذكرت إحدى الدراسات [30] وجود مبدل OpenFlow عالي الجودة هو المبدل HP Aruba 2920 24G PoE+ الذي لا يتجاوز سعره 1200.002 دولار أمريكي، وله معدل نقل يبلغ حوالي 128 جيجابت في الثانية ويسمح بتوصيل أكثر من 20 خادمًا، لكن هذا المبدل توقف الدعم الفني له لكن يوجد بدائل حديثة له توفر أداء عالي أيضاً.

وانطلاقاً من استنتاجات الدراسات السابقة والتي أكدت أن الخوارزميات الديناميكية يمكن أن تتفوق على الخوارزميات الثابتة عندما تكون ظروف الشبكة متغيرة قمنا بتنفيذ عدد من التجارب في ظروف شبكة متغيرة ومقارنة العمل المقترح مع الخوارزميات التالية:

- **Traditional Least Response [13]**

هي خوارزمية ديناميكية تعتمد على قياس وقت الاستجابة بطريقة تقليدية بالاعتماد على إرسال وحدة التحكم لرزم packet out بفاصل زمني معين وتسجيل وقت الإرسال ثم انتظار الرد من الخادم وتسجيل وقت الاستلام [13]، بعد ذلك يتم اختيار الخادم صاحب أقل زمن استجابة.

- **Least Bandwidth [30] [31]**

هي خوارزمية ديناميكية، تقوم باختيار الخادم الذي يستهلك أقل قدر من المرور (Traffic) على الشبكة للاستجابة للطلب التالي. تم الحصول على عرض النطاق الترددي للخوادم عن طريق إرسال وحدة التحكم لطلب إحصائيات التدفق إلى المبدل كل 5 ثوانٍ.

- **Round Robin [30] [31]**

هي خوارزمية ثابتة تعتمد على توزيع الطلبات بشكل دوري بين الخوادم، بحيث يتم إرسال كل طلب جديد إلى الخادم التالي في القائمة، ثم تعود إلى البداية بعد الوصول إلى آخر خادم.

- **Naïve Bayes [22]**

إلى جانب المقارنة الأساسية التي سيتم إجراؤها بين الخوارزمية المقترحة والخوارزميات الثلاث السابقة سنقوم بتنفيذ مقارنة إضافية مع خوارزمية تعلم آلي وهي Naïve Bayes ضمن جميع السيناريوهات المطبقة وذلك بهدف تقييم أداء النموذج المقترح ضمن سياق خوارزميات الذكاء الاصطناعي المستخدمة سابقاً في المجال ذاته. تم اختيار خوارزمية Naïve Bayes بناء على دراسة سابقة [22] تناولت موضوع توزيع الأحمال ضمن شبكات SDN باستخدام تقنيات التعلم الآلي، سبب اختيار هذه الخوارزمية هو أنَ تلك الدراسة وفرت مجموعة البيانات التي اعتمدت عليها ولكنها لم توفر الكود البرمجي المستخدم في تنفيذ النموذج. وبناءً عليه، تم إعادة بناء خوارزمية Naïve Bayes من الصفر، بالاعتماد على الخطوات المنهجية الموضحة في مخطط التدفق الخاص بالدراسة لضمان توافق النموذج المعاد تنفيذه مع المنطق الذي اعتمدته تلك الدراسة وتحقيق أعلى درجة ممكنة من الدقة. ولابدّ من الذكر أن خوارزمية Naïve Bayes هي واحدة من أهم خوارزميات التعلم الآلي المستخدمة في مهام التصنيف، تستند إلى مبرهنة بايز وتُستخدم لتوقع تصنيف عنصر معين بناءً على مجموعة من الميزات كما تمتاز ببساطتها وسرعتها ودقتها [32].

