

# مجلة جامعة البعث

سلسلة العلوم الهندسية الميكانيكية  
والكهربائية والمعلوماتية



مجلة علمية محكمة دورية

المجلد 45 . العدد 15

1444 هـ - 2023 م

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

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

مديرة مكتب مجلة جامعة البعث  
بشرى مصطفى

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

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

الاتصال بالعنوان التالي:

رئيس تحرير مجلة جامعة البعث

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

. هاتف / فاكس : 2138071 31 963 ++

. موقع الإنترنت : [www.albaath-univ.edu.sy](http://www.albaath-univ.edu.sy)

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

**ISSN: 1022-467X**

## شروط النشر في مجلة جامعة البعث

الأوراق المطلوبة:

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

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

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

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

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

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

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

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

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

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

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

## رسوم النشر في مجلة جامعة البعث

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

## المحتوى

الصفحة	اسم الباحث	اسم البحث
44-11	أسامة الدرمني د. سهيل الحمود	تحليل مقارن لتقنيات التعلم العميق في اكتشاف الكائنات
90-45	رولا عبد الكريم د. علي ذياب	دراسة خوارزميات توضع الخدمات المطبقة في حالات الطوارئ
108-91	م. طارق حرب د. محمود الأسعد د. ماهر الابراهيم	تأثير درجة حرارة وسرعة الطباعة ثلاثية الأبعاد على مقاومة الشد الأعظمية لمادة البولي ايثيلين تيرفتالات (PETG)
154-109	م. شفق طهماز د. رنيا لطفي	تحسين التحكم بالبيت البلاستيكي الذكي باستخدام الشبكات العصبونية







## تحليل مقارن لتقنيات التعلم العميق في اكتشاف الكائنات.

أسامة الدرميني<sup>1</sup>

د. سهيل الحمود<sup>2</sup>

### الملخص

تعدُّ مهمّة اكتشاف الكائنات من المهام الأساسية في مجال الرؤية الحاسوبية ومعالجة الصور. وتتنوّع تطبيقاته من تحديد مكان الكائنات إلى التعرف على الوجوه وتصنيف الكائنات بدلالة الشكل والأفعال.

لم تعد الطرق التقليدية في اكتشاف الكائنات تلبّي متطلّبات العصر نتيجة اعتمادها على أساليب توصيف يدويّة، وبسبب بطء أدائها في ظلّ وجود كمّيّة كبيرة من البيانات الناتجة عن الاعتماد على الوسائط المتعدّدة ووسائل التواصل الاجتماعي.

ومع التطوّر السريع للتعلم العميق وُجِدَت أدوات أكثر قوّة قادرة على معالجة الميّزات الدلاليّة عالية المستوى والمعقدة للكائنات وتمّ تطوير عدّة تقنيات لاكتشاف الكائنات باستخدام خوارزميّات التعلم العميق.

يقدم هذا البحث تحليلاً مقارناً لأشهر تقنيات التعلم العميق لاكتشاف الكائنات مبيناً شرحاً عن آلية عملها وحالات استخدامها وتقييماً تجريبياً لأدائها.

**الكلمات المفتاحية:** التعلم العميق - اكتشاف الكائنات - الرؤية الحاسوبية - الشبكات العصبونية التلافيفية - تصنيف الصور.

<sup>1</sup> طالب ماجستير - كلية الهندسة المعلوماتية - جامعة البعث - الجمهورية العربية السورية.

<sup>2</sup> دكتور مدرس - كلية الهندسة المعلوماتية - جامعة البعث - الجمهورية العربية السورية.

# A Comparative Analysis of Deep Learning Techniques in Object Detection

Usama Aldarmini<sup>3</sup>

PhD. Suhel Hammoud<sup>4</sup>

## Abstract

Objects detection is a fundamental task in computer vision and image processing. Its applications range from locating objects to recognizing faces and classifying objects in terms of form and action.

The traditional methods of discovering objects no longer meet the requirements of the times as a result of their reliance on non-dynamic methods and as a result of their slow performance in light of the world's dependence on a huge amount of multimedia and social media

With the rapid development of deep learning providing more powerful tools capable of manipulating high-level and complex semantic features of objects. Several techniques have been developed to detect objects using deep learning algorithms.

This research presents a comparative analysis of the most famous deep learning techniques for object detection, explaining their mechanisms, use cases and an experimental evaluation of their performance.

**Keywords:** Deep learning - object detection - computer vision - convolutional neural networks - image classification

---

<sup>3</sup> Master student – Informatics Engineering Faculty – ALBaath University - Syria.

<sup>4</sup> Researcher & Lecturer - Informatics Engineering Faculty – ALBaath University – Syria.

## 1. مقدمة:

تعمل شبكات CNN العميقة على تحسين تصنيف الصور بشكل كبير وزيادة دقة اكتشاف الكائنات. تعدّ عملية اكتشاف الكائنات أكثر صعوبة مقارنةً بتصنيف الصور، بحيث تتطلب طرقاً أكثر تعقيداً لحلّها، وينشأ هذا التعقيد لأن عملية الاكتشاف تتطلب تحديد موقع الكائنات بدقة، وبالتالي فإن الأساليب التقليدية لتدريب النماذج تكون عادةً بطيئة وغير دقيقة. مما يخلق تحديين أساسيين.

1. يجب معالجة العديد من مواقع الكائنات المرشحة (تسمى غالباً "Proposals").

2. يمكن أن يتم تحديد موقعاً تقريبياً فقط ثمّ يجب ضبطه لتحقيق تحديد أكثر دقة.

غالباً ما تؤثر حلول هذه التحديات على السرعة أو الدقة أو بساطة التصميم.

في هذا البحث، سنقارن بين التقنيات الأكثر استخداماً لاكتشاف الكائنات.

## 2. هدف البحث:

يهدف هذا البحث إلى تقديم تحليل مقارن لأشهر تقنيات اكتشاف الكائنات باستخدام التعلّم العميق. وتقديم شرح مبسط لكل تقنية مع حالات استخدامها ونقاط قوتها وآلية عملها، ثم إجراء تجارب لقياس أدائها ومقارنتها.

## 3. دراسات سابقة:

• تناقش الورقة البحثية [1] إمكانية استخدام شبكة CNN مصممة مسبقاً لتصنيف الصور وإضافة مهمة اكتشاف الكائنات لها. وتخلص الورقة إلى إمكانية تطوير نظام بسيط يعزز متوسط الدقة بأكثر من 40%. يجمع إطار العمل بين تقنيات رؤية الكمبيوتر القوية لتوليد bottom-up region proposals مع التطورات الحديثة في تعلم CNN. يعمل النظام بشكل مجموعة من التجارب التي توفر نظرة ثاقبة لما تتعلم الشبكة تمثيله، وكشف عن تسلسل هرمي غني من الميزات التمييزية والتي غالباً ما تكون ذات مغزى.

- تقدم الورقة البحثية [2] طريقة مختلفة للقيام باكتشاف فئة الكائنات باستخدام شبكات CNN، وهي أسرع بكثير من أحدث الحلول البديلة. تعتمد العديد من أنظمة الكشف عن الكائنات الحديثة على object proposals. تقترح هذه الورقة تقسيم الصورة إلى خلايا شبكية تعتمد على دراسة احتمالية وجود الكائنات في الخلايا وكذلك دراسة انحدار bounding box لكل كائن. السرعة هي الميزة الرئيسية لأن الشبكة تعالج الصورة مرة واحدة فقط وتكتشف الكائنات. النتائج جيدة جداً. الدقة أقل التقنيات الأخرى بحوالي 7%، لكنها أسرع بكثير في الاستدلال 45 FPS.
- تقدم الورقة البحثية [3] مسجلاً شاملاً للتطورات الحديثة في اكتشاف الكائنات المرئية باستخدام التعلم العميق. من خلال مراجعة مجموعة كبيرة من الأعمال الحديثة ذات الصلة، قام الباحثون بتحليل منهجي لأطر عمل الكشف عن الكائنات الموجودة وتنظيم المسح إلى ثلاثة أجزاء رئيسية: (1) مكونات الكشف، (2) استراتيجيات التعلم، و (3) التطبيقات والمعايير. في الاستطلاع، نغطي مجموعة متنوعة من العوامل التي تؤثر على أداء الكشف بالتفصيل، مثل بنى الكاشف، وتعلم الميزات، وإنشاء الاقتراح، واستراتيجيات أخذ العينات، وما إلى ذلك. وأخيراً، يناقش الباحثون العديد من الاتجاهات المستقبلية لتسهيل وتحفيز البحث المستقبلي لاكتشاف الأشياء المرئية مع التعلم العميق.
- تقدم الورقة البحثية [4] مراجعة شاملة للأبحاث المتعلقة باكتشاف كائنات الفيديو. يحاول هذا البحث ربط وتنظيم أحدث الأبحاث المتطورة حول اكتشاف الكائنات في الفيديو بهدف تصنيف وتحليل الخوارزميات المستخدمة بناءً على نماذج تمثيلية محددة. يتم عرض الاختلافات والتوصيلات بين اكتشاف الكائنات في الفيديو والمهام المماثلة بشكل منهجي، ويتم تقديم مقاييس التقييم والأداء للكشف عن الكائنات في الفيديو لما يقرب من 40 نموذجاً في مجموعتي بيانات. أخيراً، تمت مناقشة التطبيقات والتحديات المختلفة التي تواجه اكتشاف الكائنات في الفيديو.

#### 4. التعلم العميق Deep Learning:

قبل التحدث عن تقنيات اكتشاف الكائنات المعتمدة على التعلم العميق، سنقدم مراجعة حول التعلم العميق إلى جانب مقدمة حول البنية الأساسية ومزايا CNN.

##### 4.1. تعريف بالتعلم العميق:

يمكن الإشارة إلى النماذج العميقة على أنها شبكات عصبية ذات بنية عميقة أي أنها تتضمن عدد أكبر من الطبقات المخفية. يمكن أن يعود تاريخ الشبكات العصبية إلى أربعينيات القرن الماضي [5]. أصبح التعلم العميق شائعاً منذ عام 2006 [6]. ويمكن أن يُعزى انتشار التعلّم العميق إلى العوامل التالية:

- ظهور عدد من بيانات تدريب معلّمة (annotated)، مثل ImageNet [7].
- تطوير أنظمة الحوسبة عالية الأداء، مثل مجموعات GPU و TPU.
- تطورات كبيرة في تصميم هياكل الشبكات واستراتيجيات التدريب. بحيث يصبح تدريب الشبكات العصبية العميقة فعالاً للغاية. وفي الوقت نفسه، تمت دراسة هياكل الشبكات المختلفة، مثل AlexNet [8] و Overfeat [9] و GoogLeNet [10] و VGG [11] و ResNet [12]، على نطاق واسع لتحسين الأداء.

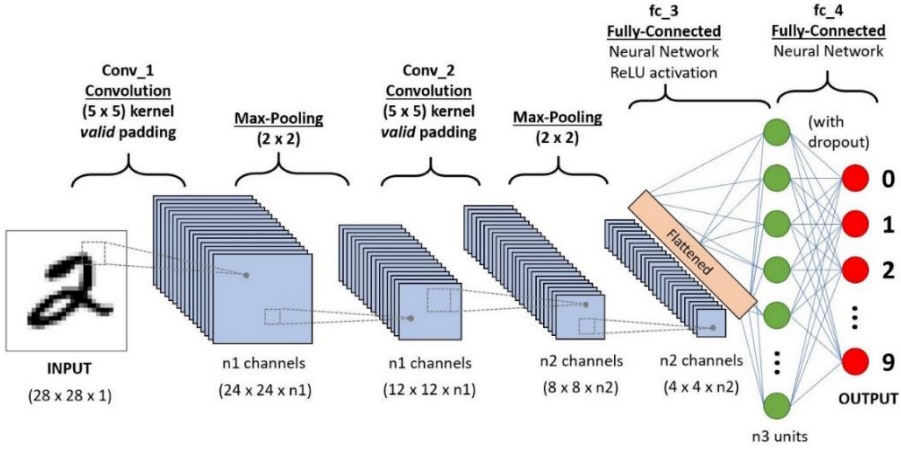
##### 4.2. بنية CNN وميزاتها:

الشبكة العصبية التلافيفية (المعروفة أيضاً باسم ConvNet أو CNN) هي نوع من الشبكات العصبية ذات التغذية الأمامية المستخدمة في مهام مثل تحليل الصور ومعالجة اللغة الطبيعية ومشكلات تصنيف الصور المعقدة الأخرى [13]. تتميز من حيث أنها يمكنها انتقاء واكتشاف الأنماط من الصور والنصوص وفهماها.

تنظر الشبكات العصبونية التلافيفية إلى رقعة (patch) واحدة من الصورة في كل مرة وتقوم بمسح الصورة بهذه الطريقة تدريجياً لاستخلاص معلومات كاملة [8].

#### 4.2.1. طبقات CNN [13]

- الطبقة التلافيفية Convolutional Layer.
- طبقة ReLU.
- طبقة التجميع Pooling Layer.
- طبقات التسوية Normalization Layer.
- الطبقات متصلة بالكامل Fully-Connected Layer.



الشكل 1 تسلسل CNN لتصنيف الأرقام المكتوبة بخط اليد [8]

#### 5. تقنيات اكتشاف الكائنات باستخدام التعلّم العميق:

اكتشاف الكائنات هو تقنية الرؤية الحاسوبية التي تسمح لنا بتحديد ماهية وتحديد موقع الكائنات في صورة أو مقطع فيديو. يمكن استخدام اكتشاف الكائنات لحساب عدد الكائنات في المشهد وتحديد مواقعها الدقيقة وتتبعها، كل ذلك مع وضع العلامات عليها بدقة.

على سبيل المثال، صورة تحتوي على قطين وشخص. يسمح لنا اكتشاف الكائن بتصنيف أنواع الأشياء التي تم العثور عليها مع تحديد موقع حدوثها في الصورة.





الشكل 2 مثال عن اكتشاف الكائنات

### 5.1. ما هو اكتشاف الكائنات:

اكتشاف الكائنات هو تقنية رؤية حاسوبية تعمل على التعرف على الأشياء وتحديد موقعها داخل صورة أو مقطع فيديو. على وجه التحديد، يرسم اكتشاف الكائنات مربعات إحاطة حول هذه الكائنات المكتشفة، مما يسمح لنا بتحديد مكان وجود الكائنات المذكورة (أو كيفية تحركها) في مشهد معين.

### 5.2. الفرق بين تصنيف الصور واكتشاف الكائنات:

تعد تقنيات تصنيف الصور واكتشاف الكائنات من الأساليب المهمة عندما يتعلق الأمر بالعمل في مجال الرؤية الحاسوبية. تساعد هذه التقنيات الآلات على فهم وتحديد الكائنات والبيئات في الوقت الفعلي بمساعدة الصور الرقمية كمدخلات.

#### 5.2.1. تصنيف الصور Image Classification

تصنيف الصور هو تقنية تستخدم لتصنيف أو التنبؤ بفئة كائن معين في صورة ما. الهدف الرئيسي من هذه التقنية هو تحديد الميزات في الصورة بدقة.

بشكل عام، يمكن تبويب تقنيات تصنيف الصور على أنها (بارامترية وغير بارامترية) أو (خاضعة للإشراف وغير خاضعة للإشراف). بالنسبة للتصنيف الخاضع للإشراف، تقدم

هذه التقنية نتائج بناءً على حدود القرار التي تم إنشاؤها، والتي تعتمد في الغالب على المدخلات والمخرجات المقدمة أثناء تدريب النموذج. ولكن في حالة التصنيف غير الخاضع للإشراف، توفر التقنية النتيجة بناءً على تحليل مجموعة بيانات الإدخال الخاصة بها؛ لا يتم تغذية الميزات مباشرة إلى النماذج.

تتمثل الخطوات الرئيسية المتضمنة في تقنيات تصنيف الصور في 1. تحديد نظام تصنيف مناسب، 2. استخراج الميزات، 3. اختيار عينات تدريب جيدة، 4. المعالجة المسبقة للصور، 5. اختيار طريقة التصنيف المناسبة، 6. ومعالجة التصنيف اللاحق، 7. أخيراً تقييم الدقة الإجمالية. في هذه التقنية، تكون المدخلات عادة صورة لكائن معين، والمخرجات هي الفئات المتوقعة التي تحدد وتطابق كائنات الإدخال. الشبكات العصبية التلافيفية (CNNs) هي أكثر نماذج الشبكات العصبية شيوعاً المستخدمة في مشكلة تصنيف الصور. [14]

## 5.2.2. اكتشاف الكائنات

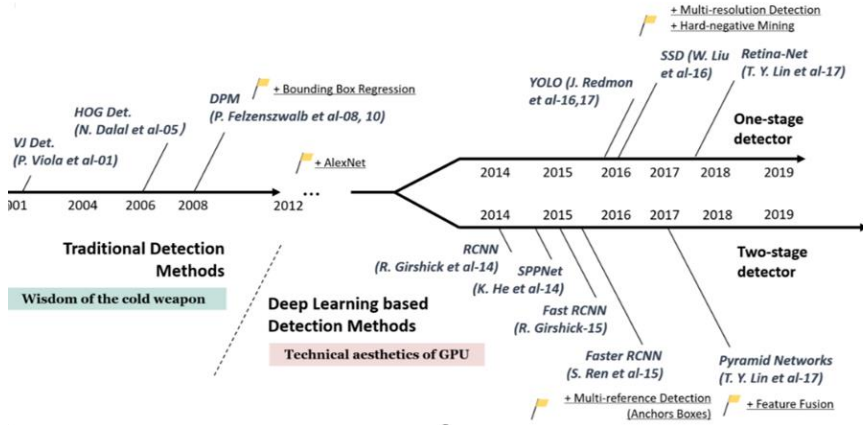
يتمثل تعريف مشكلة اكتشاف الكائنات في تحديد مكان وجود الكائنات في صورة معينة والفئة التي ينتمي إليها كل كائن. بكلمات بسيطة، يعد اكتشاف الكائن نوعاً من تقنيات تصنيف الصور، وإلى جانب التصنيف، تحدد هذه التقنية أيضاً موقع الكائن.

تتمتع هذه التقنية بالقدرة على البحث عن فئة معينة من الكائنات، مثل السيارات والأشخاص والحيوانات والطيور وما إلى ذلك، وقد تم استخدامها بنجاح في أنظمة معالجة الفيديو. أصبحت التطورات الأخيرة في هذه التقنية ممكنة فقط مع ظهور التعلم العميق.

يمكن تقسيم خطوات الكشف عن الكائنات التقليدية بشكل أساسي إلى ثلاث مراحل، وهي اختيار المنطقة المحتوية على المعلومات، واستخراج الميزات، والتصنيف.

### 5.3. محطات تطور اكتشاف الأشياء:

مجال اكتشاف الأشياء ليس جديدًا كما قد يبدو. في الواقع، تطور اكتشاف الأشياء على مدار العشرين عامًا الماضية. عادةً ما يتم فصل تقدم اكتشاف الأشياء إلى فترتين



الشكل 3 محطات تطور اكتشاف الأشياء [27]

تاريخيتين منفصلتين (قبل وبعد إدخال التعلم العميق):

قبل عام 2014 – الطرق التقليدية قبل التعلم العميق.

- Viola–Jones Detector (2001) [15] ، العمل الرائد الذي بدأ في تطوير طرق الكشف عن الكائنات
- HOG Detector (2006) [16] ، واصف ميزة شائعة لاكتشاف الكائنات في رؤية الكمبيوتر ومعالجة الصور
- DPM (2008) ، مع أول مقدمة لانحدار الصندوق المحيط ( Bounding Box Regression)

بعد 2014 - الطرق المعتمدة على التعلّم العميق.

أهم خوارزميات الكشف عن الكائنات على مرحلتين

- [1] (2014) RCNN and SPPNet
- [18] [17] (2015) Fast RCNN and Faster RCNN
- [19] (2017) Mask R-CNN
- [20] (2017) Pyramid Networks/FPN
- [21] (2021) G-RCNN

أهم خوارزميات الكشف عن الكائنات ذات المرحلة الواحدة

- [2] (2016) YOLO
- [22] (2016) SSD
- [23] (2017) RetinaNet
- [24] (2018) YOLOv3
- [25] (2020) YOLOv4
- (2021) YOLOR

كما نرى في القائمة أعلاه، يمكن تصنيف طرق اكتشاف الكائنات الحديثة إلى نوعين رئيسيين: تقنيات الكشف عن الأشياء ذات المرحلة الواحدة مقابل تقنيات الكشف عن الكائنات ثنائية المرحلة.

بشكل عام، تستخرج تقنيات الكشف عن الكائنات القائمة على التعلّم العميق الميزات من صورة الإدخال أو إطار الفيديو. تحل خوارزمية اكتشاف الكائنات مهمتين متتاليتين:

- المهمة رقم 1: البحث عن عدد عشوائي من الكائنات.
- المهمة رقم 2: تصنيف كل كائن على حدة وتقدير حجمه بمربع إحاطة.

لتبسيط العملية، يمكن فصل هذه المهام إلى مرحلتين. بينما تجمع الطرق الأخرى بين المهمتين في خطوة واحدة (تقنيات الكشف أحادية المرحلة) لتحقيق أداء أعلى على حساب الدقة.

#### 5.4. اكتشاف الكائنات بمرحلتين:

في هذا القسم، سوف نتعمق في الأفكار الرئيسية لمراحل عمل الخوارزميات المتعددة المراحل لاكتشاف الكائنات من خلال مراجعة بعض أهم الأوراق في هذا المجال.

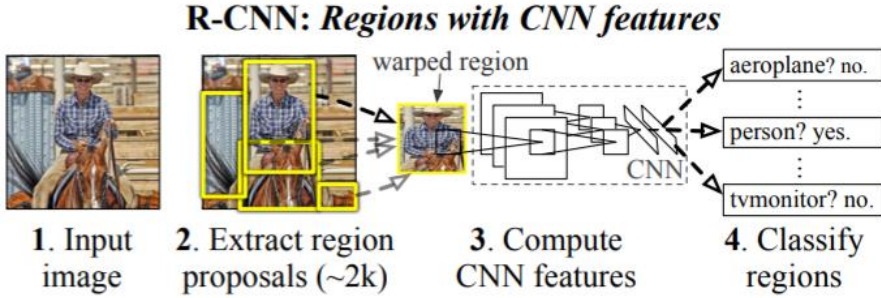
يتم استخدام نموذج واحد لاستخراج مناطق من الكائنات، ويتم استخدام نموذج ثانٍ لتصنيف وزيادة تحسين تحديد مكان الكائن. من المعروف أن مثل هذه الأساليب بطيئة نسبياً، ولكنها قوية جداً، ومع ذلك فإن التقدم الحديث مثل مشاركة الميزات (sharing features) أدى إلى تحسين أجهزة الكشف ذات المرحلتين للحصول على تكلفة حسابية مماثلة مع نماذج الكشف أحادية المرحلة. تعتمد هذه الأعمال بشكل كبير على الأعمال السابقة وتستند في الغالب إلى المراحل السابقة كبنية أساسية. لذلك، من المهم فهم جميع الخوارزميات الرئيسية في نماذج الكشف ذات المرحلتين.

##### 5.4.1 R-CNN:

تقترح ورقة عام 2014 [1] النسخة البسيطة من خوارزمية اكتشاف الكائنات على مرحلتين القائمة على CNN والتي تم تحسينها وتسريعها في الأوراق التالية. كما هو موضح في الشكل 4، يتكون سير العمل من ثلاث مراحل:

1. إنشاء مقترحات المنطقة: يجب أن يرسم النموذج ترشيحات للكائنات في الصورة، بشكل مستقل عن الفئة (تحديد المنطقة المتوقع وجود كائن فيها).
2. المرحلة الثانية هي شبكة عصبية تلافيفية بالكامل تحسب ميزات من كل منطقة مرشحة.

3. المرحلة النهائية هي طبقة متصلة بالكامل، يتم التعبير عنها في الورقة باسم



الشكل 4 نظرة عامة على مراحل R-CNN

.SVMs

يمكن إنشاء مقترحات المناطق باستخدام طرق مختلفة، وتختار الورقة استخدام البحث الانتقائي (Selective Search) [26].

في البحث الانتقائي، يتم تطبيق خوارزمية التجزئة على الصورة، ويتم رسم مقترحات المنطقة (المربعات المحيطة Bounding Box) بناءً على خريطة التجزئة. يتم دمج خريطة التجزئة بشكل منكرر (Bottom-Up) ويتم رسم مقترحات المنطقة الأكبر من الخريطة المحسنة بالتدرج كما هو موضح في الشكل 5.



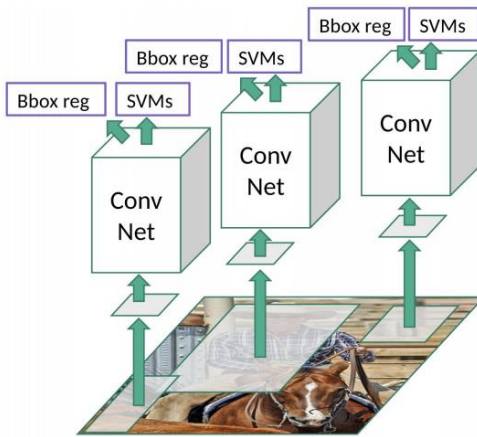
الشكل 5 البحث الانتقائي

تعمل هذه المرحلة (Selective Search) كالتالي

1. أولاً، يتم استخدام أوجه التشابه في اللون والبنية ومساحة وتعبئة للتجزئة (segmentation) غير المستندة إلى الكائن. لذلك نحصل على العديد من المناطق المجزأة الصغيرة كما هو موضح في أسفل يسار الصورة أعلاه.
2. بعد ذلك، يتم استخدام Bottom-Up approach الذي يتم فيه دمج المساحات المجزأة الصغيرة معاً لتشكيل مناطق مجزأة أكبر.
3. وبالتالي، يتم إنشاء عدة مقترحات لمناطق (bounding box المرشحين) كما هو موضح في الصورة.

بعد الانتهاء من البحث الانتقائي نأخذ كل bounding box ناتج عن هذه المرحلة وندخله في المرحلة التالية التي هي مرحلة اكتشاف الميزات للكائن المحتمل. ولكن قبل ذلك يجب إجراء تصحيح هندسي على هذا الجزء من الصورة المحدد بال bounding box وذلك لأن المرحلة الثانية التي هي شبكة CNN لا تقبل إلا دخل ثابت من حيث القياسات،

بينما خرج البحث الانتقائي هو مقترحات المنطقة ذات أحجام مختلفة وبالتالي يتم تحويل جميع المناطق المحتملة إلى مربعات



الشكل 6 عملية R-CNN

يمكن اعتبار المرحلتين الثانية والثالثة معاً شبكة CNN تقليدية تعمل على المنطقة المقترحة. تستخدم الورقة [1] CNN من نمط AlexNet كمرحلة ثانية، بينما يمكن استخدام أي بنية CNN أخرى.

في المرحلة الثانية يتم تغذية المناطق المقترحة من البحث الانتقائي كل على حدة

إلى الطبقات التلافيفية في الـ CNN وذلك من أجل استخراج الميزات.

المرحلة الثالثة هي مرحلة التنبؤ بالكائن وتتم عبر معالجة الميزات من قبل طبقات متصلة بالكامل في CNN.

وبعد عملية التنبؤ يتم تصحيح توضع الـ bounding box بشكل أكثر دقة بناءً على التنبؤ بالكائن. حيث يستخدم المؤلفون أيضاً مصنف الصندوق المحيط ( bounding box classifier ) الذي تم تدريبه لزيادة تحسين تقدير الصندوق المحيط الذي تم إجراؤه بواسطة التجزئة.

لرفض مقترحات المنطقة المتداخلة، حيث يشير مربعان محيطان أو أكثر إلى نفس الكائن، يقترح المؤلفون خوارزمية ترفض المنطقة إذا كانت تحتوي على IoU (intersection-over-union) عالٍ مع منطقة أخرى بها تنبؤ أكثر ثقة.

يأتي تفوق أداء R-CNN مقارنة بالطرق الأخرى من فكرة إجراء البحث الانتقائي من أسفل إلى أعلى أيضاً باستخدام شبكات CNN لزيادة دقة تحديد مكان الكائنات. يجمع هذا العمل بين الرؤية الحاسوبية ومعالجة الصورة التقليدية والتعلم العميق لتحسين اكتشاف الأشياء.

لكن تتلخص مشاكل R-CNN بالتالي:

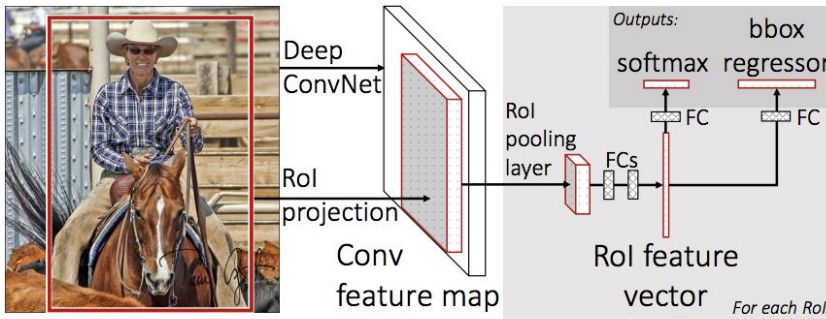
- تستغرق العملية وقتاً طويلاً لتدريب الشبكة حيث سيتعين عليك تصنيف 2000 اقتراح منطقة لكل صورة.
- لا يمكن تنفيذها في الوقت الحقيقي حيث تستغرق حوالي 47 ثانية لكل صورة اختبار.
- خوارزمية البحث الانتقائي هي خوارزمية ثابتة. لذلك، لا يوجد تعلم يحدث في تلك المرحلة. قد يؤدي هذا إلى توليد مقترحات سيئة للمنطقة المرشحة.



