

مجلة جامعة حمص

سلسلة العلوم الهندسية الميكانيكية
والكهربائية والمعلوماتية



مجلة علمية محكمة دورية

المجلد 47 . العدد 7

1447 هـ - 2025 م

الأستاذ الدكتور طارق حسام الدين رئيس جامعة حمص

المدير المسؤول عن المجلة

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

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

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

الاتصال بالعنوان التالي:

رئيس تحرير مجلة جامعة حمص

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

. هاتف / فاكس : 2138071 31 963 ++

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

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

ISSN: 1022-467X

شروط النشر في مجلة جامعة حمص

الأوراق المطلوبة:

- 2 نسخة ورقية من البحث بدون اسم الباحث / الكلية / الجامعة) + word / CD
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 ورد 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 حمص

1. دفع رسم نشر (50000) ل.س أربعون ألف ليرة سورية عن كل بحث لكل باحث يريد نشره في مجلة جامعة البعث.
2. دفع رسم نشر (200000) ل.س مئة ألف 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 (15000) ل.س ستة آلاف ليرة سورية رسم موافقة على النشر من كافة الباحثين.

المحتوى

الصفحة	اسم الباحث	اسم البحث
34-11	م. محمد أحمد علي د. اليدا إسبر د. سهيل الحمود	مقارنة أداء الشبكات العصبية الترشيحية والنماذج الهجينة في تصنيف فقاعات الإجابة
62-35	م. محمد أحمد علي د. اليدا إسبر د. سهيل الحمود	استخراج فقاعات الإجابة من أوراق الإجابة متعددة الخيارات باستخدام نموذج SegFormer وتقنيات تحليل الصورة
98-63	م. محمد أحمد علي د. اليدا إسبر د. سهيل الحمود	اكتشاف وتحليل العناصر البنيوية في أوراق الإجابة متعددة الخيارات باستخدام YOLO v11 - دراسة مطبقة على بيانات واقعية
132-99	م. قمر سباعي أ.د. عمار زقزوق أ.د. إبراهيم الشامي	تقييم أداء خوارزميات الجدولة RR, SJF, MQL, FCFS
176-133	محمد أحمد محمد د. محمد عبده باكير	دراسة المؤشرات الترموديناميكية لدارة محول حراري مبتكر وتقييم أدائه

مقارنة أداء الشبكات العصبية الترشيحية والنماذج الهجينة في تصنيف

فقاعات الإجابة

المهندس محمد أحمد علي¹

الدكتور سهيل الحمود³

إشراف: الدكتورة اليدا إسبر²

الملخص

تهدف هذه الدراسة إلى مقارنة أداء نموذج يعتمد على الشبكات العصبية الترشيحية (CNN) مع نموذج هجين يجمع بين بنية الشبكات العصبية الترشيحية CNN والمحولات Transformer في مهمة تصنيف فقاعات الإجابة (مملوءة، فارغة، أو مشطوبة). قمنا بتطوير شبكة CNN تتألف من خمس طبقات ترشيحية كنموذج أساسي، ونموذج هجين مكون من طبقات ترشيحية تليه وحدتا Transformer. تم تدريب النماذج على صور فقاعات إجابة حقيقية مقسمة إلى ثلاث فئات (مملوءة، فارغة، مشطوبة) باستخدام إعدادات تدريب موحدة. تم اختبار تأثير زيادة بيانات التدريب (Data Augmentation) على دقة التعميم في كلا النموذجين، أظهرت النتائج أن النموذج الهجين بدون زيادة البيانات حقق أفضل أداء بدقة تصنيف بلغت حوالي 99.96%. كما بينت النتائج أن معظم الأخطاء كانت في التفريق بين الفقاعات المملوءة والمشطوبة. تشير الدراسة إلى أن دمج خصائص محلية مستخرجة بواسطة الشبكة العصبية الترشيحية مع سياق عالمي يوفره المحول (Transformer) يحسّن دقة تصنيف الصور في المهام الدقيقة مثل تصنيف فقاعات الإجابة، كما تبين أن استخدام زيادة البيانات بشكل غير مدروس قد يؤدي في بعض الحالات إلى نتائج عكسية. تسلط هذه النتائج الضوء على منهجية فعّالة يمكن اعتمادها في أنظمة تصحيح الاختبارات الآلية لزيادة المرونة والدقة.

الكلمات المفتاحية: التعرف الآلي على العلامات (OMR)، المحولات (Transformers)، الشبكة العصبية الترشيحية (CNN)، زيادة البيانات (Data Augmentation)، فقاعات الإجابة (Bubbles).

¹ طالب دكتوراه - قسم هندسة البرمجيات ونظم المعلومات - كلية الهندسة المعلوماتية - جامعة حمص - سورية

² أستاذ مساعد - قسم هندسة البرمجيات ونظم المعلومات - كلية الهندسة المعلوماتية - جامعة حمص - سورية

³ مدرس - قسم هندسة البرمجيات ونظم المعلومات - كلية الهندسة المعلوماتية - جامعة حمص - سورية

Comparative Performance Analysis of Convolutional Neural Networks and Hybrid Models in Answer Bubble Classification

Eng. Mohammed Ahmad Ali

Supervision: Dr. Alida Isber

Dr. Suhel Hammoud

ABSTRACT

This study aims to compare the performance of a model based on Convolutional Neural Networks (CNN) with a hybrid model that integrates CNN architecture with Transformer layers in the task of answer bubble classification (filled, empty, or crossed-out). We developed a CNN composed of five convolutional layers as the baseline model, and a hybrid model consisting of convolutional layers followed by two Transformer units. The models were trained on real-world answer bubble images categorized into three classes—filled, empty, and crossed-out—using unified training settings.

The impact of data augmentation on generalization accuracy was also examined. Results showed that the hybrid model without data augmentation achieved the highest performance, with a classification accuracy of approximately 99.96%. The findings further indicated that most classification errors occurred in distinguishing between filled and crossed-out bubbles. The study demonstrates that combining local features extracted by CNNs with the global contextual awareness provided by Transformers enhances classification performance in fine-grained visual tasks such as answer bubble recognition. Additionally, it was found that unstructured use of data augmentation can, in some cases, lead to adverse effects. These results highlight an effective methodology that can be employed in automated exam grading systems to improve both accuracy and flexibility.

Keywords: Optical Mark Recognition (OMR), Transformers, Convolutional Neural Networks (CNN), Data Augmentation, Answer Bubble Classification.

1. مقدمة

تعتمد الكثير من القطاعات وخاصة المؤسسات التعليمية على تقنيات التعرف الآلي على العلامات (Optical Mark Recognition - OMR) في تصحيح الاختبارات متعددة الخيارات لما لها من دور في الحصول على نتائج سريعة وتقليل الجهد اليدوي [1]، لكن أغلب الأنظمة المستخدمة ما تزال تقليدية وتعتمد على خوارزميات معالجة صور ثابتة، كأن يتم تحديد ما إذا كانت الفقاعة مملوءة عن طريق تحليل مستويات الرمادي [2,3] أو حساب عدد البكسلات السوداء ضمن فقاعة الإجابة [4,5,6]، لذا عانت هذه التقنيات من محدودية في التعامل مع التنوع في شكل علامات التظليل أو وجود علامات شطب، وبالتالي قد يؤدي ذلك إلى انخفاض في دقة التصنيف، وبسبب هذا الأمر فرضت هذه الأنظمة شروط صارمة على الطالب بمنع إلغاء إجابة من خلال علامة X أو شطب على الفقاعة؛ فإذا قام بذلك قد تعجز أنظمة التصحيح عن التمييز بين الإجابة الملغاة والإجابة المؤكدة وتعتبر إجابته لاجية. ومع التقدم في مجال التعلم العميق برزت الشبكات العصبية الترشيحية (CNN) كأداة قوية في رؤية الحاسوب لقدرتها على استخلاص الخصائص المميزة من الصور بشكل تلقائي، وقد بدأ اعتمادها في مشاكل تصنيف مشابهة لتجاوز التحديات التي تواجه الطرق التقليدية [7]. بالتوازي مع ذلك ظهرت نماذج المحولات (Transformer) في السنوات الأخيرة وبدأت تبنيها في مجال الرؤية الحاسوبية حيث تمتاز ببنيتها بقدرتها على نمذجة العلاقات طويلة المدى بين أجزاء الصورة [8]، وقد بينت أبحاث لاحقة أن دمج النموذجين معاً في نموذج هجين بإمكانه أن يحقق اكتشاف الميزات بأفضل ما يمكن حيث يستفيد من قدرة شبكات CNN على استخراج سمات محلية فعالة ومن قدرة المحولات على إعادة توزيع الانتباه عبر الصورة بأكملها [9]. نقترح في هذه الورقة تصنيف فقاعات الإجابات باستخدام نموذج يعتمد على شبكات CNN ونموذج هجين يجمع بين بنية شبكات CNN والمحولات، سنقوم بمقارنة أداء النموذجين تحت ظروف تدريب متماثلة مع التركيز بشكل خاص على تأثير زيادة البيانات (Data Augmentation) على دقة النماذج. تكمن أهمية هذه الدراسة في فهم ما إذا كان إدخال وحدات

Transformer لتحسين استيعاب السياق الكلي للصورة يمكن أن يحسّن من تمييز النموذج بين الفقاعة المملوءة والفقاعة المشطوبة بعلامة، وكذلك بين الفقاعة المملوءة والفقاعة الفارغة، كما نهدف إلى فهم دور عمليات زيادة البيانات augmentation في مثل هذه المهام التي يكون فيها تنوع البيانات الحقيقية محدود (كون جميع الصور تأتي من عمليات مسح ضوئي قياسية). من المتوقع أن تساهم نتائج هذه الدراسة في تصميم أنظمة تصحيح آلي أكثر دقة ومرونة، خاصة في البيانات التعليمية التي تتطلب التعرف على أنماط تظليل غير تقليدية (مثل إلغاء الإجابة بعلامة).

2. أهداف وأهمية البحث

يهدف البحث إلى تحقيق ما يلي:

- تصميم نظام تصنيف دقيق لفقاعات الإجابة في أوراق OMR باستخدام بنى CNN و Transformer.
- تحليل تأثير استخدام تقنيات زيادة البيانات Augmentation على أداء النماذج في بيانات مستقرة.
- تقييم دقة النماذج في التمييز بين الفقاعات المملوءة والمشطوبة والفارغة.

تتبع أهمية هذا البحث من الحاجة المتزايدة إلى أنظمة تصحيح إلكترونية دقيقة وقابلة للتعميم، خاصة في المؤسسات التعليمية التي تعتمد على نماذج OMR لقياس أداء الطلبة. ويساعد هذا البحث في فهم الفروق الدقيقة بين المزايا التي تتيحها بنى شبكات CNN التقليدية والبنى المحسنة منها باستخدام المحولات، وتأثير توليد زيادة في البيانات (augmentation) على دقة التصنيف، مما ينعكس على تحسين أدوات التصحيح المؤتمت وتقليل نسبة الخطأ البشري.