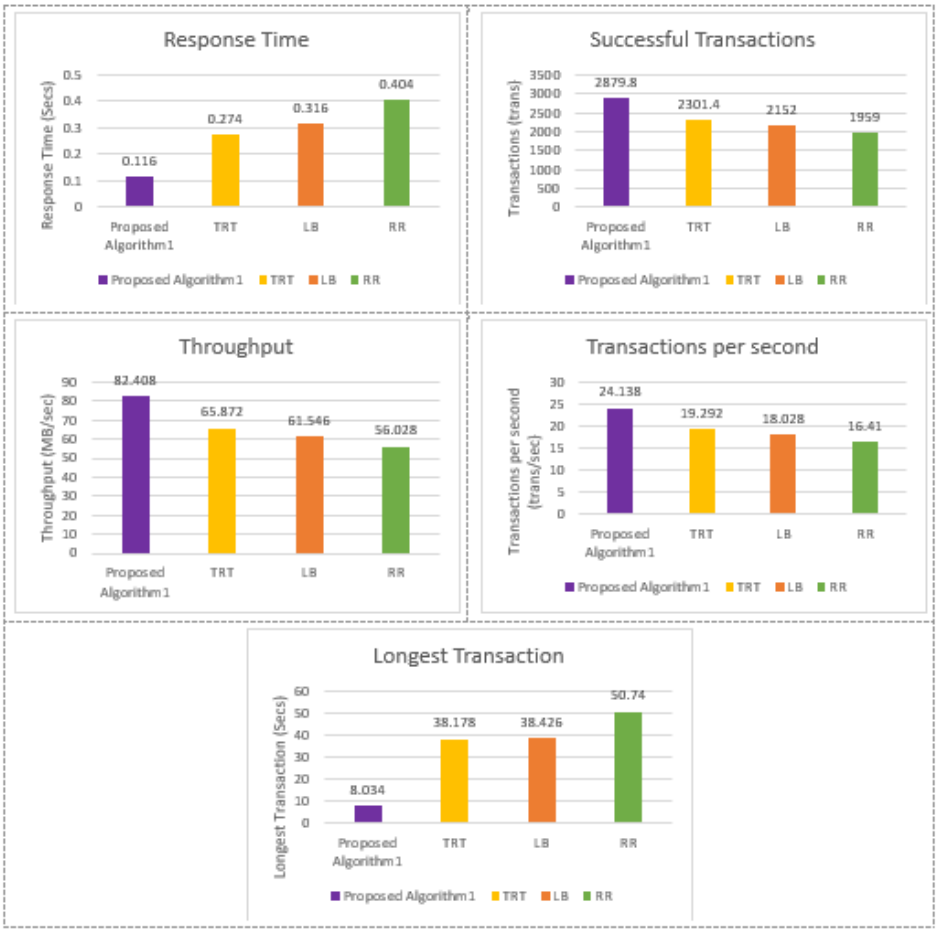
8-3 التحقيق العملي والتجارب

كما ذُكر سابقاً، تم تنفيذ عدد من السيناريوهات في ظروف شبكة متغيرة، كما تم قياس مجموعة من المعاملات واعتمادها في جميع التجارب وهي المعاملات الناتجة عن أداة Siege حيث شملت عدد المناقلات الناجحة، وقت الاستجابة، عدد المناقلات لكل ثانية، الإنتاجية، ووقت أطول مناقلة، وقد تم تنفيذ هذه السيناريوهات على النحو التالي:

8-3-1 السيناريو الأول

تم استخدام ثلاثة خوادم ويب متماثلة في المواصفات، وتم توليد حمل HTTP عبر أداة Siege إلى موازن الحمل لمدة دقيقتين بـ 15 مستخدمًا متزامنًا، مع توجيه حمل إضافي إلى الخادم الثاني فقط (ملف كبير الحجم بعدد مستخدمين متزامنين 15 لعكس الحالة التي يكون فيها الضغط على الخادم ناتج بشكل رئيسي عن حجم البيانات المنقولة أكثر من عدد الاتصالات) لخلق بيئة ديناميكية تختبر قدرة الخوارزميات على التكيف مع التغيرات. كما تم توليد حركة مرور شبكية متنوعة (غير HTTP) باستخدام أداة D-ITG تحاكي أنماط FTP و Video Streaming عبر TCP، لمحاكاة بيئة شبكة واقعية. أُعيد تنفيذ السيناريو خمس مرات من أجل كل خوارزمية، وحُسِب متوسط النتائج ورُسمت المخططات الموافقة.

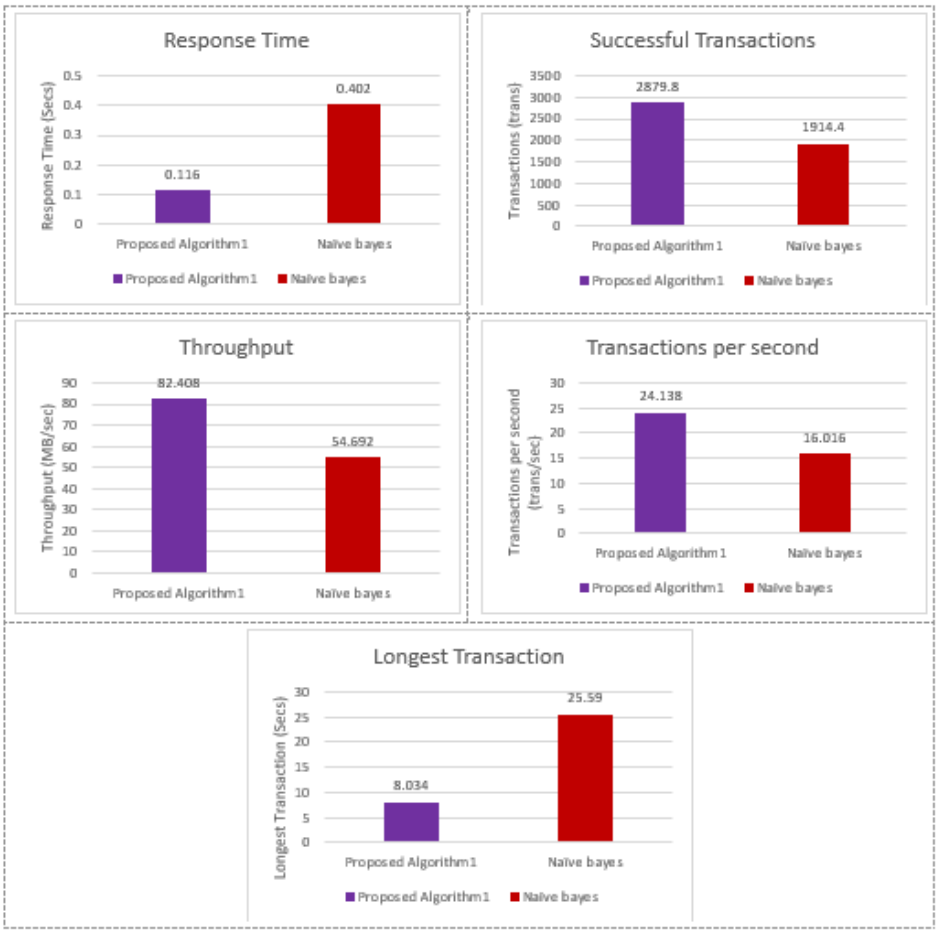
أ- المقارنة مع الخوارزميات التقليدية



الشكل (7) المقارنة مع الخوارزميات التقليدية في السيناريو الأول.

من النتائج السابقة نلاحظ تفوق أداء الخوارزمية المقترحة على الخوارزميات الأخرى من حيث كل البارامترات المقاسة.

ب- المقارنة مع خوارزمية Naïve Bayes



الشكل (8) المقارنة مع خوارزمية Naïve Bayes في السيناريو الأول.