#### 5.4.2 Fast R-CNN:

قام نفس مؤلف الورقة السابقة [1] بحل بعض عيوب R-CNN لبناء خوارزمية أسرع لاكتشاف الكائنات وسميت Fast R-CNN [17].

النهج مشابه لخوارزمية R-CNN. ولكن، بدلاً من تقديم مقترحات المنطقة إلى CNN، نقوم بتغذية صورة الإدخال إلى CNN لإنشاء خريطة الميزات. من خريطة الميزات، نحدد منطقة المقترحات ونقوم بتصحيحها إلى مربعات وباستخدام طبقة ( RoI pooling)، نعيد تشكيلها إلى حجم ثابت بحيث يمكن تغذيتها في طبقة متصلة بالكامل. من شعاع ميزة RoI، نستخدم طبقة SoftMax للتنبؤ بفئة المنطقة المقترحة وكذلك قيم الإزاحة للمربع المحيط.



الشكل 7 Fast R-CNN

السبب في أن Fast R-CNN أسرع من R-CNN هو أنه لسنا مضطرين لتقديم 2000 اقتراح منطقة إلى الشبكة العصبية التلافيفية في كل مرة. بدلاً من ذلك، تتم عملية الالتفاف مرة واحدة فقط لكل صورة ويتم إنشاء خريطة المعالم منها.

فيما يلي المساهمات الرئيسية للورقة البحثية [17]

1. اقتراح طبقة جديدة تسمى RoI pooling تستخرج أشعة المعالم متساوية الطول من جميع المقترحات (أي ROIs) في نفس الصورة.


2. بالمقارنة مع R-CNN، التي لها مراحل متعددة (إنشاء مقترحات المنطقة، واستخراج الميزات، والتصنيف باستخدام SVM)، فإن Fast R-CNN تبني شبكة تحتوي على مرحلة واحدة فقط.
3. تشارك R-CNN الحسابات (أي حسابات الطبقة الالتفافية) عبر جميع المقترحات (RoI) بدلا من إجراء الحسابات لكل اقتراح بشكل مستقل. يتم ذلك باستخدام طبقة RoI pooling، مما يجعل Fast R-CNN أسرع من R-CNN.
4. لا يقوم Fast R-CNN بتخزين الميزات المستخرجة مؤقتا، وبالتالي لا يحتاج إلى الكثير من التخزين على القرص مقارنة ب R-CNN، الذي يحتاج إلى مئات الغيغابايت.
5. Fast R-CNN أكثر دقة من R-CNN.

تغذية خريطة المعالم من الطبقة الالتفافية الأخيرة إلى طبقة ROI والسبب في ذلك هو استخراج متجه معالم ثابت الطول من كل اقتراح منطقة.

ببساطة، تعمل طبقة RoI pooling عن طريق تقسيم كل اقتراح منطقة إلى شبكة من الخلايا. يتم تطبيق عملية max pooling على كل خلية في الشبكة لإرجاع قيمة واحدة. تمثل كافة القيم من كافة الخلايا متجه المعالم. إذا كان حجم الشبكة  $2 \times 2$ ، فإن طول متجه الميزة هو 4.

ثم يتم تمرير متجه المعالم المستخرجة باستخدام RoI pooling إلى بعض طبقات المتصلة بالكامل FC. ينقسم إخراج طبقة FC الأخيرة إلى 2 فرع:

- طبقة SoftMax للتنبؤ بدرجات الفصل
- طبقة FC متصلة بالكامل للتنبؤ بالمربعات المحيطة بالكائنات المكتشفة.



الشكل 8 عملية تحديد ROI

على الرغم من مزايا نموذج Fast R-CNN، إلا أن هناك عيبا حرجا لأنه يعتمد على خوارزمية البحث الانتقائي التي تستغرق وقتا طويلا لإنشاء مقترحات المنطقة. لا يمكن تخصيص أسلوب البحث الانتقائي على مهمة اكتشاف كائن معين. وبالتالي، قد لا يكون دقيقا بما يكفي للكشف عن جميع الكائنات المستهدفة في مجموعة البيانات.

### 5.4.3 .Faster R-CNN

تم ذكرها بالورقة البحثية [18]. هي خوارزمية اكتشاف كائنات امتداد لـ Fast R-CNN ولكنها أسرع منها وذلك بفضل استخدام region proposal network (RPN) المساهمات الرئيسية في الورقة [18]

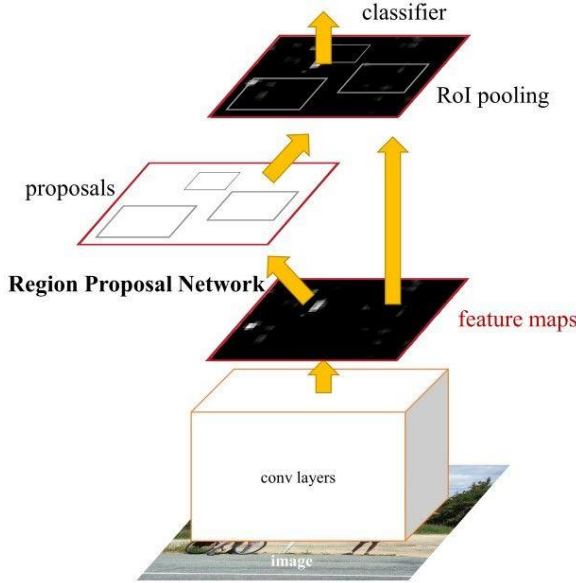
1. شبكة اقتراح المناطق (RPN) وهي شبكة تلافيفية بالكامل تولد مقترحات بمقاييس ونسب عرض إلى ارتفاع مختلفة. ينفذ RPN مفهوم neural network with attention التي تقوم بإخبار تقنية اكتشاف الكائنات (Fast R-CNN) أين تبحث.
2. بدلا من استخدام أهramات الصور (أي نسخ متعددة للصورة ولكن على مستويات مختلفة) أو أهramات المرشحات (أي مرشحات متعددة بأحجام مختلفة)، قدمت هذه الورقة مفهوم مربعات الربط (anchor boxes). مربع الربط هو مربع مرجعي لمقياس معين ونسبة عرض إلى ارتفاع. مع مربعات ربط مرجعية متعددة، توجد مقاييس متعددة ونسب عرض إلى ارتفاع للمنطقة الواحدة. يمكن اعتبار ذلك pyramid of reference anchor boxes. يتم تعيين كل منطقة إلى كل مربع ربط مرجعي، وبالتالي اكتشاف الكائنات على مقاييس ونسب عرض إلى ارتفاع مختلفة.
3. تتم مشاركة الحسابات التلافيفية عبر RPN و Fast R-CNN. هذا يقلل من الوقت الحسابي.

يتم عرض بنية Faster R-CNN في الشكل التالي. وهو يتألف من 2 وحدات:

• RPN: لتوليد مقترحات المنطقة.

• Fast R-CNN: للكشف عن الكائنات في المناطق المقترحة.

وحدة RPN هي المسؤولة عن توليد مقترحات المنطقة. يطبق مفهوم (الاهتمام) في



الشبكات العصبية، لذلك يوجه وحدة Fast R-CNN إلى مكان البحث عن الكائنات في الصورة.

لاحظ كيف تتم مشاركة خرج الطبقات التلافيفية عبر كل من وحدات RPN و Fast R-CNN.

الشكل وآلية عمل Faster R-CNN

تعمل Faster R-CNN

على النحو التالي:

1. تقوم RPN بإنشاء مقترحات المنطقة.
2. بالنسبة لجميع مقترحات المناطق في الصورة، يتم استخراج متجه ميزات ثابت الطول من كل منطقة باستخدام طبقة ROI
3. ثم يتم تصنيف أشعة الميزات المستخرجة باستخدام Fast R-CNN.
4. يتم إرجاع دقة التنبؤ بالفئة للكائنات المكتشفة بالإضافة إلى مربعاتها المحيطة.

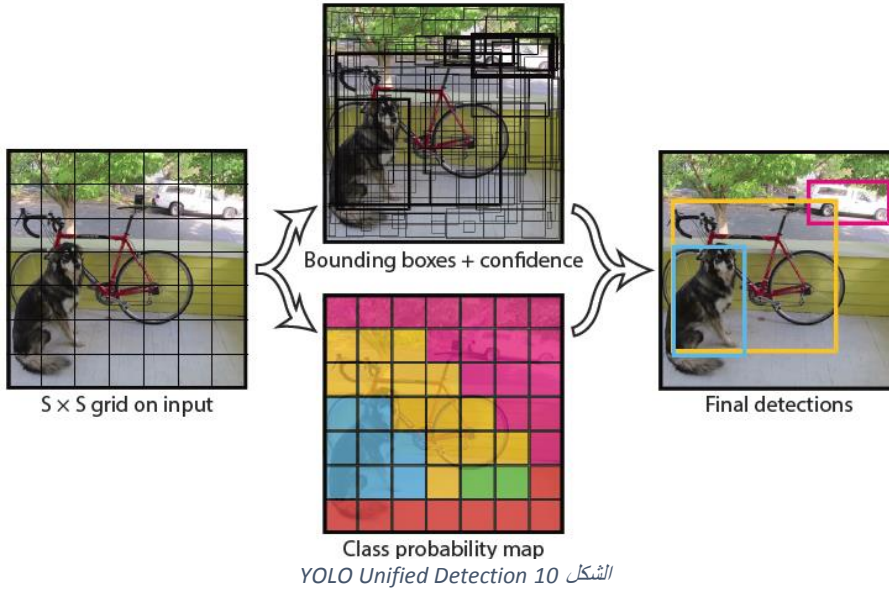
يمكن الاطلاع على الآلية التفصيلية لعمل RPN بالاطلاع على الورقة

### 5.5. اكتشاف الكائنات بمرحلة واحدة:

سنركز على بنية النموذج التي تنتبأ مباشرة بالمربعات المحيطة بالكائن لصورة بطريقة المرحلة الواحدة. بمعنى آخر، لا توجد مهمة وسيطة (كما ناقشنا سابقاً في اقتراح المنطقة) والتي يجب تنفيذها من أجل إنتاج مخرجات. تؤدي هذه الطريقة إلى بنية نموذج أبسط وأسرع.

#### 5.5.1. You Only Look Once (YOLO):

يقترح YOLO أن يكون لديك شبكة موحدة لأداء كل شيء مرة واحدة. أيضاً، يمكن تحقيق شبكة تدريب شاملة [2].




تقسم صورة الدخل إلى شبكة  $S \times S$  ( $S = 7$ ). إذا وقع مركز الكائن في خلية شبكة، فإن خلية الشبكة هذه تكون مسؤولة عن اكتشاف هذا الكائن.

تتوقع كل خلية شبكة مربعات إحاطة ( $B = 2$ ) ودرجات الثقة لتلك المربعات. تعكس درجات الثقة هذه مدى ثقة النموذج في احتواء الصندوق على كائن  $P$

يتكون كل مربع محيط من 5 تنبؤات:  $(x, y, w, h, confidence)$ .

- تمثل إحداثيات  $(x, y)$  مركز المربع بالنسبة لحدود خلية الشبكة.
- يتم توقع العرض  $w$  والارتفاع  $h$  بالنسبة للصورة بأكملها.
- تمثل الثقة (IOU) بين المربع المتوقع وأي مربع حقيقة أساسي.

تتنبأ كل خلية شبكة أيضاً باحتمالات الفئة الشرطية،  $P(\text{Class} | \text{Object})$ . (إجمالي عدد الفصول = 20)




الشكل 11 خرج YOLO

فيما يلي توضيح إخراج الشبكة:


$$7 \times 7 \times (2 \times 5 + 20) = 1470$$

### 5.5.1.1. بنية شبكة YOLO:

يتكون النموذج من 24 طبقة تلافيفية تليها طبقتان متصلتان بالكامل. تعمل الطبقات التلافيفية المتتالية  $1 \times 1$  على تقليل مساحة الميزات من الطبقات السابقة. (تم استخدام تحويل  $1 \times 1$  في GoogLeNet لتقليل عدد البارامترات).



الشكل 12 بنية YOLO model network



الشكل 13 مراحل YOLO

لذلك، يمكننا أن نرى أن صورة الإدخال تمر عبر الشبكة مرة واحدة ثم يمكن اكتشاف الكائنات. ويمكننا الحصول على التعلم الشامل. باستثناء الطبقة النهائية، تستخدم جميع الطبقات الأخرى ReLU كتابع تنشيط.




تم اختبار أول 20 طبقة تلافيفية بواسطة ImageNet للحصول على دقة تصل إلى 88%. ثم يتم تدريب الشبكة لنحو 135 حقبة على مجموعات بيانات التدريب والتحقق من PASCAL VOC.

### 5.5.2. Single Shot Detector (SSD)

SSD عبارة عن ورقة بحثية نشرت في عام 2016 [22]. يعمل SSD على تسريع عملية اكتشاف الكائنات من خلال التخلص من الحاجة إلى شبكة مقترحات المنطقة. لاستعادة الانخفاض في الدقة، يطبق SSD بعض التحسينات بما في ذلك multi-scale features و default boxes. تسمح هذه التحسينات لـ SSD بمطابقة دقة R-CNN Faster باستخدام صور ذات دقة أقل، مما يزيد السرعة بشكل أكبر. وفقًا للمقارنة التالية، فهي تحقق سرعة المعالجة في الوقت الفعلي وتتفوق حتى على دقة أسرع R-CNN Faster.


يتكون اكتشاف كائن باستخدام SSD من جزأين:

- استخراج خرائط المعالم.
- تطبيق مرشحات الالتفاف لاكتشاف الكائنات.



الشكل 14 Modified from SSD: Single Shot MultiBox Detector

يستخدم SSD شبكة VGG16 لاستخراج خرائط المعالم. ثم يكتشف الكائنات باستخدام طبقة Conv4\_3. للتوضيح، نرسم Conv4\_3 ليكون  $8 \times 8$  مكانياً (يجب أن يكون

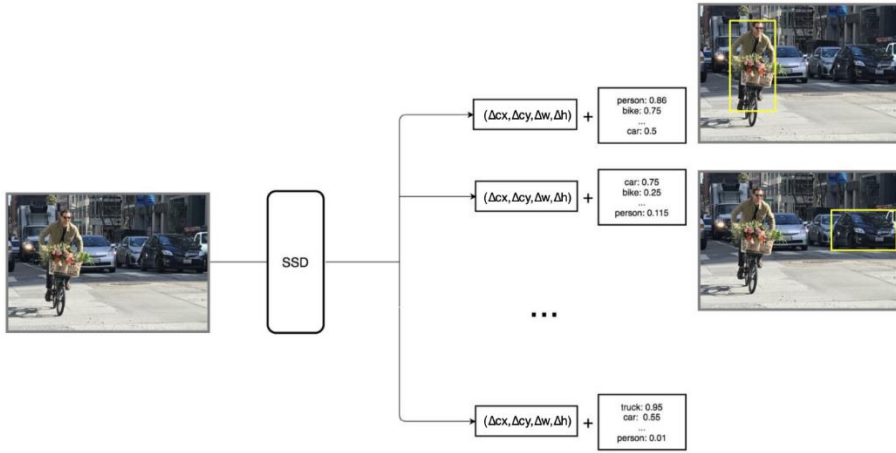


الشكل 15 الصورة اليسارية هي الصورة الأصلية وفي اليمين التنبؤ في كل خلية.

$38 \times 38$ ). لكل خلية (تسمى أيضاً الموقع)، تقوم بعمل 4 تنبؤات كائن.

يتكون كل توقع من boundary box و 21 درجة لكل فئة (فئة إضافية واحدة لعدم وجود كائن)، ونختار أعلى درجة باعتبارها فئة الكائن المحدد. يجعل Conv4\_3 إجمالي تنبؤات  $4 \times 38 \times 38$ : أربع تنبؤات لكل خلية بغض النظر عن عمق خرائط المعالم. كما هو متوقع، العديد من التنبؤات لا تحتوي على أي كائن. يحتفظ SSD بفئة "0" للإشارة إلى عدم احتوائه على كائنات.

يُطلق على إجراء تنبؤات متعددة تحتوي على مربعات حدود ودرجات الثقة اسم .multibox



نلاحظ أننا نقوم بعمل تنبؤات أكثر بكثير من عدد العناصر الموجودة. لذلك هناك العديد من المطابقات السلبية أكثر من التطابقات الإيجابية. هذا يخلق عدم توازن يضر بالتدريب. نحن ندرّب النموذج على تعلم مساحة الخلفية بدلاً من اكتشاف الأشياء. ومع ذلك، لا يزال SSD يتطلب أخذ عينات سلبية حتى يتمكن من معرفة ما يشكل تنبؤاً سيئاً. لذلك، بدلاً من استخدام كل السلبيات، نقوم بفرز تلك السلبيات من خلال فقدان الثقة المحسوب. يختار SSD السلبيات ذات الخسارة الأعلى ويتأكد من أن النسبة بين السلبيات والإيجابيات المختارة هي 3:1 على الأكثر. هذا يؤدي إلى تدريب أسرع وأكثر استقراراً.

## 6. مقارنات تقنيات اكتشاف الكائنات:

تبين الجداول التالية مقارنة الخوارزميات التي سبق وتمت مراجعتها تتناول المراجعة تقنية اقتراح المنطقة وإمكانية إدخال صور مختلفة القياسات وطريقة التعلّم، كما يتم تبين نوع دالة الخسارة المستخدمة كما يتم تبين خالة وجود طبقة SoftMax واللغة المكتوبة فيها الخوارزمية.

الجدول 1، 2، 3 مقارنة بعض تقنيات اكتشاف الأشياء

Framework	Proposal	Multi-scale Input	Learning Method
R-CNN	Selective Search	No	SGD, BP
SPP-net	EdgeBoxes	Yes	SGD
Fast RCNN	Selective Search	Yes	SGD
Faster R-CNN	RPN	Yes	SGD
YOLO	–	NO	SGD
SSD	–	NO	SGD
YOLOv2	–	NO	SGD

Framework	Loss Function
R-CNN	Hinge loss (classification), Bounding box regression
Fast RCNN	Class Log loss + bounding box regression
Faster R-CNN	Class Log loss + bounding box regression
YOLO	Class sum-squared error loss + bounding box regression + object confidence+background confidence
SSD	Class softmax loss + bounding box regression
YOLOv2	Class sum-squared error loss + bounding box regression + object confidence+background confidence

Framework	Softmax Layer	End-to-end Train	Platform	Language
R-CNN	Yes	No	Caffe	Matlab
Fast RCNN	Yes	No	Caffe	Python
Faster R-CNN	Yes	Yes	Caffe	Python/Matlab
YOLO	Yes	Yes	Darknet	C
SSD	No	Yes	Caffe	C++
YOLOv2	Yes	Yes	Darknet	C

## 7. التجربة والنتائج:

سيتم تجربة التقنيات التي تم شرحها سابقاً على مجموعات بيانات محددة لمعرفة كفاءة كل تقنية ومواضع تفوقها.

### 7.1 مجموعات بيانات التدريب:

إن تطور الرؤية الحاسوبية أدى إلى زيادة الحاجة إلى مجموعات بيانات صور واسعة النطاق. كمية كبيرة من البيانات التوضيحية الكبيرة هي السبب الرئيسي وراء النجاح الهائل لاستخدام تقنيات التعلم العميق في اكتشاف الكائنات. يلعب الإنترنت دوراً حيوياً في بناء

مجموعة بيانات شاملة لتوفير الوصول إلى مجموعة واسعة من الصور التي تغطي اتساع وتنوع الكائنات. تحظى خمس مجموعات بيانات شعبية كبيرة في مجال اكتشاف الأشياء العامة، وهي PASCAL VOC 2007 و PASCAL VOC2012 و ImageNet و Microsoft COCO و OpenImages. يلخص الجدول 3 المواصفات والسمات الخاصة بمجموعات البيانات هذه.

## تحليل مقارنة لتقنيات التعلم العميق في اكتشاف الكائنات

الجدول 4 المواصفات والسمات الخاصة بمجموعات البيانات [28]

S/no	Datasets	Reference	No of images	Images Size	Categories	per category images	Objects per images	Initial Date	Description
1	PASCAL VOC (2007/ 2012)	[103, 145]	11,540	470x380	20	303-4087	2.4	2005	The dataset consists of 20 categories from daily life; Contain large no of real-world training images; multiple objects in one image; images of scenes; complex sample; Intra-class variations
2	ImageNet (2015)	[56]	14,197,122	500x400	21,841	—	1.5	2010	dataset based on WordNet hierarchy; per image more instance and objects; Benchmark for ILSVRC challenged ; Object- centric images
3	MS COCO (2014)	[104]	328,000+	640 x 480	91	—	7.3	2014	The dataset contains real-world scenes; multiple objects in each image and fully annotated; images with objects segmentation
4	Place(2017)	[270]	10 million+	256 x 256	434	—	—	2014	The Largest scenes recognition annotated dataset; Places 365 (Standard); Places 365(Challenge); Places205 and Place 88 ( Benchmarks) ; four subsets
5	Open Images( 2019)	[150]	9 million+	Varying	6000+	—	8.3	2017	A large scale object detection dataset: Open Images v5; visual relationship detection and instance segmentation

وستنعمد في هذه الورقة البحثية على مجموعتي البيانات Pascal VOC (2007/2012).

الجدول 5 تكوين مجموعات بيانات Pascal VOC [28]

challenge	Object categories	Total images			Annotated objects		Training + Val set		
		Train set	Val set	Test set	Train- set	Val-set	Instance	Boxes	Per image boxes
<b>Object detection challenge PASCAL VOC:</b>									
VOC07	20	2501	2501	4952	6301	6307	5011	12608	2.5
VOC08		2111	2221	4133	5082	5281	4332	10364	2.4
VOC09		3473	3581	6650	8505	8713	7054	17218	2.3
VOC10		4998	5105	9637	11577	11797	10103	23374	2.4
VOC11		5717	5823	10,994	13609	13841	11540	27450	2.4
VOC12		5717	5823	10,991	13609	13841	11540	27450	2.4

## 7.2. النتائج:

عند تجربة التقنيات التي قمنا بشرحها سابقا على البيانات نصل إلى النتائج التالية

الجدول 6 نتائج اختبار Pascal VOC 2007 على تقنيات اكتشاف الكائنات

Methods	Trained on	areo	bike	bird	boat	bottle	bus	car	cat	chair	cow	table	dog	horse	mbike	person	plant	sheep	sofa	train	tv	mAP
R-CNN(Alex)	07	68.1	72.8	56.8	43	36.8	66.3	74.2	67.6	34.4	63.5	54.5	61.2	69.1	68.6	58.7	33.4	62.9	51.1	62.5	68.6	58.5
R-CNN(VGG16)	07	73.4	77	63.4	45.4	44.6	75.1	78.1	79.8	40.5	73.7	62.2	79.4	78.1	73.1	64.2	35.6	66.8	67.2	70.4	71.1	66
Fast R-CNN	07+12	77	78.1	69.3	59.4	38.3	81.6	78.6	86.7	42.8	78.8	68.9	84.7	82	76.6	69.9	31.8	70.1	74.8	80.4	70.4	70
Faster R-CNN	07	70	80.6	70.1	57.3	49.9	78.2	80.4	82	52.2	75.3	67.2	80.3	79.8	75	76.3	39.1	68.3	67.3	81.1	67.6	69.9
Faster R-CNN	07+12	76.5	79	70.9	65.5	52.1	83.1	84.7	86.4	52	81.9	65.7	84.8	84.6	77.5	76.7	38.8	73.6	73.9	83	72.6	73.2
Faster R-CNN	07+12+COCO	84.3	82	77.7	68.9	65.7	88.1	88.4	88.9	63.6	86.3	70.8	85.9	87.6	80.1	82.3	53.6	80.4	75.8	86.6	78.9	78.8
SSD300	07+12+COCO	80.9	86.3	79	76.2	57.6	87.3	88.2	88.6	60.5	85.4	76.7	87.5	89.2	84.5	81.4	55	81.9	81.5	85.9	78.9	79.6
SSD512	07+12+COCO	86.6	88.3	82.4	76	66.3	88.6	88.9	89.1	65.1	88.4	73.6	86.5	88.9	85.3	84.6	59.1	85	80.4	87.4	81.2	81.6

الجدول 7 ملخص نتائج اختبار Pascal VOC 2007 على تقنيات اكتشاف الكائنات

Methods	Trained on	mAP
R-CNN(Alex)	07	58.5
R-CNN(VGG16)	07	66
Fast R-CNN	07+12	70
Faster R-CNN	07	69.9
Faster R-CNN	07+12	73.2
Faster R-CNN	07+12+COCO	78.8
SSD300	07+12+COCO	79.6
SSD512	07+12+COCO	81.6

تحليل مقارن لتقنيات التعلم العميق في اكتشاف الكائنات

الجدول 8 نتائج اختبار Pascal VOC 2012 على تقنيات اكتشاف الكائنات

Methods	Trained on	areo	bike	bird	boat	bottle	bus	car	cat	chair	cow	table	dog	horse	mbike	person	plant	sheep	sofa	train	tv	mAP
R-CNN(Alex)	12	71.8	65.8	52	34.1	32.6	59.6	60	69.8	27.6	52	41.7	69.6	61.3	68.3	57.8	29.6	57.8	40.9	59.3	54.1	53.3
R-CNN(VGG16)	12	79.6	72.7	61.9	41.2	41.9	65.9	66.4	84.6	38.5	67.2	46.7	82	74.8	76	65.2	35.6	65.4	54.2	67.4	60.3	62.4
Fast R-CNN	07++12	82.3	78.4	70.8	52.3	38.7	77.8	71.6	89.3	44.2	73	55	87.5	80.5	80.8	72	35.1	68.3	65.7	80.4	64.2	68.4
Faster R-CNN	07++12	84.9	79.8	74.3	53.9	49.8	77.5	75.9	88.5	45.6	77.1	55.3	86.9	81.7	80.9	79.6	40.1	72.6	60.9	81.2	61.5	70.4
YOLO	07++12	77	67.2	57.7	38.3	22.7	68.3	55.9	81.4	36.2	60.8	48.5	77.2	72.3	71.3	63.5	28.9	52.2	54.8	73.9	50.8	57.9
YOLOv2	07++12+coco	88.8	87	77.8	64.9	51.8	85.2	79.3	93.1	64.4	81.4	70.2	91.3	88.1	87.2	81	57.7	78.1	71	88.5	76.8	78.2
SSD300	07++12+coco	91	86	78.1	65	55.4	84.9	84	93.4	62.1	83.6	67.3	91.3	88.9	88.6	85.6	54.7	83.8	77.3	88.3	76.5	79.3
SSD512	07++12+coco	91.4	88.6	82.6	71.4	63.1	87.4	88.1	93.9	66.9	86.6	66.3	92	91.7	90.8	88.5	60.9	87	75.4	90.2	80.4	82.2

الجدول 9 ملخص نتائج اختبار Pascal VOC 2012 على تقنيات اكتشاف الكائنات

Methods	Trained on	mAP
R-CNN(Alex)	12	53.3
R-CNN(VGG16)	12	62.4
Fast R-CNN	07++12	68.4
Faster R-CNN	07++12	70.4
YOLO	07++12	57.9
YOLOv2	07++12+coco	78.2
SSD300	07++12+coco	79.3
SSD512	07++12+coco	82.2



## 8. مناقشة النتائج:

من خلال النتائج السابقة نجد ما يلي:

- سلبية تقنيات اكتشاف الكائنات القائمة على مرحلتين (اقتراح المنطقة) هي الحاجة إلى قوة حسابية عالية
- بنية تقنيات اكتشاف الكائنات القائمة على مرحلتين أكثر مرونة وكفاءة من التقنيات القائمة على مرحلة واحدة
- تتطلب تقنيات اكتشاف الكائنات القائمة على مرحلة واحدة (YOLO, SSD) وقتاً أقل مقارنةً بالتقنيات القائمة على مرحلتين:
  - نظراً لشبكات CNN لاستخراج الميزات أقل استهلاكاً
  - تجنب خوارزميات المعالجة المسبقة
  - لا يوجد مرحلة اقتراح منطقة
- نلاحظ أن أداء تقنيات اكتشاف الكائنات القائمة على مرحلة واحدة ليس ممتاز بالعموم حيث تجد هذه التقنيات صعوبة في اكتشاف الكائنات الصغيرة
- عند توفر عتاد جيد للتغلب على وقت المعالجة، فإن التقنيات القائمة على مرحلتين هي الخيار الأفضل

## 9. الخاتمة:

يعتمد نجاح اكتشاف الكائنات بشكل أساسي على التقنيات المستخدمة. تعد التقنيات القائمة على مرحلة واحدة أكثر وضوحًا وأسرع، بينما تعد التقنيات القائمة على مرحلتين أكثر دقة وكفاءة.

الهدف النهائي هو تطوير تقنية اكتشاف كائنات قادرة على تحديد والتعرف على الآلاف من فئات الكائنات الجديدة في مشاهد العالم الحقيقي المفتوح بدقة وكفاءة. وبالتالي نحتاج مجموعات بيانات أكبر حجمًا تضم المزيد من الفئات نظرًا لأن مجموعات البيانات المعيارية الحالية تغطي بضع مئات من فئات الكائنات التي هي أقل بكثير من الفئات المعترف بها من قبل الإنسان.

استعرضنا في هذا البحث مفهوم اكتشاف الكائنات بعد أن قدمنا مقدمة موجزة عن التعلم العميق والشبكات العصبونية التلافيفية.

ثم تم عرض تحليل لأهم الأوراق العلمية التي أطلقت مجموعة من خوارزميات اكتشاف الكائنات المستندة على التعلم العميق. قمنا بدراسة بنية أشهر هذه الخوارزميات وسبب إطلاقها وآلية عملها. ثم قمنا باختبار هذه البيانات ومناقشة النتائج للوصول إلى بعض المعايير لاستخدام بعض تقنيات اكتشاف الكائنات .