تُلخص مساهمات البحث بالنقاط التالية:

- تطوير مقارنة بين أربع نماذج للتصنيف تشمل نموذج CNN والنموذج الهجين (CNN+Transformer) (مع وبدون زيادة البيانات).

- استخدام إعدادات تدريب موحدة لجميع النماذج لتقديم مقارنة فعلية.
- تحليل مصفوفات الالتباس وحالات الخطأ في التصنيف.
- توضيح تأثير عمليات زيادة البيانات (Augmentation) على مهام التصنيف الدقيقة ضمن بيئة بيانات مستقرة.
- تقديم توصيات عملية لتحسين تصميم نماذج OMR المستقبلية بناءً على النتائج التجريبية.

3. دراسة مرجعية

ركزت العديد من الأعمال السابقة على تحسين عملية تصحيح الاختبارات المؤتمتة، يمكن تصنيف هذه الأعمال ضمن فئتين رئيسيتين: طرق تقليدية قائمة على معالجة الصور، وطرق حديثة قائمة على التعلم الآلي العميق. فيما يلي نستعرض أبرز ما قدمته الدراسات في كلا الاتجاهين:

3.1. نماذج تقليدية Traditional Models:

اعتمدت الطرق الأولى لتحديد الإجابات على خطوات معالجة صورة بسيطة، مثل تحويل الصورة إلى الأبيض والأسود ثم تحديد مناطق العلامات ومقارنتها بعتبة معينة. قدم Deng وآخرون [10] حلاً منخفض التكلفة لتحديد الإجابات المملوءة باستخدام تقنيات معالجة متوازية، كما اقترح Sanguansat [11] في دراسته نظام آلي لقراءة العلامات يعتمد على أساليب معالجة الصور التقليدية، تضمنت أغلب هذه الأساليب خطوات معايرة (لتصحيح ميلان ورقة الإجابة) ثم تقسيم الورقة إلى خانات كل سؤال، وأخيراً تصنيف كل فقاعة عبر قياس كثافة اللون أو عدد البكسلات الغامقة فيها [2-6]. نجحت هذه الطرق إلى حد كبير في بيئات منتظمة، لكنها وجدت صعوبة في التعامل مع الحالات غير الاعتيادية (مثل وجود علامات شطب داخل الفقاعة أو اختلاف أشكال التظليل من طالب لآخر) مما أثر على موثوقية نتائجها.

3.2. نماذج شبكات عصبية عميقة Deep Neural Networks Models:

مع ظهور الشبكات العصبية وازدياد القدرة الحاسوبية، اتجه الباحثون لتوظيف التعلم العميق في مشكلة تصنيف فقاعات الإجابة. من أوائل الأبحاث في هذا السياق دراسة عفيفي وحسين [12] حيث قدموا خلالها منهجية لتصنيف مربعات الإجابات في أوراق الاختبار متعددة الخيارات، عملوا على استخراج صورة كل فقاعة إجابة بشكل مستقل وإدخالها إلى نموذج تصنيف يقوم بتحديد حالة

الفقاعة (الإجابة المؤكدة (مملوءة)، والإجابة الملغاة بعلامة (مشطوبة)، والإجابة الفارغة)، جرب الباحثان في هذه الدراسة طريقتين: الأولى باستخدام السمات التقليدية (مثل طريقة Bag of Visual Words) والثانية باستخدام شبكة CNN مدربة لهذا الغرض، بينت نتائجهم أن نموذج CNN استطاع تحقيق دقة تصنيف أعلى ومرونة أفضل في التعامل مع الاختلافات بين أنماط التظليل المختلفة وفي التعرف على الحالات التي يضع فيها الطالب علامة (×) لإلغاء إجابة معينة، وتعد مجموعة البيانات التي نشرها (MCQ Dataset) إحدى أوائل المجموعات المتاحة التي تحتوي على أمثلة حقيقية لحالات إلغاء الإجابات بعلامات شطب، مما ساهم في تحفيز أعمال لاحقة.

وفي السنوات الأخيرة اقترح Mondal وآخرون [13] نموذج OMRNet يستخدم بنية MobileNetV2 خفيفة الوزن لتصنيف الفقاعة إلى ثلاث فئات، وقد حقق دقة عالية جداً بعد تدريبه على مجموعة بيانات فقاعات الإجابة التي قدمها عفيفي في بحثه سابقاً. أثبتت هذه النماذج المقترحة أن شبكات CNN بإمكانها تحقيق دقة عالية في تصنيف فقاعات الإجابات عند توفر بيانات تدريب كافية وعند تمثيل جميع حالات الإجابات الممكنة (مملوءة بالكامل، مملوءة جزئياً، مشطوبة، ... إلخ) في البيانات.

3.3. نماذج مبنية على المحولات Transformer-based Models والنماذج الهجينة:

في الوقت الذي حققت فيه نماذج CNN نجاحات ملموسة، بدأت الأبحاث المهمة بمجال الرؤية الحاسوبية باستكشاف نماذج مبنية على المحولات Transformer. يُعتبر نموذج Vision Transformer (ViT) المقترح من قبل Dosovitskiy وزملائه [14] أحد أبرز التطورات، حيث أظهر إمكانية منافسة نماذج CNN عبر تقسيم الصورة إلى بقع وتمثيلها بتسلسل مدخلات للمحول Transformer، يتمتع Transformer بقدرته على النظر إلى الصورة كوحدة متكاملة والتعلم من علاقات بعيدة المدى بين أجزائها.

وقد أشارت بعض الدراسات إلى تكاملية دور كل من CNN وTransformer؛ حيث تتفوق CNN في استخلاص ملامح محلية (كحافة أو زاوية ضمن فقاعة) بينما يُبرز Transformer العلاقات السياقية الشاملة (مثل نمط العلامة داخل الفقاعة بالنسبة لإطارها الكلي). بناءً على ذلك اتجهت بعض الأبحاث الحديثة إلى بناء نماذج هجينة تدمج المماريتين معاً، حيث قدم Nie

وآخرون [15] مثال ناجح لذلك في المجال الطبي، إذ دمجا CNN مع Transformer لتصنيف صور الأورام الجلدية وحققوا تفوق على نماذج CNN التقليدية في الدقة. في ذلك النموذج تتولى نماذج CNN استخراج خصائص أولية من الصورة، ثم يقوم المحول Transformer بمعالجة هذه الخصائص على مستوى أعلى لاكتساب فهم شامل للصورة قبل اتخاذ قرار التصنيف. هذه النتائج الواعدة تدفعنا لاستكشاف ما إذا كان نهج مشابه يمكن أن يفيد في مشكلة تصنيف فقاعات الإجابة، خاصة في التمييز الدقيق بين الفقاعة المملوءة وتلك المشطوبة اللتان قد تبدوان متشابهتين للوهلة الأولى.

4. مواد وطرائق البحث

يستعرض هذا القسم توصيف مجموعة البيانات والنموذج والخوارزميات المستخدمة ومقاييس التقييم المعتمدة وتفاصيل بيئة التجربة.

1.4 توصيف مجموعة بيانات البحث Dataset

تم استخدام مجموعة بيانات تحتوي على صور لفقاعات الإجابات المقصودة من أوراق إجابة حقيقية عددها 18000 صورة (6000 صورة لكل فئة). كل صورة بالأبيض والأسود أو التدرج الرمادي تمثل فقاعة إجابة واحدة مقطوعة (من ورقة إجابة مسحوبة ضوئياً) ومصنفة يدوياً إلى إحدى ثلاث فئات:

- فئة "مملوءة" (Filled): وتشمل الفقاعات التي تم تظليلها بشكل واضح كدلالة على اختيار الإجابة.
- فئة "فارغة" (Empty): وتشمل الفقاعات التي تركت بدون أي علامة أو تظليل.
- فئة "مشطوبة" (Crossed-out): وتشمل الفقاعات التي وضع عليها علامة إلغاء (مثل علامة X) أو تم شطبها بخطوط مائلة للدلالة على أن الطالب اختار إلغاء تلك الإجابة.

2.4 النماذج والخوارزميات المستخدمة

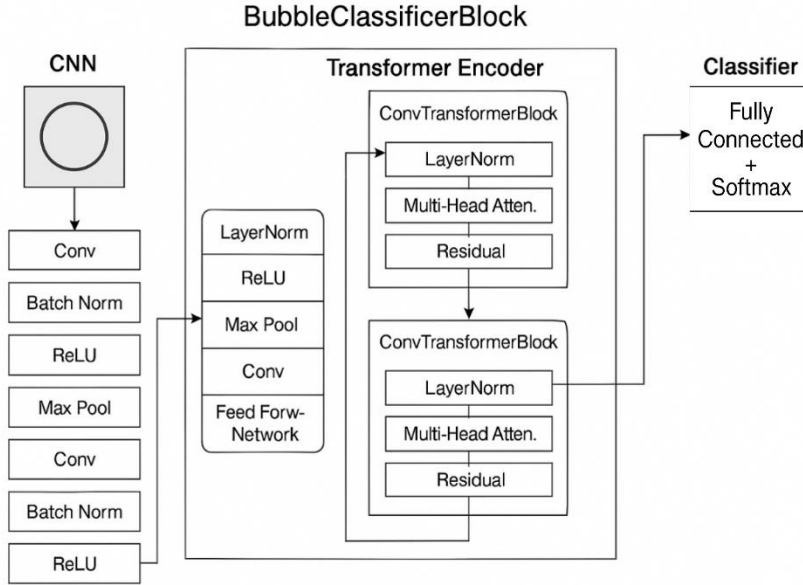
طورنا نموذجين رئيسيين للمقارنة:

1.2.4 نموذج CNN:

عبارة عن شبكة عصبية ترشيحية مكونة من خمس طبقات ترشيحية متتابعة، تتخللها طبقات تفعيل غير خطية (ReLU) وطبقات تجميع (Pooling) لخفض الأبعاد تدريجياً. ينتهي النموذج بطبقة كاملة الاتصال (Fully Connected) مع دالة softmax بثلاث وحدات تمثل احتمالات الفئات الثلاث. تم اختيار بنية CNN بسيطة نسبياً (5 طبقات) لتكون مماثلة من حيث التعقيد للنموذج الهجين اللاحق، وضمان أن الفرق في الأداء يرجع لوجود وحدة Transformer من عدمه وليس لحجم النموذج. هذا النموذج لا يحتوي على أي مكون Transformer أو آلية انتباه، ويُفترض أنه يلتقط الملامح المحلية مثل مساحات الظل داخل الفقاعة أو أجزاء من حدودها.