من النتائج السابقة نلاحظ أيضاً تفوق الخوارزمية المقترحة على خوارزمية Naïve Bayes من حيث كل البارامترات المقاسة.

8-3-2 السيناريو الثاني

تم تطبيق نفس السيناريو الأول تماما مع تغيير طبيعة الحمل الإضافي الموجه إلى المخدم الثاني حيث تم استخدام ملف بحجم أصغر ولكن مع عدد اتصالات أكبر بلغ 100 اتصال. وعلى الرغم من أنّ

حجم الملف في هذا السيناريو أصغر، إلا أنّ زيادة عدد الاتصالات إلى 100 اتصال أدت إلى زيادة الحمل على المخدم الثاني بحوالي 46%، فبزيادة عدد الاتصالات زاد إجمالي البيانات المنقولة وعدد الطلبات التي يجب على الخادم معالجتها في الوقت نفسه وهذا ما يؤدي إلى استهلاك أكبر لموارد الخادم نتيجة إدارة عدد كبير من الجلسات المتزامنة، لذلك يعتبر هذا السيناريو أكثر ضغطاً على النظام والشبكة ككل بسبب زيادة حجم المرور المار عبر السويتش وبالتالي زيادة استهلاك موارد الشبكة وحدوث ضغط على البنية التحتية. نُفِّذ السيناريو خمس مرات لكل خوارزمية، وحُسِب متوسط النتائج ورُسمت المخططات الموافقة.

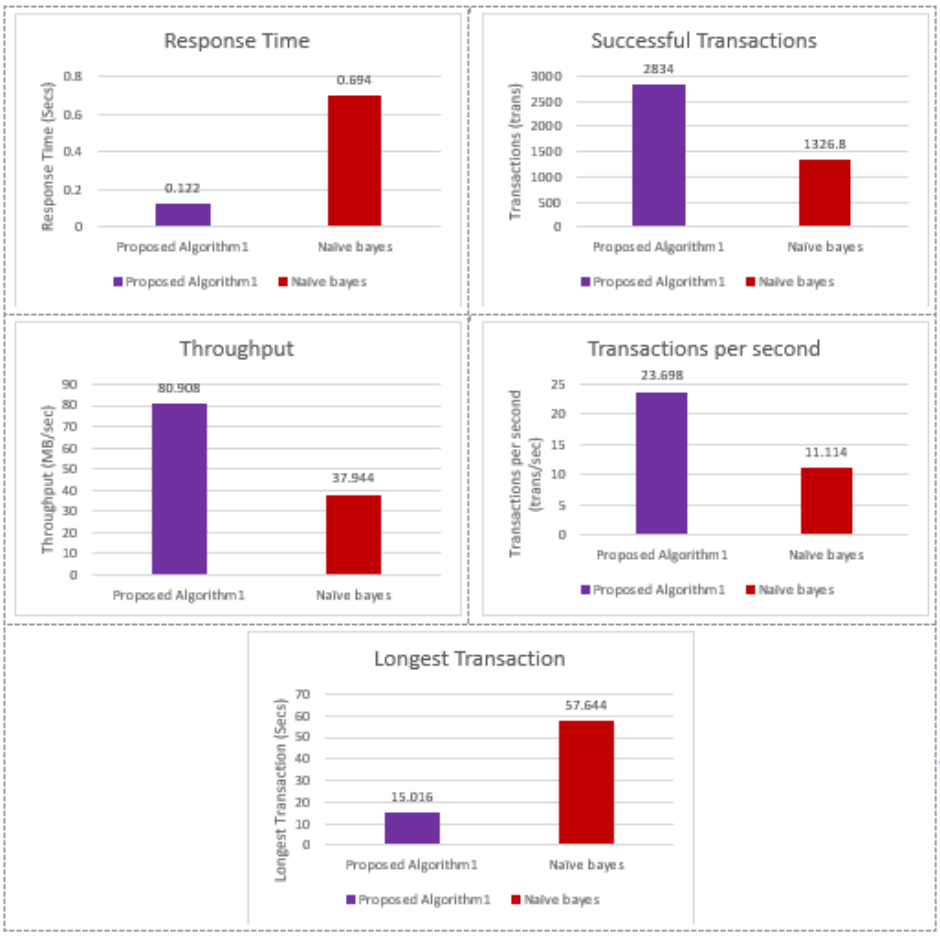
المقارنة مع الخوارزميات التقليدية



الشكل (9) المقارنة مع الخوارزميات التقليدية في السيناريو الثاني.

في هذا السيناريو أيضاً نلاحظ تفوق الخوارزمية المقترحة على الخوارزميات الثلاث الأخرى من حيث كل البارامترات المقاسة.

أ- المقارنة مع خوارزمية Naïve Bayes



الشكل (10) المقارنة مع خوارزمية Naïve Bayes في السيناريو الثاني.

من النتائج السابقة نلاحظ أيضاً هنا تفوق الخوارزمية المقترحة على خوارزمية Naïve Bayes من حيث كل البارامترات المقاسة.

❖ **تحليل وخلاصة السيناريوهين الأول والثاني**

للتأكد من جاهزية الخوارزمية للعمل في بيئات شبكية ديناميكية ومتعددة الاستخدامات، تم اختبارها في ظروف غير مثالية تحتوي مصادر متعددة للمرور. أظهرت النتائج تفوقها على الخوارزميات التقليدية الأخرى بفضل مراعاتها لعدة متغيرات رئيسية بدلاً من التركيز على عامل واحد، حيث استطاعت باستخدام التعلم الآلي التعامل مع العلاقات غير الخطية والمعقدة بين الموارد، مما أدى إلى توقعات دقيقة لزمن الاستجابة وقرارات أكثر كفاءة. بالمقابل، تفوقت أيضاً على خوارزمية Naïve Bayes التي اكتفت بتحليل حالة الخادم من خلال مؤشرات داخلية محدودة (استخدام المعالج والذاكرة والقرص) دون الأخذ بعين الاعتبار العوامل الشبكية؛ وهذا ما جعل الخوارزمية المقترحة تتفوق عليها بفضل شمولية المدخلات ومرونة النموذج وقدرته على التقاط العلاقات غير الخطية بين المتغيرات.