## 10. المراجع

- [1]. Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 580-587).
- [2]. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 779-788).
- [3]. Wu, X., Sahoo, D., & Hoi, S. C. (2020). Recent advances in deep learning for object detection. *Neurocomputing*, 396, 39-64.
- [4]. Jiao, L., Zhang, R., Liu, F., Yang, S., Hou, B., Li, L., & Tang, X. (2021). New generation deep learning for video object detection: A survey. *IEEE Transactions on Neural Networks and Learning Systems*.
- [5]. Pitts, W., & McCulloch, W. S. (1947). How we know universals the perception of auditory and visual forms. *The Bulletin of mathematical biophysics*, 9(3), 127-147.
- [6]. Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *science*, 313(5786), 504-507.
- [7]. Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009, June). Imagenet: A large-scale hierarchical image database. In 2009 IEEE conference on computer vision and pattern recognition (pp. 248-255). Ieee.
- [8]. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- [9]. Sermanet, P., Eigen, D., Zhang, X., Mathieu, M., Fergus, R., & LeCun, Y. (2013). Overfeat: Integrated recognition, localization and detection using convolutional networks. *arXiv preprint arXiv:1312.6229*.
- [10]. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9).
- [11]. Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [12]. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).
- [13]. O'Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*.
- [14]. Chan, T. H., Jia, K., Gao, S., Lu, J., Zeng, Z., & Ma, Y. (2015). PCANet: A simple deep learning baseline for image classification?. *IEEE transactions on image processing*, 24(12), 5017-5032.

- [15]. Viola, P., & Jones, M. (2001, December). Rapid object detection using a boosted cascade of simple features. In Proceedings of the 2001 IEEE computer society conference on computer vision and pattern recognition. CVPR 2001 (Vol. 1, pp. I-I). Ieee.
- [16]. Dalal, N., Triggs, B., & Schmid, C. (2006, May). Human detection using oriented histograms of flow and appearance. In European conference on computer vision (pp. 428-441). Springer, Berlin, Heidelberg.
- [17]. Girshick, R. (2015). Fast r-cnn. In Proceedings of the IEEE international conference on computer vision (pp. 1440-1448).
- [18]. Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28.
- [19]. He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask r-cnn. In Proceedings of the IEEE international conference on computer vision (pp. 2961-2969).
- [20]. Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature pyramid networks for object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2117-2125).
- [21]. Pramanik, A., Pal, S. K., Maiti, J., & Mitra, P. (2021). Granulated RCNN and multi-class deep sort for multi-object detection and tracking. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 6(1), 171-181.
- [22]. Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016, October). Ssd: Single shot multibox detector. In European conference on computer vision (pp. 21-37). Springer, Cham.
- [23]. Lin, T. Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2017). Focal loss for dense object detection. In Proceedings of the IEEE international conference on computer vision (pp. 2980-2988).
- [24]. Redmon, J., & Farhadi, A. (2018). Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*.
- [25]. Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*.
- [26]. Uijlings, J. R., Van De Sande, K. E., Gevers, T., & Smeulders, A. W. (2013). Selective search for object recognition. *International journal of computer vision*, 104(2), 154-171.
- [27]. Zou, Z., Shi, Z., Guo, Y., & Ye, J. (2019). Object detection in 20 years: A survey. *arXiv preprint arXiv:1905.05055*.
- [28]. Aziz, L., Salam, M. S. B. H., Sheikh, U. U., & Ayub, S. (2020). Exploring deep learning-based architecture, strategies, applications and current trends in generic object detection: A comprehensive review. *IEEE Access*, 8, 170461-170495.

## دراسة خوارزميات توضع الخدمات المطبقة في

### حالات الطوارئ

طالبة الدراسات العليا: رولا محمد عبد الكريم

قسم التحكم الآلي والحواسيب - كلية: الهك - جامعة البعث

الدكتور المشرف: علي ذياب

#### الملخص

تعد شبكات الاتصالات مجال بحثي واسع يتضمن العديد من التحديات خصوصاً عند حدوث حالات طوارئ لا يمكن بسهولة التنبؤ بها، فعند حصول حالة الطوارئ تنهار أجزاء من الشبكة. لا بد من طريقة يتم فيها استعادة الخدمات بشكل سريع وفق الموارد والمعايير المتاحة بحيث نستطيع إعادة الاتصال الى المستوى الذي كنا عليه قبل حدوث الحالة الطارئة إن أمكن. تعمل خوارزميات توضع الخدمات في الشبكات على توزيع الخدمات على العقد المختلفة لتضمن أفضل أداء ممكن.

قمنا في هذا البحث بالعمل على مجال خوارزميات توضع الخدمات في الشبكات من خلال بناء محاكي شبكي باستخدام لغة البرمجة JAVA ذات الإمكانيات العالية لمحاكاة عمل الخوارزميات المختارة.

حيث عملنا على تطبيق سيناريو شبكي باستخدام ثلاث خوارزميات لتوضع الخدمات (Random , SO-RAP , SO-ARAP) في الحالة الطبيعية للشبكة وفي حال حدوث حالات طوارئ (فشل في العقد أو المخدمات أو انقطاعات في الاتصالات) واستخدام أعداد مختلفة من العقد ضمن مساحة جغرافية محددة والعمل على تحليل النتائج للحصول على متوسط استهلاك الموارد لمختلف العقد وجودة الخدمات المقدمة من المخدمات للعقد الزبائن ومقارنة عمل الخوارزميات المستخدمة وتلاؤمها مع حالات الطوارئ.

الكلمات المفتاحية: الشبكات، الخدمات، خوارزميات توضع الخدمات، حالات الطوارئ، محاكي

شبكي.

# Studying of Service Placement Algorithms applied in emergency situations

## Abstract

Communication networks are considered a broad field of research that includes many challenges, especially during emergencies which can't be predicted easily. So, When an emergency occurs, some parts of the network fail. So that, it's urgent to find a way to restore the services rapidly according to the available resources and standards, so we can reconnect to the previous level. Network service placement algorithms distribute services to different nodes to ensure the best possible performance.

Consequently, In this research we worked on the field of service placement algorithms in networks by building similar network using the high-powered JAVA programming language to simulate the work of the chosen algorithm. We have done that by applying a network scenario using three algorithm to placement services (Random, SO-RAP, SO-ARAP) in the normal state of the network and in the event of emergency situations such as node's and servers failures or communication outages. We have also used different numbers of nodes within a geographical specific space and we have worked on analyzing the results to obtain the average consumption of resources for the various nodes and the quality of services provided by the servers to the client nodes. Finally, we have compared the work of the used algorithms and their compatibility with emergency situations.

Keywords: Networks, Services, Service Placement Algorithms, Emergencies, Network Simulator

## 1 - مقدمة

تعدُّ التكنولوجيا مظهراً من مظاهر العصر الحديث، وقد تداخلت مع حياتنا في كافة جوانبها، حتى أصبحت التكنولوجيا موجودة في كل بيت، وهي رفيقتنا الدائمة التي لا يمكننا الفكاك عنها أو تجاهلها، وهذا العصر هو عصرها، وفيه تطورت وازدهرت ووصلت إلى أعلى مراتب الحداثة والتجدد. وقد كانت بدايات ظهور التكنولوجيا مع بداية العصر الحديث، إذ بدأت الاختراعات بالظهور، وشرعت تتدفق المنتجات العصرية إلى الأسواق، فظهرت السيارات، والطائرات، والدراجات البخارية.

حيث أصبحت أجهزة الكمبيوتر والأجهزة المحمولة مثل الهواتف المحمولة وأجهزة الكمبيوتر المحمولة جزءاً مهماً في حياتنا اليومية لا يمكننا الاستغناء عنه.

وفي الوقت الحاضر تعد المعلومات الرقمية الوسيلة الأسرع نمواً المستخدمة لتخزين ونقل البيانات في العالم ، ويعد الوصول الشامل إلى المعلومات والخدمات في أي لحظة وفي أي مكان وبكلفة منخفضة أحد الأشياء الرئيسية التي يجب أن تميز شبكات الاتصال في المستقبل.

فمن الواضح أن أحد أهم التحديات التي تواجه الشبكات المستقبلية هو الطلب المتزايد بشكل كبير على الموارد والخدمات من قبل العملاء وسيكون لهذه الزيادة آثار سلبية على أداء الشبكة وكلفة الاتصال وجودة الخدمة (QoS).

يقدم هذا البحث بناء محاكي شبكي قادر على محاكاة عمل خوارزميات توزيع الخدمات في الحالات الطبيعية وفي حالات الطوارئ التي تنتج عن حدوث فشل في أحد العقد أو في أحد المخدمات وفي حال انقطاع الاتصال.

وقمنا بتطبيق سيناريو شبكي لمقارنة عمل ثلاث خوارزميات ( Random , SO-RAP ) و تحليل النتائج من خلال متوسط استهلاك الموارد وجودة الخدمات المقدمة.

## 2 - هدف البحث

يهدف هذا البحث الى دراسة أداء خوارزميات توزيع الخدمات المطبقة في حالات الطوارئ وذلك من خلال بناء محاكي لعملها وتقييم أداءها في الحالات الطبيعية وحالات الطوارئ من خلال تحديد متوسط استهلاك الموارد المختلفة ضمن الشبكة وحساب جودة الخدمات المقدمة.

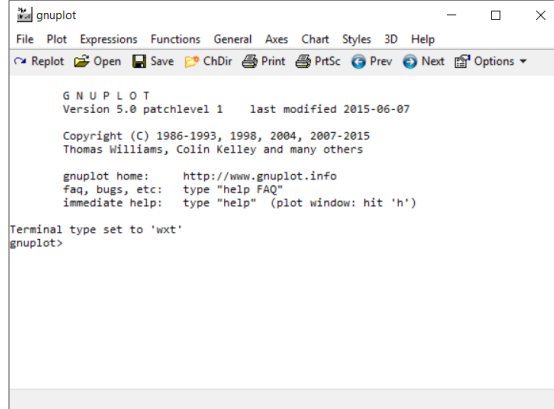
## 3 - مواد وطرائق البحث

- ✓ Netbeans 8.2 + java 11



- ✓ GNUPlot 5.0 patchlevel 1 for draw graphs.





```

gnuplot
File Plot Expressions Functions General Axes Chart Styles 3D Help
Replot Open Save ChDir Print PrtSc Prev Next Options
G N U P L O T
Version 5.0 patchlevel 1 last modified 2015-06-07
Copyright (C) 1986-1993, 1998, 2004, 2007-2015
Thomas Williams, Colin Kelley and many others
gnuplot home: http://www.gnuplot.info
faq, bugs, etc: type "help FAQ"
immediate help: type "help" (plot window: hit 'h')
Terminal type set to 'wxt'
gnuplot>

```

#### 4 - المفاهيم النظرية

##### 4-1 مفهوم مسألة توزيع الخدمات

تشير مسألة توزيع الخدمات (Service Placement) إلى اختيار العقدة الأنسب في الشبكة لاستضافة الخدمة والتي ستستجيب للطلبات الواردة من العقد الأخرى ، إذ يقلل التوزيع المثالي لنسخ الخدمات من كلفة تخديم الزبائن ، كما يحسن من الاتصال بين الزبائن والخدمات ، ويمكن من المحافظة على جودة الخدمة وتحسين استخدام المصادر المتوفرة.

إن توزيع الخدمات على العقد المناسبة سيققل من حركة مرور الشبكة ويعزز الاتصال بين العملاء والخوادم.

قبل التطرق إلى موضوع توزيع الخدمة يجب تعريف بعض المصطلحات والمفاهيم:

**الخدمة (Service):** يتم تعريف الخدمة كما ورد ضمن ( Service Oriented

Architectures SOAs ) على أنها آلية تمكن من الوصول إلى مجموعة من

الإمكانات المتاحة عبر واجهة موصوفة بشكل مسبق، مع تقييد الوصول من خلال قواعد وأذونات محددة [1]، يتم منح الخدمة من خلال مكون برمجي تنفذه عقدة واحدة أو عدة عقد في الشبكة وهي ترد على طلبات الخدمة الواردة من عقد العميل دون توفر معلومات مسبقة لديها عنهم.

نسخة (مثيل) الخدمة (Service Instance): هي عبارة عن نسخة متطابقة من المكون البرمجي للخدمة ، تعمل ضمن عقد مختلفة في الشبكة. يجب أن تتبادل النسخ المعلومات فيما بينها من أجل المحافظة على مزامنة الحالة العامة للخدمة، فيما يتعلق بطلبات الزبائن وترابط المعطيات بينها [2].

نظام توزيع الخدمة (Service Placement System): هو عبارة عن مجموعة من المكونات البرمجية التي تقوم بإنجاز التشكيل المطلوب للخدمة بناء على التغيرات الآنية الحاصلة في الشبكة ، من خلال مجموعة من الوظائف منها قياس جودة الخدمة، وبالتالي اتخاذ قرار إعادة التوزيع [2].

#### 2-4 الدراسات السابقة بموضوع توزيع الخدمات

قام الباحثون في [3] بتحسين خوارزمية SONDe عن طريق إضافة ذاكرة كاش لكل عقدة سواء أكانت زبوناً أم مخدماً من أجل حفظ العقد التي تعمل كمخدمات بحيث تحدث محتويات الذاكرة كلما وجدت العقدة مخدماً في الجوار. بينت النتائج تفوق خوارزمية SONDe - Enhanced المطورة عن SONDe من ناحية أنها تشغل عرض حزمة أصغر من عرض الحزمة الذي تشغله خوارزمية SONDe أثناء تنفيذها بسبب أن الرسائل المتبادلة بين العقد تكون أقل يضاف إلى ذلك زمن الاستجابة يكون أصغر .

كما قام الباحثون في [4] بتقديم خوارزمية حيوية لتوضيح نسخ الخدمات في الشبكة من خلال مراقبة الحمل ضمن العقدة المخدم وجوارها واختيار العقدة التي يرد منها أكبر حمل ونسخ الخدمة إليها بحيث تصبح المسافة التي تعبرها الطلبات القادمة من العقد الزبائن أصغر ما يمكن نتيجة توزيع الخدمات في مواقع قريبة منهم. وبينت النتائج أن الخوارزمية المقترحة قد حققت تحسناً في الأداء من ناحية تلبية الخدمات المطلوبة خلال أقصر زمن وعرض حزمة أقل.

بينما الباحثون في [5] قاموا بتطوير طريقة حيوية تعتمد على البحث الهجين بالإستفادة من القدرة الحسابية العالية التي تقدمها طريقة البحث المحلية الجشعة من أجل إيجاد المواقع المثالية لعقد المراقبة ضمن شبكات الاتصالات وتوزيع العدد المناسب في الشبكة بحيث يتم تحقيق وفرة المصادر مع التأقلم مع التغييرات التي تطرأ على بنية الشبكة . بينت النتائج أن هذه الطريقة تعمل بشكل جيد في حالات التغير في البنية في الزمن الحقيقي ومن أجل أعداد عقد كبيرة تصل إلى الملايين مقارنة مع العديد من الخوارزميات التطويرية .

كما قام الباحثون في [6] بنمذجة مسألة توزيع الخدمات المكروية في إنترنت الأشياء وقاموا باقتراح استراتيجية توفير خدمة السحابة المحسنة المسماة (O-FSP) وقد أثبتوا أن الحل المقترح مقبول من ناحية الكلفة واستهلاك المصادر مقارنة ببعض المفاهيم التقليدية مثل خوارزمية (best-fit) .

في دراسة أجراها الباحث في [7] حول تقييم ومقارنة مجموعة من خوارزميات توزيع الخدمات في شبكات الاتصالات (SO-RAP, SO-ARAP, SONDe, CACF) خلصت نتائجها إلى أن الخوارزمية SONDe تعتبر من أهم الخوارزميات ضمن مجال

توزيع الخدمات ذاتية التأقلم إذ تنقص من استهلاك المصادر كما تحقق وفرة المخدمات بحيث يصل عددها إلى حالة الاستقرار بعد فترة من الزمن .

قام الباحثون في [8] بتطوير خوارزمية SONDe من أجل إيجاد العدد المثالي للمخدمات ومواقعها ضمن الشبكة وذلك من خلال الكشف والتحري الدوري ضمن الجوار عن وجود عقد مخدمات وتحول العقدة الزبون إلى مخدم في حال عدم وجوده ضمن جوارها . أثبتت نتائجهم أن عدد المخدمات يصل إلى حالة الاستقرار بعد فترة قصيرة من الزمن مما يحقق وفرة في المصادر المتاحة وتلبية الخدمات في أقصر زمن وتوفير عرض الحزمة للمستخدم.

#### 4-3 دراسة مسألة توزيع الخدمات من الناحية النظرية

يمكن اعتبار مسألة توزيع الخدمات كتطبيق نظري لنظرية مواقع الخدمات ( Facility Location Theory ) ضمن شبكات الاتصالات اللاسلكية [9]. تقدم المفاهيم التي تعتمد على هذه النظرية حلاً لمشكلة إيجاد مواقع الخدمات غير محدودة المصادر ( Un Capacitated Facility Location Problem ) من خلال إيجاد العدد المطلوب من نسخ الخدمات تبعاً لبنية الشبكة والطلب على هذه الخدمات، ولا تهتم كثيراً بالحمل الزائد الناتج عن المزامنة بين النسخ. تتعلق نظرية مواقع الخدمات بشكل أساسي بمعرفة الإعدادات الثابتة ( Static Setting ) المتعلقة بتوصيف المشكلة الثابت غير المتغير مع الزمن .

#### 4-4 نظرية مواقع الخدمات (Facility Location Theory)

تمثل هذه النظرية أحد فروع العلم ضمن مجال بحوث العمليات ، وتستخدم نماذج رياضية من أجل حل المشاكل المتعلقة بالتوزيع أو التوزيع المثالي للخدمات المتاحة كالمصانع، مراكز التوزيع أو مراكز التبديل ( Switching Centers ) ضمن الشبكات .

تمت دراسة العديد من المسائل ضمن هذا المجال، وتبين أنه توجد مسألتان منها قابلتان للتطبيق على مسألة توزيع الخدمات عبر الشبكات، هما مسألة الموقع الأمثل (P-median) ومسألة مواقع الخدمات غير محدودة المصادر (uncapacitated facility location).

#### 4-5 مسألة الموقع الأمثل (P-median)

يمكن تعريف هذه المسألة بالإستناد إلى التعريف المقدم من قبل الباحث في [10] على النحو الآتي:

على فرض لدينا البيان الآتي الممثل للشبكة ، والمعرف بالشكل  $G=(V,E)$ . تهدف المسألة إلى إيجاد مجموعة الرؤوس  $V_P \subseteq V$  بحيث أن  $|V_P|=P$  ، علماً أن P إما ثابت أو متغير ، وبحيث يكون مجموع المسافات الأقصر من الرؤوس  $V/V_P$  إلى الرؤوس المجاورة ضمن  $V_P$  أصغر ما يمكن .

تكون العقد ضمن مجال الشبكات اللاسلكية ممثلة برؤوس البيان بينما تمثل الحواف قنوات الاتصال اللاسلكية بين العقد . وقد قام الباحث (Hakimi) بشكل أساسي بتعريف (P-median) لبيان ما G ، على أنه مجموعة الرؤوس  $V^*_P$  التي تحقق العلاقة [2] :

$$\forall V_P \subseteq V \sum_{i=1}^n w_i \cdot d(v_i, v_p) \leq \sum_{i=1}^n w_i \cdot d(v_i, v_p) \quad (1)$$

#### 4-6 تقنيات توزيع الخدمات في الشبكات:

يمكن تصنيف تقنيات توزيع الخدمات في الشبكات إلى [11]:

- ✓ تقنيات توزيع الخدمات المركزية.
- ✓ تقنيات توزيع الخدمات الموزعة .
- ✓ تقنيات توزيع الخدمات الهجينة .

#### 4-6-1 تقنيات توزيع الخدمات المركزية ( Centralized Service ) (Placement Techniques)

تتطلب تقنيات توزيع الخدمات المركزية معلومات حول النظام ليتم جمعها في كيان مركزي. هذا الكيان المركزي مسؤول عن التحكم في المهام المتعلقة بتوزيع الخدمات. من أجل توزيع أمثلي ، فإن الحالة المثالية هي أنه يجب جمع جميع المعلومات عن النظام في كيان مركزي. لكن المشكلة الرئيسية هي أنها تتطلب معرفة كاملة بأصحاب الخدمة والعملاء والتكاليف ، وبالتالي فهي أقل قابلية للتوسع ولا تنطبق على شبكات الاتصالات المتنقلة المستقبلية. المشكلة المعروفة في هذه الأساليب هي نقطة الفشل الوحيدة.

من مزايا هذه التقنيات:

- ✓ تعتمد على وجود عقدة مركزية تحتوي على معلومات عامة عن النظام بأكمله
- ✓ هذه العقدة مسؤولة عن كل المهام المرتبطة بتوزيع الخدمات
- ✓ يمكن إجراء توزيع مثالي للخدمات عبر عقد الشبكة
- ✓ سهولة التطبيق والإدارة

ومن سلبياتها:

- ❖ تتطلب معرفة مسبقة وعامة عن بنية الشبكة وأماكن توضع العقد
- ❖ قابلية التوسع محدودة
- ❖ غير مناسب للتطبيق في الشبكات الخلوية المستقبلية
- ❖ نقطة الفشل الوحيدة
- ❖ لا تسمح بإنشاء الكثير من مثيلات الخدمة

#### 4-6-2 تقنيات توزيع الخدمات الموزعة ( Distributed Service Placement ) ( Techniques

على عكس التقنيات المركزية، تفترض مناهج وضع الخدمة الموزعة عدم وجود كيان مركزي مسؤول عن التحكم في عملية التوزيع وأن كل كيان لديه معلومات جزئية فقط حول حالة النظام. تؤدي هذه الأساليب إلى تحسين قابلية التوسع وعدم وجود نقطة واحدة للفشل لذلك هي أكثر قابلية للتطبيق على شبكات المحمول المستقبلية. ومع ذلك، على الرغم من أن الأساليب الموزعة تؤدي إلى انخفاض التكلفة وزيادة قابلية التوسع وإعادة النشاط، لا يمكن توقع أن يكون وضع الخدمات الذي تم الحصول عليه هو الأمثل.

من مزايا هذه التقنيات:

- ✓ تمتلك كل عقدة معلومات جزئية عن حالة النظام
- ✓ تتخذ القرار بشأن أخذ موضع الخدمة دون الحاجة إلى معرفة عامة بينية الشبكة
- ✓ عدم وجود نقطة فشل وحيدة
- ✓ قابلية التوسع أكثر من المركزية ومتانة نحو المشاكل والفشل
- ✓ تسمح بإنشاء الكثير من مثيلات الخدمة أكثر من المركزية
- ✓ أكثر قابلية للتطبيق ضمن الشبكات اللاسلكية المستقبلية

ومن سلبياتها:

- ❖ لا يمكن اجراء توزيع مثالي للخدمات عبر عقد الشبكة جميعها
- ❖ صعوبة الإدارة والتحكم

#### 4-6-3 تقنيات توزيع الخدمات الهجينة ( Hybrid Service Placement ) ( Techniques

الاستراتيجية الأخيرة هي الجمع بين كل من التقنيات المركزية والموزعة في التقنيات الهجينة. هذه الأساليب لها بعض المهام يتم أداؤها بطريقة مركزية والبعض الآخر بطريقة موزعة، وهناك احتمالات لنقطة فشل واحدة. هذه الأساليب أقل قابلية للتوسع من الأساليب الموزعة وأفضل من الأساليب المركزية. علاوة على ذلك، فهي أقل قابلية للتطبيق على شبكات الاتصالات المتنقلة المستقبلية مقارنة بالنهج الموزعة وأفضل من المركزية .

من مزايا هذه التقنيات:

- ✓ تنفذ بعض المهام بطريقة مركزية وبعضها بطريقة موزعة
- ✓ تتطلب معرفة عن الشبكة تبعا للمهام الواجب تنفيذها

ومن سلبياتها:

- ❖ نقطة فشل وحيدة
- ❖ لا تحل سلبيات الموزعة والمركزية بل تخففهم



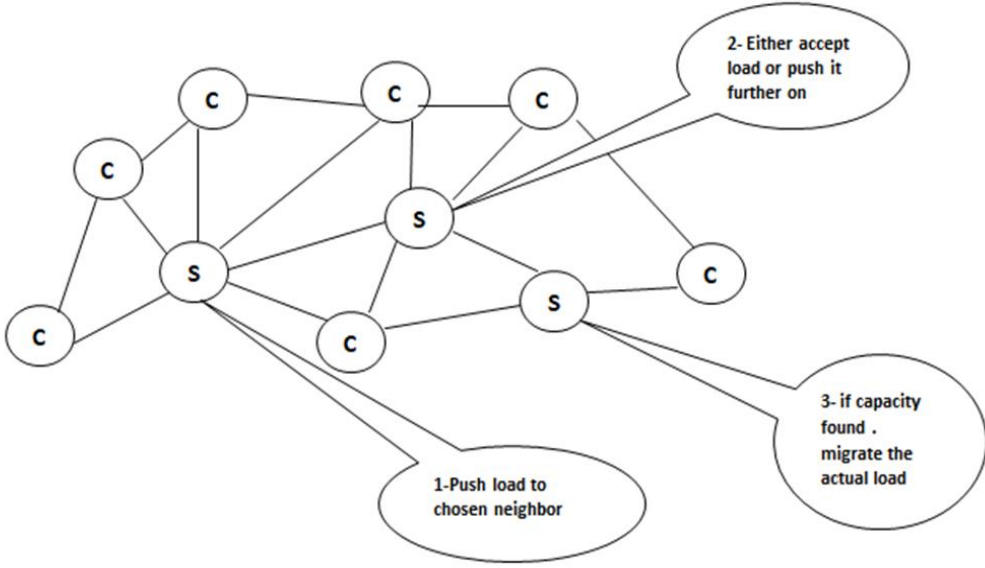
## 5 - توصيف الخوارزميات المستخدمة

قمنا في هذا البحث بدراسة ثلاث أنواع مختلفة من خوارزميات توزيع الخدمات ضمن الشبكات الحاسوبية وهي:

### 1-5 خوارزمية التوزيع العشوائي (Random placement Algorithm):

هي خوارزمية تنتمي إلى تقنيات توزيع الخدمة المركزية. تعتمد على وضع النسخ المتماثلة لمثيلات الخدمة بطريقة عشوائية ضمن عقد الشبكة. من أهم ميزات البساطة وسليبتها عدم القدرة على التنبؤ واحتمالية عدم تخديم كل الزبائن وتعامل مع مشكلة توزيع الحمل بطريقة عشوائية. بداية كل العقد في الشبكة زبائن. تقوم العقدة المركزية بتوليد قيمة عشوائية لكل عقدة في الشبكة ونحدد نسبة العقد في الشبكة التي ستصبح خوادم ، في كل عقدة تابع يقوم بمقارنة القيمة العشوائية المولدة لها مع نسبة الخوادم وبناءً على نتيجة المقارنة يحدد نوع العقدة (server/client)، إذا كانت القيمة العشوائية للعقدة أكبر من النسبة المحددة تبقى زبوناً (client) وإذا أصغر أو تساوي تقلب مخدماً (server).

يوضح الشكل (1) أنه عندما يعاني الخادم من حمل زائد فإن هذه الخوارزمية تجبر الحمل على التحرك إلى مخدم تم اختياره في الجوار قد يكون لديه القدرة على تحمله إذا كان ممكناً أو دفعه بعيداً إلى مخدم آخر بنفس الطريقة. وحالما يكون لدى المخدم القدرة على استضافة الحمل، تبدأ فعلياً عملية نقل الحمل ضمن البنية التحتية للنظام.



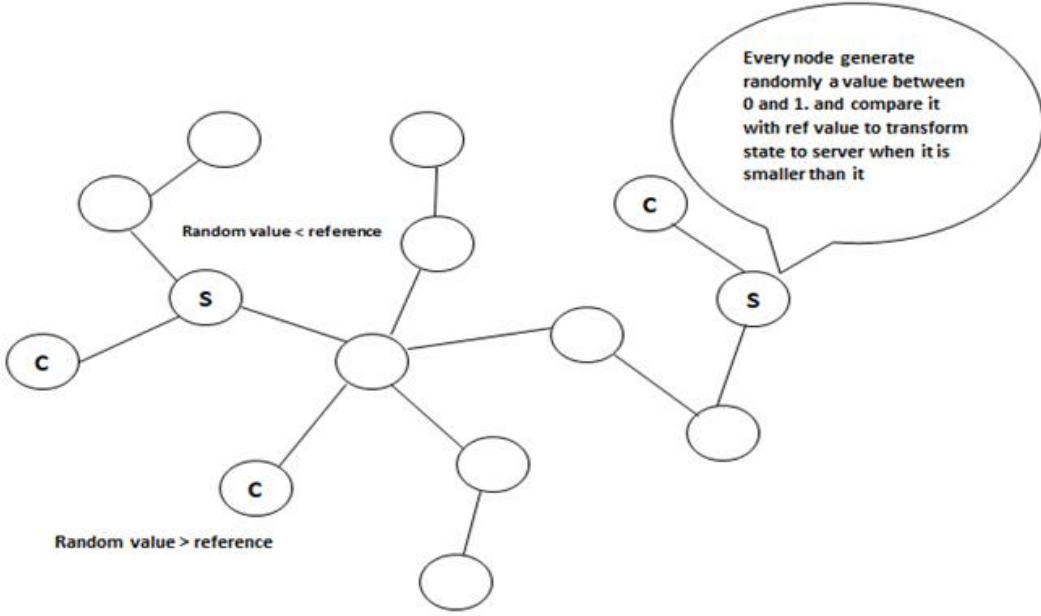
الشكل (1) مثال يوضح آلية تنفيذ خوارزمية التوزيع العشوائي للحمل

## 2-5 الخوارزمية العشوائية المعتمدة على الاحتمالات ( Self-Organizing Random Algorithm based on Probability (SO-RAP) :

هي خوارزمية موزعة منظمة ذاتياً. تعتمد هذه الخوارزمية على مراقبة قيمة يتم توليدها عشوائياً لكل العقد في الشبكة. تختار وفق آلية محددة عقداً لتعمل مخدمات والعقد الباقية زبائن. يتم بناء نموذج الشبكة بحيث كل عقدة لا تمتلك معلومات مسبقة عن كامل الشبكة .