2.2.4 النموذج الهجين (CNN+Transformer) :

يتكون من قسمين أساسيين: قسم أمامي Extractor CNN وقسم خلفي Transformer Encoder. القسم الأول هو طبقات من شبكة CNN (بضع طبقات ترشيحية) بهدف استخراج خرائط الخصائص المميزة من صورة الفقاعة. بعد المرور عبر الطبقات، نحصل على تمثيل ذو أبعاد منخفضة للصورة (مثلاً خارطة خصائص بحجم $4 \times 4 \times \text{عمق معين}$). يتم تسطيح (Flatten) هذه الخارطة وتحويلها إلى سلسلة من المتجهات (patch embeddings) تمهيداً لإدخالها إلى القسم الثاني. القسم الثاني هو المحوّل (Transformer) مكون من طبقتين من طبقات Encoder الخاصة بالمحوّل Transformer. كل طبقة Transformer تتألف من آلية انتباه متعدد الرؤوس (Multi-Head Self-Attention) يليها طبقة تغذية أمامية (Feed-Forward Network) مع إضافة اتصالات الالتفاف (skip connections) والتطبيع (Layer Norm) كما هو متبع في بنية Transformer الأصلية. يقوم Transformer بمعالجة متجهات الخصائص المستخرجة من شبكة CNN بطريقة تأخذ بالاعتبار العلاقات المتبادلة بين جميع أجزاء الصورة (أي أنه يمكنه مثلاً ملاحظة علامة الشطب كاملة وعلاقتها بحواف دائرة الفقاعة). مخرج آخر طبقة Transformer يمر عبر طبقة تصنيف نهائية (fully connected + softmax) لإنتاج احتمالات الفئات الثلاث. الشكل العام لهذا النموذج الهجين موضح ضمن المخطط في الشكل 1 أدناه.



الشكل 1 - بنية النموذج الهجين المقترح

3.4. استراتيجيات زيادة البيانات (Augmentation) :

في البداية تم الاعتماد على مجموعة متنوعة من تقنيات زيادة البيانات أثناء تدريب النماذج لمحاولة تحسين قدرتها على التعميم. شملت هذه التقنيات تدوير الصور بزوايا عشوائية صغيرة (مثلاً ± 5 درجات) وقص بسيط أو إزاحة طفيفة للصورة، بالإضافة إلى تغيير مستويات الإضاءة أو التباين بشكل طفيف. الغرض من استخدام augmentation هو إعطاء النموذج حالات متنوعة من نفس الفقاعة حتى لا يحفظ تفاصيل محددة جداً للصورة خلال التدريب، ولكن بخلاف مهام الرؤية التقليدية، تبين أن بيانات فقاعات الإجابة تتمتع بقدر عالٍ من الثبات، فكل الصور ناتجة عن ماسح ضوئي بنفس الدقة، والفقاعات دائماً في مواضع متشابهة وبخطوط موحدة، ولا توجد اختلافات كبيرة في الإضاءة أو الميلان (بعد عملية المعايرة)، لذا بدت بعض عمليات زيادة البيانات وكأنها تولّد حالات غير واقعية بالنسبة لهذه المهمة (مثل تدوير الفقاعة بزوايا كبيرة أو تغيير السطوع بشكل مبالغ فيه). وقد أشار بعض الباحثين إلى أن الإفراط في زيادة البيانات augmentation قد يؤدي إلى إدخال أنماط لا تعكس التوزيع الحقيقي للبيانات، مما يربك النموذج

بدلاً من تحسينه [16]. بناءً على ذلك قمنا بإعداد تجربة خاصة ضمن منهجيتنا: درّينا نفس النموذجين (CNN والهجين) دون أي عمليات Augmentation على الإطلاق، وقارنا أداءهما مع النماذج نفسها لكن المدربة بعد زيادة البيانات augmentation. الهدف من ذلك هو رصد ما إذا كانت عمليات زيادة البيانات تساعد النموذج في التعميم في هذه المهمة أم أنها تتسبب في تشويش قد يضر بالأداء نظراً لطبيعة البيانات المستقرة. باختصار لدينا أربع نماذج نقارن بينها في التجارب:

- 1) نموذج CNN بدون استخدام augmentation.
- 2) نموذج CNN مع استخدام augmentation.
- 3) نموذج هجين CNN+Transformer بدون استخدام augmentation.
- 4) نموذج هجين CNN+Transformer مع استخدام augmentation.

4.4. بيئة التجربة

استُخدم عدد من مكتبات لغة بايثون Python في تجارب البحث، وأُجريت جميع التجارب ضمن بيئة Google Colab pro باستخدام Python 3 على وحدة معالجة رسومية (GPU) من نوع NVIDIA A100-SXM4-40GB ووحدة معالجة مركزية (CPU) من نوع Intel(R) Xeon(R) CPU @ 2.20GHz , 6 cores, 12 threads وذاكرة وصول عشوائي (RAM) بحجم 83.5GB.

5. التجارب والنتائج ومناقشتها

مرت عملية الحصول على نموذج بخطوات عدة يمكن تلخيصها وفق الآتي:

1.5. تهيئة وتقسيم مجموعة البيانات

تم تقسيم البيانات إلى مجموعات تدريب وتقييم باستخدام أسلوب (5-fold cross-validation) لضمان الاستفادة القصوى من البيانات المحدودة وضمان أن يتم اختبار النموذج على بيانات لم يرها أثناء التدريب، تمت موازنة التوزيع بين الفئات الثلاث في مجموعات التدريب والاختبار (بعد التجزئة) بقدر الإمكان بحيث لا يطغى عدد عينات فئة على أخرى.

تم تقسيم مجموعة البيانات إلى ثلاث مجموعات وهي مجموعة التدريب (Training) 70% من مجموعة البيانات الكلية) ومجموعة التحقق (Validation) 15% ومجموعة الاختبار (Testing) 15%.

2.5. الضبط الدقيق للنموذج

تم تدريب كل النماذج باستخدام نفس إعدادات التدريب لضمان مقارنة عادلة، بداية تم تحجيم الصور كلها لتكون موحدة الحجم في تدريب كل النماذج (بحجم 44×67) لضمان تتسق المدخلات للنموذج، تم استخدام دالة خسارة (CrossEntropyLoss) مدمجة مع softmax على المخرجات للتصنيف متعدد الفئات، تم اعتماد المُحسّن (Optimizer: Adam) بقيمة تعلم ابتدائية مناسبة (learning rate= 1e-3). كما تم تطبيق ضبط لمعدل التعلم لتخفيضه تدريجياً أثناء التدريب عند ثبات الأداء وعدم تحسن دقة التحقق لفترة محددة (ReduceLROnPlateau)، تم تدريب النماذج لعدد من الأجيال (epochs=50)، وتم تحديد حجم الدفعة (Batch Size=128). وخلال التدريب تمت مراقبة الدقة على مجموعة التحقق (validation) لتتبع أداء النموذج وتجنب حدوث (overfitting) باستخدام الإيقاف المبكر (Early Stopping).

3.5. مقاييس التقييم:

تم تحديد أخطاء التصنيف من قبل كل من النماذج باستخدام مصفوفات الالتباس (Confusion Matrix) [17,18]:

		Assigned Class	
		Positive	Negative
Actual Class	Positive	TP	FN
	Negative	FP	TN

الشكل 2 - مصفوفة الالتباس

TP تعني تصنيفاً إيجابياً صحيحاً و FP تعني تصنيفاً إيجابياً خاطئاً و TN تعني تصنيفاً سلبياً صحيحاً و FN تعني تصنيفاً سلبياً خاطئاً.

يستخدم البحث أيضاً عدداً من المقاييس وهي: الدقة Accuracy والإحكام Precision والاستدعاء Recall ومقياس إف1 F1-Score. تُحسب هذه المقاييس وفق المعادلات التالية [18,19]:

$$\frac{TP + TN}{TP + TN + FP + FN} = \text{الدقة}$$

$$\frac{TP}{TP + FP} = \text{الإحكام}$$


$$\frac{TP}{TP + FN} = \text{الاستدعاء}$$

$$2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} = \text{مقيا إف1}$$

4.5. النتائج والتقييم

بعد تدريب النماذج الأربعة تم تقييمها على مجموعة الاختبار، وبشكل عام أظهرت جميع النماذج دقة تصنيف عالية جداً لكن مع وجود فروق دقيقة فيما بينها. نستعرض فيما يلي نتائج كل نموذج على حدا:

1.4.5 نموذج CNN بدون Augmentation



الشكل 2 - مصفوفة الالتباس لنموذج CNN بدون زيادة البيانات

يعرض الشكل 2 مصفوفة الالتباس لنموذج CNN المدرب بدون أي زيادة للبيانات. صنف النموذج جميع الفقاعات بشكل صحيح (900 صحيحة)، أيضاً بالنسبة للفقاعات الفارغة تم تصنيفها جميعها بشكل صحيح على أنها فارغة، بينما وقع 14 خطأ عند تصنيف الفقاعات المملوءة حيث اعتبر فقاعة مملوءة على أنها فارغة و 13 منها تم تصنيفها على أنها مشطوبة. يبين الجدول (1) نتائج اختبار أداء نموذج CNN المدرب (بدون زيادة البيانات) وقد بلغت الدقة الكلية تقريباً 99.48%:


الجدول 1 - نتائج اختبار أداء نموذج CNN بدون زيادة البيانات

مقياس إف1 F1-score	الاستدعاء Recall	الإحكام Precision	عدد العينات Support	
0.9928	1.0000	0.9858	900	فقاعات مشطوبة
0.9994	1.0000	0.9989	900	فقاعات فارغة

مقارنة أداء الشبكات العصبية الترشيحية والنماذج الهجينة في تصنيف فقاعات الإجابة

0.9922	0.9844	1.0000	900	فقاعات مملوءة
0.9948	0.9948	0.9949	2700	إجمالي الفقاعات

2.4.5 نموذج CNN مع Augmentation



الشكل 3 - مصفوفة الالتباس لنموذج CNN مع زيادة البيانات


يوضح الشكل 3 مصفوفة الالتباس لنموذج CNN المدرب مع تطبيق زيادة البيانات augmentation. يمكن ملاحظة أن النموذج حقق أداء جيد جداً بشكل عام، حدث خطأ في تصنيف (5 فقاعات من 900) من فئة المشطوبة تم تصنيفها على أنها مملوءة، وبالنسبة لفئة الفقاعات الفارغة صُنفت جميعها بشكل صحيح على أنها فارغة ولم يتواجد أي خطأ. أما فئة الفقاعات المملوءة، فقد تم تصنيف 888 منها بشكل صحيح وحدث 12 خطأ، خطأين صنفنا على أنهما فارغتين و 10 حالات صُنفت بأنها مشطوبة.