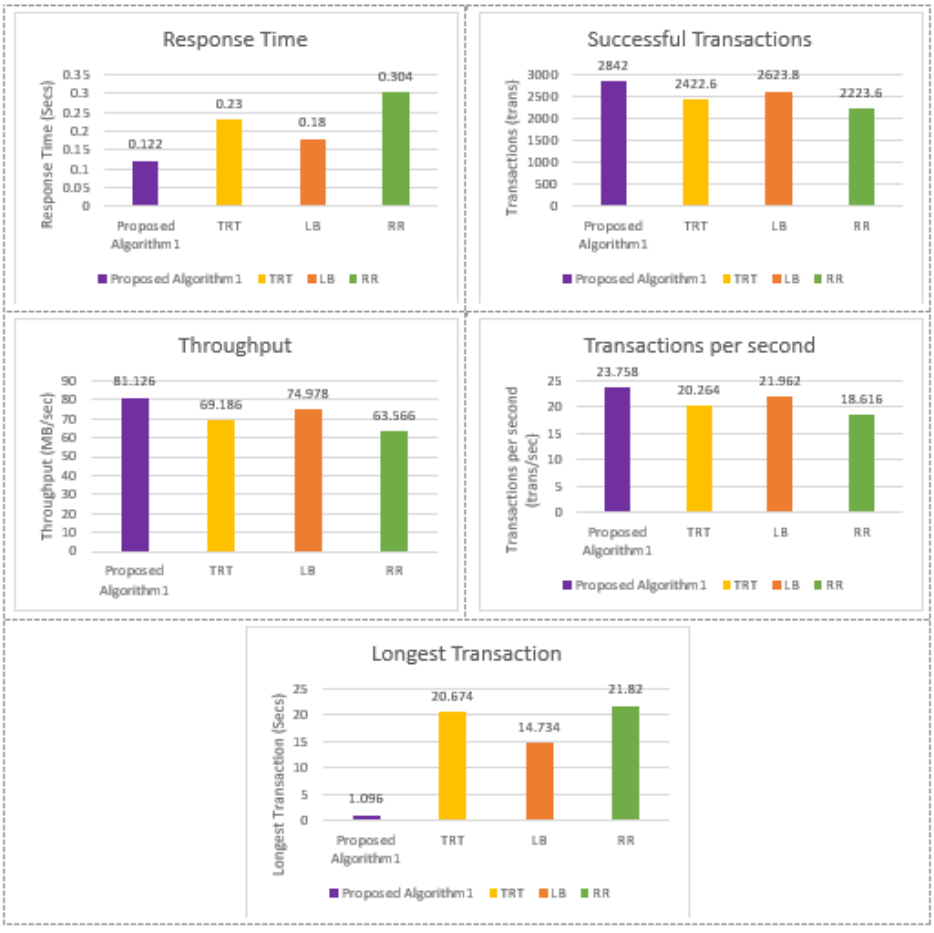
❖ **توسيع نطاق التجارب للتحقق من فعالية النموذج**

في البداية تم إجراء التجارب على ثلاث مخدمات فقط، مما أعطى تصوراً أولياً عن أداء الخوارزمية، لكن لضمان موثوقية النتائج وتقييم قدرتها على التكيف مع بيئات تشغيل مختلفة، تم توسيع نطاق الاختبار ليشمل خمس مخدمات. هذا التوسع يتيح لنا التأكد فيما إذا كان أداء الخوارزمية يتمتع بالثبات والدقة عبر أنظمة متعددة وليس مرتبطاً ببيئة محددة لتعزيز قابليتها للتطبيق العملي في سيناريوهات واقعية.

8-3-3 السيناريو الثالث

تم تطبيق نفس السيناريو الأول تماماً لكن باستخدام خمس مخدمات ويب.