يتم بدايةً توليد قيمة عشوائية لكل العقد في الشبكة وتعتبر العقد كلها زبائن وتحدد نسبة العقد التي ستعمل في الشبكة كخوادم مسبقاً وتقارن قيمة هذه النسبة مع القيمة العشوائية المولدة لكل عقدة. نتيجة هذه المقارنة هي التي تحدد العقد التي ستعمل كخوادم فإذا

كانت القيمة العشوائية المولدة أصغر أو تساوي النسبة المحددة للخوادم تقلب العقدة وضعها إلى مخدم وإن كانت أكبر تبقى زبون، يبين الشكل (2) آلية توزيع المخدمات في خوارزمية SO-RAP.



الشكل (2) توزيع المخدمات في خوارزمية SO-RAP

### 3-5 الخوارزمية العشوائية المتقدمة المعتمدة على الاحتمالات ( Self-Organizing Advanced Random Algorithm based on Probability (SO-ARAP):

هي نسخة محدثة من So-RAP تعتمد على وضع عشوائي للخوادم عبر الشبكة اعتماداً على المبدأ السابق وهو أن كل تولد قيمة عشوائية ونحدد نسبة العقد التي ستعمل في الشبكة كخوادم مسبقاً وتقارن قيمة هذه النسبة مع القيمة العشوائية المولدة لكل عقدة.

نتيجة هذه المقارنة هي التي تحدد العقد التي ستعمل خوادم فإذا كانت القيمة العشوائية المولدة أصغر أو تساوي النسبة المحددة للخوادم تقلب العقدة وضعها إلى مخدم وإن كانت أكبر تبقى زيون، ثم يتحقق كل خادم بشكل دوري إذا كانت حركته من مكانه الأصلي إلى العقد المجاورة أفضل من ناحية عدد الزبائن المخدمة إن كان يخدم عدد زبائن أكثر فينتقل المخدم إلى العقدة المجاورة وتقلب وضعها إلى مخدم والعقدة التي كانت مخدم تقلب وضعها إلى زيون.

و بناءً على الدراسة المرجعية [7] التي أخذت بعين الاعتبار أعداد مختلفة من العقد ومعايير محددة وقارنت بين أداء الخوارزميات في الحالة الطبيعية للشبكة تبين أن الخوارزمية (So-ARAP) تعتبر أفضل من Random و So-RAP ضمن مجال توزيع الخدمات كونها توصل الشبكة إلى الاستقرار بعد فترة قصيرة من الزمن وتحقق وفرة في المخدمات وهي تنقل الخوادم إلى عقد الجوار وتمتاز بقابليتها للتوسع وتأخذ استهلاك الموارد بعين الاعتبار.

## 6 - معايير تقييم أداء عمل الخوارزميات

تمت مقارنة أداء الخوارزميات التي تم اختيارها (Random , SO-RAP , SO-) (ARAP) من خلال:

- متوسط استهلاك الموارد :
- ✓ المعالج ( CPU )
- ✓ الذاكرة (Ram)
- ✓ قرص التخزين الصلب (Hard Disk)
- ✓ عرض الحزمة (Bandwidth)
- نسبة جودة الخدمة المقدمة والجودة الممكن الحفاظ عليها في حالة الطوارئ.

## 7 - النتائج العملية

### 1-7 بنية وآلية عمل المحاكى الشبكي المصمم لتقييم عمل الخوارزميات:

يعتبر المحاكى الشبكي VCC Simulator الذي تم العمل عليه في هذا البحث عبارة عن محاكي شبكي ذو واجهة رسومية سهلة الاستخدام قادر على محاكاة عمل الخوارزميات التي تم اختيارها (Random , SO-RAP , SO-ARAP) ضمن سيناريوهات مختلفة تضمن حالات طبيعية وعدة حالات طوارئ، ويظهر الشكل (3) الواجهة الرئيسية للمحاكي.

يمكن من خلال الواجهة الرئيسية للمحاكي تحديد بارامترات المحاكاة كالتالي:

- ❖ عدد العقد في الشبكة.
- ❖ مجال ارسال العقد (مقدراً بالمتر).
- ❖ المساحة الجغرافية ( العرض - الارتفاع ).
- ❖ نسبة المخدمات ضمن الشبكة.
- ❖ القيمة العظمى للموارد (معالج - ذاكرة رئيسية RAM- قرص صلب - عرض حزمة) التي سوف تحتاجها الخدمات المقدمة لكل زبون ضمن الشبكة كما في الشكل (4).

SO\_RAP

Service Placement Algorithms applied in emergency situations

## خوارزميات تموضع الخدمات

عدد العقد: 20 (10,20,30, 40, 50,100)

اسم العقدة: node

النسبة المئوية للخدمات: 0.3

نطاق العقد: 150

**Max Service Data**

CPU: 1 GHz  
RAM: 4 GB  
HDD: 128 GB  
BW: 128 KB

**Max Node Resources**

CPU: 5 GHz  
RAM: 32 GB  
HDD: 1024 GB  
BW: 1024 KB

**بيانات العقد**

Random Algorithm

(SO-RAP) Self Organizing Random Algorithm based on Probability

(SO-ARAP) Self Organizing Advanced Random Algorithm based on Probability

عرض: 1000

ارتفاع: 1000

**حالات الطوارئ**

نسبة فشل العقد: 0.1 [ 0 -1 ]

نسبة فشل الخدمات: 0.2 [ 0 -1 ]

نسبة فشل الاتصالات: 0.2 [ 0 -1 ]

show Nodes

Plot

Start

وقت الخوارزمية:

الشكل (3) الواجهة الرئيسية لمحاكي خوارزميات تموضع الخدمات

Max Service Data		
CPU	1	GHz
RAM	4	GB
HDD	128	GB
BW	128	KB

الشكل (4) تحديد القيمة العظمى للموارد (معالج - ذاكرة رئيسية RAM - قرص صلب - عرض حزمة)

- ❖ القيمة العظمى لإمكانيات كل عقدة (معالج - ذاكرة رئيسية RAM - قرص صلب - عرض حزمة) ضمن الشبكة كما في الشكل (5).
- ❖ تحديد النسبة المئوية للفشل في حالات الطوارئ كما هو موضح في الشكل (6):

✓ نسبة فشل العقد

✓ نسبة فشل المخدمات

✓ نسبة فشل الاتصالات

Max Node Resources		
CPU	5	GHz
RAM	32	GB
HDD	1024	GB
BW	1024	KB

الشكل (5) تحديد القيمة العظمى لإمكانيات كل عقدة (معالج - ذاكرة رئيسية RAM - قرص صلب - عرض حزمة)

حالات الطوارئ		
نسبة فشل العقد	0.1	[ 0 - 1 ]
نسبة فشل المخدمات	0.2	[ 0 - 1 ]
نسبة فشل الاتصالات	0.15	[ 0 - 1 ]

### الشكل (6) تحديد النسبة المئوية للفشل في حالات الطوارئ

كما يمكن من خلال المحاكى معرفة بيانات كل عقدة بعد تنفيذ المحاكاة حيث يقوم بعرض البيانات التالية:

- رقم فريد لكل عقدة.
  - الموقع الجغرافي (محور X ومحور y).
  - نوع العقدة (زبون-مخدم).
  - الخدمة التي قامت العقدة بطلبها.
  - إمكانيات العقدة.
  - هل فشلت العقدة أم لا.
  - هل حصلت العقدة على الخدمة ام لم تحصل.
- ويظهر الشكل (7) مثال عن بيانات العقد عند تنفيذ المحاكاة.



Number of Nodes	<input type="text" value="20"/>	(10,20,30, 40, 50,100)
Name Of Node	<input type="text" value="node"/>	Node Range
ServerPercent	<input type="text" value="0.3"/>	[ 0 -1] <input type="text" value="150"/>

### Random Algorithm

(SO-RAP) Self Organizing Random Algorithm based on Probability

(SO-ARAP) Self Organizing Advanced Random Algorithm based on Probability

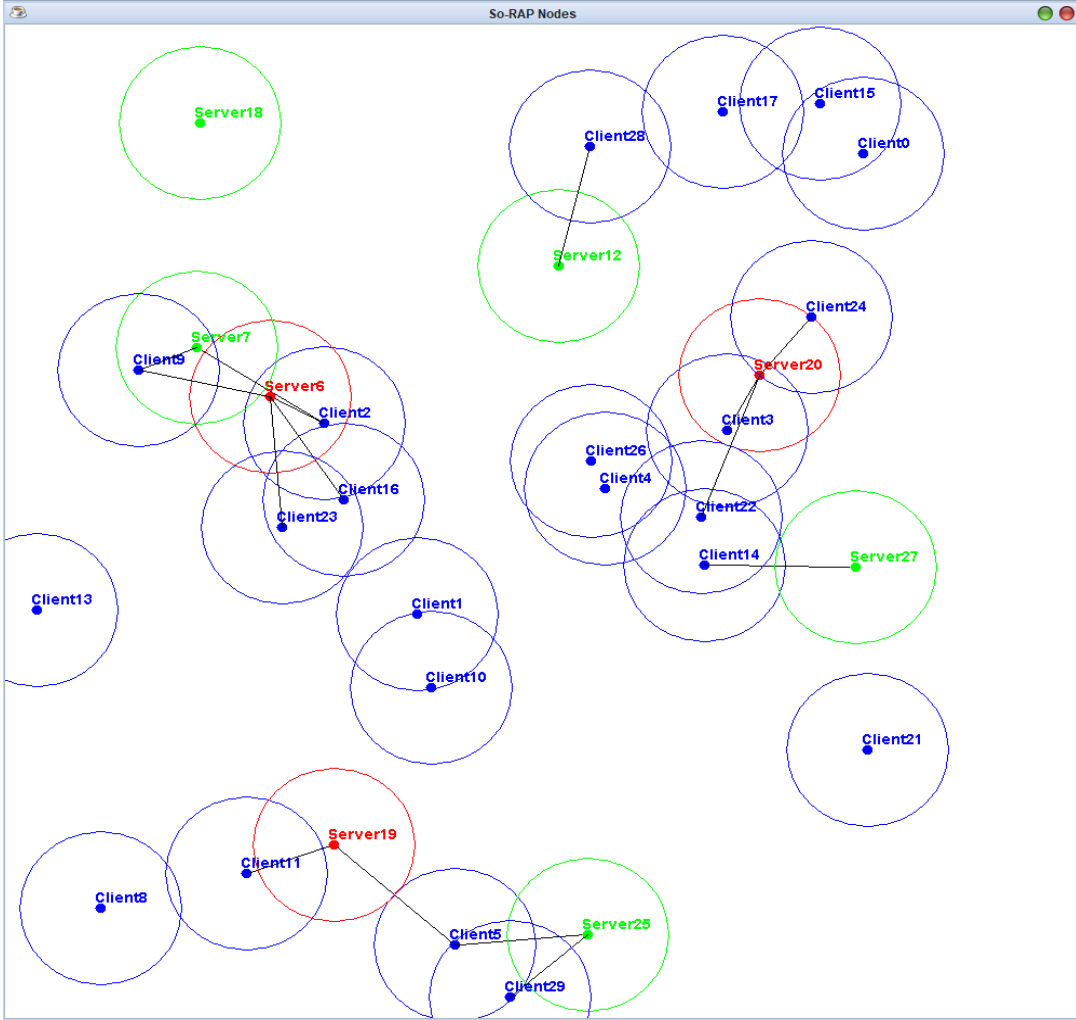
### بيانات العقد

```
Node{id=17, x=287, y=631, name=Node17, type=Client, service=Service
Service_hdd=11.34GB, Service_bw=67.51KB}, Node_cpu=4.37GHz, No
Node{id=18, x=499, y=53, name=Node18, type=Client, service=Service{
Service_hdd=3.33GB, Service_bw=76.58KB}, Node_cpu=0.36GHz, Nod
Node{id=19, x=485, y=940, name=Node19, type=Client, service=Service
Service_hdd=69.37GB, Service_bw=98.1KB}, Node_cpu=1.06GHz, Nod
finish SO_RAP
```

الشكل (7) بيانات العقد بعد تنفيذ سيناريو على المحاكى

يتضمن المحاكى أداة لعرض تموضع العقد كما في الشكل (8) حيث تظهر كل عقدة على شكل دائرة ملونة باللون الأزرق في حال كانت العقدة زبون وباللون الأخضر في حال تحولها إلى مخدم وبالنسبة للعقد التي فشلت تظهر باللون الأحمر، ويقوم بوصل خط بين العقد الزبون والمخدم المتصلة به بشكل مباشر.

و يمكن اختيار نوع الخوارزمية المراد تنفيذها (SO- , SO-RAP , Random (ARAP من خلال القائمة المنسدلة في أعلى المحاكى كما في الشكل (9).



الشكل (8) أداة عرض تموضع العقد في المحاكى

Service Placement Algorithms applied in em

تموضع الخدمات

الخدمات قبل بارامترات المحاكات

SO\_RAP

Random

SO\_RAP

SO\_ARAP

Number of Nodes 20 (10,20,30, 40, 50,100)

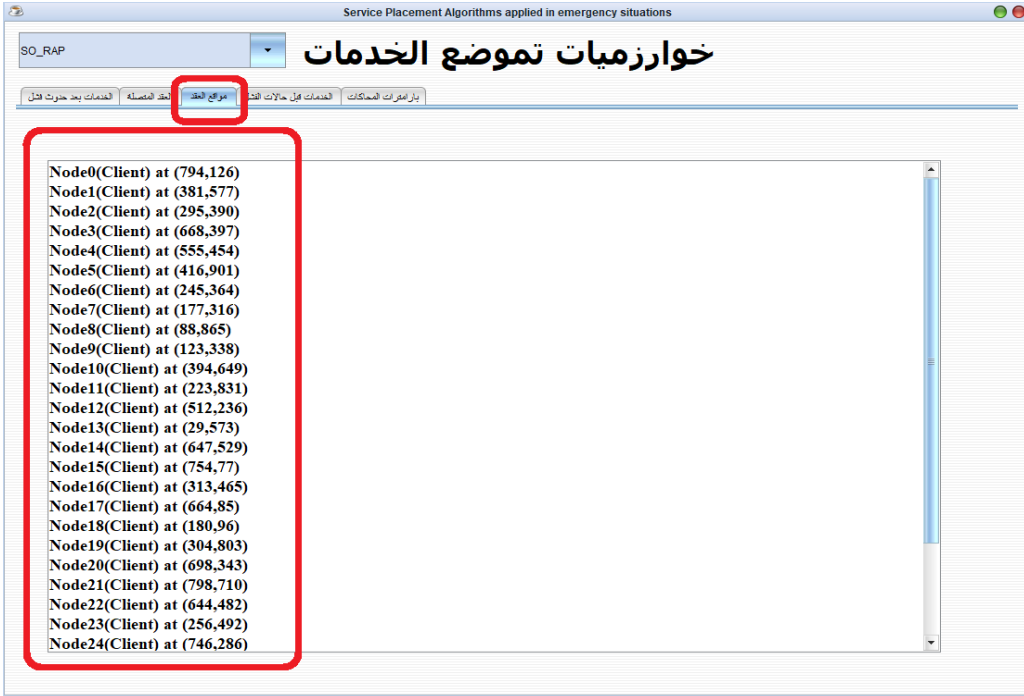
Name Of Node node Node Range 150

ServerPercent 0.3 [0 -1]

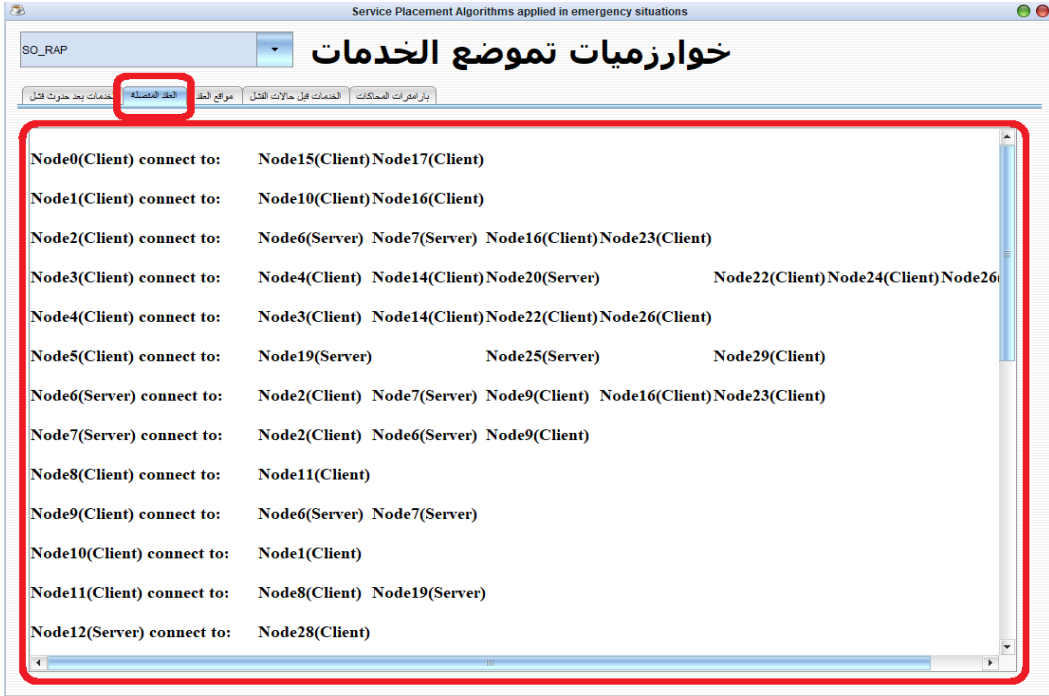
Random Algorithm

### الشكل (9) اختيار نوع الخوارزمية في المحاكي

يقوم المحاكي بتسجيل (تعقب) مجموعة من البيانات وتشمل موقع كل عقدة ضمن الشبكة كما في الشكل(10) والعقد المتصلة بشكل مباشر كما في الشكل (11). ويقوم المحاكي بعرض الخدمات المقدمة قبل حدوث حالات الفشل المختلفة (العقد-المخدمات-الاتصالات) كما في الشكل (12) والخدمات التي تم تقديمها من قبل المخدمات إلى العقد الزبائن بعد حدوث حالات الفشل كما في الشكل (13).



الشكل (10) واجهة عرض موقع كل عقدة في الشبكة (محور x - محور y)



الشكل (11) واجهة عرض العقد المتصلة بوصلة مباشرة في الشبكة



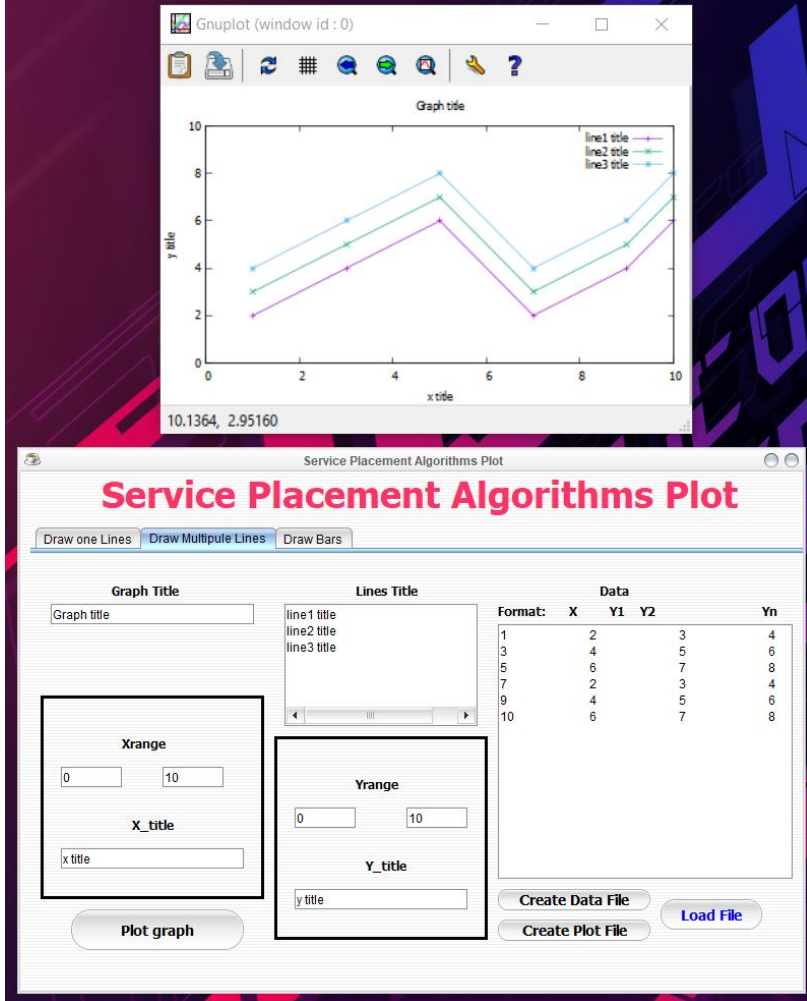
الشكل (12) واجهة عرض الخدمات المقدمة قبل حدوث حالات الفشل



### الشكل (13) واجهة عرض الخدمات المقدمة بعد حدوث حالات الفشل

وبالتالي من خلال تحليل البيانات التي يقوم بعرضها المحاكي يمكن تقييم أداء عمل الخوارزميات الثلاثة (Random , SO-RAP , SO-ARAP) على سيناريو معين وتحديد الأفضل بينها في حال حدوث حالة فشل معينة.

ويتضمن المحاكي أداة لرسم المخططات البيانية بعد عملية تحليل الخرج بالاعتماد على برنامج Gnuplot بحيث تسمح برسم عدة خطوط بيانية إضافة الى رسم أبراج لمقارنة أداء الخوارزميات الثلاثة التي يدعمها المحاكي الشبكي كما في الشكل (14).



الشكل (14) أداة رسم المخططات البيانية في المحاكي

وبالتالي من خلال تحليل البيانات التي يقوم بعرضها المحاكي يمكن تقييم أداء عمل الخوارزميات الثلاثة (Random , SO-RAP , SO-ARAP) على سيناريو معين وتحديد الأفضل بينها في حال حدوث حالة فشل معينة.



2-7 بارامترات السيناريو المقترح لتقييم عمل المحاكى :

الجدول (1) بارامترات السيناريو المقترح


البارامتر	القيمة
عدد العقد	20,30,40,50 Node
مجال ارسال العقد	150 متر
نسبة المخدمات	25%
المساحة الجغرافية	1000*1000 متر <sup>2</sup>
إمكانيات العقد العظمى	CPU:5GHz-RAM:32GB- HDD:1024GB-BW:1024KB
قيمة الخدمات العظمى	CPU:1GHz-RAM:4GB- HDD:128GB-BW:128KB
نسب الفشل (حالات الطوارئ)	Nodes (20%) Servers (10%) Communications (20%)
الخوارزميات المستخدمة	Random , SO-RAP , SO-) (ARAP

### 3-7 النتائج والمناقشة:

#### 1-3-7 متوسط استهلاك الموارد المختلفة (الحالات طبيعية والطوارئ) ضمن السيناريو:

قمنا بتطبيق السيناريو على المحاكى الشبكي وتنفيذ الخوارزميات (Random , SO-ARAP , SO-RAP) وتغيير عدد العقد وفي كل مرة تم تحليل النتائج وحساب متوسط استهلاك الموارد ضمن كل عقدة (مخدم) وحساب متوسط الاستهلاك على كامل الشبكة كما في الاشكال (15) (16) (17) (18) والتي تحتوي متوسط استهلاك الموارد المختلفة (CPU-RAM-HDD-BW).


متوسط استهلاك المعالج في الحالة الطبيعية



الشكل (15) متوسط استهلاك الموارد (المعالج) في الحالة الطبيعية ضمن السيناريو


المقترح

متوسط استهلاك الذاكرة الرئيسية في الحالة الطبيعية




الشكل (16) متوسط استهلاك الموارد (الذاكرة الرئيسية RAM) في الحالة الطبيعية ضمن السيناريو المقترح

متوسط استهلاك القرص الصلب في الحالة الطبيعية



الشكل (17) متوسط استهلاك الموارد (القرص الصلب) في الحالة الطبيعية ضمن السيناريو المقترح


متوسط استهلاك عرض الحزمة في الحالة الطبيعية



الشكل (18) متوسط استهلاك الموارد (عرض الحزمة) في الحالة الطبيعية ضمن السيناريو المقترح

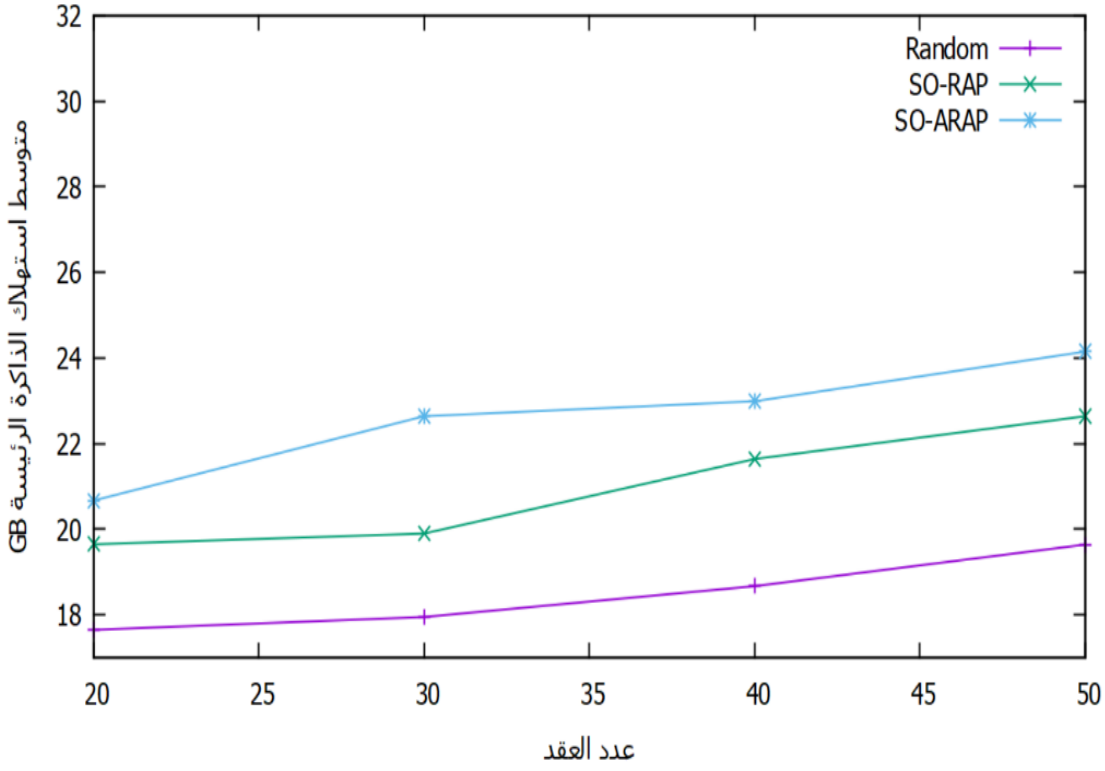
نلاحظ من الأشكال السابقة أن خوارزمية SO-ARAP قد قدمت أعلى استهلاك موارد مقارنة مع الخوارزمتين SO-RAP و Random كونها تعمل على نقل الخوادم إلى عقد الجوار إذا كان لديهم القدرة على تقديم كل الخدمات المطلوبة من السيرفر، ثم خوارزمية SO-RAP ثم Random في الحالة الطبيعية . وهذا موافق لما ورد في البحث [7] وبالتالي المحاكى يعمل بشكل صحيح ويمكن استخدامه لتقييم العمل عند أخذ حالات الطوارئ بعين الاعتبار .

قمنا بتنفيذ السيناريو مع إضافة حالات للفشل (عقد - مخدمات - اتصالات) وتغيير عدد العقد وفي كل مرة تم تحليل النتائج وحساب متوسط استهلاك الموارد ضمن كل عقدة (مخدم) وحساب متوسط الاستهلاك على كامل الشبكة كما في الاشكل (19) (20) (21) (22).