يبين الجدول (2) نتائج اختبار أداء نموذج CNN المدرب (مع زيادة البيانات):
الجدول 2 - نتائج اختبار أداء نموذج CNN مع زيادة البيانات

مقياس إف1 F1-score	الاستدعاء Recall	الإحكام Precision	عدد العينات Support	
0.9917	0.9944	0.9890	900	فقاعات مشطوبة
0.9989	1.0000	0.9978	900	فقاعات فارغة
0.9905	0.9867	0.9944	900	فقاعات مملوءة
0.9937	0.9937	0.9937	2700	إجمالي الفقاعات

تبين النتائج أن معدل الدقة الكلي لهذا النموذج قد بلغ 99.37%، لكن النموذج (بعد زيادة البيانات) أظهر خطأ أكبر في التصنيف بين الفقاعات المملوءة والمشطوبة.


3.4.5 النموذج الهجين (CNN+Transformer) بدون زيادة البيانات



الشكل 4 - مصفوفة الالتباس للنموذج الهجين بدون زيادة البيانات

مقارنة أداء الشبكات العصبية الترشيحية والنماذج الهجينة في تصنيف فقاعات الإجابة

يبين الشكل 4 مصفوفة الالتباس للنموذج الهجين عند تدريبه بدون زيادة البيانات نلاحظ تحسن في تصنيف الفقاعات مقارنة بنماذج CNN، حيث لا توجد أي أخطاء في تصنيف الفقاعات ضمن فئة الفقاعات الفارغة، وبالنسبة للفقاعات الفارغة تمكن النموذج من تصنيفها بشكل صحيح، ظهر خطأ وحيد فقط في تصنيف فقاعة مملوءة حيث صنف على أنها مشطوبة. العدد الإجمالي للأخطاء هو خطأ واحد فقط من أصل 2700 عينة مبين في الشكل 5:



الشكل 5 - حالة الخطأ في تصنيف الفقاعات باستخدام النموذج الهجين بدون زيادة البيانات


حقق النموذج دقة إجمالية حوالي 99.96% كما هو مبين في الجدول 3:

الجدول 3 - نتائج اختبار أداء النموذج الهجين بدون زيادة البيانات

مقياس إف1 F1-score	الاستدعاء Recall	الإحكام Precision	عدد العينات Support	
0.9994	1.0000	0.9989	900	فقاعات مشطوبة
1.0000	1.0000	1.0000	900	فقاعات فارغة
0.9994	0.9989	1.0000	900	فقاعات مملوءة
0.9996	0.9996	0.9996	2700	إجمالي الفقاعات

نلاحظ أن النموذج الهجين بدون زيادة البيانات (augmentation) كان الأفضل من حيث تقليل أخطاء التصنيف ودقته، يعود ذلك إلى دمج المحول Transformer الذي مكّنه من التقاط أنماط العلامات بشكل أشمل، فمثلاً استطاع النموذج الانتباه إلى وجود خطوط مائلة مميزة في الفقاعة المشطوبة تميّزها عن الفقاعة المملوءة كلياً، مما قلل من خلطه بينهما مقارنة بالنماذج السابقة.


4.4.5 النموذج الهجين (CNN+Transformer) مع زيادة البيانات



الشكل 6 - مصفوفة الالتباس للنموذج الهجين مع زيادة البيانات

يعرض الشكل 6 مصفوفة الالتباس للنموذج الهجين عندما تم تدريبه مع تطبيق زيادة البيانات. نلاحظ من الشكل أن جميع عينات الفقاعات المشطوبة صُنفت صحيحة عدا واحدة صُنفت على أنها مملوءة (899 من 900)، وكذلك جميع عينات الفقاعات الفارغة صُنفت صحيحة (900 من 900) دون أي خطأ. أما بالنسبة لعينات الفقاعات المملوءة صُنفت 895 منها بشكل صحيح وال 5 عينات المتبقية صُنفت بشكل خاطئ على أنها مشطوبة. عدد الأخطاء الكلية في التصنيف 6 أخطاء مبيّنة في الشكل 7:

مقارنة أداء الشبكات العصبية الترشيحية والنماذج الهجينة في تصنيف فقاعات الإجابة



الشكل 7 - حالات الخطأ في تصنيف الفقاعات باستخدام النموذج الهجين مع زيادة البيانات

حقق النموذج دقة تقارب 99.78% كما هو موضح في الجدول 4:

الجدول 4 - نتائج اختبار أداء النموذج الهجين مع زيادة البيانات

مقياس إف1 F1-score	الاستدعاء Recall	الإحكام Precision	عدد العينات Support	
0.9967	0.9989	0.9945	900	فقاعات مشطوبة
1.0000	1.0000	1.0000	900	فقاعات فارغة
0.9967	0.9944	0.9989	900	فقاعات مملوءة
0.9978	0.9978	0.9978	2700	إجمالي الفقاعات

يبين الجدول 5 مقارنة أداء النماذج الأربعة:

الجدول 5 - مقارنة أداء النماذج المقترحة في تصنيف الفقاعات

النموذج	Augmentation	الدقة الكلية (Accuracy)	عدد العينات الصحيحة من 2700	عدد الأخطاء الكلية
CNN	×	0.9948	2686	14
CNN	✓	0.9937	2683	17
CNN + Transformer	×	0.9996	2699	1
CNN + Transformer	✓	0.9978	2694	6

6. الاستنتاجات والتوصيات

تشير نتائج الدراسة إلى أن النموذج الهجين المقترح الناتج عن دمج بنية الشبكة العصبية الترشيحية CNN مع المحولات Transformer حقق أعلى أداء في تصنيف فقاعات الإجابات دون تطبيق تقنيات زيادة البيانات Augmentation، حيث سجّل دقة كلية بلغت 99.96% مع خطأ واحد فقط من أصل 2700 عينة. يُعزى هذا النجاح إلى قدرة المحولات Transformer على تمثيل السياق الكامل للصورة ومساعدة CNN في التقاط العلاقات الدقيقة داخل الفقاعة، مثل نمط التظليل أو وجود خطوط الإلغاء.

وبخصوص زيادة البيانات augmentation بهدف تعميم النماذج على حالات مختلفة مولدة من مجموعة البيانات الحقيقية، توضح هذه الدراسة أن استخدام هذه التقنيات في بيئة بيانات حساسة قد يؤدي إلى إدخال أنماط مشوشة وغير واقعية تؤثر سلباً على فعالية النموذج، خاصة عند التعامل مع تصنيفات دقيقة تتطلب حساسية عالية لاختلافات طفيفة في نمط الحبر أو التظليل. بينت نتائج اختبار النماذج أن عملية زيادة البيانات أضعفت دقة بعض الفئات، كحالة فقاعات OMR التي تم تدويرها أو قلبها دون مراعاة "السلامة التصنيفية" (label safety)، إذ إن أي تدوير للصورة يمكن أن يغيّر نمط الحبر داخل الفقاعة بطرق غير واقعية مما يُدخل تشويش لا داعي له ويتسبب في تعلم النموذج لأنماط زائفة.

أحد أبرز أخطاء التصنيف في جميع النماذج تمثلت في التمييز بين فقاعات مملوءة وأخرى مشطوبة، وهذا ما أظهرته مصفوفات الالتباس حيث أن غالبية الأخطاء نتجت عن خلط بين هاتين الفئتين، وبالعودة إلى حالات الفقاعات التي صنفت بشكل خاطئ وجدنا تشابه بين تظليل الفقاعة بخطوط أشبه بالشطب ومنها مملوءة بخطوط مائلة حتى خارج زوايا الفقاعة، يزداد التصنيف الخاطئ عند تطبيق تحويلات هندسية مثل التدوير أو قلب الصورة حيث يجعل التظليل المشوّه أكثر تشابهاً مع الشطب، يشير ذلك إلى ضرورة تجنب زيادة البيانات بشكل غير مدروس عندما يتعلق الأمر بفئات تتداخل بصرياً بشكل كبير.

بناءً على ما سبق، نوصي بما يلي:

- تبني نموذج هجين (CNN + Transformer) عند تطوير أنظمة تصحيح OMR لضمان دقة أعلى في التمييز بين الفئات.
- الامتناع عن زيادة البيانات Augmentation بشكل عشوائي في بيانات بيانات حساسة، واعتماد تحويلات مدروسة فقط تعكس الواقع الحقيقي.
- التركيز على تحليل الأخطاء الناجمة عن التمييز بين filled و crossed-out لتحسين المعالجة الدقيقة للفروقات.

تؤكد هذه النتائج أن التصميم الدقيق للبنية وتخصيص استراتيجيات زيادة البيانات بما يتوافق مع طبيعة المهمة يلعب دور حاسم في تحسين الأداء، وتفتح الطريق نحو تطوير أدوات تصحيح مؤتمنة أكثر ذكاءً وموثوقية.

7. المراجع:

- [1] DE ELIAS,E., TASINAFFO,P. , HIRATA,R. 2021 Optical mark recognition: Advances, difficulties, and limitations, SN Computer Science, Vol. 2(5), 367.
- [2] PATEL, R., SANGHAVI, S., GUPTA, D., RAVAL, M.S. 2015 CheckIt–A low cost mobile OMR system, TENCON IEEE Region 10 Conference, pp. 1–5.
- [3] ZAMPIROLI, F., GONZALEZ, J.A.Q., DE OLIVEIRA NEVES, R. 2010 Automatic correction of multiple-choice tests using digital cameras and image processing, Universidade Federal do ABC, Brazil, 34p.
- [4] HUSSMANN, S., DENG, P.W. 2005 A high-speed optical mark reader hardware implementation at low cost using programmable logic, Real-Time Imaging, Vol. 11(1), 19–30.
- [5] GOROKHOVATSKYI, O. 2016 Neocognitron as a tool for optical marks recognition, IEEE International Conference on Data Stream Mining & Processing (DSMP), 169–172.
- [6] PARUL, H.M., KAUR, M. 2012 A novel optical mark recognition technique based on biogeography based optimization, International Journal of Information Technology and Knowledge Management, Vol. 5(2), 331–333.
- [7] KHAN, S., NASEER, M., HAYAT, M., ZAMIR, S.W., KHAN, F.S., SHAH, M. 2022 Transformers in vision: A survey, ACM Computing Surveys (CSUR), Vol. 54(10s), 1–41.
- [8] BHATT, D., PATEL, C., TALSANIA, H., PATEL, J., VAGHELA, R., PANDYA, S., GHAYVAT, H. 2021 CNN variants for computer vision: History, architecture, application, challenges and future scope, Electronics, Vol. 10(20), 2470.
- [9] SHEN, Z. 2024 A comparative study of hybrid CNN and Vision Transformer models for facial emotion recognition, IEEE

- International Conference on Dependable Systems and Their Applications (DSA), 401–408.
- [10] DENG, H., WANG, F., LIANG, B. 2008 A low-cost OMR solution for educational applications, IEEE International Symposium on Parallel and Distributed Processing with Applications, 967–970.
- [11] SANGUANSAT, P. 2015 Robust and low-cost Optical Mark Recognition for automated data entry, IEEE International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON), 1–5.
- [12] AFIFI, M., HUSSAIN, K.F. 2019 The achievement of higher flexibility in multiple-choice-based tests using image classification techniques, International Journal on Document Analysis and Recognition (IJ DAR), Vol. 22, 127–142.
- [13] MONDAL, S., DE, P., MALAKAR, S., SARKAR, R. 2024 OMRNet: A lightweight deep learning model for optical mark recognition, Multimedia Tools and Applications, Vol. 83(5), 14011–14045.
- [14] DOSOVITSKIY, A., BEYER, L., KOLESNIKOV, A., WEISSENBERN, D., ZHAI, X., UNTERTHINER, T., HOULSBY, N. 2020 An image is worth 16×16 words: Transformers for image recognition at scale, arXiv preprint, arXiv:2010.11929.
- [15] NIE, Y., SOMMELLA, P., CARRATÙ, M., O'NILS, M., LUNDGREN, J. 2022 A deep CNN transformer hybrid model for skin lesion classification of dermoscopic images using focal loss, Diagnostics, Vol. 13(1), 72.
- [16] MAI, J., GAO, C., BAO, J. 2025 Domain generalization through data augmentation: A survey of methods, applications, and challenges, Mathematics, Vol. 13(5), 824.