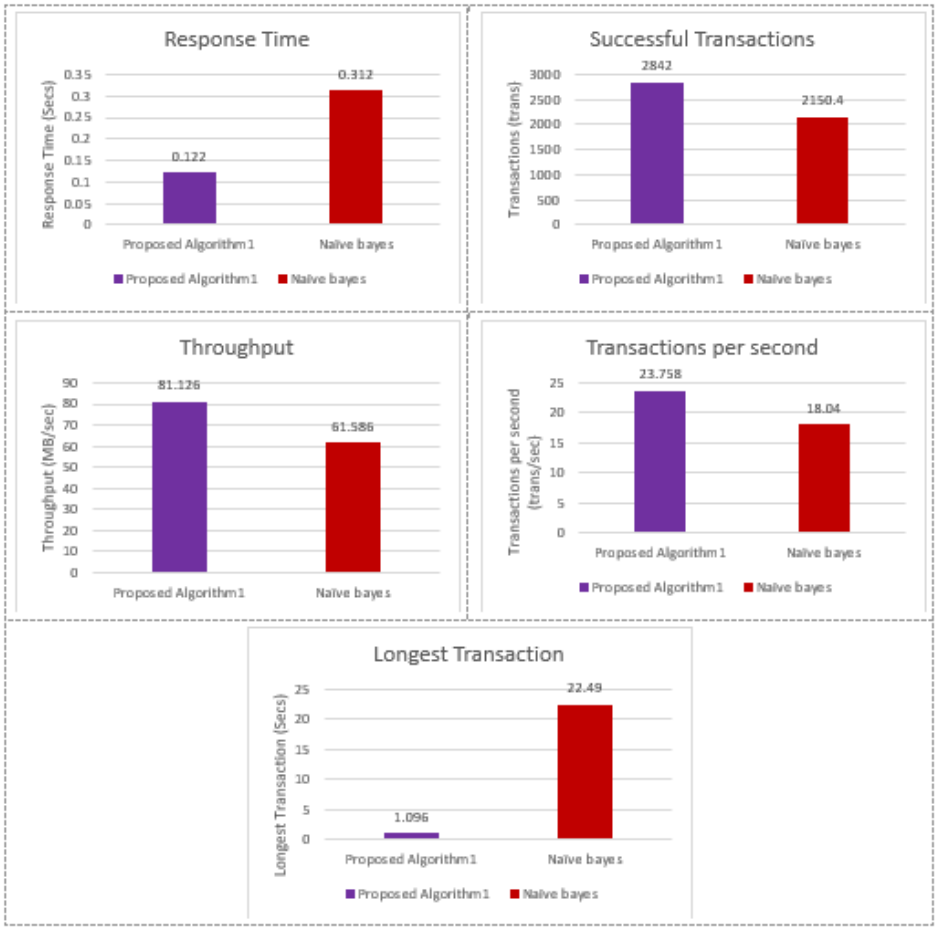
أ- المقارنة مع الخوارزميات التقليدية



الشكل (9) المقارنة مع الخوارزميات التقليدية في السيناريو الثالث.

مما سبق نلاحظ أنه بزيادة عدد المخدمات إلى خمسة بقيت الخوارزمية المقترحة تقدم نتائج أفضل من الخوارزميات التقليدية المُقارن معها.

ب- المقارنة مع خوارزمية Naïve Bayes



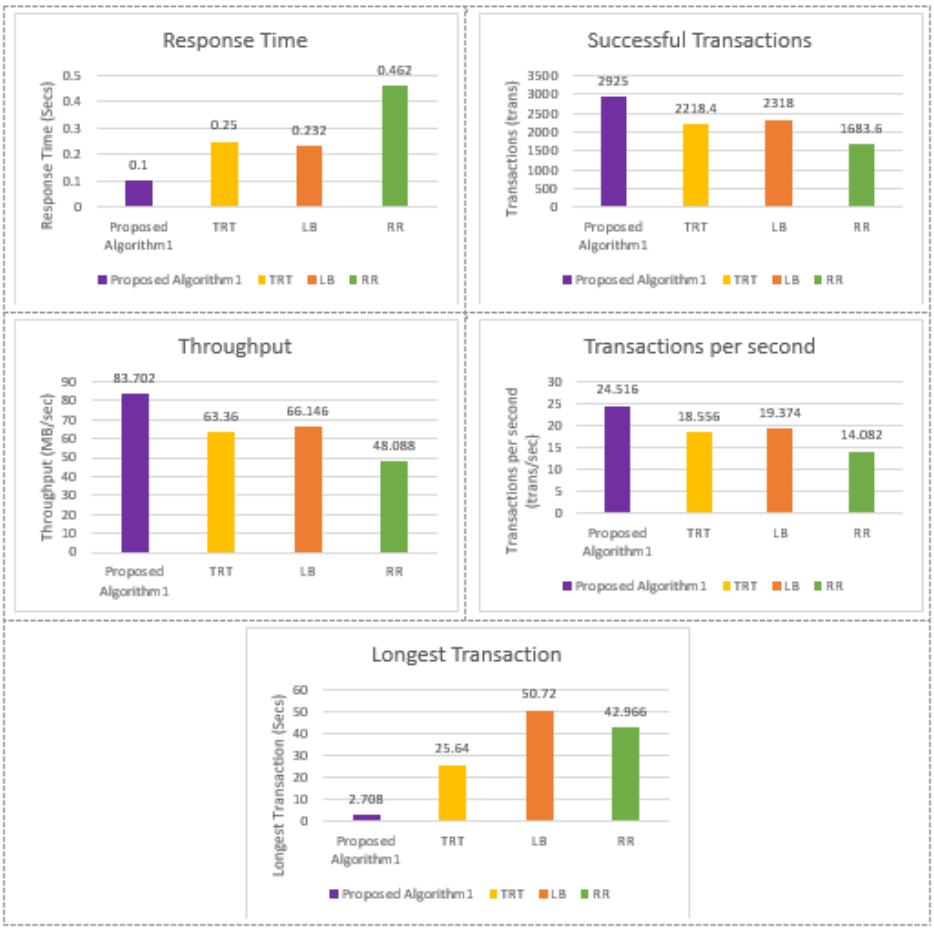
الشكل (10) المقارنة مع خوارزمية Naïve Bayes في السيناريو الثالث.

مما سبق نلاحظ أيضاً أن الخوارزمية المقترحة حافظت على تفوقها على خوارزمية Naïve Bayes بزيادة عدد المخدمات إلى خمسة.

8-3-4 السيناريو الرابع

تم تطبيق نفس السيناريو الثاني تماماً لكن باستخدام خمس مخدمات ويب.