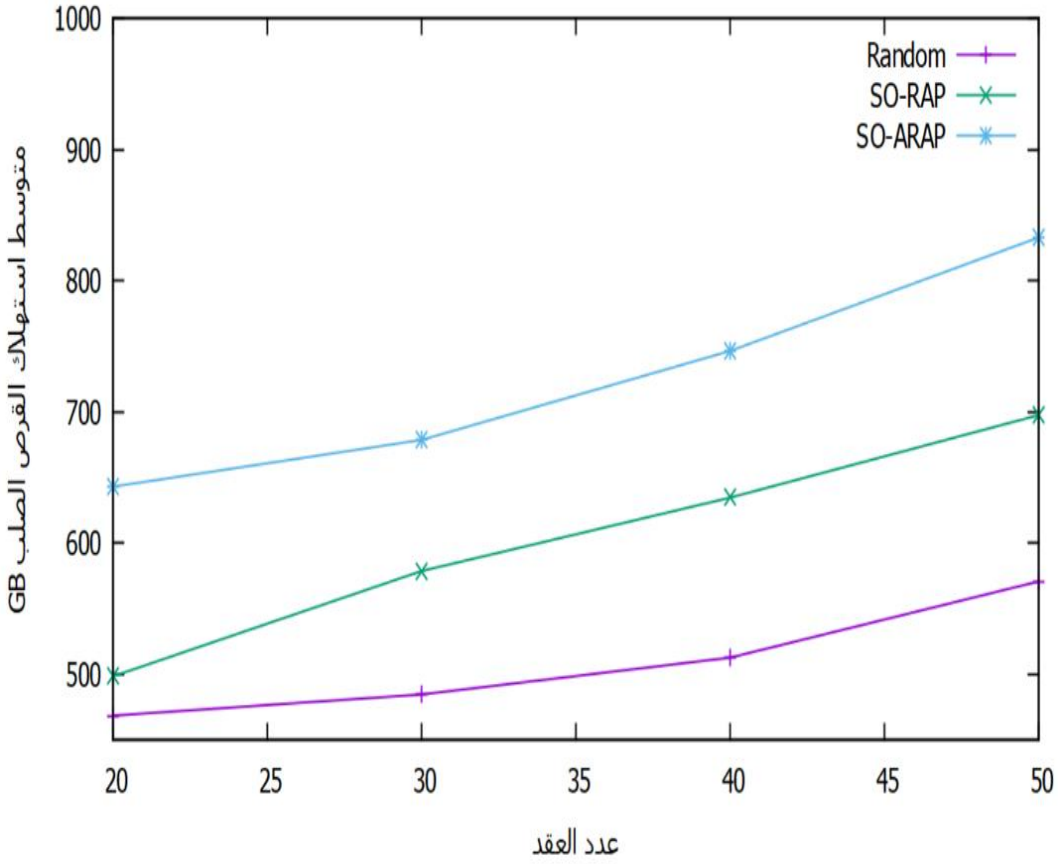
الشكل (19) متوسط استهلاك الموارد (المعالج) في حالات الفشل ضمن السيناريو المقترح

متوسط استهلاك الذاكرة الرئيسة في حالات الطوارئ



الشكل (20) متوسط استهلاك الموارد (الذاكرة الرئيسة RAM) في حالات الفشل ضمن السيناريو المقترح


متوسط استهلاك القرص الصلب في حالات الطوارئ



الشكل (21) متوسط استهلاك الموارد (القرص الصلب) في حالات الفشل ضمن السيناريو المقترح



متوسط استهلاك عرض الحزمة في الحالة الطبيعية



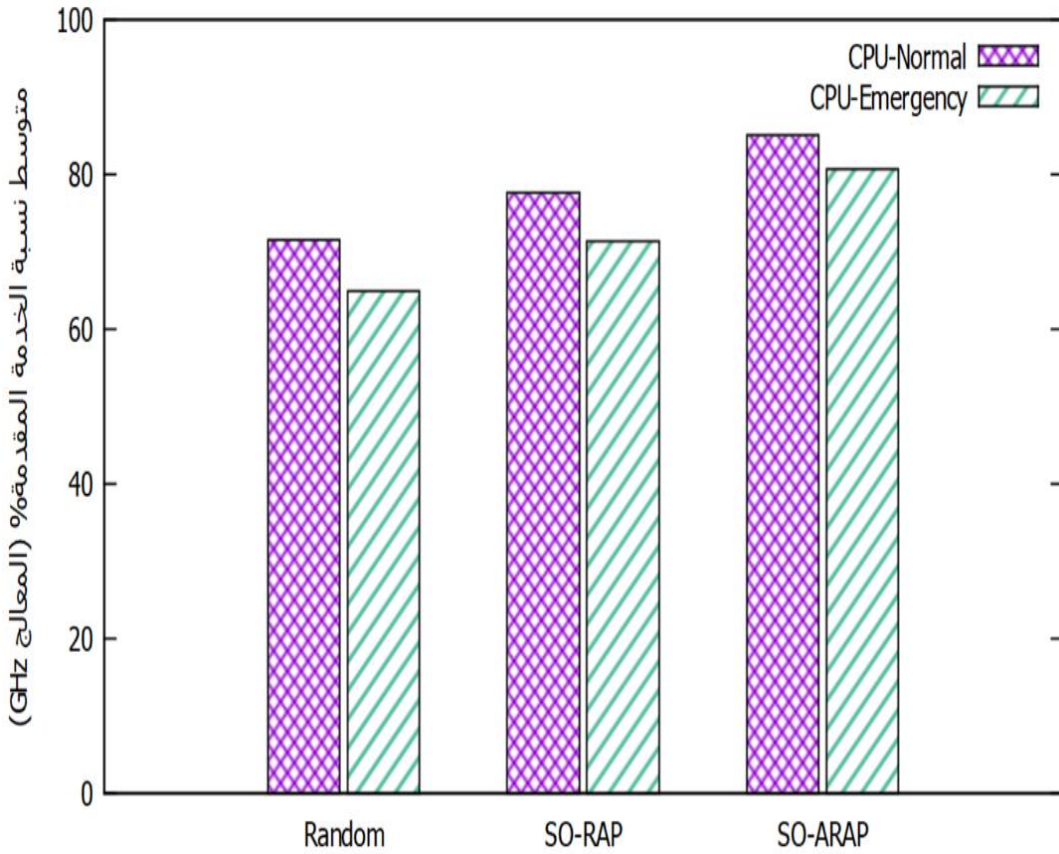
الشكل (22) متوسط استهلاك الموارد (عرض الحزمة) في حالات الفشل ضمن السيناريو المقترح

نجد من الأشكال السابقة أن خوارزمية SO-ARAP قد قدمت أعلى استهلاك موارد عند حدوث فشل مقارنة مع باقي الخوارزميات وبالتالي تلاؤم أكبر مع حالات الطوارئ في الشبكات الحاسوبية في السيناريو المقترح بينما تقدم الخوارزمية العشوائية أقل استهلاك موارد مقارنة مع الأخيرتين.

### 7-3-2 متوسط نسبة الخدمات المقدمة (الحالات طبيعية والطوارئ) ضمن السيناريو:


قمنا هنا بتنفيذ السيناريو السابق وحساب نسبة تقديم الخدمات التي قامت العقد المخدّمة بتقديمها الى العقد الزبائن وذلك في الحالة الطبيعية وبعد حدوث بعض حالات الفشل (عقد - مخدّمة - اتصالات).

متوسط نسبة الخدمة المقدمة% (المعالج GHz) ضمن السيناريو

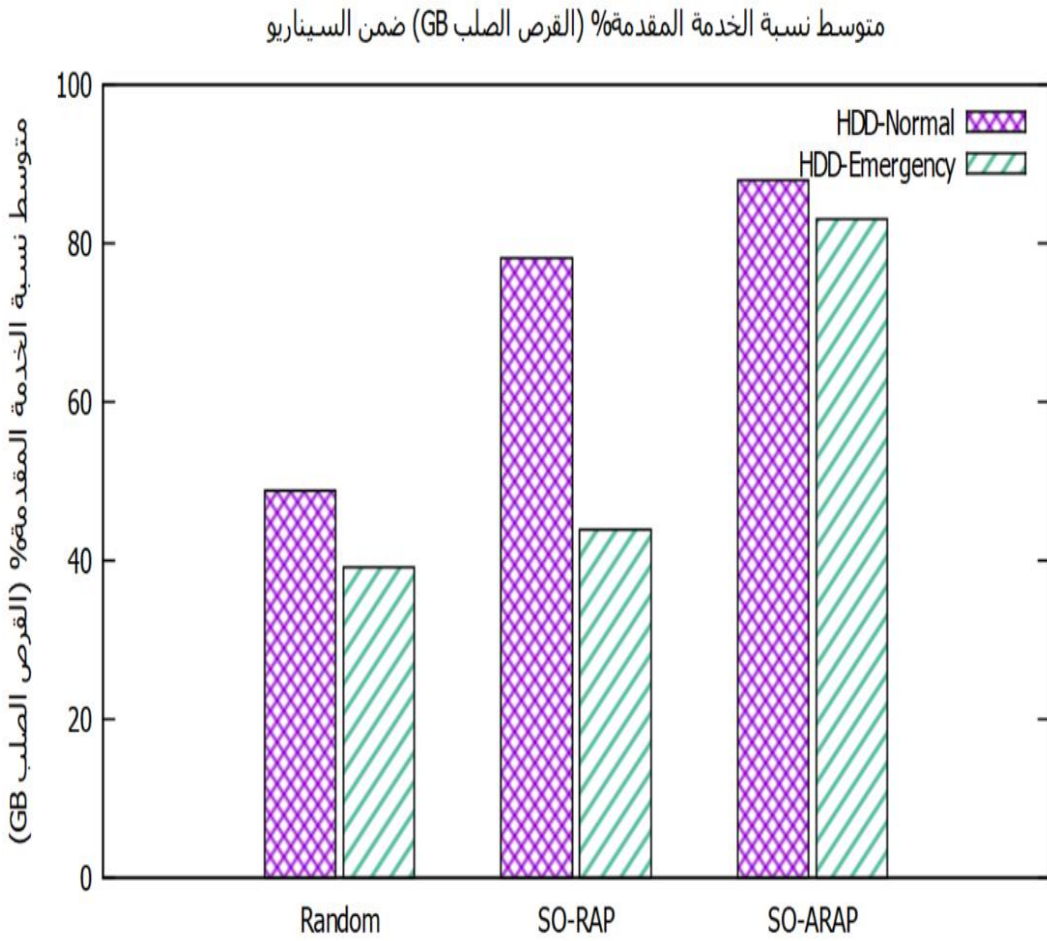


الشكل (23) متوسط نسبة الخدمات المقدمة (المعالج) ضمن السيناريو

متوسط نسبة الخدمة المقدمة (الذاكرة الرئيسية GB) ضمن السيناريو




الشكل (24) متوسط نسبة الخدمات المقدمة (الذاكرة الرئيسية RAM) ضمن السيناريو



الشكل (25) متوسط نسبة الخدمات المقدمة (القرص الصلب) ضمن السيناريو

متوسط نسبة الخدمة المقدمة% (عرض الحزمة KB) ضمن السيناريو



الشكل (26) متوسط نسبة الخدمات المقدمة (عرض الحزمة) ضمن السيناريو

وبناءً على الأشكال السابقة نجد أن الخوارزمية العشوائية قد قدمت أقل جودة خدمة مقارنة مع باقي الخوارزميات بينما خوارزمية SO-ARAP قد قدمت أعلى أداء في الحالة الطبيعية للشبكة، أما في حالات الطوارئ نلاحظ انخفاض أداء الخوارزميات الثلاثة ولكن تبقى خوارزمية SO-ARAP تعطي أداء جيد من حيث الخدمات المقدمة وأعلى من الخوارزميات الأخرى المدروسة.

## 8 - الاستنتاجات والتوصيات:

من خلال دراسة عمل الخوارزميات (Random , SO-RAP , SO-ARAP) على السيناريو المقترح نستنتج ما يلي:

- ❖ تم بناء محاكي لمحاكاة عمل الخوارزميات واختباره والتأكد من صحته ويمكن اعتماده في اختبارات أخرى.
- ❖ قدمت خوارزمية SO-ARAP أعلى استهلاك موارد في الشبكة مقارنة مع الخوارزميتين الأخرى كونها تعمل على نقل الخوادم الى عقد الجوار.
- ❖ قدمت خوارزمية SO-ARAP أعلى استهلاك موارد عند حدوث فشل (حالة طوارئ) مقارنة مع باقي الخوارزميات وبالتالي تلاؤم أكبر مع حالات الطوارئ في السيناريو المقترح بينما تقدم الخوارزمية العشوائية أقل استهلاك موارد مقارنة مع الأخيرتين.
- ❖ قدمت الخوارزمية العشوائية أقل جودة خدمة مقارنة مع باقي الخوارزميات بينما خوارزمية SO-ARAP قد قدمت اعلى أداء في الحالة الطبيعية للشبكة، أما في حالات الطوارئ نلاحظ انخفاض أداء الخوارزميات الثلاثة ولكن تبقى خوارزمية SO-ARAP تعطي أداء جيد من حيث الخدمات المقدمة وأعلى من الخوارزميات الأخرى المدروسة.
- ❖ يمكن التوصية باستكمال العمل من خلال إمكانية إضافة حالات طوارئ أخرى (التشويش بسبب الحواجز) وتقديم حركية للعقد.

## 9 - الخاتمة:

يعتبر موضوع توزيع الخدمات في الشبكات الحاسوبية من المواضيع الهامة والحديثة وبالتالي قمنا في هذا البحث بعرض مفهوم توزيع الخدمات ودراسة مرجعية لأهم الخوارزميات المستخدمة في مجال توزيع الخدمات.

حيث تم اختيار ثلاث خوارزميات (Random , SO-RAP , SO-ARAP) وبناء محاكي شبكي باستخدام لغة Java لدراسة أداء كل منها في الحالة الطبيعية وفي حال حدوث حالة طوارئ من فشل في العقد أو انقطاع في الاتصالات.

وتم تحقيق سيناريو شبكي وتنفيذ الخوارزميات الثلاثة في الحالة الطبيعية للشبكة وفي حال حدوث حالة طوارئ ومن ثم تحليل النتائج وحساب متوسط استهلاك الموارد وجودة الخدمة المقدمة لنجد أن خوارزمية SO-ARAP تقدم أعلى أداء وتلائم مع حالات الطوارئ مقارنة مع الخوارزميتين الأخرتين.

## المراجع

- 1- MACKENZIE, C. M & LASKEY,K MCCABE,F & BROWN,P & METZ, T & Hamilton,b.(2006)- Reference Model for Service Oriented Architecture 1.0. OASIS Standard, 31p.
- 2- WITTENBURG, G. (2010)- Service Placement in Ad Hoc Networks, Doctoral Dissertation, freie Universität Berlin, 219p.
- 3- م. منار الجبر ، "تحسين أداء خوارزمية SONDe لتوزيع الخدمات ذاتية التأقلم في الشبكات المستقبلية"، مجلة جامعة البعث، 2021.
- 4- م. منار الجبر ، "خوارزمية حيوية ذاتية التأقلم لتوزيع الخدمات في الشبكات المستقبلية"، مجلة جامعة حماة، 2021
- 5-Martin, R. M ., Inmaculada, k., & Palomo-lozano, F.(2019). An evolutionary hybrid search heuristic for monitor placement in communication networks. Journal of Heuristics.  
<https://doi.org/10.1007/s10732-019-09414-z>
- 6-Danossolo, B., Fajjari, I., Legrand, A., & Mertikopoulos, P.(2019). Fog Based Farmework for IoT Service Provisioning. 2019 16 th IEEE Annual Consumer Communications & Networking Conference (CCNC), 1-6.



- 7-KAILOUH, I.(2011)- Evaluation and Comparison of Service Placement Algorithm in Communication Networks, Ilmenau University of Technology,97.
- 8-V. Gramoli, A.M. Kermarrec, E. Le Merrer, "SONDe, a SelfOrganizing Object Deployment Algorithm in Large-Scale Dynamic Systems", Dependable Computing Conference, 2008. EDCC 2008. Seventh European, 2008.
- 9-LAOUTARIS, N , SMARAGDAKIS, G, OIKONOMOU, K.(2007)- Distributed Placement of Service Facilities in Large-Scale Networks. IEEE Communications Society subject,2144-2152p.
- 10-REESE, J. (2006)- Solution Methods for the p-Median Problem: An Annotated Bibliography. Wiley Periodicals, Inc. Networks, 48(3): 125-142p.
- 11-Diab, A. , Mitschele-Thiel A. , Shahzad ,A.,"A Survey of Services Placement Mechanisms for Future Mobile Communication Networks",December.2011.
- 12-] WITTENBURG, G., & SCHILLER, J- (2008). A survey of current directions in service placement in mobile ad-hoc networks. 6th Annual IEEE International Conference on Pervasive Computing and Communications, PerCom 2008, 548-553p.

- 13- SOCIETY,I.C. & INFOCOM,I. (2007)-Distributed Placement of Service Facilities in Large-Scale Networks. IEEE Communications Society subject, 2144–2152p.
- 14- Guerrero, C., Lera, I., & Juiz, C. (2019)- Evaluation and Efficiency Comparison of Evolutionary Algorithms for Service Placement Optimization in Fog Architectures. Future Generation Computer Systems. <https://doi.org/10.1016/j.future.2019.02.056>
- 15- Wittenburg, G., & Schiller, J., (2008)- Service Placement in Ad Hoc Networks, pp.1–2.
- 16- WITTENBURG, G.(2010)- Service Placement in Ad Hoc Networks, Doctoral Dissertation, freie Universität Berlin, 219p
- 17- Tian, H., Wu, J., Shen, H., & Science, C. (2017)- Efficient Algorithms for VM Placement in Cloud Data Centers. <https://doi.org/10.1109/PDCAT.2017.00021>

## تأثير درجة حرارة وسرعة الطباعة ثلاثية الأبعاد على مقاومة الشد الأعظمية لمادة البولبي ايثيلين تيرفتالات (PETG)

د.م محمود الأسعد\* د.م ماهر الابراهيم\*\* م.طارق حرب\*\*\*  
\* أستاذ في قسم هندسة التصميم والإنتاج، كلية الهندسة الميكانيكية والكهربائية،  
جامعة البعث  
\*\* أستاذ مساعد في قسم هندسة التصميم والإنتاج، كلية الهندسة الميكانيكية  
والكهربائية، جامعة البعث  
\*\*\* عضو هيئة فنية في قسم هندسة التصميم والإنتاج، كلية الهندسة الميكانيكية  
والكهربائية، جامعة البعث

### الملخص

في هذا البحث تم اجراء تجارب الطباعة ثلاثية الأبعاد باستخدام طريقة الطباعة بالإضافة وبتقنية الFDM لمادة الPETG حيث تعتبر هذه المادة من المواد حديثة الاستخدام في الطباعة لما تتمتع به من ميزات مختلفة كالمقاومة العالية نسبياً مقارنة بمواد الطباعة الأخرى والمرونة الجيدة نسبياً، في هذا البحث تم دراسة خمس درجات حرارة مختلفة للطباعة وهي على التوالي ( $225, 235, 245, 255, 265$  C°) وثلاث سرع مختلفة ( $50, 60, 70$  mm/sec) ودراسة تأثيرها على مقاومة الشد الأعظمي للعينات المطبوعة حيث تم طباعة خمس عينات لكل مجموعة بطبعة واحدة أظهرت النتائج تحسن مقاومة الشد بشكل طردي مع زيادة سرعة الطباعة وبالنسبة لدرجة حرارة الطباعة كانت مقاومة الشد العظمى تتزايد بشكل طردي مع ارتفاع درجة الحرارة حتى درجة الحرارة  $245$  C° ثم تنخفض بعد هذه الدرجة.

الكلمات المفتاحية: الطباعة ثلاثية الأبعاد، درجة حرارة الطباعة، البولبي ايثيلين

تيرفتالات.

## Effect of 3D printing temperature and speed on the ultimate tensile strength of PETG

### Abstract

In this research, 3D printing experiments were carried out using the addition printing method and the FDM technique of PETG, as this material is considered one of the modern used materials in printing because of its different advantages such as relatively high strength compared to other printing materials and relatively good flexibility. In this research, five Different printing temperatures, which are respectively (225, 235, 245, 255, 265 C°) and three different speeds (50, 60, 70 mm/sec), and studying their effect on the maximum tensile strength of the printed samples, where five samples were printed for each group with one print. The results showed that the tensile strength improved directly with increasing the printing speed and for the printing temperature, the maximum tensile strength increased proportionally with the increase in temperature until the temperature was 245 C°, then it decreased after this degree

Keywords: 3D printing , temperature printing , PETG.

## 1- مقدمة:

تعد الطباعة ثلاثية الأبعاد إحدى تقنيات التصنيع -التصنيع بالإضافة- حيث يتم تصنيع القطع عن طريق طباعة الطبقة فوق الطبقة الأخرى حتى يتكون المنتج النهائي حيث يتم قبل الطباعة تجهيز نموذج ثلاثي الأبعاد على الحاسوب وتقسيم هذا التصميم إلى طبقات صغيرة جداً باستخدام برامج حاسوبية، كذلك تنتج الطباعة ثلاثية الأبعاد قطع متداخلة معقدة التركيب وتمكن من صناعة أجزاء من مواد مختلفة لها مواصفات ميكانيكية مختلفة ويعد إنتاج النماذج الأولية والمفردة بهذه الطريقة من أسرع وأوفر وأسهل التقنيات المستخدمة للتصنيع.

من أحد أكثر التقنيات المستخدمة في الطباعة هي الطباعة بالبتق الحراري، في هذه التكنولوجيا يتم تزويد الطابعة بمادة الطباعة على شكل أسلاك أو خيوط، تتصل برأس مدبب دقيق فيه فوهة، يسخن هذا الرأس ليذيب مادة الطباعة، وعند حركته أفقياً ورأسياً يخرج المادة حسب الشكل المطلوب، وحال خروج المادة من الرأس تبرد في درجة حرارة الغرفة وتتصلب. واحدة من أشهر التقنيات التي بنيت على هذه التجربة هي نمذجة تموضع المصهور (Fused Deposition Modeling (FDM) ، التي اخترعها سكوت كرمب في نهاية الثمانينات من القرن الماضي. ومن أكثر المواد المستخدمة في هذه التقنية هي اللدائن الحرارية، لأن هذا النوع من المواد يمكن تلدينه بسهولة وبتقته للحصول على الشكل المطلوب.

إن الاختلاف الرئيسي بين تقنيات التصنيع التقليدية والتصنيع بالإضافة هو آلية العمل المتمثلة بإضافة المواد إلى المنتج وبنائه بشكل متتالي وهذا يمكن المصنع من تصنيع منتجات لها أشكال معقدة ويستحيل الحصول عليها بالطرق التقليدية.

مازالت الأبحاث مستمرة لاستغلال جميع الإمكانيات التي توفرها هذه التقنية، وكما ذكرنا تعد تقنية النمذجة بتموضع المصهور (FDM) من أكثر التقنيات انتشاراً وأهمها وفي الوقت الحالي يهتم الباحثون بشكل رئيسي بعلاقة الخواص الميكانيكية للقطع المنتجة بهذه الطريقة مع متغيرات الطباعة مثل (سرعة الطباعة، نسبة الملء، سماكة طبقة الطباعة، اتجاه الطباعة ..)[1].

قام الباحث E said [1] بدراسة تأثير اتجاه الطباعة على الخواص الميكانيكية (مقاومة الشد، متانة الصدم) لعينات ABS مطبوعة بتقنية FDM ووجد الباحثون أن الاتجاه (0 درجة) يعطي أفضل النتائج وكذلك فإن أصغر سمك لطبقة الطباعة ودرجة حرارة طباعة الأعلى هي التي أعطت أفضل الخصائص الميكانيكية، وهذا ما توافق مع نتائج لأبحاث أخرى كالدراسة التي قام بها الباحث subham [2] والتي أكد فيها أن زيادة سماكة الطبقة للعينات المطبوعة لنفس المادة ABS وبنفس التقنية تؤدي إلى تقليل مقاومة الشد بنسبة 46%.

في عام 2020 قام الباحث Fountas وآخرون [3] بإجراء بحث تجريبي على عينات PLA مطبوعة وذلك بهدف ربط متغيرات الطباعة مع خواص مقاومة الشد للمنحنيات وأبرز هذه المتغيرات هي سماكة الطبقة، نسبة الملء، اتجاه الطباعة وسرعة الطباعة وتوصل الباحثون إلى أن نسبة الملء للطباعة تعد من أهم المتغيرات التي تؤثر على مقاومة الشد أما بالنسبة لسماكة الطبقة فيجب أن تكون صغيرة قدر الإمكان.

وفي عام 2020 قام الباحث vǎlean [4] باختبار مقاومة الشد لعينات مصنعة بالطباعة ثلاثية الأبعاد وبنفس التقنية FDM من مادة PLA وفق متغيرين أساسيين (اتجاه الطباعة، سماكة الطبقة) وتوصل الباحث إلى أن الاتجاه يلعب دور بالغ الأهمية في

مقاومة الشد حيث أن الطباعة وفق الاتجاه X أو Y تعطي مقاومة شد مماثلة لمقاومة الشد للقطع المنتجة بالحقن.

قام الباحثان ASSAD.M & MAKI A [5] بدراسة تأثير نسبة الملء وأشكاله أثناء الطباعة لمادة PETG مع تثبيت بقية المتغيرات كالسرعة ودرجة الحرارة وذلك بهدف الحصول على أعلى قيمة للمقاومة النوعية (قوة تحمل مع وزن خفيف) مع أقل كلفة وتوصل الباحثون إلى أن استخدام الشكل المسدس للبناء والملء يعطي أفضل النتائج من حيث الكلفة المنخفضة والمقاومة النوعية العالية.

وفي عام 2021 أجرى الباحث ASSAD.M [6] دراسة تجريبية بهدف دراسة تأثير سرعة الطباعة بالاتجاهات الثلاثة على مقاومة الانعطاف لعينات مصنعة من بوليمير ال PLA وتوصل الباحث إلى أن النتائج لا تتأثر بشكل كبير بالسرعة وإنما تتأثر بالاتجاه وأن الطباعة بسرعات أعلى تتعلق بجودة المنتج بالدرجة الأولى.

## 2- هدف البحث:

مما ذكر سابقاً في الدراسات السابقة نلاحظ اهتمام متزايد وبشكل كبير بتقنية الطباعة FDM (النمذجة بتموضع المصهور) وبشكل خاص من جهة تأثير متغيرات الطباعة المختلفة على الخواص الميكانيكية للقطعة المطبوعة وعلى اعتبار أن مادة PETG مادة مستخدمة في الطباعة حديثاً وبشكل متزايد ولم تركز الأبحاث الحديثة على ربط الخواص الميكانيكية بمتغيرات الطباعة لهذه المادة فإن هدف هذه الدراسة هو إيجاد علاقة درجة حرارة الطباعة لهذه المادة بمقاومة الشد العظمى للعينات المطبوعة بهدف استخدام النتائج لتحديد درجة الحرارة الأمثل لإنتاج منتجات لها مقاومة شد عظمى عند نفس السرعة والزمن اللازم للإنتاج.

### 3- مواد وطرائق البحث:

#### 1-3 مواد البحث:

##### 1-1-3 مادة الطباعة:

لقد تم الاعتماد في هذا البحث على أحدث المواد اللدنة المستخدمة في الطباعة ثلاثية الأبعاد بتقنية FDM وهي مادة الـ (Polyethylene Terephthalate) PETG وهي عبارة عن خيوط بلاستيكية بقطر [mm] 1.75 وهي معدلة خصيصاً للطباعة ثلاثية الأبعاد بتقنية FDM وتعد هذه المادة من المواد الحديثة في الطباعة ثلاثية الأبعاد حيث تتمتع بخواص مقاومة عالية مقارنة بالمواد الأخرى المستخدمة بالطباعة وخواص مرونة جيدة نسبياً، وبالتالي تعد مادة PETG مادة تجمع بين خاصتي المرونة والمقاومة العالية نسبياً وهذا ما يجعلها خيار جيد في التطبيقات الميكانيكية المتنوعة يضاف إلى ذلك أنها من المواد المعترف بها من قبل (food and drug administration) FDA

وبالتالي يمكن استخدامها في حالات التماس المباشر مع الجسم والأغذية.

#### 3-1-2 الطباعة المستخدمة:

تعتمد الطباعة ثلاثية الأبعاد بتقنية الـ FDM على مبدأ البناء بالطبقات (layer by layer building)، وتستخدم الطابعات ثلاثية الأبعاد التي تعمل بهذه التقنية مواد أولية لدنة تكون على شكل خيوط filaments ملفوفة على بكرات spools وبأقطار عيارية هي [mm] 1.75 للطابعات الصغيرة الحجم نسبياً و [mm] 3 للطابعات كبيرة الحجم.


- يعتمد مبدأ الطباعة ثلاثية الأبعاد بتقنية الـ FDM على دفع المادة الأولية باستخدام محركات مقادة حاسوبياً باتجاه فوهة البثق Nozzle بسرعات مختلفة تتعلق بسرعة الطباعة وقطر فوهة البثق، يتم تسخين فوهة البثق لدرجة حرارة البثق وهي عبارة



عن درجة حرارة محددة يتم تحديدها من قبل الشركة الصانعة بحيث لا تقل عن درجة انصهار المادة البلاستيكية[5].

- يتم التحكم بحركة رأس البثق عن طريق الحاسب حيث يتم توجيهه في كل طبقة على حدا وفق مسارات الطباعة ثلاثية الأبعاد وفي كل مرة يتم فيها انهاء بناء طبقة من الشكل ثلاثي الأبعاد المراد بناؤه تقوم الطباعة بإنشاء طبقة تالية في مستو تالي يبعد عن المستوي السابق بمسافة شاقوليه هي سماكة الطبقة المراد بناؤها.

يوضح الشكل(1) مبدأ الطباعة ثلاثية الابعاد بتقنية FDM



الشكل(1) مبدأ الطباعة ثلاثية الابعاد بتقنية FDM

تأثير درجة حرارة وسرعة الطباعة ثلاثية الأبعاد على مقاومة الشد الأعظمية لمادة البولي ايثيلين تيرفتالات (PETG)

- تم العمل على الطباعة ثلاثية الأبعاد بتقنية الـ FDM من ماركة Wanhao الأكثر انتشاراً عالمياً في الوقت الحالي، وتعد من فئة الطابعات المكتبية Desktop 3D printer متوسطة الحجم وتتمتع الطباعة بالموصفات التالية الموضحة في الجدول (1).