- [17] TING, K.M. 2011 – Confusion Matrix. In: Sammut, C., Webb, G.I. (eds), Encyclopedia of Machine Learning. Springer, Boston, USA.
- [18] OBI, J.C. 2023 A comparative study of several classification metrics and their performances on data, World Journal of Advanced Engineering Technology and Sciences, Vol. 8(1), 308–314.
- [19] AL-KURDI, R.M. 2024 Interpreting a model trained for detecting hate speech in Arabic tweets, Homs University Journal – Series of Engineering Science, Vol. 46(1), 133–168.

استخراج فقاعات الإجابة من أوراق الإجابة متعددة الخيارات باستخدام

نموذج SegFormer وتقنيات تحليل الصورة

المهندس محمد أحمد علي¹

الدكتور سهيل الحمود³

إشراف: الدكتورة اليدا إسبر²

الملخص

تهدف هذه الدراسة إلى تطوير نظام فعال ودقيق لاستخراج فقاعات الإجابة من أوراق الإجابة متعددة الخيارات باستخدام تقنيات التقسيم الدلالي (Semantic Segmentation) وخصوصاً نموذج التعلم العميق SegFormer-B0. تم تدريب النموذج على صور بحجم ثابت (1024×1024 بكسل)، باستخدام خوارزمية التحسين AdamW ودالة الخسارة CrossEntropyLoss. أظهرت النتائج أداءً متميزاً، حيث وصلت الدقة (Accuracy) إلى 0.9977، والاستدعاء (Recall) إلى 0.9961، والدقة التنبؤية (Precision) إلى 0.9970، ومعامل F1 Score إلى 0.9965، ومؤشر التقاطع على الاتحاد (IoU) إلى 0.9931، ما يدل على كفاءة النموذج العالية في التحديد الدقيق لحدود صندوق الإجابة.

اعتمدت الدراسة أيضاً على خوارزمية متكيفة لاكتشاف حدود صفوف الأسئلة، باستخدام تقنية الإسقاط الأفقي وتحليل القناة الحمراء (Red Channel Projection) لتحديد وفصل الأسطر بدقة. كما تم تطبيق آلية احتياطية (Fallback) لتجنب فشل عملية التقسيم في الحالات التي تفتقر فيها الصورة لمؤشرات واضحة. تضمن البحث في مرحلته الأخيرة استخدام خوارزمية التجميع DBSCAN لاكتشاف وتحديد مواضع الفقاعات بدقة عالية، مما يعزز موثوقية النتائج وملاءمة النظام للاستخدام العملي في تطبيقات التصحيح الآلي داخل البيئات التعليمية.

الكلمات المفتاحية: التعرف الآلي على العلامات (OMR)، المحولات (Transformers)،

SegFormer، تقنيات الإسقاط (Projection Techniques)، فقاعات الإجابة (Bubbles).

¹ طالب دكتوراه - قسم هندسة البرمجيات ونظم المعلومات - كلية الهندسة المعلوماتية - جامعة حمص - سورية

² أستاذ مساعد - قسم هندسة البرمجيات ونظم المعلومات - كلية الهندسة المعلوماتية - جامعة حمص - سورية

³ مدرس - قسم هندسة البرمجيات ونظم المعلومات - كلية الهندسة المعلوماتية - جامعة حمص - سورية

Extracting Answer Bubbles from Multiple-Choice Answer Sheets Using SegFormer and Image Analysis Techniques

Eng. Mohammed Ahmad Ali

Supervision: Dr. Alida Isber

Dr. Suhel Hammoud

ABSTRACT

This study aims to develop an efficient and accurate system for extracting answer bubbles from multiple-choice answer sheets using semantic segmentation techniques. especially, the deep learning model SegFormer-B0. The model was trained on images with a fixed size (1024×1024 pixels) utilizing the AdamW optimizer and the CrossEntropyLoss function. The results demonstrated outstanding performance, with accuracy reaching 0.9977, recall 0.9961, precision 0.9970, F1 score 0.9965, and intersection over union (IoU) 0.9931, indicating the model's high capability in accurately delineating the boundaries of the answer box.

The study also employed an adaptive algorithm to detect question row boundaries, utilizing horizontal projection and red channel analysis (Red Channel Projection) to accurately segment and separate the rows. A fallback mechanism was implemented to ensure the robustness of the segmentation process in cases where clear boundary indicators were absent. In the final stage, the DBSCAN clustering algorithm was used to accurately detect and locate the answer bubbles, further enhancing the reliability of the results and ensuring the system's suitability for practical use in automated grading applications within educational environments.

Keywords: Optical Mark Recognition (OMR), Transformers, SegFormer, Semantic Segmentation, Projection Techniques, Answer Bubbles, Automated Grading.

1. مقدمة

توفر عملية تصحيح أوراق الإجابة متعددة الخيارات السرعة والموضوعية في رصد أداء عمليات التقييم الامتحانية مما جعلها من المهام الأساسية في البيئات التعليمية [7]. ومع ذلك، تواجه الأنظمة التقليدية لتصحيح هذه الأوراق تحديات تقنية عند التعامل مع تباين جودة الأوراق الممسوحة ضوئياً أو المطبوعة بأنماط مختلفة [7]. من بين الأساليب الأكثر شيوعاً في الأبحاث الحديثة نماذج كشف الكائنات (Object Detection) مثل سلسلة YOLO، والتي حققت نجاحاً ملحوظاً في تحديد مواضع العناصر الصغيرة والمتوسطة الحجم بدقة عالية داخل الصور واكتشاف العناصر المرجعية في الورقة الامتحانية. [3,6,7]

تواجه عملية اكتشاف العناصر الكبيرة مثل صناديق الإجابة (Answer Box) صعوبة كبيرة بالرغم من كفاءة YOLO في رصد العناصر الدقيقة كالعلامات والرموز، خاصة في وجود اختلاف كبير في أبعاد الكائنات ضمن الصورة نفسها [3,7,19]. يعود ذلك إلى طبيعة بنية YOLO المعتمدة على تقسيم الصورة إلى شبكات صغيرة وتخصيص مرشحات (Anchors) للأحجام الأكثر شيوعاً، مما يجعلها أكثر ملاءمة لاكتشاف الكائنات الصغيرة أو المتوسطة، وأقل دقة أو استقراراً عند محاولة اكتشاف الكائنات الكبيرة التي تحتل جزءاً كبيراً من الصورة أو تتداخل مع الحواف، مما قد يؤدي إلى قصور في تحديد حدودها بدقة أو حتى فقدانها تماماً في بعض الحالات. [3,6,7]

تتيح نماذج التقسيم الدلالي المعتمدة على المحولات (Transformers) مثل SegFormer معالجة الصورة كاملة بشكل تسلسلي مع فهم السياق المكاني لكل جزء من أجزاء الصورة بغض النظر عن حجم أو موقع العنصر [6]. يمتاز نموذج SegFormer بقدرته على استخلاص مناطق الاهتمام الكبيرة والدقيقة بنفس الكفاءة، مستفيداً من بنية الانتباه الذاتي (Self-Attention) التي تدعم الربط بين جميع أجزاء الصورة بشكل ديناميكي وفعال. [6]

تهدف هذه الورقة إلى تقديم إطار منهجي متكامل لاستخراج صناديق الإجابة من أوراق الإجابة متعددة الخيارات، ثم تقطيعها إلى صفوف أسئلة واستخراج الفئات بدقة عالية. يعتمد النظام المقترح على تدريب نموذج SegFormer-B0 لتقسيم صورة الورقة إلى صندوق الإجابة والخلفية، متبوعاً بخوارزميات إسقاط وتجزئة متكيفة تعتمد على التحليل الإحصائي والإسقاط الأفقي لتحليل الحدود الفاصلة بين الأسطر. وفي المرحلة الأخيرة، يتم استخراج الفئات باستخدام تقنيات معالجة

مسبقة متقدمة وخوارزمية التجميع DBSCAN لضمان فصل الفقاعات حتى في حالات التداخل أو التشويش.

تستعرض الدراسة نتائج تجريبية دقيقة على بيانات واقعية، وتقرن أداء النظام مع الأنظمة التقليدية، مؤكدة تفوق النظام المقترح في دقة الاستخلاص وموثوقية الأداء، مما يعزز فرص اعتماده في التطبيقات التعليمية الفعالية ويساهم في تقليل الوقت والجهد المطلوبين لعملية التصحيح اليدوي.

2. أهداف وأهمية البحث

يهدف هذا البحث إلى تطوير نظام مؤتمت ودقيق لاستخراج فقاعات الإجابة من أوراق الإجابة متعددة الخيارات مع التركيز على معالجة التحديات المرتبطة باختلاف جودة الصور وتعدد أنماط الطباعة. يسعى النظام المقترح إلى الاستفادة من إمكانيات نماذج التقسيم الدلالي المعتمدة على المحولات (مثل SegFormer) لتجاوز تحديات نماذج كشف الكائنات التقليدية، خاصة فيما يتعلق باكتشاف العناصر البنيوية الكبيرة مثل صناديق الإجابة، والتي غالباً ما تتعرض للفقدان أو عدم التحديد الدقيق بسبب قيود بنية YOLO [3,6,7].

تتجلى أهمية هذا البحث في تقديم إطار عمل متكامل وقابل للتعميم على مختلف أنماط وتصاميم أوراق الإجابة، بما يعزز دقة التصحيح الآلي ويحد من تدخل العامل البشري، وبالتالي يقلل من احتمالية الخطأ ويزيد من كفاءة العملية التعليمية. كما يساهم النظام المقترح في تسهيل إعداد بيانات تدريبية منظمة وحديثة لأنظمة الذكاء الاصطناعي الأخرى، ويضع الأسس التقنية اللازمة لتطوير تطبيقات تصحيح آلي قابلة للاستخدام في البيئات التعليمية الواقعية بمختلف الظروف والإمكانيات التقنية [6,7]، حيث يمكن تلخيص أهمية البحث الحالي في النقاط التالية:

1. **تحسين دقة التصحيح الآلي** يساهم النظام المقترح في رفع مستوى الدقة عند استخراج مناطق الإجابة والفقاعات، مقارنةً بالأساليب التقليدية، مما يقلل احتمالية وقوع الأخطاء البشرية.