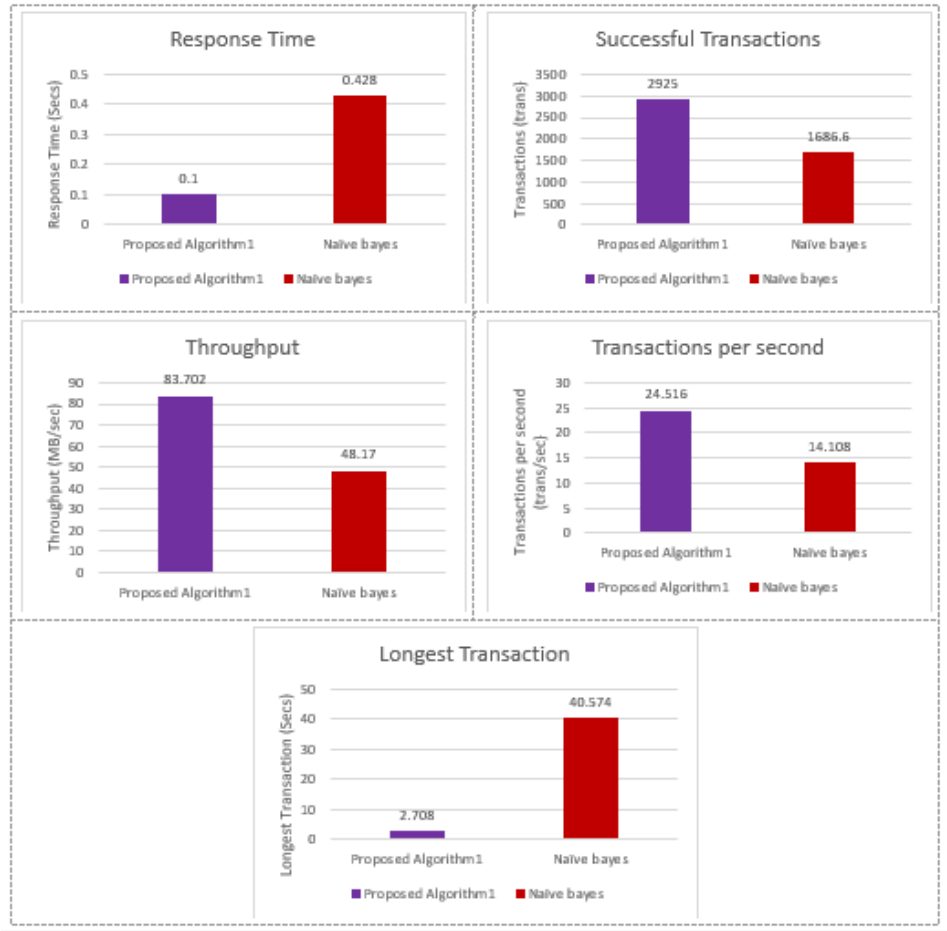
أ- المقارنة مع الخوارزميات التقليدية



الشكل (11) المقارنة مع الخوارزميات التقليدية في السيناريو الرابع.

في هذا السيناريو أيضاً نلاحظ تفوق الخوارزمية المقترحة على بقية الخوارزميات التقليدية بزيادة عدد المخدمات إلى خمسة.

ب- المقارنة مع Naïve Bayes



الشكل (12) المقارنة مع خوارزمية Naïve Bayes في السيناريو الرابع.

أيضاً في هذا السيناريو تفوقت الخوارزمية المقترحة على خوارزمية Naïve Bayes.

❖ تحليل وخلاصة السيناريوهين الثالث والرابع

تعتمد الخوارزمية المقترحة على آلية تنبؤية ذات تكلفة حسابية ثابتة وجمع لإحصائيات المخدمات، مما يجعلها عرضة لتأثير الحمل الناتج عن التوسع. في السيناريو الثالث، لم يكن الحمل الشبكي مرتفعاً، فكانت الفائدة من زيادة المخدمات إلى خمسة محدودة وأثر التكلفة أكثر بروزاً، لكنها بقيت الأفضل. أما

في السيناريو الرابع، فإن الشبكة كانت تحت ضغط عالٍ، فتجاوزت فائدة التوزيع الذكي تكلفة القرار وتحسن الأداء بزيادة المخدمات. أظهرت الخوارزميات التقليدية تحسناً ملحوظاً عند الانتقال من ثلاث إلى خمس مخدمات بفضل حساباتها المحلية، لكن بقيت الخوارزمية المقترحة هي الأفضل في إدارة الأحمال. بالمقارنة مع Naïve Bayes، تحسن أداء Naïve Bayes بشكل ملحوظ على خمسة خوادم بفضل بساطتها الحسابية وتكيفها مع البيئة الموسعة دون التأثر بحمل الإحصائيات الإضافي. مع ذلك، حافظت الخوارزمية المقترحة على تفوقها عليها بفضل قدرة الغابة العشوائية على التعامل مع البيانات متعددة الأبعاد ودمجها بطريقة فعالة عبر مجموعة من الأشجار التنبؤية، مما يتيح نتائج أكثر استقراراً وواقعية حتى في ظل بيئة تشغيل معقدة.

9. التحليل الإحصائي للنتائج السابقة

لإثبات تفوق الخوارزمية المقترحة بشكل علمي موثوق، تم إجراء تحليل إحصائي شامل على النتائج التجريبية المستخرجة من تنفيذ السيناريوهات الأربعة. تم اختيار مؤشري الأداء الأكثر أهمية في تقييم أنظمة موازنة الحمل، وهما: زمن الاستجابة (Response Time) والإنتاجية (Throughput)، للمقارنة الإحصائية بين الخوارزمية المقترحة والخوارزميات الأربعة الأخرى.

أظهر تحليل التباين الثنائي (Two-way ANOVA) [33] وجود تأثير رئيسي معنوي للخوارزمية على زمن الاستجابة ($F(4,80) = 178.86$، $p < 0.001$) وعلى الإنتاجية ($F(4,80) = 294.76$، $p < 0.001$)، مع وجود تأثير تفاعلي معنوي بين الخوارزمية والسيناريو في كلا المؤشرين ($p < 0.001$). وأكد التحليل اللاحق بطريقة توكي للمقارنات المتعددة (Tukey HSD) [34] والاختبار التائي المستقل (Independent Samples t-test) [35] أن الخوارزمية المقترحة حققت أداءً متفوقاً بشكل إحصائي معنوي على جميع الخوارزميات المقارنة في كلا المؤشرين. في زمن الاستجابة، سجلت الخوارزمية المقترحة أقل متوسط بلغ 0.1150 ± 0.0132 ثانية، متفوقةً على ثاني أفضل خوارزمية TRT بنسبة 59%، وكانت جميع الفروقات معنوية ($p < 0.001$). وفي الإنتاجية، سجلت الخوارزمية المقترحة أعلى متوسط بلغ 82.04 ± 1.81، متفوقةً على ثاني أفضل خوارزمية LB بنسبة 29%،

وكانت جميع الفروقات معنوية ($p < 0.001$). تفصيل الإحصائيات الكاملة موضح في الجداول التالية.