الجدول (1) مواصفات الطباعة المستخدمة

$V = 15 \times 23 \times 15$ $V = 5175$	حجم الطباعة الأعظمي $Cm^3$
$V_{max} = 120$	سرعة الطباعة الأعظمية [mm/sec]
(0.05-0.25)	سماكة الطبقة المطبوعة [mm]
ABS-PLA-PETG-TPU	المواد الممكن طباعتها

والشكل (2) يوضح الطباعة المستخدمة Wanhao



الشكل (2) الطباعة المستخدمة WANHAO


### 3-2 تنفيذ تجارب الطباعة:

تم اجراء جميع تجارب الطباعة مع تثبيت البارامترات الموضحة بالجدول (2) التالية:

الجدول(2) القيم المثبتة المستخدمة

0.2 [mm]	سماكة الطبقة المطبوعة
+45/-45	اتجاه الطباعة
110 [C°]	درجة حرارة الطاولة
1 [shell]	عدد القشور المحيطة

واستخدام خمس درجات حرارة للطباعة وهي (225,235,245,255,265 C°) ولكل درجة حرارة ثلاث سرع طباعة مختلفة ( $50,60,70 \frac{\text{mm}}{\text{sec}}$ ) والجدول التالي يوضح المتغيرات مع الترميز لكل مجموعة عينات للطبعة الواحدة والتي تحوي على خمس عينات مطبوعة موضحة في الشكل(3).



الشكل(3) تصميم العينات وطباعتها

تأثير درجة حرارة وسرعة الطباعة ثلاثية الأبعاد على مقاومة الشد الأعظمية لمادة البولي ايثيلين  
تيرفتالات (PETG)

الجدول (3) مجموعة العينات مع المتغيرات المستخدمة

السرعة $\frac{mm}{sec}$	درجة الحرارة C°	الرمز
50	225	S <sub>1</sub>
	235	S <sub>2</sub>
	245	S <sub>3</sub>
	255	S <sub>4</sub>
	265	S <sub>5</sub>
60	225	S <sub>6</sub>
	235	S <sub>7</sub>
	245	S <sub>8</sub>
	255	S <sub>9</sub>
	265	S <sub>10</sub>
70	225	S <sub>11</sub>
	235	S <sub>12</sub>
	245	S <sub>13</sub>
	255	S <sub>14</sub>
	265	S <sub>15</sub>


### 3-3 اختبار الشد الميكانيكي:

جهاز الشد المستخدم (TINIUS OLSEN HK50S) الموضح في الشكل (4)



الشكل (4) جهاز اختبار الشد الستاتيكي المستخدم

أما عينة اختبار الشد فتم تصميمها اعتماداً على المواصفة القياسية ASTM D638 (standard test method for tensile properties of plastics) Type 5 والموضحة بالشكل (5) [7].



Specimen Dimensions for Thickness,  $T$ , mm (in.)<sup>A</sup>

Dimensions (see drawings)	7 (0.28) or under		Over 7 to 14 (0.28 to 0.55), incl	4 (0.16) or under		Tolerances
	Type I	Type II	Type III	Type IV <sup>B</sup>	Type V <sup>C,D</sup>	
W—Width of narrow section <sup>A,E</sup>	13 (0.50)	6 (0.25)	19 (0.75)	6 (0.25)	3.18 (0.125)	±0.5 (±0.02) <sup>B,C</sup>
L—Length of narrow section	57 (2.25)	57 (2.25)	57 (2.25)	33 (1.30)	9.53 (0.375)	±0.5 (±0.02) <sup>C</sup>
WO—Width overall, min <sup>F</sup>	19 (0.75)	19 (0.75)	29 (1.13)	19 (0.75)	...	+6.4 (+0.25)
WO—Width overall, min <sup>F</sup>	...	...	...	...	9.53 (0.375)	+3.18 (+0.125)
LO—Length overall, min <sup>D</sup>	165 (6.5)	183 (7.2)	246 (9.7)	115 (4.5)	63.5 (2.5)	no max (no max)
G—Gage length <sup>H</sup>	50 (2.00)	50 (2.00)	50 (2.00)	...	7.62 (0.300)	±0.25 (±0.010) <sup>C</sup>
G—Gage length <sup>H</sup>	...	...	...	25 (1.00)	...	±0.13 (±0.005)
D—Distance between grips	115 (4.5)	135 (5.3)	115 (4.5)	65 (2.5) <sup>I</sup>	25.4 (1.0)	±5 (±0.2)
R—Radius of fillet	76 (3.00)	76 (3.00)	76 (3.00)	14 (0.56)	12.7 (0.5)	±1 (±0.04) <sup>C</sup>
RO—Outer radius (Type IV)	...	...	...	25 (1.00)	...	±1 (±0.04)

الشكل (5) أبعاد عينة اختبار الشد الستاتيكي

تأثير درجة حرارة وسرعة الطباعة ثلاثية الأبعاد على مقاومة الشد الأعظمية لمادة البولي إيثيلين تيرفتالات (PETG)

4- النتائج:


نتائج اختبار الشد الستاتيكي:

يبين الجدول (4) متوسط قيم مقاومة الشد للعينات المطبوعة عند السرعة  $50 \frac{mm}{sec}$

الجدول (4) متوسط قيم مقاومة الشد للعينات المطبوعة عند السرعة  $50 \frac{mm}{sec}$

مقاومة الشد الأعظمي [Mpa]	درجة الحرارة C°	سرعة الطباعة $\frac{mm}{sec}$	رمز العينة
16.82	225	<b>50</b>	S <sub>1</sub>
18.32	235		S <sub>2</sub>
23.35	245		S <sub>3</sub>
17.85	255		S <sub>4</sub>
16.75	265		S <sub>5</sub>

ويبين الشكل (6) المخطط البياني لقيم مقاومة الشد الاعظمي للعينات المطبوعة.




يبين الجدول (5) متوسط قيم مقاومة الشد للعينات المطبوعة عند السرعة  $60 \frac{mm}{sec}$

الجدول (5) متوسط قيم مقاومة الشد للعينات المطبوعة عند السرعة  $60 \frac{mm}{sec}$

رمز العينة	سرعة الطباعة $\frac{mm}{sec}$	درجة الحرارة C°	مقاومة الشد الأعظمي [Mpa]
S <sub>6</sub>	<b>60</b>	225	19.34
S <sub>7</sub>		235	21.46
S <sub>8</sub>		245	28.85
S <sub>9</sub>		255	20.68
S <sub>10</sub>		265	18.40

ويبين الشكل (7) المخطط البياني لقيم مقاومة الشد الاعظمي للعينات المطبوعة




تأثير درجة حرارة وسرعة الطباعة ثلاثية الأبعاد على مقاومة الشد الأعظمية لمادة البولي إيثيلين تيرفتالات (PETG)

يبين الجدول (6) متوسط قيم مقاومة الشد للعينات المطبوعة عند السرعة  $70 \frac{\text{mm}}{\text{sec}}$

الجدول (6) متوسط قيم مقاومة الشد للعينات المطبوعة عند السرعة  $70 \frac{\text{mm}}{\text{sec}}$


رمز العينة	سرعة الطباعة $\frac{\text{mm}}{\text{sec}}$	درجة الحرارة C°	مقاومة الشد الأعظمي [Mpa]
S <sub>11</sub>	70	225	19.73
S <sub>12</sub>		235	22.33
S <sub>13</sub>		245	29.95
S <sub>14</sub>		255	21.70
S <sub>15</sub>		265	19.18

ويبين الشكل (8) المخطط البياني لقيم مقاومة الشد الاعظمي للعينات المطبوعة





ويوضح الشكل (9) المخطط البياني ثلاثي الابعاد لعلاقة كل من سرعة الطباعة ودرجة الحرارة مع مقاومة الشد الأعظمي.




ويوضح الجدول (7) المتوسط الحسابي لقيم الشد العظمي للمجموعات والانحراف المعياري ضمن المجموعة وأعلى قيمة وأصغر قيمة ضمن المجموعة نفسها.

الجدول (7) المتوسط الحسابي لقيم الشد العظمي للمجموعات والانحراف المعياري ضمن المجموعة وأعلى قيمة وأصغر قيمة

أعلى قيمة/أقل قيمة	الانحراف المعياري	المتوسط الحسابي	المجموعة
16.75/23.35	1.89	18.62	الأولى 50 mm/sec
18.4/28.85	2.84	21.75	الثانية 60 mm/sec
19.18/29.95	2.94	22.58	الثالثة 70 mm/sec

تأثير درجة حرارة وسرعة الطباعة ثلاثية الأبعاد على مقاومة الشد الأعظمية لمادة البولي ايثيلين تيرفتالات (PETG)



الشكل (10) المتوسط الحسابي والانحراف المعياري لمجموعات سرعة الطباعة

### 5- مناقشة النتائج:

أظهرت النتائج أن مقاومة الشد للعينات المطبوعة عند السرعة الواحدة وباختلاف قيم درجات حرارة الطباعة (درجة حرارة الباثق) تزداد بشكل تدريجي وطردي مع الارتفاع في درجة الحرارة حتى القيمة  $245^{\circ}\text{C}$  ومن ثم تنخفض كما هو موضح في الشكل (9) كما نلاحظ اختلاف مقدار التدرج باختلاف السرعة وهذا ما توضحه قيم الجدول (7) وبالتالي نلاحظ تقارب القيم عند السرعة المنخفضة وتباعدها واضح عند زيادة سرعة الطباعة.

يعزى ازدياد قيمة مقاومة الشد بشكل تدريجي قبل درجة حرارة الذروة ( $245^{\circ}\text{C}$ ) الى ازدياد لزوجة البوليمير حيث من المعروف أن المادة البلاستيكية الشبه الكريستالية (كما في حالة دراستنا) تمتلك مجالين مميزين الأول هو مجال التبلور (للـ PETG  $80-90^{\circ}$ ) ومجال الانصهار (للـ PETG  $250-260^{\circ}$ ) وبين هاتين القيمتين تقل لزوجة المادة بشكل طردي حتى القيمة  $245^{\circ}\text{C}$  ومن ثم تصبح المادة بشكل مصهور ويكون مقدار

التدفق للمصهور أكبر من الحاجة للطباعة مما يؤدي إلى حدوث العيوب المختلفة بالطباعة كالفراغات، ومع ازدياد السرعة تتحسن آلية تدفق المادة إلى منطقة الطباعة- حتى في الحالة المصهورة- مما يؤدي إلى زيادة الخواص الميكانيكية للعينة وبشكل خاص حد المقاومة الأعظمي.

## 6- الاستنتاجات والتوصيات:

تم في هذا البحث دراسة تأثير سرعة الطباعة ودرجة الحرارة على مقاومة الشد للعينات المطبوعة وأظهرت النتائج ازدياد المقاومة بشكل طردي مع الازدياد في سرعة الطباعة أما درجة حرارة الطباعة فلها تأثير متباين وذلك بسبب وجود ذروة في النتائج ( $245^{\circ}$ ) عند نفس السرعة كما أنها تؤثر على تباعد القيم بالازدياد في السرعة. وبالاعتماد على فهم هذه العلاقة يمكن دراسة تأثير نفس هذه المتغيرات على الخواص الميكانيكية الأخرى مثل مقاومة التعب والزحف للعينات المطبوعة، ومن الممكن أن تركز الأبحاث اللاحقة على دراسة هذا التأثير ولكن ضمن مجال أوسع وفي سرعات أعلى والتي يمكن تحقيقها بأساليب طباعة مختلفة.

7- المراجع:

- [1] **S-Said, O.S., Foyos, J., Noorani, R., Mendelson, M., Marloth, R. and Pregger, B.A., 2000.** Effect of layer orientation on mechanical properties of rapid prototyped samples. Materials and Manufacturing Processes, 15(1), pp.107-122.
- [2] **Shubham, P., Sikidar, A. and Chand, T., 2016.** The influence of layer thickness on mechanical properties of the 3D printed ABS polymer by fused deposition modeling. In Key engineering materials, 706, pp. 63-67. Trans Tech Publications Ltd.
- [3] **Fountas, N.A., Kostazos, P., Pavlidis, H., Antoniou, V., Manolakos, D.E. and Vaxevanidis, N.M., 2020.** Experimental investigation and statistical modelling for assessing the tensile properties of FDM fabricated parts. Procedia Structural Integrity, 26, pp.139-146.
- [4] **Vălean, C., Marşavina, L., Mărghitaş, M., Linul, E., Razavi, J. and Berto, F., 2020.** Effect of manufacturing parameters on tensile properties of FDM printed specimens. Procedia Structural Integrity, 26, pp.313-320.
- [5] **ASSAD.M , MAKI., A(2020)** Study the Influence of Trajectory Planning & Infill Ratio in 3D Printing (FDM Technique) Using PETG Material, on the Properties of Specific Strength and Overall Cost of Printed Parts. AIBAATH UNIVERSTY.
- [6] **ASSAD.M (2021)** Studying the effect of 3D printing speed using FDM technology for PLA material on the flexural strength. AIBAATH UNIVERSTY.
- [7] **ASTM, D. (2014).** ASTM D-638. Standard Test Method for Tensile Properties of Plastics. ASTM Int.

## تحسين التحكم بالبيت البلاستيكي الذكي باستخدام الشبكات العصبونية

طالبة ماجستير: م. شفق طهماز قسم هندسة البرمجيات ونظم المعلومات

كلية الهندسة المعلوماتية - جامعة البعث

إشراف: د. رانيا لطفي

### الملخص

تعتبر تقنية انترنت الأشياء إحدى التقنيات الثورية في مجال تكنولوجيا المعلومات والتي استهدفت مجالات واسعة طبيياً وعلمياً وزراعياً، حيث أنه ليس بالمفهوم حديث الولادة لكن توفر التقنيات المساعدة أدت إلى انتشار تطبيقاته العديدة حيث سندر في هذا البحث تطبيق انترنت الأشياء في الزراعة وبالتحديد البيوت البلاستيكية لبناء ما يسمى بالبيت البلاستيكي الذكي (الدفينة الذكية) التي لها القدرة على التحكم بالمناخ من حرارة ورطوبة وإنارة وضبط جميع العمليات آلياً مما يلغي الحاجة إلى التدخل اليدوي والمراقبة الآتية. كما تم في هذا البحث استخدام كل من المنطق الضبابي والشبكات العصبونية من أجل التحكم في البيت البلاستيكي وأثبت النتائج فعالية الشبكات العصبونية بالمقارنة مع المنطق الضبابي.

**الكلمات المفتاحية:** انترنت الأشياء - البيوت البلاستيكية الذكية - الحساسات - الزراعة الدقيقة - المنطق الضبابي - الشبكات العصبونية.

# Enhancing the control of smart greenhouse using neural network

**Master student: Eng. Shafak Tehmaz**

**Faculty of Informatics Engineering**

**Supervised By: Dr. Rania Loutfi**

## Abstract

Internet of things technology is considered one of the revolutionary technologies in the field of information technology, which targeted wide fields in the medical, scientific and agricultural fields, as it is not a newborn concept, but the availability of assistive technologies led to the spread of its many applications. Where we will study in this research the application of the Internet of Things in agriculture, specifically greenhouses, to build a so-called smart plastic house that has the ability to control the climate such as temperature, humidity, lighting and control all operations automatically, which eliminates the need for manual intervention and simultaneous monitoring. In this research, both fuzzy logic and neural networks were used to control the greenhouse, and the results proved the effectiveness of neural networks compared to fuzzy logic.

**Keywords:** Internet of things – Smart greenhouses – Sensors – Precision agriculture – Fuzzy logic – Neural Networks.

## 1- مقدمة:

يعتبر القطاع الزراعي من الركائز الأساسية التي يستند عليها الاقتصاد الوطني في سورية نظراً للتنوع الحيوي والمناخي هذا ما دفع الكثير إلى الاهتمام بتطوير المجال الزراعي واستخدام الأساليب الحديثة التي وفرت الوقت والجهد وزادت معدل الانتاج من خلال توظيف التكنولوجيا في هذا المجال.

وإن التقدم العلمي الذي حدا بالإنسان أن يتعرف على احتياجات هذه النباتات من الحرارة المناسبة والرطوبة..الخ دفعه لتوفير هذه الأجواء الاصطناعية للنبات ليحصل على محاصيل الخضراوات الصيفية في غير زمن وجودها الطبيعي.

من هنا بدأت عملية الزراعة ضمن البيوت البلاستيكية والتي تُعرف بالزراعة المغطاة وهي إنتاج الخضراوات والزهور ضمن أنفاق أو غرف بلاستيكية تتم تدفئتها بالأشعة الشمسية أو المدفأة، مع تأمين حاجة النباتات البيئية وحمايتها من التيارات الهوائية، ومن الآفات الزراعية.

وهناك عدة عوامل ساعدت على نجاح هذه الزراعة منها أن تكون التربة المراد إقامة البيوت البلاستيكية عليها ذات قوام خفيف وخصبة، أن تكون البيوت بعيدة عن الظل تماماً بمسافة لا تقل عن 5 م، توفر مصدر مائي كافي للري، توفر مصدر كهربائي إضافي لتأمين التدفئة والتهوية باستمرار، اختيار الموعد الملائم للإنتاج، الرقابة الصحية الجيدة للنباتات.

يتوفر في سورية 150295 بيت بلاستيكي مستثمر، يتواجد منهم ما يقارب 85% في محافظة طرطوس (حسب آخر إحصائية لوزارة الزراعة والإصلاح الزراعي في سورية لعام 2020)[1].

## 2- المشكلة العلمية ومبررات مشروع البحث:

تُعتبر تقنية انترنت الأشياء إحدى التقنيات الثورية في مجال تكنولوجيا المعلومات والتي لاقت انتشاراً واسعاً في مجالات عديدة طبيياً وزراعياً وصحياً خلال السنوات الأخيرة مما دفعنا لتطبيقها في مجال البيوت البلاستيكية لإنشاء بيت بلاستيكي ذكي قادرين على التحكم بمناخه وضبط جميع العمليات التي تتم فيه آلياً دون الحاجة للتدخل اليدوي.

## 3- أهمية البحث:

فيما يتعلق بالقضايا البيئية يمكن لتطبيق انترنت الأشياء في المجال الزراعي أن يوفر مزايا كبيرة من حيث استخدام المياه بشكل أكثر كفاءة، مضاعفة كمية الإنتاج بسبب الضبط الدقيق للعوامل المحيطة بالنبات والحصول على جودة إنتاج أعلى.

كما أن له أهمية كبيرة في تقليل استخدام الأيدي البشرية العاملة كون المراقبة ممكن أن تتم من أي مكان على وجه الأرض ويمكن أن يقوم بها شخص واحد من خلال هاتفه المحمول أو حاسبه الشخصي.

يوضح الشكل رقم (1) نموذج لبيت بلاستيكي ذكي مثالي مضبوط بأغلب عناصره حيث دُكرت في الصورة الحساسات التي استُخدمت للتحكم به وضبطه (حساس الحرارة - الرطوبة - قيمة PH - كمية الضوء) أماكن تركيب الحساسات، التجهيزات الخاصة بعملية التحكم ( فتح النوافذ - التدفئة - مضخات المياه - المرشات - مصابيح الإنارة - ... الخ) أدوات الإدارة عن بعد (أجهزة الجوال الذكية - الرسائل القصيرة -... الخ) وأخيراً وسائل التحكم الآلي.





الشكل رقم (1) نموذج لبيت بلاستيكي ذكي [14]

#### 4- هدف البحث:

يهدف البحث إلى تحسين عملية التحكم بالبيت البلاستيكي الذكي باستخدام خوارزمية المنطق الضبابي وباستخدام الشبكات العصبونية ومقارنة النتائج التي تم الحصول عليها من الطريقتين واعتماد الطريقة الأفضل.

#### 5- الدراسات المرجعية:

استخدم الباحثون في الدراسة [2] حول البيوت البلاستيكية الذكية خوارزمية المنطق الضبابي لجعل مدة ري النباتات أكثر عملية وفاعلية وفقاً لدرجة الحرارة والرطوبة المقاسة داخل البيت بحيث يتم الحفاظ على درجة حرارة ورطوبة الجو ضمن البيوت البلاستيكية بما يتناسب مع النبات المزروع. وتوصلوا إلى نتائج تجريبية بأن طريقة المنطق الضبابي فعالة للتحكم في مدة الري والحفاظ على درجة الحرارة والرطوبة المثلى داخل الدفيئة.

عمل الباحثون في الدراسة [3] على دراسة العوامل المناخية المختلفة في البيت البلاستيكي من درجة الحرارة والرطوبة النسبية ورطوبة التربة وشدة الضوء وذلك عن طريق استخدام مجموعة من الحساسات، حيث تم توزيع العديد من عقد الاستشعار التي تشكل جزءاً من مجموعة الحزم العقدية على شبكة استشعار لاسلكية (WSN) تم إنشاؤها في هيكل نجمي. بالإضافة إلى ذلك، تم التحكم في البيانات التي تم الحصول عليها من العقد ومراقبتها باستخدام إستراتيجية تحكم تعتمد على المنطق الضبابي المقترحة كواجهة قائمة على نظام أندرويد ويمكن الوصول إليها عن بعد كما تم اختيار Elazig في تركيا كبيئة لتطبيق النظام المقترح الذي كان له الفائدة في إدارة استهلاك الطاقة والضوء والمياه بشكل أكثر كفاءة و بفضل هذا النظام يبقى المستخدم للبيت البلاستيكي على علم بحالتها، كما تم تقييم هذا النظام من حيث فائدته بالنسبة للمستخدم وبالنسبة للبيت اللاستيكي.

قدم الباحثون في الدراسة [4] ورقة بحثية منهجية تضمنت إجراء دراسة شاملة لتقنيات إنترنت الأشياء واستخدامها الحالي في مجالات مختلفة ضمن القطاع الزراعي حيث تم تجميع هذه البيانات عن طريق دراسة المقالات البحثية التي تم نشرها بين عامي 2006 و 2019 في مجلات ذات أهمية كبيرة حيث تم اختيار ما يقارب على 67 ورقة بحثية بعناية من خلال عملية منهجية وتم تصنيفها وفقاً لذلك. الهدف الأساسي من هذه الدراسة المنهجية هو جمع جميع الأبحاث ذات الصلة بتطبيقات إنترنت الأشياء في المجال الزراعي من أجهزة الاستشعار، بروتوكولات الاتصال وأنواع الشبكات المختلفة بالإضافة إلى ذلك، فإنه يناقش أيضاً القضايا والتحديات الرئيسية التي يتم التحقيق فيها في مجال الزراعة، كما تم تقديم تقنية إنترنت الأشياء في المجال الزراعي الذي قدم لنا مجموعة واسعة من الحلول الحالية في مجال الزراعة. وبالمثل، سياسات الدول التي تم فيها استخدام إنترنت الأشياء زراعياً. وفي ختام الدراسة تم عرض القضايا والتحديات المفتوحة لتزويد الباحثين باتجاهات مستقبلية واعدة حول تطبيق إنترنت الأشياء في مجال الزراعة.

اقترح الباحثون في ورقتهم البحثية [5] تصميماً لبيت بلاستيكي ذكي باستخدام تقنية انترنت الأشياء حيث يراقب هذا التصميم المناخ ضمن البيت البلاستيكي ويتحكم فيه بذكاء دون تدخل الإنسان، كما ركز البحث على زراعة الفلفل الأحمر حيث يشيع في الهند (مكان تطبيق البحث) استخدام الفلفل الأخضر لكن المدة الطويلة للحصول على اللون الأحمر والطعم الحلو في الفلفل أكثر من أي فلفل آخر أصبح أمراً مكلفاً ومجهداً للمزارعين وهذا يتطلب اهتماماً خاصاً لزراعة هذا الصنف من النباتات. ناقش الباحثون تصميم البيئة الخاضعة للمراقبة بشكل دائم حيث استخدموا أجهزة استشعار مختلفة لقياس العناصر البيئية المختلفة ضمن البيت البلاستيكي ومدى ملائمتها لمتطلبات النبات من خلال تطبيق إنترنت الأشياء، حيث قاموا بإنشاء خادم سحابي للوصول إليه عن بعد، هذا يحد من التدخل اليدوي المستمر كما ويسمح الخادم السحابي أيضاً بمعالجة البيانات وتطبيق إجراءات التحكم داخل البيت البلاستيكي الذكي. توصل الباحثون إلى أن هذا التصميم ساعد في توفير الحلول المثلى والفعالة من حيث التكلفة لمزارعي الفلفل الأحمر في مكان إجراء البحث الهند.

تحدث الباحثون في الدراسة [17] عن نماذج الشبكات العصبونية الصناعية (ANNS) والأفق المستقبلي لتطوير هذه النماذج لتتماشى مع التقنيات الحديثة من انترنت الأشياء والذكاء الصناعي، كما ركز البحث على الشبكات ذات التغذية الأمامية *backpropagation feedforward* واستخدام نماذج مختلفة لتدريبها، بالإضافة لدراسة مزايا وعيوب الشبكات العصبونية عند تطبيقها في البيوت البلاستيكية، كما تحدث عن دورها في توقع المناخ الداخلي لها والطاقة المستهلكة ضمنها، ووصل لمجالات أبعد من ذلك منها التحكم بثنائي أكسيد الكربون، كما يمكن استخدام نتائج هذا البحث كدليل إرشادي لمستخدمي البيوت البلاستيكية الذكية.

عمل الباحثون في الدراسة [18] على بناء نموذج شبكة عصبونية صناعية متعددة الطبقات قادرة على تقدير درجة الحرارة والرطوبة النسبية في البيت البلاستيكي، مع الأخذ بالعلم قيم المدخلات من درجة الحرارة الخارجية والإشعاع الشمسي وسرعة الرياح ودرجة الحرارة الداخلية، والهدف الرئيسي من هذا النموذج هو توليد قيم بأقل

نسبة من الخطأ. ركز البحث على مدى دقة التنبؤ كون التنبؤ بقيم غير صحيحة يمكن أن يؤدي إلى عدم تشغيل المحركات بالوقت الصحيح أو عدم تشغيلها نهائياً مما قد يسبب ب تلف المزروعات بينما التنبؤ بقيم صحيحة له دور في تشغيل المحركات عند الحاجة لها فقط بالإضافة إلى الحد من استهلاك الطاقة. ناقشت الورقة البحثية أن أكبر أخطاء النموذج نتجت عن تغير مفاجيء في درجة الحرارة أو الرطوبة النسبية، كما ناقش الباحثون فكرة إضافة بيانات تصف الظروف القاسية التي تترافق مع ارتفاع كبير ومفاجئ في درجة الحرارة أو انخفاضها الشديد والتي تساعد على تدريب النموذج في هذه الحالات التي قد تتسبب بضرر كبير للمزروعات.

## 6- آلية التحكم في البيت البلاستيكي:

### 6-1- مخطط توضيحي للنظام المقترح:

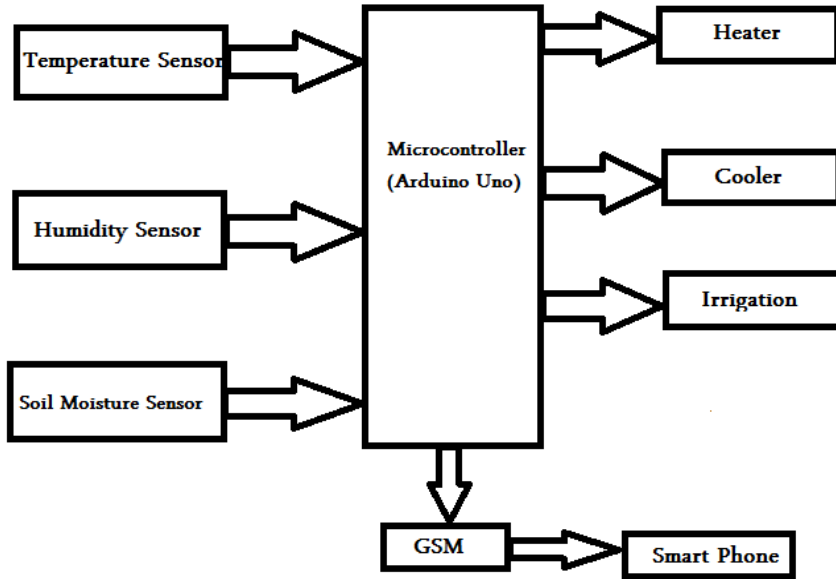
يوضح الشكل رقم (2) مخططاً للنظام المقترح الذي يمثل لوح الأردوينو العقل المتحكم به الذي يأخذ كدخل ثلاثة أنواع من القيم يتم الحصول عليها من الحساسات وهي:

- درجة الحرارة (من حساس الحرارة).
- درجة الرطوبة (من حساس الرطوبة).
- درجة رطوبة التربة (من حساس رطوبة التربة).

ويعطي كخرج أربعة أنواع من الخرج هي:

- زمن تشغيل التدفئة المطلوب (يستخدم كدخل لوحدة التحكم Heater).
- زمن تشغيل المراوح المطلوب (يستخدم كدخل لوحدة التحكم Cooler).
- زمن تشغيل مضخة المياه المطلوب (يستخدم كدخل لوحدة التحكم Irrigation).

- رسالة توجه إلى مشغل الرسائل وتصل إلى الهاتف الخاص بالمزارع تتضمن الأزمنة السابقة بالإضافة إلى وقت التشغيل والإيقاف لكل وحدة تحكم.



الشكل رقم (2) مخطط النظام المقترح

الحساسات المستخدمة في المخطط أعلاه هي حساس الحرارة والرطوبة الجوية (DHT22 Sensor) وحساس رطوبة التربة (Soil Moisture Sensor) بالإضافة إلى اللوحة الالكترونية القابلة للبرمجة والتي تمثل المتحكم الصغير Arduino Uno تتميزها مجموعة من الخصائص موضحة في -الجدول رقم (1) - وسوف يتم استخدام شريحة خاصة بعملية الاتصال لتأمين وصول رسالة بالتغيرات التي تحدث على الهاتف الذكي للمسؤول عن البيت البلاستيكي والشريحة هي .Sim800L

### الجدول رقم (1) - مواصفات Arduino Uno

Operating Voltage	5V
Input Voltage (recommended)	7-12V
Input Voltage (limits)	6-20V
Digital I/O Pins	14 (of which 6 provide PWM output)
Analog Input Pins	6
DC Current per I/O Pin	40 Ma
DC Current for 3.3V Pin	50mA
Flash Memory	32 KB of which 0.5KB
SRAM	2 KB
EEPROM	1 KB
Clock Speed	16 MHz
Length	68.6 mm
Weight	25g

يمثل الـ Arduino Uno هنا العقل المتحكم بالنظام حيث أنه يتلقى القيم من الحساسات باستمرار وعند تجاوز أي قيمة للعتبة المناسبة لها (صعوداً أو نزولاً) تتم عملية معالجة الموضوع لتعديل القيمة عن طريق إرسال إشارة إلى مجموعة المتحكمات لتعديل المناخ في البيت البلاستيكي لإعادة ضبط القيمة إلى المستوى المطلوب.