2. **معالجة اختلافات جودة الصور** يوفر النظام مرونة عالية في التعامل مع التباين الكبير في جودة الأوراق الممسوحة ضوئياً أو المطبوعة، سواء من حيث الدقة أو تباين الألوان وأنماط الطباعة. [1,6]

3. تجاوز تحديات نموذج YOLO يتغلب النموذج المقترح على قصور نماذج كشف الكائنات التقليدية مثل YOLO في اكتشاف العناصر الكبيرة، مثل صناديق الإجابة، من خلال توظيف نماذج التقسيم الدلالي. [3,6,7]
4. إمكانية التعميم يتمتع النظام بقابلية التكيف مع تصاميم وأشكال متعددة لأوراق الإجابة، مما يجعله ملائماً لمختلف المؤسسات التعليمية.
5. توفير إطار بيانات حديث يتيح النظام إنشاء بيانات تدريبية منظمة وحديثة، يمكن الاستفادة منها في تطوير وتدريب نماذج ذكاء اصطناعي متقدمة أخرى. [6]
6. تقليل الزمن والجهد يسرع النظام من عمليات التصحيح ويقلل الحاجة للتدخل اليدوي، ما ينعكس إيجاباً على كفاءة العملية التعليمية ككل.

3. دراسة مرجعية

تُعتبر تقنيات التعرف الضوئي على العلامات (OMR) واحدة من أبرز التقنيات في مجال التعليم والتقييم الآلي، حيث تتيح إمكانية التصحيح التلقائي والسريع لأوراق الاختبارات التي تعتمد على الإجابات ذات الخيارات المتعددة. فعلى مدار العقود الماضية، شهدت هذه التقنيات تحولات كبيرة، من الأنظمة التقليدية التي اعتمدت على أجهزة مخصصة ومكلفة [18]، إلى الأنظمة القائمة على تقنيات التصوير الرقمي والمعالجة الحاسوبية الحديثة [16]. ومنذ اعتماد التقنيات الرقمية في هذا المجال، ظهرت تحديات عديدة، أبرزها اختلاف جودة الصور وتباين أساليب الطباعة، ما أدى لضرورة تطوير خوارزميات أكثر ذكاءً وقابلية للتكيف مع هذه الظروف [7، 16].

3.1 نماذج تقليدية Traditional Models

في البداية، ركزت الأبحاث على أساليب تقليدية مثل استخدام خوارزميات كشف الحواف ومعالجة الصور باستخدام مرشحات بسيطة، والتي أظهرت تحديات كبيرة في التعامل مع الضوضاء والتشويش الموجود في الصور الناتجة عن المساحات الضوئية أو الكاميرات الرقمية منخفضة الجودة [12، 17، 13]. ومع زيادة الطلب على حلول أقل تكلفة وأكثر فعالية، برزت تقنيات جديدة تعتمد على المعالجة المسبقة المتقدمة، كاستخدام تقنيات تحسين التباين مثل (CLAHE) [1]، وطرق الفلترة مثل (Gaussian Blur) وتقنيات عتبة التكيف (Adaptive Thresholding)، التي وفرت قدرة أكبر على معالجة الصور وتحسين دقة الكشف [1، 13].

3.2. نماذج تقنيات التعلم الآلي Artificial Intelligence Models

ومع ظهور تقنيات التعلم الآلي والشبكات العصبية الاصطناعية، انتقلت الأبحاث إلى استخدام شبكات مثل Neocognitron لتحقيق أداء أفضل في كشف وتحديد العلامات الضوئية [11]. وعلى الرغم من أن هذه النماذج وفرت تحسينات ملحوظة مقارنة بالطرق التقليدية، إلا أنها ظلت محدودة من حيث القدرة على التعميم والتعامل مع البيئات والظروف المتنوعة.

3.3. نماذج شبكات عصبية عميقة Deep Neural Networks Models

في السنوات الأخيرة، شهد مجال OMR تقدماً كبيراً نتيجة إدخال نماذج كشف الكائنات المتقدمة القائمة على التعلم العميق، مثل عائلة نماذج YOLO التي برزت كحلول قوية لقدرتها على كشف العناصر بدقة عالية وبسرعة كبيرة [3]. ومع ذلك، أوضحت دراسات حديثة مثل دراسة Mondal وآخرين (2024) [3]، أن هذه النماذج تواجه تحديات واضحة عند محاولة اكتشاف العناصر الكبيرة مثل صناديق الإجابة، وذلك بسبب التقسيم الشبكي للصورة واعتماد هذه النماذج بشكل أساسي على التنبؤات المحلية لكل شبكة على حدة، مما يجعلها أقل فعالية في الحالات التي تتطلب معالجة سياق بصري واسع النطاق [3، 8].

لهذا السبب، برزت نماذج التقسيم الدلالي (Semantic Segmentation) المستندة إلى المحولات (Transformers)، كبديل فعال وواعد في هذا المجال [6، 9]. تستفيد هذه النماذج من آلية الانتباه الذاتي (Self-Attention)، التي تتيح لها فهم العلاقات السياقية بين الأجزاء المختلفة للصورة، مما يزيد من قدرتها على تحديد المناطق ذات الاهتمام مهما كانت كبيرة أو صغيرة، مع الحفاظ على كفاءة حسابية عالية [6]. ومن أبرز هذه النماذج نموذج SegFormer، الذي أظهر نتائج متقدمة في مهام التقسيم الدلالي في تطبيقات متنوعة كتصنيف الآفات الجلدية [5]، وتصنيف التعبيرات الوجهية [2]، وكذلك في تطبيقات رؤية الحاسوب العامة [6، 8].

كما بيّنت دراسة Khan وآخرين (2022) [6] أن النماذج المبنية على المحولات توفر قدرات فائقة على استيعاب العلاقات بعيدة المدى بين عناصر الصورة، ما يمنحها تفوقاً واضحاً مقارنة بالشبكات الترشيفية التقليدية (CNN)، التي تعتمد بشكل رئيسي على العمليات المحلية والمحدودة [8]. من ناحية أخرى، أثبت نموذج Vision Transformer (ViT) الذي قدمه Dosovitskiy

وآخرون (2020) [9]، قدرة متميزة في مهام التصنيف البصري المعقدة، ما شجع على توظيف تقنيات مشابهة في مجال OMR لتعزيز قدرة الأنظمة على التعامل مع البيانات التعليمية المعقدة. إضافة إلى تقنيات الكشف والتقسيم، اهتم الباحثون أيضاً بأساليب متقدمة في معالجة النتائج وتقييم دقتها، وذلك باستخدام مصفوفات الارتباك (Confusion Matrix) ومقاييس تقييم متقدمة مثل Precision، Recall، F1-Score و IoU [4، 15]. وقد أكدت هذه الدراسات أهمية اختيار مقاييس التقييم الصحيحة لتحديد مدى قدرة الأنظمة على الاستجابة لمتطلبات الواقع التعليمي بشكل دقيق [4، 15].

بناءً على ما سبق، تتضح أهمية الجمع بين تقنيات التعلم العميق المتقدمة مثل نماذج SegFormer، وتقنيات المعالجة الإحصائية للصورة والإسقاط الأفقي، من أجل تطوير أنظمة قادرة على تحقيق دقة عالية جداً في استخراج صناديق الإجابة وفقاعات الخيارات من أوراق الإجابة متعددة الخيارات، مع تحقيق أقصى قدر ممكن من المرونة والتكيف مع الظروف الواقعية التي تواجه هذه التطبيقات.

4. مواد وطرائق البحث

يستعرض هذا القسم توصيف مجموعة البيانات والنموذج والخوارزميات المستخدمة ومقاييس التقييم المعتمدة وتفاصيل بيئة التجربة.

1.4. توصيف مجموعة بيانات البحث Dataset

بدأ العمل بجمع أوراق امتحانية حقيقية من جامعة حمص، شملت نماذج متعددة لمقررات واختصاصات من السنوات الأولى وحتى الخامسة. كان الهدف من تنويع البيانات هو محاكاة سيناريوهات حقيقية متنوعة تعكس الفوارق في التنسيق الطباعي وعدد الأسئلة وتصميم شبكة الفقاعات وحالات التظليل الجزئي.

تم جمع الأوراق باستخدام طريقتين:

- المسح الضوئي باستخدام جهاز Ricoh 5400 Auto Feeder Scanner : تصوير 6400 صورة لأوراق إجابة متعددة الخيارات.
- التصوير اليدوي باستخدام هواتف محمولة: تصوير 3000 صورة لأوراق إجابة متعددة الخيارات بزوايا ميل مختلف وفي ظروف إضاءة متنوعة.

تضمنت الأوراق عدة عناصر بنيوية بالإضافة إلى رئيسي وهو صندوق الإجابة (answer_box) حيث يمثل صناديق الإجابة من كل ورقة، يحوي كل صندوق على 50 مستطيل يمثل فقاعات الأسئلة الامتحانية لاستخدامها لاحقاً في عينات التدريب والتحقق.

2.4. النماذج والخوارزميات المستخدمة

تضمنت منهجية البحث اعتماد مجموعة من النماذج والخوارزميات الحديثة والمتكاملة بهدف تحقيق دقة عالية في عملية استخراج وتحليل صناديق الإجابة وفقاعات الخيارات من أوراق الإجابة متعددة الخيارات. تم تقسيم العمل إلى مراحل متسلسلة، حيث يؤدي كل نموذج أو خوارزمية دوراً أساسياً ضمن إطار النظام الكلي. وفيما يلي توضيح للنماذج والخوارزميات المعتمدة:

1.2.4 نموذج SegFormer للتقسيم الدلالي

اعتمدت الدراسة على نموذج SegFormer-B0، وهو أحد نماذج التقسيم الدلالي (Semantic Segmentation) القائمة على بنية المحولات (Transformers). يتميز النموذج بقدرته على استخلاص مناطق الاهتمام في الصور، وتحديد صناديق الإجابة بدقة عالية. تم تدريب النموذج على صور بحجم 1024×1024 بكسل باستخدام خوارزمية AdamW ودالة خسارة CrossEntropyLoss، واعتمد إخراج النموذج على أقنعة ثنائية الفئة (صندوق الإجابة/خلفية). يعد نموذج SegFormer-B0 من النماذج الحديثة والفعالة في مجال التقسيم الدلالي للصور (Semantic Segmentation)، حيث يعتمد على بنية المحولات (Transformers) بدلاً من الشبكات العصبية الترشيحية التقليدية (CNN). يمتاز SegFormer بكونه يجمع بين الدقة العالية في تحديد حدود الكائنات داخل الصور وبين كفاءته الحسابية، ما يجعله مناسباً للتطبيقات العملية واسعة النطاق مثل استخراج مناطق الإجابة من أوراق الامتحانات.