الجدول (1) مقارنة زمن الاستجابة

الخوارزمية	المتوسط ± الانحراف المعياري	الترتيب
Proposed Algorithm	0.0132 ± 0.1150	1
Traditional Response Time	0.0720 ± 0.2800	2
Least Bandwidth	0.0961 ± 0.2825	3
Naive Bayes	0.1542 ± 0.4590	4
Round Robin	0.1764 ± 0.4770	5

الجدول (2) مقارنة الإنتاجية

الخوارزمية	المتوسط ± الانحراف المعياري	الترتيب
Proposed Algorithm	1.81 ± 82.04	1
Least Bandwidth	9.01 ± 63.69	2
Traditional Response Time	7.77 ± 62.91	3
Round Robin	10.74 ± 50.93	4
Naive Bayes	9.31 ± 50.60	5

الجدول (3) الإحصائيات التفصيلية ـــ زمن الاستجابة

المقارنة	Tukey HSD (p-adj)	t-test (t)	t-test (p)	فرق المتوسطات	CI95%
PA vs TRT	0.0002	10.08−	0.001 >	0.1650−	[−0.197, −0.133]
PA vs LB	0.0002	7.72−	0.001 >	0.1675−	[−0.210, −0.125]
PA vs NB	0.001 >	9.94−	0.001 >	0.3440−	[−0.412, −0.276]
PA vs RR	0.001 >	9.15−	0.001 >	0.3620−	[−0.440, −0.285]

الجدول (4) الإحصائيات التفصيلية ـــ الإنتاجية

المقارنة	Tukey HSD (p-adj)	t-test (t)	t-test (p)	فرق المتوسطات	CI95%
PA vs LB	0.001 >	8.93	0.001 >	18.34	[14.32, 22.37]
PA vs TRT	0.001 >	10.72	0.001 >	19.12	[15.63, 22.62]
PA vs RR	0.001 >	12.78	0.001 >	31.11	[26.34, 35.88]
PA vs NB	0.001 >	14.83	0.001 >	31.44	[27.28, 35.59]

تُظهر الجداول 1 و2 متوسطات مؤشري الأداء (زمن الاستجابة والإنتاجية) مع الانحراف المعياري لكل خوارزمية، حيث القيمة الأقل في زمن الاستجابة والأعلى في الإنتاجية تشيران إلى الأداء الأمثل. أما الجداول 3 و4 فيُفصّلان النتائج الإحصائية للمقارنات الثنائية بين الخوارزمية المقترحة والخوارزميات الأخرى باستخدام الاختبار التائي المستقل (t–test) وطريقة توكي (Tukey HSD)، مع فترات الثقة 95%(CI95%) . جميع القيم $p < 0.001$ وفترات الثقة لا تشمل الصفر، مما يؤكد أن تفوق الخوارزمية المقترحة على جميع الخوارزميات إحصائياً معنوي ومؤكد في كلا المؤشرين.

10.الخاتمة

أظهرت هذه الدراسة فعالية استخدام تقنيات التعلم الآلي في تحسين أداء موازنة حمل الخوادم ضمن بيئة الشبكات المعرفة بالبرمجيات، من خلال التنبؤ بزمن استجابة الخوادم بناءً على مؤشرات الأداء الفعلية، فقد أثبتت الخوارزمية المقترحة قدرتها على تحقيق توزيع أكثر فعالية للحمل مقارنةً بالخوارزميات الأخرى. تفتح هذه النتائج آفاقاً واعدة لتطوير حلول ذكية وقابلة للتكيف في إدارة موارد الشبكات خاصة في البيئات الديناميكية والمعقدة.

1. المراجع

[1]. Diel, G., Miers, C. C., Pillon, M. A., & Koslovski, G. P. (2023). RSCAT: Towards zero touch congestion control based on actor–critic reinforcement learning and software-defined networking. *Journal of Network and Computer Applications*, 215, 103639.

[2]. Beissenova, G., Zhidebayeva, A., Kopzhassarova, Z., Kozhabekova, P., Myrzakhmetova, B., Kerimbekov, M., Ussipbekova, D., & Yeshenkozhaev, N. (2024). Load balancing in DCN servers through software defined network machine learning. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 15(2), 509-519.

[3]. Muhammad, T. (2022). A Comprehensive Study on Software-Defined Load Balancers: Architectural Flexibility & Application Service Delivery in On-Premises Ecosystems. *INTERNATIONAL JOURNAL OF COMPUTER SCIENCE AND TECHNOLOGY*, 6(1), 1-24.

[4]. Maugendre, M. (2015). Development of a performance measurement tool for SDN (Master's thesis). Polytechnic University of Catalonia.

[5]. Ghazi, Y., & Mustafa, A. (2025). Improving single-controller software-defined networks architecture using named data networks architecture. *Homs University Journal*,*47*(2),49-76.

[6]. InterServer. (2019). *How to perform HTTP load testing using Siege*. https://www.interserver.net/tips/kb/http-load-testing-siege/.

[7]. Rodola, G. (2009–2025). *psutil documentation*. https://psutil.readthedocs.io/en/latest.

[8]. Botta, A., Donato, W., Dainotti, A., Avallone, S., & Pescapé, A. (2013). *D-ITG 2.8.1 manual*. COMICS Group, University of Napoli Federico II.

[9]. Alssaheli, O. M. A., Abidin, Z. Z., Zakaria, N. A., & Abas, Z. A. (2022). Software defined network based load balancing for network performance evaluation. *International Journal of Advanced Computer Science and Applications*, *13*(4), 117–124.