مجموعة المتحكمات هنا تتمثل بقيم تحكم معينة هي التسخين (عن طريق تشغيل التدفئة في البيت البلاستيكي كأجهزة التكييف)، التبريد (عن طريق تشغيل المراوح أو أجهزة التكييف)، الري (عن طريق تشغيل مضخات المياه أو المرشات).

كما أنه يتم بشكل دوري إرسال رسالة إلى المسؤول عن البيت البلاستيكي بجميع القيم التي يتم جمعها من الحساسات.

تتم برمجة لوحة التحكم الالكترونية Arduino Uno عن طريق تنزيل بيئة العمل الخاصة بها Arduino IDE - الشكل رقم(3)-.

```

Smart_Greenhouse | Arduino 1.8.13
File Edit Sketch Tools Help
Smart_Greenhouse.g
//Libraries
#include <DHT.h>
#include <SoftwareSerial.h>

//Constants
#define DHTPIN 7 // what pin we're connected to for DHT Sensor
#define soilPin A0 // what pin we're connected to for Soil Moisture Sensor
#define DHTTYPE DHT22 // DHT 22 (AM2302)
DHT dht(DHTPIN, DHTTYPE); // Initialize DHT sensor for normal 16MHz Arduino

float humidity; //Stores humidity value
float tempair; //Stores temperature value
int soilValue; //Stores soil moisture value

int threshold%bluehigh_moisture = 500;
int threshold%bluelow_moisture = 300;
int threshold%bluelow_temp = 25;
int threshold%bluehigh_temp = 32;

int greenLED = 6;
int redLED = 5;
String data;

SoftwareSerial mySerial(3, 2); //SIM800L Tx & Rx is connected to Arduino #3 & #2

void setup() {
// put your setup code here, to run once:

Sketch uses 9536 bytes (29%) of program storage space. Maximum is 32256 bytes.
Global variables use 496 bytes (33%) of dynamic memory, leaving 1352 bytes for local variables. Maximum is 2048 bytes.
Activate Windows
Go to PC settings to activate Windows.
Arduino Uno as COM6

```

### الشكل رقم (3) Arduino IDE

#### 6-2- بنية النظام المقترح:

#### 6-2-1- مواصفات البيت البلاستيكي المستخدم:

تم استخدام بيت بلاستيكي بالأبعاد التالية 125سم طولاً - 45 سم عرضاً - 35 سم ارتفاعاً مغطى بغلاف بلاستيكي في مدينة سلمية - الشكل رقم(4)-.

تم اختيار محصول البندورة ليكون المحصول الذي سوف تتم زراعته في البيت البلاستيكي.

درجة الحرارة المناسبة لنمو محصول البندورة تتراوح ما بين 25 - 32 درجة مئوية والرطوبة المناسبة ضمن مجال يتراوح بين 50% إلى 75%، ورطوبة التربة ضمن مجال يتراوح بين 60% - 80%.



الشكل رقم (4) نموذج البيت البلاستيكي المستخدم

#### 6-2-2- جمع البيانات من الحساسات:

تم جمع البيانات على مدى خمسة أشهر من تاريخ 2022/7/1 وحتى تاريخ 2022/11/30 وذلك خلال كل ساعة من ساعات النهار والليل.

تم الحصول على بيانات خاصة بدرجة الحرارة والرطوبة ورطوبة التربة باستخدام مجموعة من الحساسات المتصلة بلوحة الأردوينو المصممة بجانب البيت البلاستيكي.

تم حساب المتوسط الحسابي للقيم المقاسة من الحساسات للحصول على قيمة كلية للبيانات.

بسبب اختلاف درجة الحرارة بين الليل والنهار يتم تقسيم اليوم إلى قسمين:

- بيانات تقاس من الساعة 6 صباحاً وحتى الساعة 5 مساءً وتسمى بيانات النهار.



- بيانات تقاس من الساعة 5 مساءً إلى الساعة 6 صباحاً وتسمى بيانات الليل.

تم حساب متوسط بيانات النهار وبيانات الليل للحصول على قيمة كلية شهرية للبيانات وتخزينها في ملف Excel باستخدام برنامج tera term.

#### 7- استخدام خوارزميات المنطق الضبابي Fuzzy Logic:

المنطق الضبابي بالمعنى الواسع هو منظومة منطقية تقوم على تعميم للمنطق التقليدي ثنائي القيم، وذلك للاستدلال في ظروف غير مؤكدة، وبالمعنى الضيق فهو نظريات وتقنيات تستخدم المجموعات الضبابية التي هي مجموعات بلا حدود قاطعة.

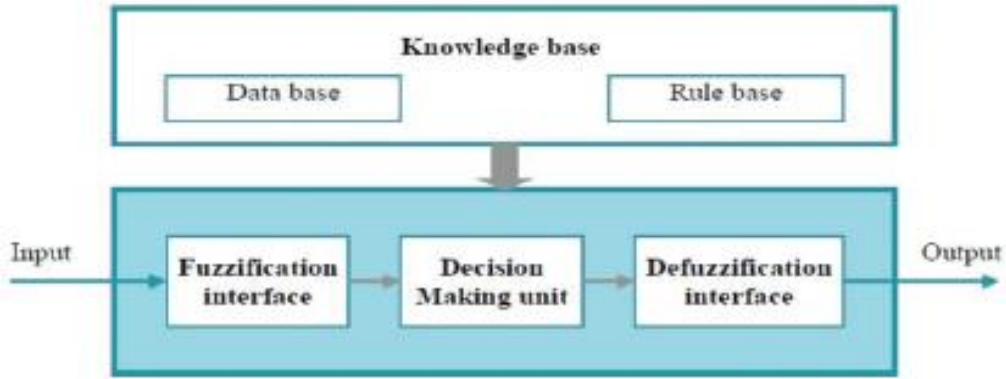
يمثل هذا المنطق طريقة سهلة لتوصيف وتمثيل الخبرة البشرية، كما أنه يقدم الحلول العملية للمشاكل الواقعية، وهي حلول بتكلفة فعالة ومعقولة، بالمقارنة مع الحلول الأخرى التي تقدمها التقنيات الأخرى.

إن وحدة المنطق الضبابي المستخدمة سوف يتم تقسيمها وفق المخطط أدناه إلى:

1. Fuzzification Interface :

2. Decision Making Interface :

3. Defuzzification Interface :



الشكل رقم (5) [3] بنية المنطق الضبابي

### 7-1- بنية نظام المنطق الضبابي المقترح:

يتكون نظام التحكم المنطقي الضبابي المستخدم في النظام المقترح من ثلاثة مدخلات وثلاثة مخرجات.

بيانات المدخلات هي درجة الحرارة (C) والرطوبة النسبية (%) ورطوبة التربة (%). بينما بيانات المخرجات هي زمن تشغيل أجهزة التبريد وزمن تشغيل أجهزة التدفئة وزمن تشغيل مضخة المياه.

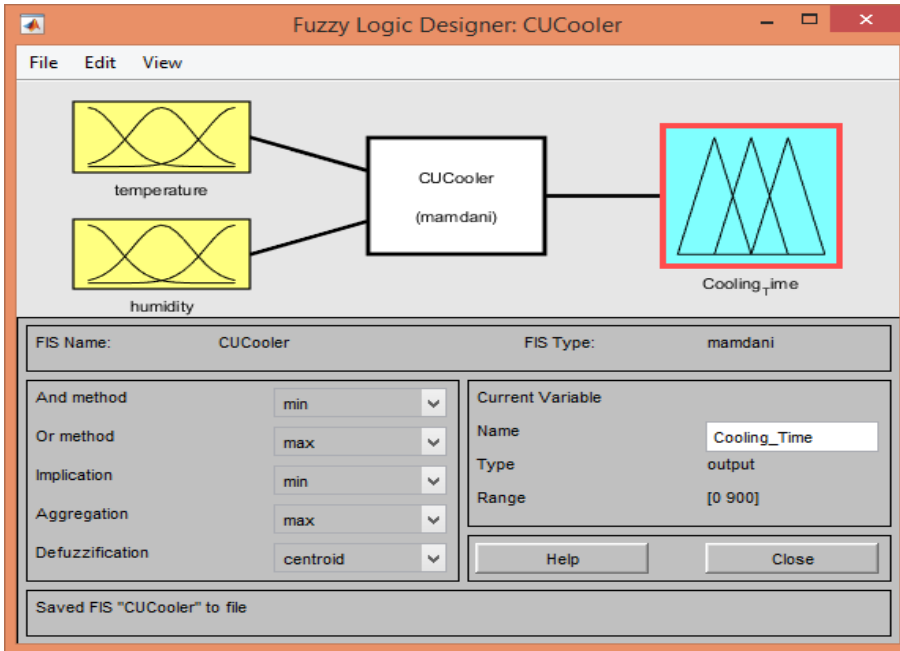
تم توضيح بيانات المدخلات والمخرجات ومجالاتها والقيم اللغوية المرافقة لها وفق الجدول التالي:

الجدول رقم (2)

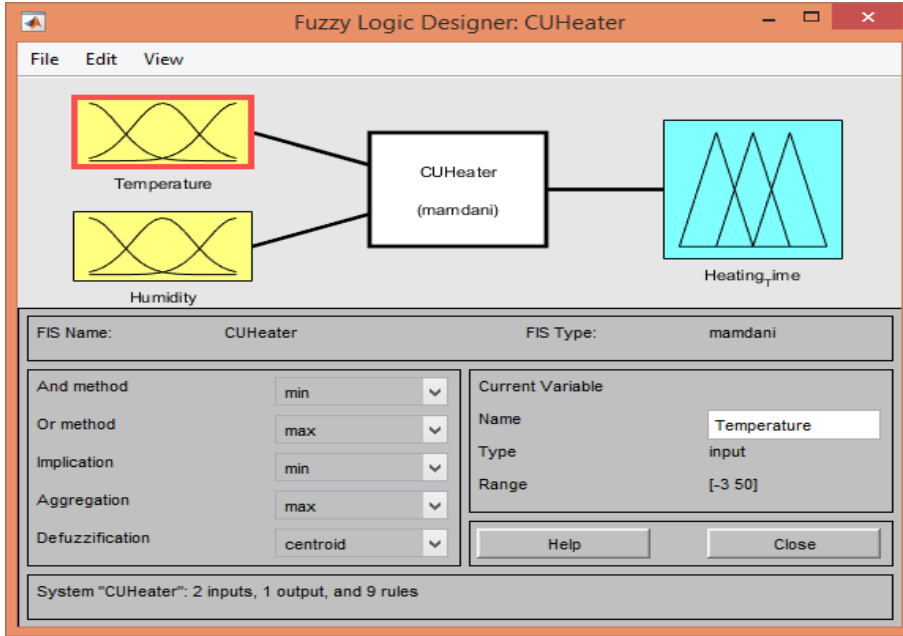
القيم اللغوية	مجال القيم	المتحولات	
Low – Medium – High	50 – 3-	درجة الحرارة	متحولات الحالة
Low – Medium – High	%100 – %20	الرطوبة النسبية	
Low – Medium – High	%100 – %0	رطوبة التربة	
Short – Medium – Long	900 – 0 ثانية	زمن التبريد	متحولات التحكم
Short – Medium – Long	1200 – 0 ثانية	زمن التدفئة	
Short – Medium – Long	900 – 0 ثانية	زمن الري	

يتألف النظام المقترح من ثلاثة وحدات تحكم:

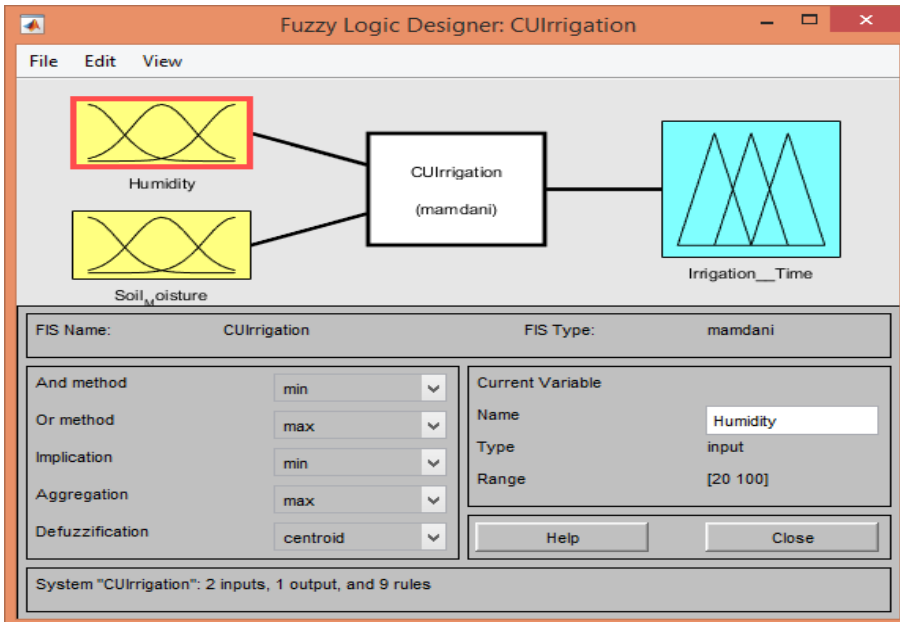
- 1- وحدة التحكم الأولى CUCooler: تأخذ كمدخل درجة الحرارة والرطوبة النسبية لتعطي كخرج زمن التبريد المطلوب- الشكل رقم(6)-.
- 2- وحدة التحكم الثانية CUHeater: تأخذ كمدخل درجة الحرارة والرطوبة النسبية لتعطي كخرج زمن التدفئة المطلوب- الشكل رقم(7)-.
- 3- وحدة التحكم الثالثة CUIrrigation: تأخذ كمدخل الرطوبة النسبية ورطوبة التربة لتعطي كخرج زمن الري المطلوب- الشكل رقم(8)-.



الشكل رقم (6) وحدة التحكم الأولى CUCooler



الشكل رقم (7) وحدة التحكم الثانية CUHeater



الشكل رقم (8) وحدة التحكم الثالثة CUirrigation

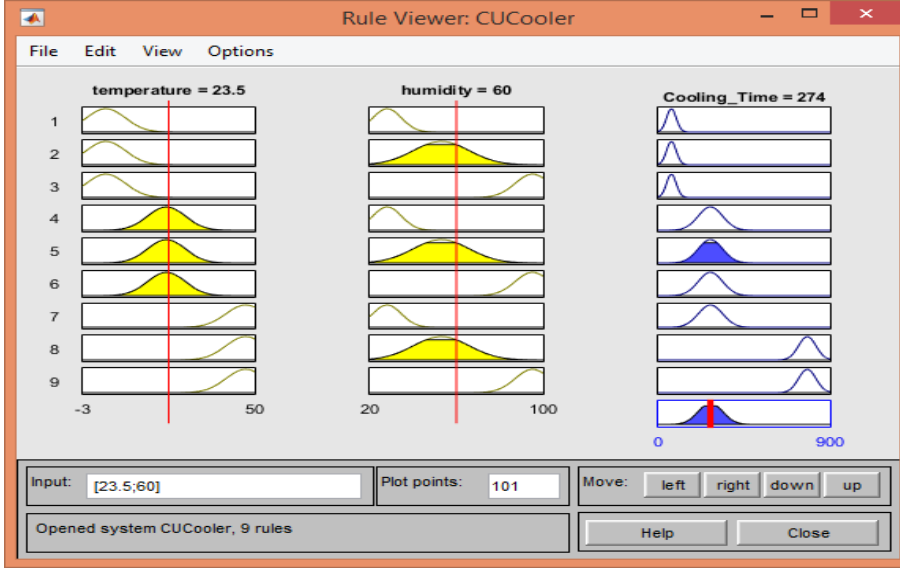
تم إنشاء القواعد الخاصة بنظام المنطق الضبابي المقترح عن طريق استخدام مجموعة من القواعد الشرطية (هنالك تسع قواعد لكل وحدة تحكم)، فيما يلي مجموعة الجداول التي توضح القواعد الخاصة بكل وحدة تحكم والتي تم الاعتماد عليها في إنشاء القواعد الشرطية:

يوضح الجدول رقم (3) القواعد الخاصة بوحدة التحكم الأولى CUCooler حيث أنه إذا كانت قيمة درجة الحرارة (T) هي Low وقيمة الرطوبة (H) هي Low إذاً زمن التبريد سيأخذ القيمة Short وهكذا الأمر بالنسبة لباقي القواعد.

الجدول رقم (3)

High	Medium	Low	T H
Short	Short	Short	Low
Medium	Medium	Medium	Medium
Long	Long	Medium	High

تم تطبيق القواعد وعرضها في نافذة Rules Viewer كما يلي:



الشكل رقم (9) الـ Rules Viewer الخاص بوحدة التحكم الأولى CUCooler

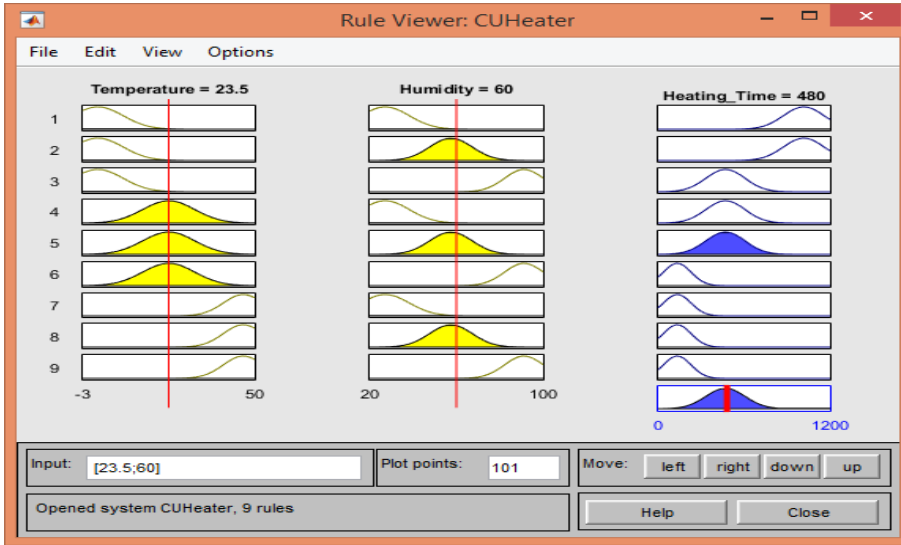
من خلال الشكل رقم (9) نلاحظ بأنه إذا كانت درجة الحرارة تساوي 23,5 والرطوبة 60% عند إذن زمن التبريد المطلوب سيكون 274 ثانية.

الجدول رقم (4) يوضح القواعد الخاصة بوحدة التحكم الثانية CUHeater:

الجدول رقم (4)

High	Medium	Low	T
Medium	Long	Long	Low
Short	Medium	Medium	Medium
Short	Short	Short	High

تم تطبيق القواعد وعرضها في نافذة Rules Viewer كما يلي:



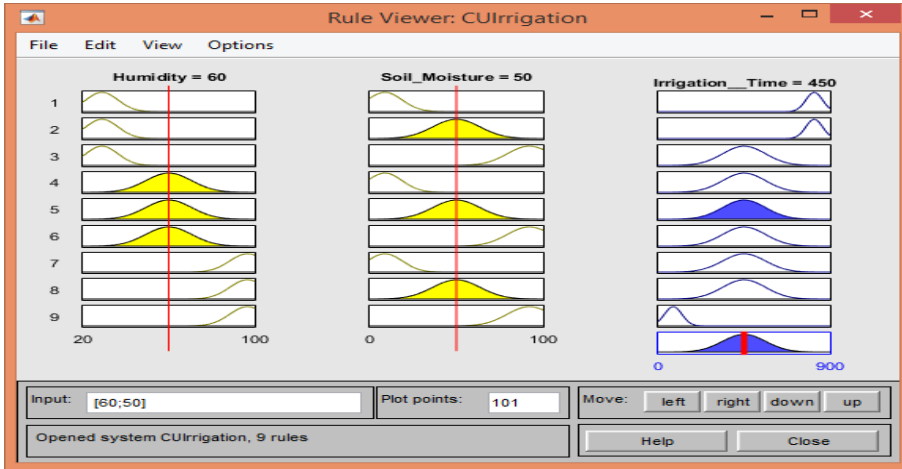
الشكل رقم (10) الـ Rules Viewer الخاص بوحدة التحكم الثانية CUHeater

الجدول رقم (5) يوضح القواعد الخاصة بوحدة التحكم الثالثة CUirrigation:

الجدول رقم (5)

High	Medium	Low	H / SM
Medium	Long	Long	Low
Medium	Medium	Medium	Medium
Short	Medium	Medium	High

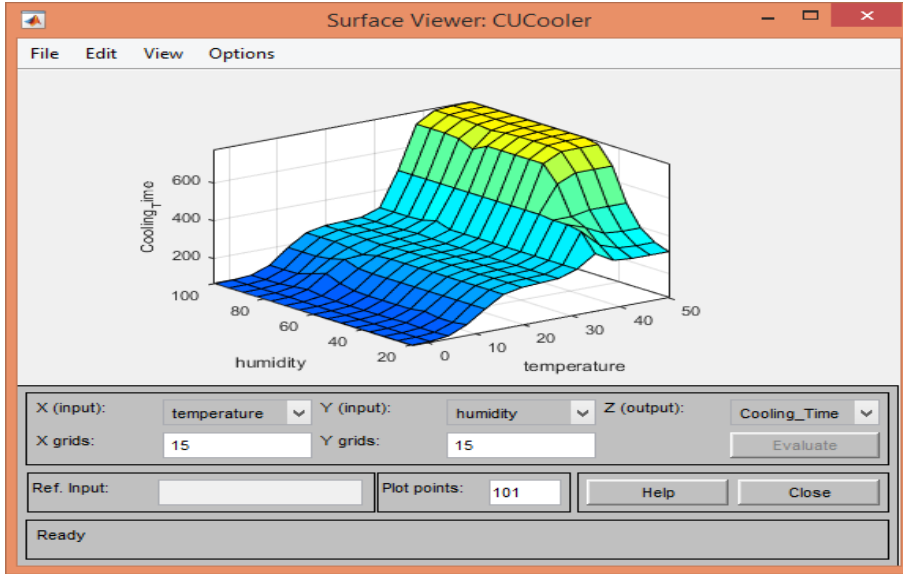
تم تطبيق القواعد وعرضها في نافذة Rules Viewer كما يلي:



الشكل رقم (11) الـ Rules Viewer الخاص بوحدة التحكم الثالثة CUirrigation

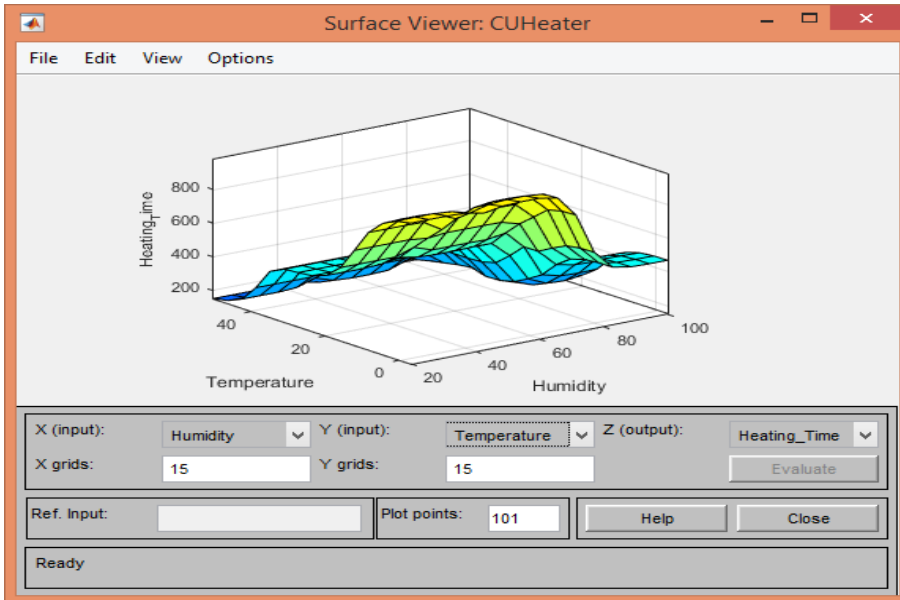
يمكن عرض النتائج الخاصة بالـ Rules Viewer على شكل رسم ثلاثي الأبعاد يوضح البيانات التي تم الحصول عليها من عملية الـ Defuzzification كما هو موضح في الشكل رقم (12) الذي يمثل الـ Surface Viewer الخاص بوحدة التحكم الأولى.





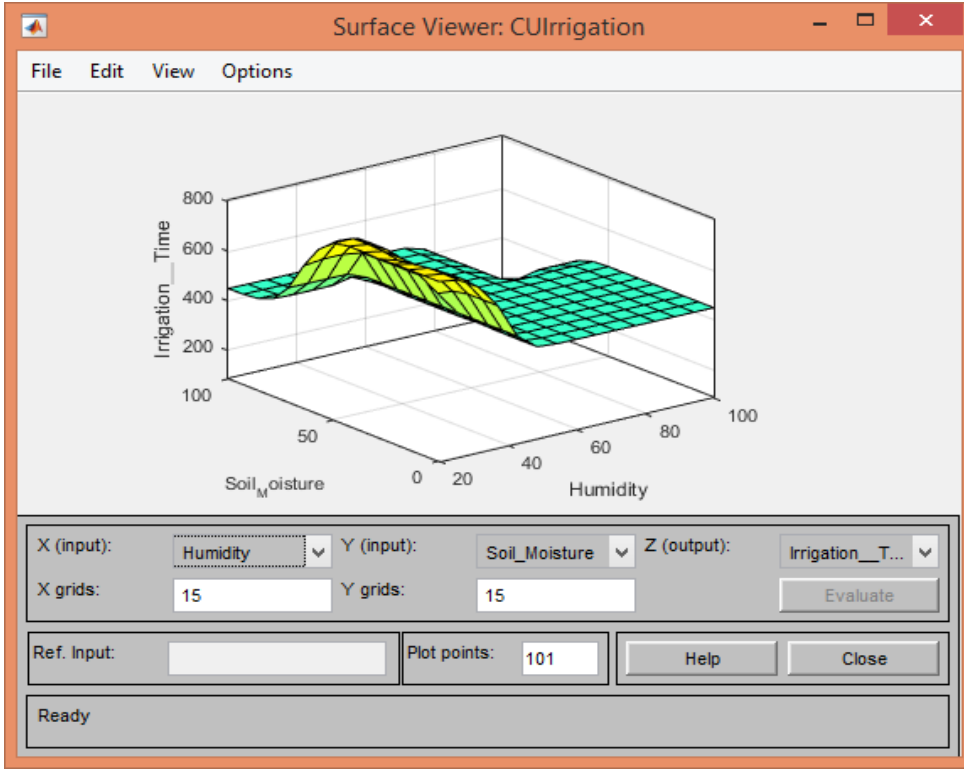
الشكل رقم (12) الـ Surface Viewer الخاص بوحدة التحكم الأولى CUCooler

يوضح الشكل رقم (13) الـ Surface Viewer الخاص بوحدة التحكم الثانية:



الشكل رقم (13) الـ Surface Viewer الخاص بوحدة التحكم الثانية CUHeater

يوضح الشكل رقم (14) يوضح الـ Surface Viewer الخاص بوحدة التحكم الثالثة:



الشكل رقم (14) الـ Surface Viewer الخاص بوحدة التحكم الثالثة  
CUirrigation

## 7-2- نتائج تطبيق خوارزمية المنطق الضبابي:

يوضح الجدول رقم (6) قيم المدخلات والمخرجات وفق وحدات التحكم أعلاه كالتالي:

**الجدول رقم (6)**

المخرجات			المدخلات	
CUIrrigation	CUHeater	CUCooler	درجة الحرارة - الرطوبة النسبية - رطوبة التربة	الأشهر
451	480	274	درجة الحرارة= 23,68 - الرطوبة= 53,04 - رطوبة التربة= 65	تموز ليلاً
556	461	323	درجة الحرارة= 31,59 - الرطوبة= 41,08 - رطوبة التربة= 36,77	تموز نهاراً
460	477	275	درجة الحرارة= 24,84 - الرطوبة= 47,67 - رطوبة التربة= 53,94	آب ليلاً
620	455	363	درجة الحرارة= 32,73 - الرطوبة= 38,64 - رطوبة التربة= 36,06	آب نهاراً
450	481	273	درجة الحرارة= 22,9 - الرطوبة= 68,69 - رطوبة التربة= 60,7	أيلول ليلاً
451	464	318	درجة الحرارة= 31,39 - الرطوبة= 52,06 - رطوبة التربة= 32,67	أيلول نهاراً
381	343	259	درجة الحرارة= 19,39 - الرطوبة= 79,98 - رطوبة التربة= 90,1	تشرين أول ليلاً
450	470	280	درجة الحرارة= 28,77 - الرطوبة= 58,31 - رطوبة التربة= 75,96	تشرين أول نهاراً
429	508	213	درجة الحرارة= 11,53 - الرطوبة= 76,91 - رطوبة التربة= 96,57	تشرين ثاني ليلاً
450	492	272	درجة الحرارة= 21,44 - الرطوبة= 60,05 - رطوبة التربة= 93,27	تشرين ثاني نهاراً

نلاحظ أنه تم حساب متوسط درجات الحرارة والرطوبة النسبية ورطوبة التربة للأشهر الثلاثة خلال ساعات الليل والنهار واستخدام قيم المتوسطات كدخل لوحدات التحكم لتعطينا كخرج الزمن المطلوب للتحكم في كل وحدة حيث أعطتنا الوحدة الأولى زمن التبريد المطلوب بالثانية (زمن تشغيل المراوح أو أجهزة التكييف) كما كان زمن تشغيل أجهزة التدفئة بالثانية هو الخرج الذي حصلنا عليه من وحدة التحكم الثانية كما أعطتنا وحدة التحكم الثالثة زمن الري المطلوب بالثانية (زمن تشغيل مضخة المياه أو أجهزة الري المناسبة).