1.1.2.4 بنية النموذج

يعتمد SegFormer على تصميم هرمي متعدد المستويات، حيث يتم استخراج التمثيلات المميزة من الصورة عبر مراحل متعددة. تستخدم كل مرحلة آلية Attention مخصصة، ما يسمح للنموذج بفهم العلاقات السياقية بين الأجزاء المختلفة من الصورة على المدى البعيد والقصير معاً. على عكس شبكات CNN التي تعتمد على نطاق استقبال محلي محدود

(receptive field)، تتيح بنية Transformers للنموذج استيعاب بنية الصورة بالكامل وفهم حدود الكائنات الكبيرة والصغيرة بنفس الكفاءة [6، 7].

2.1.2.4 مميزات SegFormer

دقة عالية في التقسيم: يحقق النموذج أداءً متفوقاً في تحديد مناطق الاهتمام حتى في ظل اختلاف الإضاءة أو جودة الطباعة.

كفاءة حسابية: تم تصميم النموذج ليكون خفيفاً من حيث عدد المعاملات الحسابية (Parameters)، مما يسمح بتدريبه وتشغيله بكفاءة حتى على موارد عتادية محدودة. مرونة مع اختلاف أبعاد الكائنات: قادر على معالجة واكتشاف العناصر البنيوية الكبيرة مثل answer box والعناصر الصغيرة بنفس الدقة، وهو ما يمثل نقطة قوة مقارنة بنماذج YOLO أو نماذج CNN التقليدية [6، 7].

قابلية التعميم: أظهر النموذج قدرة على التكيف مع صور متنوعة المصدر، سواء كانت ممسوحة ضوئياً أو ملتقطة بكاميرا محمولة، دون الحاجة لتعديلات جوهرية على البنية.

3.1.2.4 آلية الاستخدام في البحث:

تم تدريب نموذج SegFormer-B0 على مجموعة بيانات موسومة يدوياً، حيث اعتبر كل بكسل في الصورة إما ينتمي إلى فئة "صندوق الإجابة" أو "الخلفية". تم توحيد حجم جميع الصور إلى 1024×1024 بكسل، واستخدمت خوارزمية AdamW كخوارزمية تحسين، بينما تم اعتماد دالة CrossEntropyLoss لاحتساب الخسارة. بعد التدريب، تمكن النموذج من توليد قناع دلالي ثنائي الفئة بدقة شبه تامة، بحيث تمثل المنطقة المصنفة كصندوق إجابة أساساً لعمليات التقسيم والتحليل اللاحقة.

4.1.2.4 سبب اختيار النموذج

تم اختيار SegFormer تحديداً لما يوفره من توازن بين الأداء والكفاءة الحسابية، ولأن بنيته المبنية على المحولات تمنحه ميزة استثنائية في استيعاب السياق العام للصورة، الأمر الذي يتفوق فيه على نماذج مثل YOLO التي غالباً ما تقشل في اكتشاف أو تحديد العناصر الكبيرة التي تغطي مساحات واسعة من الصورة. وبذلك شكل SegFormer خياراً مثالياً

كمرحلة ثانية بعد استخراج العناصر البنيوية في منظومة معالجة وتصحيح أوراق الإجابة متعددة الخيارات.

2.2.4 خوارزمية الإسقاط الأفقي والتقسيم الصفي

تم تطوير خوارزمية متكيفة تعتمد على الإسقاط الأفقي (Horizontal Projection) وتحليل القناة الحمراء (Red Channel Analysis) لتحديد وفصل صفوف الأسئلة داخل صندوق الإجابة. تعتمد هذه الخوارزمية على حساب إسقاط كثافة البكسلات عمودياً، وتطبيق عتبات ديناميكية لتحديد مواضع الصفوف بدقة، مع دعم آلية احتياطية (Fallback) لضمان استمرارية الأداء في حال عدم وضوح المؤشرات.

تعتمد خوارزمية الإسقاط الأفقي والتقسيم الصفي على سلسلة خطوات دقيقة لضمان استخراج المستطيلات على شكل صناديق يمثل كل صندوق منها سؤال يحوي على فقاعات الإجابة مبينة في الخوارزمية 1:

الخوارزمية 1 - خوارزمية الإسقاط الأفقي والتقسيم الصقي

— المدخلات: صورة صندوق الإجابة (answer box) بعد القص والمعالجة المبدئية.
— المخرجات: صور منفصلة لكل سطر أسئلة Q01.png إلى Q50.png

1. بداية الخوارزمية
2. تحسين الصورة (Preprocessing)
 - تحويل الصورة إلى تدرج رمادي.
 - تطبيق CLAHE لتحسين التباين.
 - تطبيق Gaussian Blur لإزالة التشويش.
 - تطبيق Adaptive Thresholding لاستخراج حدود الفقاعات وتوضيح التباين.
3. إسقاط الخطوط (Horizontal Projection)
 - جمع القيم عبر كل صف (axis=1) لإسقاط الصورة إلى بُعد واحد.
 - توليد ملف إسقاط أفقي يوضح توزيع الكثافة السوداء (intensity) في الصفوف.
4. اكتشاف الخطوط الأفقية الفاصلة (Dynamic Thresholding)
 - حساب العتبة الديناميكية:
 - $\text{threshold} = \text{mean} + 0.8 * \text{std}$ للإسقاط.
 - تم أخذ العتبة 0.8 تجريبياً لأنه يجب أن يحقق الحد الفاصل بين كل سؤال والذي يليه أكثر من 80% من العرض الكلي الخاص بكل answer box.
 - تحديد المؤشرات ذات الكثافة العالية، والتي تمثل الفواصل بين الأسطر.
5. استخراج مستطيلات الأسطر (Row Region Detection)
 - دمج المؤشرات القريبة (بفارق أقل من 5 بيكسل) لتكوين حدود كل سطر. (y1, y2)
 - اعتبار كل زوج (y1, y2) يمثل بداية ونهاية سطر أسئلة.
6. معالجة الحالات الخاصة (Fallback Row Splitting)
 - إذا لم يتم اكتشاف 50 أو 51 سطراً بوضوح:
 - تفعيل الوضع الاحتياطي: (fallback) تقسيم الصورة إلى ارتفاعات متساوية بناءً على عدد الأسطر المتوقع.
7. تحسين تقطيع fallback باستخدام الحواف الحمراء (Red Edge Refinement)
 - في الوضع الاحتياطي فقط، استخدام Red Projection (فرق القناة الحمراء عن المتوسط) لتعديل y2 بدقة لكل سطر.
 - تحسين دقة نهاية كل سطر وتجنب التداخل.
8. تقطيع الأسطر وحفظها (Row Cropping and Saving)
 - قص كل سطر من الصورة الأصلية باستخدام الإحداثيات. (y1, y2)
 - حفظ كل سطر كصورة منفصلة بالترتيب. (Q01.png, Q02.png, ... Q50.png)
9. التحقق البصري (Debug Visualization)
 - عرض مراحل التقطيع (الصورة الأصلية، الرمادية، المعالجة، الإسقاط الأحمر) باستخدام matplotlib.
 - حفظ هذه النتائج للمرجعة اليدوية.
10. إرجاع النتائج
 - صور الأسطر المقسمة جاهزة للمعالجة اللاحقة.

3.2.4 خوارزمية اكتشاف الفقاعات DBSCAN

تبعد تقسيم الصندوق إلى صفوف، استُخدمت خوارزمية التجميع المكاني DBSCAN (Density-Based Spatial Clustering of Applications with Noise) لاكتشاف مواقع الفقاعات الفردية ضمن كل صف. تتيح هذه الخوارزمية تجميع النقاط القريبة وفصل الفقاعات المظلمة فعلياً عن الضوضاء أو العلامات غير المقصودة، مما يرفع من موثوقية النتائج في ظروف الطباعة أو التصوير غير المثالية.

تعتمد خوارزمية اكتشاف الفقاعات على سلسلة خطوات دقيقة لضمان استخراج فقاعات الإجابة على شكل صناديق يمثل كل صندوق منها فقاعة إجابة مبيّنة في الخوارزمية 2:

الخوارزمية 2 - خوارزمية اكتشاف الفقاعات DBSCAN

— المدخلات: صورة سطر سطر (بعد التقسيم الصف) —

○ تحديد المجموعة ذات أكبر مساحة محاطة كمجموعة مرشحة تمثل الفقاعة الفعلية في هذا العمود.

6. استخراج الفقاعة بدقة: (Precise Bubble Extraction)

○ حساب المستطيل المحيط (Bounding Box) حول المجموعة المختارة من نقاط DBSCAN.

○ قص صورة الفقاعة بدقة من العمود، وحفظها في ملف منفصل مع تسمية واضحة (A, B, C, D, E).

7. التحقق البصري: (Debug Visualization)

○ رسم مستطيل حول كل فقاعة مكتشفة على صورة السطر الأصلية مع وضع الحرف المقابل (A-E).

○ حفظ الصورة الناتجة ضمن مجلد Debug للمراجعة اليدوية والتدقيق البصري.

8. إرجاع النتائج:

○ صور الفقاعات الخمسة (A-E) جاهزة للمعالجة أو التصنيف اللاحق.

9. نهاية الخوارزمية

الصغيرة في الفقاعات.

4. اكتشاف الفقاعات (Contours Detection)

○ استخراج جميع الكنتورات (Contours) داخل كل عمود.

○ تم استخراج الكنتورات باستخدام خوارزمية DBSCAN الموضحة في الخطوة 5.

○ فلتر الكنتورات بناءً على معايير الحجم (Area) والنسبة البعدية (Aspect Ratio)، لاستبعاد الضجيج والعناصر غير المنطقية.

5. تجميع باستخدام DBSCAN (Bubble Clustering)

○ حساب مركز كل فقاعة (Center Point) في العمود.

○ تطبيق خوارزمية DBSCAN لتجميع المراكز القريبة ضمن نفس الفقاعة، دون الحاجة لتحديد عدد الفقاعات مسبقاً.