[10]. Linn, A. S., Win, S. H., & Win, S. T. (2019). Server load balancing in software defined networking. *National Journal of Parallel and Soft Computing*, *1*(1), 261–265.

[11]. Hamed, M. I., ElHalawany, B. M., Fouda, M. M., & Tag Eldien, A. S. (2017). Performance analysis of applying load balancing strategies on different SDN environments. *Benha Journal of Applied Sciences*, *2*(1), 91–97.

[12]. ElHalawany, B. M., Hamed, M. I., Fouda, M. M., & Tag Eldien, A. S. (2017). A new approach for server-based load balancing using software-defined networking. In *Proceedings of the 8th International Conference on Intelligent Computing and Information Systems (ICICIS 2017)* (pp. 155–160). IEEE.

[13]. Zhong, H., Fang, Y., & Cui, J. (2018). Reprint of: LBBSRT: An efficient SDN load balancing scheme based on server response time. *Future Generation Computer Systems*, *80*, 409–416.

[14]. Kumar, N., & Venkatesha Prasad, R. (2019). A comparative study on load balancing algorithms in software defined networking. In N. Kumar & R. Venkatesha Prasad (Eds.), *Ubiquitous communications and network computing (UBICNET 2019). Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering (LNICST)* (Vol. 276, pp. 142–150). Springer Nature.

[15]. Al-Bahadili, R. J., & Al-Saadi, A. (2020). An investigation of using traffic load in SDN based load balancing. *Iraqi Journal of Computer Communication Control and System Engineering*, *20*(2), 38–44.

[16]. Vani, K. A., & RamaMohanBabu, K. N. (2023). An intelligent server load balancing based on multi-criteria decision-making in SDN. *International Journal of Advanced Computer Science and Applications*, *14*(4), 888–896.

[17]. Soleimanzadeh, K., Ahmadi, M., & Nassiri, M. (2019). SD-WLB: An SDN-aided mechanism for web load balancing based on server statistics. *ETRI Journal*, *41*(2), 197–206.

[18]. Li, G., Gao, T., Zhang, Z., & Chen, Y. (2018). Fuzzy logic load-balancing strategy based on software-defined networking. *IEEE Access*, *6*, 2915–2924.

[19]. Malbašić, T., Bojović, P. D., Bojović, Ž., Šuh, J., & Vujošević, D. (2022). Hybrid SDN networks: A multi-parameter server load balancing scheme. *Journal of Network and Systems Management*, *30*(2), Article 32.

[20]. Krishna, P. M., Rao, S. S., Bhurat, S. S., Venkatesh, T., & Vani, K. A. (2021). Machine learning to balance web applications using SDN. *International Journal of Innovative Research in Management, Engineering and Computer Science (IJIRMPS)*, *9*(3), 201-207.

[21]. Hamdan, A. A., Trisnawan, P. H., & Bakhtiar, F. A. (2022). Implementation of load balancing using linear regression method on software defined network. *Journal of Information Technology and Computer Science Development*, *6*(7), 3560–3569.

[22]. Utomo, A. A., Trisnawan, P. H., & Primananda, R. (2020). Server load balancing mechanism using naive Bayes method with psutils agent on software defined network. *Journal of Information Technology and Computer Science Development*, *4*(10), 3961–3968.

[23]. Aldaher, M., Abbas, M., & Abboud, M. (2026). Review of server load balancing in software defined networks. *Homs University Journal*.

[24]. Xia, W., Wen, Y., Foh, C. H., Niyato, D., & Xie, H. (2015). A survey on software-defined networking. *IEEE Communications Surveys & Tutorials*, *17*(1), 27–51.

[25]. Ongaro, F. (2014). *Enhancing quality of service in software-defined networks* (Master's thesis). University of Bologna.

[26]. Wilk, P., & Nawrocki, P. (2014). Network management services based on the OpenFlow environment. *Computer Science*, *15*(4), 45–60.

[27]. المحلل العربي. (2017). *تطبيع البيانات: مهارة على كل محلل إتقانها*. https://www.arabiananalyst.com/2017/11/17/normalizing-data-an-analytical-trick-you-must-know-ar/

[28]. Muraina, I. O. (2021). Ideal dataset splitting ratios in machine learning algorithms: General concerns for data scientists and data analysts. In *Proceedings of the 7th International Mardin Artuklu Scientific Research Conference* (pp. 496–504). Mardin, Turkey.

[29]. Hamdan, A. A., Trisnawan, P. H., & Bakhtiar, F. A. (2022). Implementation of load balancing using linear regression method on software defined network. *Journal of Information Technology and Computer Science Development*, *6*(7), 3560–3569.

[30]. Aguilar, L. C. F. P., & Batista, D. M. (2019). Effectiveness of implementing load balancing via SDN. In *Proceedings of the Brazilian Symposium on Computer Networks and Distributed Systems (SBRC 2019)* (pp. 535–548).

[31]. Padilha, L. (n.d.). *pox* [Computer software]. GitHub. https://github.com/lcfpadilha/pox

[32]. علوم24. (n.d.). *فهم خوارزمية Naïve Bayes مع مثال عملي في Python*. https://sciences24.com/%d8%ae%d9%88%d8%a7%d8%b1%d8%b2%d9%85%d9%8a%d8%a9-naive-bayes/

[33]. Seltman, H. W. (n.d.). Chapter 11: Two-way ANOVA. In *Experimental design and analysis*. Department of Statistics, Carnegie Mellon University.

[34]. Tukey, J. W. (1949). Comparing individual means in the analysis of variance. *Biometrics*, *5*(2), 99–114. https://doi.org/10.2307/3001913

[35]. Student. (1908). The probable error of a mean. *Biometrika*, *6*(1), 1–25. https://doi.org/10.1093/biomet/6.1.1

[36].