## 8- استخدام الشبكات العصبونية Neural Networks:

تعتبر الشبكات العصبونية الصناعية (Artificial Neural Networks) واحدة من أهم التقنيات المستخدمة في مجال الذكاء الصناعي (Artificial Intelligence) والتي سُميت بهذا الإسم لأنها تُحاكي الشبكات العصبونية الموجودة بالعقل البشري.

نقسم الشبكات العصبونية بشكل رئيسي إلى قسمين:

- الشبكات العصبونية ذات التغذية الأمامية Feedforward neural networks (FFNNs):

تعد من أبسط أنواع الشبكات حيث تتحرك فيها البيانات باتجاه واحد من طبقة الدخل إلى طبقة الخرج، كما يمكن أن تحوي طبقات مخفية أو ألا تحوي أي طبقة مخفية.

- الشبكات العصبونية المتكررة أو الالتفافية (RNNs) Recurrent neural networks:

على عكس الشبكات ذات التغذية الأمامية تنتقل البيانات في الشبكات المتكررة ذهاباً وإياباً وفق حلقات تغذية راجعة موجهة، حيث تكون مبنية على أساس قدرة الخلايا العصبونية على أن تستخدم كدخل البيانات المعالجة في نفس الطبقة أو في الطبقات السابقة.

## 8-1- هيكلية الشبكات العصبونية:

سوف نعتمد في بحثنا هذا على الشبكات العصبونية ذات التغذية الأمامية حيث تتكون

الشبكة العصبونية من مجموعة من الطبقات والتي تنقسم إلى ثلاث أنواع:

1- طبقات المدخلات (input layers) والتي تعمل كحلقة الوصل بين

الشبكات والعالم الخارجي وذلك بإستقبالها للمدخلات من المستخدم.


2- الطبقات الخفية (hidden layers) والتي تلعب دوراً أساسياً في تصميم

حلول لأعقد المشاكل.

3- طبقات المخرجات (output layers) وهي تمثل الناتج الذي تم الحصول

عليه بناءً على المدخلات المستقبلية من خلال طبقة المدخلات.

- في كل طبقة يوجد عدد من الخلايا العصبونية (neurons).



الشكل رقم (15) بنية الشبكة العصبونية ذات التغذية الأمامية [17]

## 8-2- بنية الشبكات العصبونية للنظام المقترح:

تم العمل على برنامج Matlab R2015a لتطبيق الشبكات العصبونية باستخدام القيم التي تم الحصول عليها من الحساسات.

لبناء الشبكات تم حساب متوسط درجات الحرارة والرطوبة ورطوبة التربة لليوم كاملاً لاستخدامها لاحقاً كمدخل للشبكات.

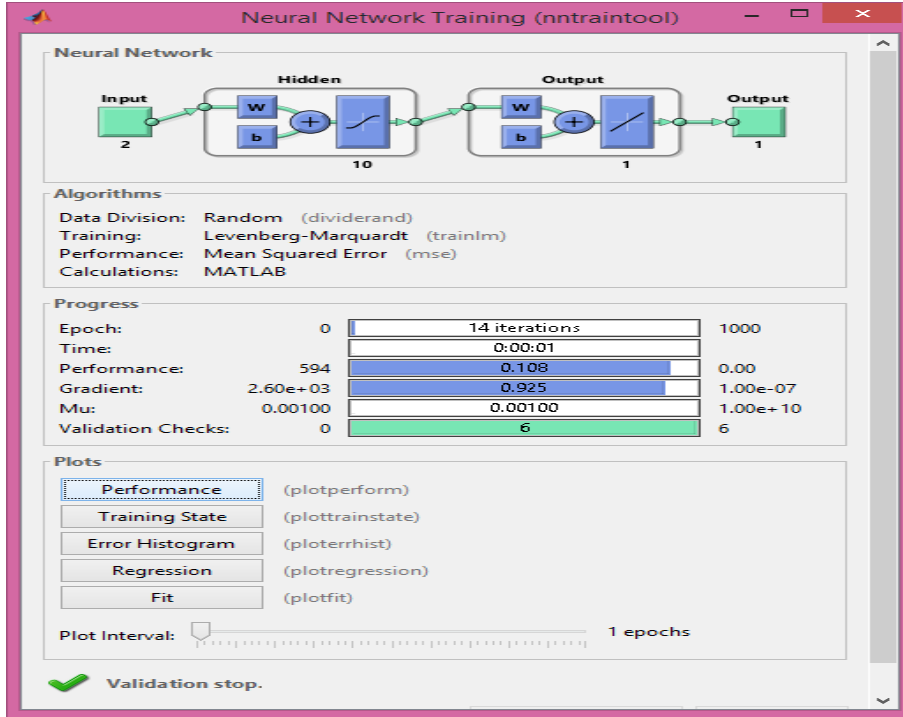
تم اختيار نسبة 70% من هذه البيانات لتكون بيانات تدريب للشبكة ونسبة 30% الباقية (15% للتحقق + 15% للاختبار).

### • الشبكة الأولى CNetwork:

عند إجراء أول تدريب للشبكة تتغير القيم الخاصة بتابع الخطأ والممثلة بالقيم:

- MSE (Mean Squared Error) الذي يمثل متوسط مربع الفروقات ما بين خرج الشبكة المتوقع والخرج الحقيقي حيث كلما كانت قيمته قريبة من من الصفر كانت نسبة الخطأ في تدريب الشبكة قليلة والعكس صحيح.
- معامل الارتباط Correlation Coefficient (R) الذي يقيس مدى الارتباط ما بين الخرج المتوقع والخرج الحقيقي حيث أن القيم القريبة من الواحد تعني ترابط وثيق بينما القيم القريبة من الصفر تعني عدم وجود ترابط.


تظهر نافذة التدريب مخطط الشبكة وعدد التكرارات بالإضافة إلى مجموعة من المخططات التي تعبر عن أداء الشبكة كما هو موضح في الشكل رقم (16):



الشكل رقم (16) نافذة التدريب الخاصة بالشبكة

نستعرض من الشكل (16) المخططات الخاصة بعملية التدريب وأول المخططات هو مخطط أداء التدريب الذي يمثل المخطط البياني لتطور حالة التدريب ما بين عدد التكرارات (Epochs) وبين المتوسط التربيعي للخطأ حيث يظهر في المخطط تطور قيم بيانات التدريب (الخط الأزرق) والتحقق (الخط الأخضر) والاختبار (الخط الأحمر) كما يوضح المخطط أقل قيمة للخطأ والتي تمثل أفضل قيمة لتدريب الشبكة وعند أي تكرار تحققت حيث نلاحظ أنه بعد هذه القيمة يتكرر التدريب لـ 6 مرات لمراقبة عملية التدريب فنلاحظ بعدها عدم وجود تحسن لأداء التدريب فيتوقف التدريب.


مخطط الأداء لأول تدريب للشبكة حيث أن أفضل نقطة للتدريب كانت بقيمة 0.20718 عند التكرار الثامن من إجمالي عدد التكرارات وهو 14 وهو موضع بالشكل رقم (17):



الشكل رقم (17) مخطط الأداء لأول تدريب للشبكة CNetwork


بتدريب الشبكة للمرة الثانية نلاحظ أن مخطط الأداء للشبكة عند ثاني تدريب تحققت فيه أفضل قيمة أداء وهي 0.24623 عند التكرار 7 من العدد الكلي للتكرارات وهو 13 كما هو موضح في الشكل رقم (18):





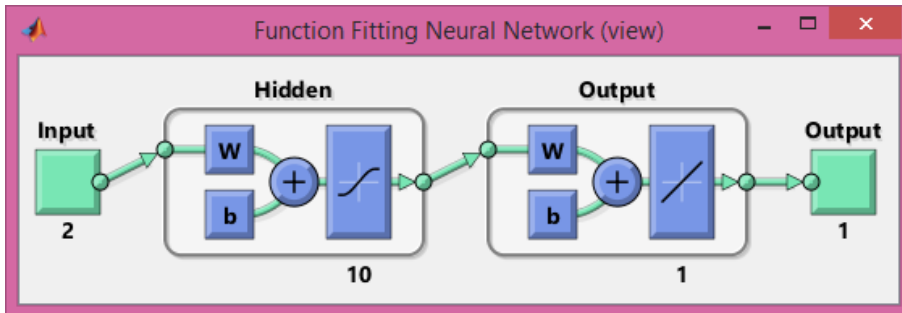
### الشكل رقم (18) مخطط الأداء لثاني تدريب للشبكة CNetwork

بتدريب الشبكة للمرة الثالثة نرفق مخطط أداء الشبكة عند ثالث تدريب للشبكة حيث تحققت أفضل نقطة أداء فيه عند القيمة 0.23139 عند التكرار 12 من أصل العدد الكلي للتكرارات وهو 18 كما هو موضح في الشكل رقم (19):



الشكل رقم (19) مخطط الأداء لثالث تدريب للشبكة CNetwork

يكون الرسم البياني الخاص بالشبكة والذي يوضح عدد طبقة المدخلات والطبقة المخفية وطبقة المخرجات إضافة إلى عدد العصبونات المستخدمة والذي هو 10 عصبونات في هذه الشبكة كما هو موضح في الشكل رقم (20):



الشكل رقم (20) المخطط البياني للشبكة CNetwork


ينتج لدينا بعد تدريب الشبكة لثلاثة مرات القيم الخاصة بالـ MSE والـ R والموضحة في الجدول رقم (7) مع عدد التكرارات في كل عملية تدريب حيث نلاحظ تحسن أداء الشبكة بعد ثالث تدريب كما هو موضح أدناه:

### الجدول رقم (7)

Num Of Iterations	R			MSE			CNetwork
	Testing	Validation	Training	Testing	Validation	Training	
14	9.98559e-1	9.96514e-1	9.98591e-1	2.15919e-1	2.07182e-1	1.48866e-1	أول تدريب
13	9.99147e-1	9.95284e-1	9.98489e-1	6.06815e-1	2.46226e-1	1.07179e-1	ثاني تدريب
18	9.98924e-1	9.95432e-1	9.99015e-1	1.0.1273e-1	2.31386e-1	1.14333e-1	ثالث تدريب

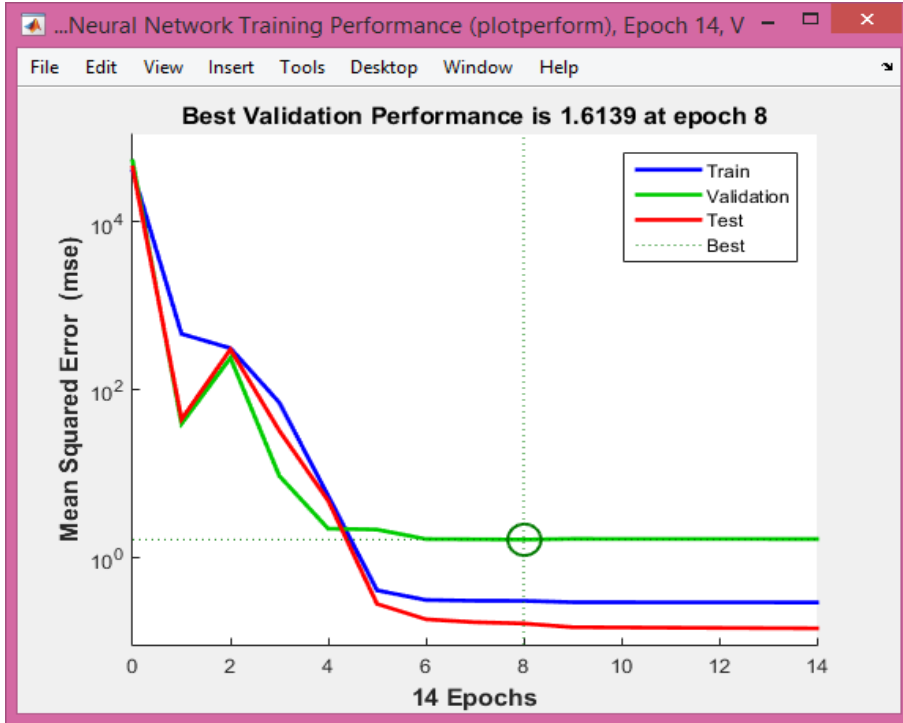
### • الشبكة الثانية HNetwork:

يوضح الشكل رقم (20) مخطط أداء الشبكة الناتج عن تدريب الشبكة لأول مرة والذي تحققت فيه أفضل قيمة أداء 0.1797 عند التكرار 75 من أصل عدد التكرارات الكلي 81 حيث كما ذكرنا سابقاً بأنه بعد الوصول لأفضل نقطة يتكرر التدريب لـ 6 مرات ونلاحظ عدم تحسن في أداء الشبكة بعد هذه القيمة فتتوقف عملية التدريب.




الشكل رقم (21) مخطط الأداء لأول تدريب للشبكة HNetwork

بتدريب الشبكة للمرة الثانية نلاحظ أن مخطط أداء الشبكة للتدريب الثاني يعطي أفضل قيمة هي 1.6139 عند التكرار 8 من أصل عدد التكرارات الكلي 14 كما هو موضح في الشكل رقم (22):



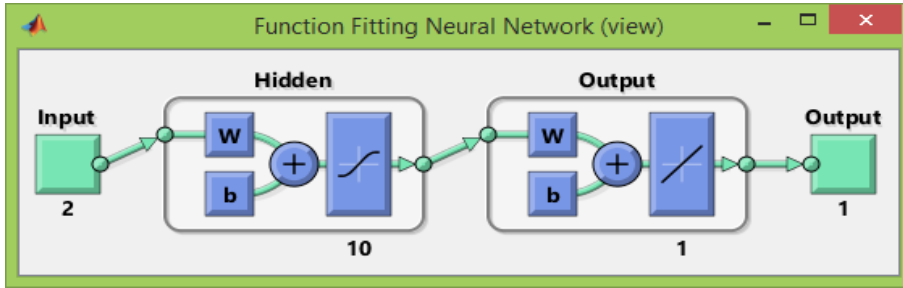
### الشكل رقم (22) مخطط الأداء لثاني تدريب للشبكة HNetwork

بتدريب الشبكة للمرة الثالثة نرفق أدناه مخطط الأداء للشبكة عند ثالث تدريب حيث تحققت أفضل قيمة 0.13991 للشبكة عند التكرار 24 من أصل عدد التكرارات الكلي 30 كما هو موضح في الشكل رقم (23):



### الشكل رقم (23) مخطط الأداء لثالث تدريب للشبكة HNetwork

يكون الرسم البياني الخاص بالشبكة والذي يوضح عدد طبقة المدخلات والطبقة المخفية وطبقة المخرجات إضافة إلى عدد العصبونات المستخدمة والذي هو 10 عصبونات في هذه الشبكة كما هو موضح في الشكل رقم (24):



الشكل رقم (24) المخطط البياني للشبكة الثانية HNetwork


ينتج لدينا بعد تدريب الشبكة لثلاثة مرات القيم الخاصة بالـ MSE والـ R والموضحة في الجدول رقم (8) مع عدد التكرارات في كل عملية تدريب حيث نلاحظ تحسن أداء الشبكة بعد ثالث تدريب كما هو موضح أدناه:

الجدول رقم (8)

Num Of Iterations	R			MSE			HNetwork
	Testing	Validation	Training	Testing	Validation	Training	
81	9.9112e-1	9.88351e-1	9.99782e-1	1.16283e-1	1.79695e-1	4.46314e-1	أول تدريب
14	9.95765e-1	8.85499e-1	9.99857e-1	1.60975e-1	1.61385e-1	2.99970e-1	ثاني تدريب
30	8.75209e-1	9.95078e-1	9.99880e-1	1.69992e-1	1.39908e-1	2.49810e-1	ثالث تدريب

• الشبكة الثالثة IRNetwork:


يوضح الشكل رقم (25) مخطط أداء الشبكة الناتج عن تدريب الشبكة لأول مرة حيث تحققت فيه أفضل قيمة 0.72476 عن التكرار 7 من أصل عدد التكرارات الكلي 13:



### الشكل رقم (25) مخطط الأداء لأول تدريب للشبكة IRNetwork


بتدريب الشبكة للمرة الثانية نلاحظ أن مخطط أداء الشبكة للتدريب الثاني كانت أفضل قيمة له 0.24025 عند التكرار 59 من أصل عدد التكرارات الكلي 65 كما هو موضح في الشكل رقم (26):





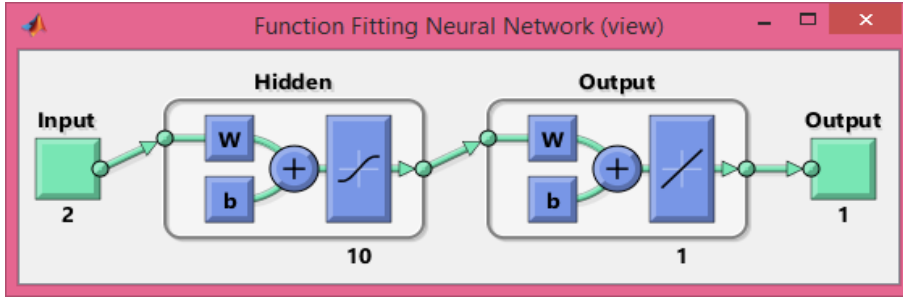
### الشكل رقم (26) مخطط الأداء لثاني تدريب للشبكة IRNetwork

بتدريب الشبكة للمرة الثالثة يكون مخطط الأداء للشبكة عند ثالث تدريب للشبكة قد حقق أفضل قيمة 0.28033 عن التكرار 84 من أصل عدد التكرارات الكلي 90 كما هو موضح في الشكل رقم (27):



الشكل رقم (27) مخطط الأداء لثالث تدريب للشبكة IRNetwork

يكون الرسم البياني الخاص بالشبكة والذي يوضح عدد طبقة المدخلات والطبقة المخفية وطبقة المخرجات إضافة إلى عدد العصبونات المستخدمة والتي هي 10 عصبونات في هذه الشبكة كما هو موضح في الشكل رقم (28):



الشكل رقم (28) المخطط البياني للشبكة IRNetwork

ينتج لدينا بعد تدريب الشبكة لثلاثة مرات القيم الخاصة بالـ MSE والـ R والموضحة في الجدول رقم (9) مع عدد التكرارات في كل عملية تدريب حيث نلاحظ تحسن أداء الشبكة بعد ثالث تدريب كما هو موضح أدناه:

الجدول رقم (9)

Num Of Iterations	R			MSE			IRNetwork
	Testing	Validation	Training	Testing	Validation	Training	
13	9.99922e-1	9.99621e-1	9.99748e-1	1.23437e-0	7.24758e-1	1.29774e-0	أول تدريب
65	9.99118e-1	9.99891e-1	9.99980e-1	6.34084e-0	2.40254e-1	1.17044e-1	ثاني تدريب
90	9.99942e-1	9.99798e-1	9.99790e-1	1.50937e-0	2.80328e-1	1.08744e-0	ثالث تدريب

### 8-3- نتائج تطبيق الشبكات العصبونية على النظام المقترح:

يوضح الجدول رقم (10) قيم المدخلات والمخرجات بعد تطبيق الشبكات العصبونية:

الجدول رقم (10)

المخرجات			المدخلات	
IRNetwork	HNetwork	CNetwork	درجة الحرارة - الرطوبة النسبية - رطوبة التربة	الأشهر
449	479	275	درجة الحرارة = 23,68 - الرطوبة = 53,04 - رطوبة التربة = 65	تموز ليلاً
558	466	317	درجة الحرارة = 31,59 - الرطوبة = 41,08 - رطوبة التربة = 36,77	تموز نهاراً
463	478	275	درجة الحرارة = 24,84 - الرطوبة = 47,67 - رطوبة التربة = 53,94	آب ليلاً
624	465	335	درجة الحرارة = 32,73 - الرطوبة = 38,64 - رطوبة التربة = 36,06	آب نهاراً
449	482	274	درجة الحرارة = 22,9 - الرطوبة = 68,69 - رطوبة التربة = 60,7	أيلول ليلاً
452	466	314	درجة الحرارة = 31,39 - الرطوبة = 52,06 - رطوبة التربة = 32,67	أيلول نهاراً
307	307	272	درجة الحرارة = 19,39 - الرطوبة = 79,98 - رطوبة التربة = 90,1	تشرين أول ليلاً
448	472	284	درجة الحرارة = 28,77 - الرطوبة = 58,31 - رطوبة التربة = 75,96	تشرين أول نهاراً
335	472	274	درجة الحرارة = 11,53 - الرطوبة = 76,91 - رطوبة التربة = 96,57	تشرين ثاني ليلاً
445	485	275	درجة الحرارة = 21,44 - الرطوبة = 60,05 - رطوبة التربة = 93,27	تشرين ثاني نهاراً

نلاحظ أنه تم حساب متوسط درجات الحرارة والرطوبة ورطوبة التربة ليلاً ونهاراً للأشهر الخمسة واستخدام هذه القيم كدخل للشبكات الثلاثة، حيث تعطينا الشبكة الأولى CNetwork الزمن المطلوب لتشغيل المراوح بالثانية، بينما تعطينا الشبكة

الثانية HNetwork الزمن المطلوب لتشغيل أجهزة التدفئة الثانية كما تعطينا الشبكة الثالثة IRNetwork الزمن المطلوب لتشغيل مضخات المياه الثانية.

لحساب دقة الشبكة نستخدم التابع diff الذي يأخذ كوسيط الخرج المتوقع والخرج الحقيقي ويعطينا كنتاج مصفوفة الفرق بينهما.

نأخذ القيم المطلقة لمصفوفة الفرق الناتج ثم نحسب المتوسط الحسابي لهذه القيمة ونأخذ نسبته المئوية ثم نطرحه من واحد وبالتالي نكون حصلنا على دقة الشبكة، يظهر الجدول أدناه الدقة الخاص بكل من الشبكات الثلاثة:

### الجدول رقم (11)

IRNetwork	HNetwork	CNetwork	
0.99065448	0.996159143	0.99650911	الدقة

### 9- مقارنة النتائج:

نلاحظ من خلال النتائج التي تم جمعها في الجدولين - الجدول رقم (6) والجدول رقم (10)- أن زمن التحكم الناتج عن تطبيق الشبكات العصبونية كان في كثير من الأحيان أقل من الزمن الناتج عن تطبيق خوارزميات المنطق الضبابي أو يساويه، وإن كان هذا الزمن مقاساً بالثواني لكن أجزاء من الثانية في زيادة الرطوبة أو التدفئة أو التبريد قد تؤثر سلباً على النبات المزروع مما ينصح باستخدام الشبكات العصبونية كون الزمن الذي تعطيه يحقق أسرع وصول للعوامل المناسبة ضمن البيت البلاستيكي مما يؤدي إلى الضبط التام للعناصر إضافة إلى توفير الموارد من كهرباء ومياه.

## 10- الخاتمة:

تم في هذه الدراسة محاكاة لنموذج بيت بلاستيكي ذكي باستخدام تقنية انترنت الأشياء وخوارزمية المنطق الضبابي التي ساعدتنا على ضبط قيمة الحرارة ما بين 25 - 32 درجة مئوية وقيمة الرطوبة النسبية ما بين 50% - 75% وقيمة رطوبة التربة ما بين 60% - 80%.

نظام المنطق الضبابي المستخدم عمل على مراعاة الشروط المناخية المطلوبة للمحصول المزروع ضمن البيت البلاستيكي وأثبتت فعاليته أمام الطرق التقليدية.

تم استخدام الشبكات العصبونية أيضاً التي ساعدت على ضبط العوامل الخاصة بالبيت البلاستيكي بزمن أقل في كثير من الأحيان من خوارزميات المنطق الضبابي.

يمكن توسيع هذه الدراسة في المستقبل لتشمل التحكم بعناصر أخرى وأشمل كما يمكن إضافة توصيف كامل للنبات المزروع بحيث تتغير العوامل وفقاً لهذا التوصيف ويستخدم كدخل إضافي ضمن الخوارزميات المستخدمة.

11- المراجع:

- [1] <http://moaar.gov.sy/>
- [2] Rafiuddin Syam, Wahyu H. Piarah and Budi Jaelani, "Controlling Smart Green House Using Fuzzy Logic Method", International Journal on Smart Material and Mechatronics IJSMM Vol. 2 No. 2 2015.
- [3] Özlem Alpay, Ebubekir Erdem , "The Control of Greenhouses Based on Fuzzy Logic Using Wireless Sensor Networks", International Journal of Computational Intelligence Systems Vol. 12(1); 2019, pp. 190–203.
- [4] Muhammad Shoaib Farooq, Shamyla Riaz, Adnan Abid, Tariq Umer Yousaf Bin Zikria, "Role of IoT Technology in Agriculture: A Systematic Literature Review", Electronics 2020, 9, 319; doi: 10.3390/electronics9020319.
- [5] Prof. Ami J. Shukla, Viraj Panchal and SahilPatelis, "Intelligent Greenhouse Design based on Internet of Things (IoT)", International Journal of Emerging Trends in Electrical and Electronics (IJETEE – ISSN: 2320–9569) Vol. 11, Issue. 2, June 2015.

- [6] Ravi Kishore Kodali, Vishal Jain, “IoT based smart greenhouse”, Conference Paper · December 2016.
- [7] M.Krishna Mohan, Jakkula Likhitha, Tejaswy Yamarthi and Kagitha Sravani, “Greenhouse Monitoring System Using IOT”, International Journal for Modern Trends in Science and Technology, Vol. 03, Special Issue 02, 2017, pp. 96–100.
- [8] Revathi S, Sivakumaran N, “Fuzzy Based Temperature Control of Greenhouse”, IFAC–PapersOnLine 49–1 (2016) 549–554.
- [9] Sujeet More, Jimmy Singla, “Machine Learning Techniques with IoT in Agriculture”, International Journal of Advanced Trends in Computer Science and Engineering, Volume 8, No.3, May – June 2019.
- [10] Mahmoud Abbasi, Mohammad Hossein Yaghmaee and Fereshteh Rahnama, “Internet of Things in agriculture: A survey”, Third International Conference on Internet of Things and Applications, University of Isfahan, Isfahan, Iran, Conference Paper · April 2019.
- [11] Francisco Javier Ferrández–Pastor, Sara Alcañiz–Lucas, Juan Manuel García–Chamizo and Manuel Platero–Horcajadas, “Smart



Environments Design on Industrial Automated Greenhouses”, Proceedings 2019, 31, 36; doi:10.3390/proceedings2019031036.

[12] Niaz Mostakim, Shuaib Mahmud and Khalid Hossain Jewel, “A SIMULATION BASED STUDY OF A GREENHOUSE SYSTEM WITH INTELLIGENT FUZZY LOGIC”, International Journal of Fuzzy Logic Systems (IJFLS) Vol.10, No.1, January 2020.

[13] Sheetal Vatari, Aarti Bakshi and Tanvi Thakur, “Green House by using IOT and Cloud computing”, IEEE International Conference On Recent Trends In Electronics Information Communication Technology, May 20–21, 2016, India.

[14] MUHAMMAD SHOAIB FAROOQ, SHAMYLA RIAZ, MAMOUN ABU HELOU, FALAK SHER KHAN, ADNAN ABID, (Senior Member, IEEE), AND ATIF ALVI, “Internet of Things in Greenhouse Agriculture:A Survey on Enabling Technologies, Applications, and Protocols”, IEEE Access, VOLUME 10, 2022.

[15] Junhu Ruan, Xiangpei Hu, Xuexi Huo<sup>1</sup>, Yan Shi, Felix T. S. Chan, Xuping Wang, Gunasekaran Manogaran, George Mastorakis, Constandinos X. Mavromoustakis, Xiaofeng Zhao, “An IoT-based E-business model of intelligent vegetable greenhouses and its key operations management issues”, Article in Neural

Computing and Applications · March 2019 DOI: 10.1007/s00521-019-04123-x.

[16] PALLAVI VERMA<sup>1</sup>, SAKSHAM BHUTANI, S.SRIVIDHYA, DR.J KARTHIKEYAN, DR.CHONG SENG TONG, “REVIEW OF INTERNET OF THINGS TOWARDS SUSTAINABLE DEVELOPMENT IN AGRICULTURE”, Journal of Critical Reviews, ISSN- 2394-5125, Vol 7, Issue 3, 2020.

[17] Axel Escamilla-García, Genaro M. Soto-Zarazúa, Manuel Toledano-Ayala, Edgar Rivas-Araiza and Abraham Gastélum-Barrios, “Applications of Artificial Neural Networks in Greenhouse Technology and Overview for Smart Agriculture Development” , Applied Sciences open access journal, Appl. Sci. 2020, 10, 3835; doi:10.3390/app10113835.

[18] Theodoros Petrakis, Angeliki Kavga , Vasileios Thomopoulos and Athanassios A. Argiriou, “Neural Network Model for Greenhouse Microclimate Predictions”, Agriculture 2022, 12, 780. <https://doi.org/10.3390/agriculture12060780>.