5. التجارب والنتائج ومناقشتها

1.5. بيئة التجريب

تم تنفيذ عملية تدريب النماذج واختبارها ضمن بيئة Google Colab Pro، والذي بدوره وفر إمكانيات مناسبة للتعامل مع النماذج العميقة والبيانات بدقة عالية، تضمنت البيئة التقنية المستخدمة وحدة معالجة مركزية Intel Xeon سداسية النوى (6 cores) مع 12 خيط معالجة (threads)

بسرعة 2.2 جيجاهرتز، مما أتاح معالجة متوازية فعالة خلال تحميل البيانات والتدريب. كما تم تخصيص 83.5 جيجابايت من الذاكرة العشوائية (RAM) مما ساهم في تسريع عمليات التخزين المؤقت وتخفيض معدلات التباطؤ الناتجة عن نقص الذاكرة أثناء التدريب. أما فيما يخص وحدة المعالجة الرسومية (GPU) فقد تم استخدام بطاقة NVIDIA A100 ذات ذاكرة من نوع HBM2 بسعة 40 جيجابايت، والتي تعتبر من أقوى بطاقات المعالجة المخصصة لتدريب نماذج التعلم العميق، وخاصة مع الصور الكبيرة ومعالجة المهام المتعددة. ساهمت هذه البيئة في تسريع التدريب بشكل كبير مما سمح بتحقيق كفاءة حسابية عالية أثناء تنفيذ جميع مراحل ضبط النموذج وتقييمه.

2.5. مقاييس تقييم الأداء

لقياس فعالية النماذج المدربة على كشف عناصر بنوية في الورقة الامتحانية، تم اعتماد مجموعة من المعايير المعروفة في مجال الرؤية الحاسوبية والتي تُمثل الأساس في تقييم نماذج التعرف على الأشياء. شملت هذه المقاييس:

(1) مصفوفة الالتباس (Confusion Matrix)

تُستخدم مصفوفة الالتباس لعرض نتائج اكتشاف النموذج ضمن أربع حالات رئيسية [19]:

- TP (True Positive): اكتشف النموذج العنصر بشكل صحيح.
- TN (True Negative): لم يكتشف النموذج العنصر وكان فعلاً غير موجود.
- FP (False Positive): اكتشف النموذج عنصر لم يكن موجود.
- FN (False Negative): لم يكتشف النموذج العنصر رغم أنه كان موجود بالفعل.

(2) التقاطع على الاجتماع (IoU - Intersection over Union)

ظهر تحديد موقع العناصر بأفضل دقة ممكنة كمهمة رئيسية عند استخدام نماذج التعرف على الأشياء. يوضح الشكل 3 وجود صندوقين محاطين أحدهما باللون الأسود يمثل المربع المحيط بقاعدة الحقائق الأساسية للعنصر، والآخر باللون الأبيض يمثل ناتج تنبؤ نموذج الكشف، نلاحظ أنهما لا يتداخلان بشكل تام لذلك نحتاج إلى قياس مدى تطابق أو سوء تطابقهما كنتيجة دقة اكتشاف حدود العنصر، لذا يتم حساب التقاطع على الاجتماع IoU بقسمة مساحة تقاطع الصندوقين على مساحة اجتماعهما كما هو موضح في الشكل، ويتم اعتبار التعرف أفضل كلما

اقتربت قيمة IoU من 1، ويتم اعتبار التوقع جيد عندما تتجاوز قيمة IoU عتبة محددة (مثل 0.5) [19]:

$$IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$

الشكل 1 - علاقة التقاطع على الاجتماع (IoU) [19]

(3) متوسط الدقة (mean Average Precision – mAP)

عند تقييم جودة نماذج الكشف عن الأشياء يُعد مقياس mAP من أكثر مؤشرات الأداء استخداماً، يقيس متوسط دقة التوقعات عبر جميع الفئات بناءً على مدى تطابق الصناديق المتوقعة مع الصناديق الحقيقية ضمن مستويات مختلفة من التداخل الهندسي. تم في هذه الدراسة استخدام معيارين رئيسيين [19,15]:

- $mAP@0.5$: يتم اعتبار التوقع صحيح عندما يكون تقاطع المساحة بين الصندوق المتوقع والحقيقي $(IoU) \geq 0.5$.
- $mAP@0.5:0.95$: وهو متوسط الدقة عند عشر عتبات مختلفة من IoU (من 0.5 إلى 0.95 بفواصل 0.05)، ويُعتبر المقياس الأكثر صرامة لقياس دقة التحديد.

يمكن حساب متوسط الدقة الكلي mAP من أجل n فئة وفق العلاقة (1) [19,15]:

$$mAP = \frac{\sum_{i=0}^n AP_i}{n}$$

حيث أن AP متوسط الدقة للفئة i، ونقيس قدرة النموذج على اكتشاف الإيجابيات الحقيقية

(TP) من بين جميع التوقعات الإيجابية (TP+FP) لها وتحسب وفق العلاقة (2):

$$AP = \frac{TP}{TP + FP}$$

4) مقاييس أخرى

يستخدم البحث أيضاً عدد من المقاييس وهي: الدقة Accuracy والإحكام Precision والاستدعاء Recall ومقياس إف1 F1-Score. تُحسب هذه المقاييس وفق المعادلات التالية [15]:

$$\text{الدقة} = \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{الإحكام} = \frac{TP}{TP + FP}$$

$$\text{الاستدعاء} = \frac{TP}{TP + FN}$$

$$\text{مقياس إف1} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

3.5. تقسيم مجموعة البيانات

تم تقسيم مجموعة البيانات المكونة من 300 صورة تضم أوراق الإجابة التي سميت في مرحلة تحضير البيانات (200 منها بشكل يدوي و100 صورة تم تسميتها بشكل شبه آلي باستخدام نموذج مدرب مسبقاً) إلى ثلاث مجموعات وهي مجموعة التدريب Training (70%) من مجموعة البيانات الكلية) ومجموعة التحقق Validation (15%) ومجموعة الاختبار Testing (15%).

4.5. الضبط الدقيق لنموذج SegFormer

لتحقيق تم ضبط نموذج SegFormer-B0 بعناية لضمان أداء عالٍ في مهمة التقسيم الدلالي لصناديق الإجابة. يوضح الجدول التالي أهم إعدادات ومعايير التدريب، مع شرح موجز لكل منها:

الجدول 1 - إعدادات تدريب نموذج SegFormer

المكوّن / المعامل	القيمة	الشرح
النموذج المستخدم	SegFormer-B0 (Transformers)	نموذج تقسيم دلالي حديث يعتمد على بنية المحولات (Transformers)
نوع التعلم	Semantic Segmentation	تقسيم الصورة إلى مناطق دلالية (صندوق إجابة/خلفية)
عدد الفئات	2	0 خلفية، 1 صندوق إجابة
حجم الصورة	1024 × 1024	توحيد أبعاد جميع الصور لتسهيل التدريب والمعالجة
نوع الإخراج	قناع ثنائي الفئة	صورة لكل بكسل تحدد ما إذا كان ينتمي للصندوق أم الخلفية
المحسن	AdamW	إصدار محسن من Adam مناسب لنماذج Transformers
دالة الخسارة	CrossEntropyLoss	تقيس الخطأ في تصنيف كل بكسل داخل القناع
عدد الدورات (Epochs)	50	عدد مرات مرور النموذج على مجموعة البيانات كاملة
حجم الدفعة (Batch Size)	8	عدد الصور التي تُستخدم في كل خطوة تدريبية واحدة

5.5. نتائج أداء نموذج SegFormer المدرب

تم تقييم أداء النموذج النهائي SegFormer المدرب على مجموعة اختبار تتألف من 30 صورة تنوعت من حيث جودة التصوير ووجود الميلاق.

1.5.5 الأداء الإجمالي للنموذج


أظهرت النتائج أداء مميز في جميع المقاييس كما هو موضح في الجدول 5 أدناه:
الجدول 2 - نتائج اختبار الأداء الإجمالي SegFormer على 300 ورقة


المقياس	القيمة
Accuracy	0.9977
Precision	0.9970

استخراج فقاعات الإجابة من أوراق الإجابة متعددة الخيارات باستخدام نموذج SegFormer وتقنيات تحليل الصورة

المقياس	القيمة
Recall	0.9961
F1 Score	0.9965
IoU (Jaccard)	0.9931

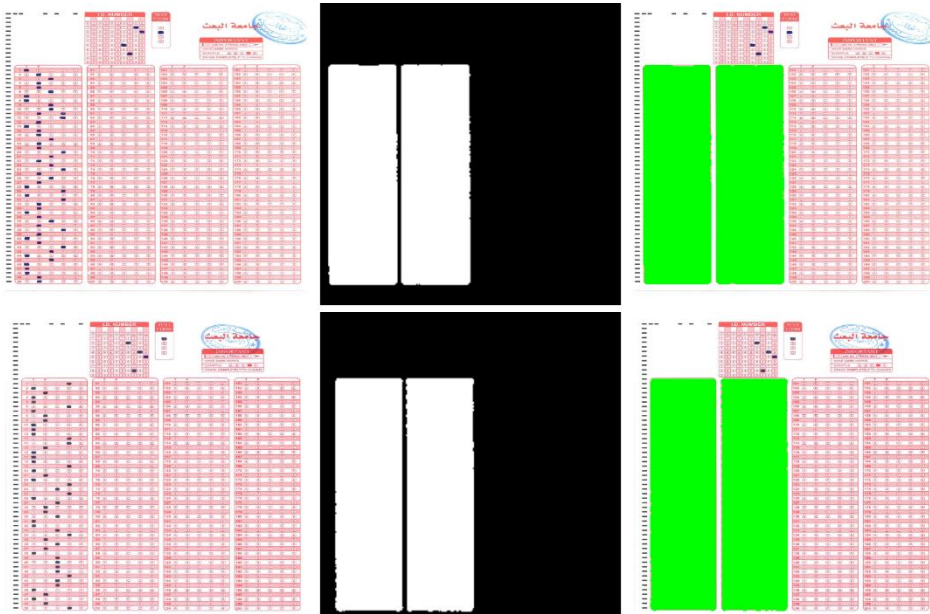
توضح الصور التالية المبينة في الشكل 2 نتائج الكشف على ثلاث صور بحيث يبين الشكل الصورة الاصلية وبجانبها القناع الخاص اضمن تسمية البيانات وبجانبه القناع الناتج من توقع النموذج SegFormer، وأظهرت الصور المخرجة دقة تحديد ممتازة لصندوقتي الإجابة في كل ورقة:






الشكل 2 - صور توضيحية لنتائج اختبار أداء نموذج الكشف SegFormer

وتوضح الصور التالية المبينة في الشكل 3 نتائج الكشف على ثلاث صور بحيث يبين الشكل الصورة الاصلية وبجانبها القناع الذي نتج عن النموذج بالإضافة الى الجزء المقطع من الصورة باللون الأخضر في القسم الثالث:



استخراج فقاعات الإجابة من أوراق الإجابة متعددة الخيارات باستخدام نموذج SegFormer وتقنيات تحليل الصورة



الشكل 3 - صور توضيحية لنتائج اختبار أداء النموذج على الصور ويظهر القسم المقطع بالأخضر

وتوضح الصور التالية المبينة في الشكل 4 والذي يظهر أربع صناديق إجابة مقطوعة من اثنتين من الصور الأصلية:

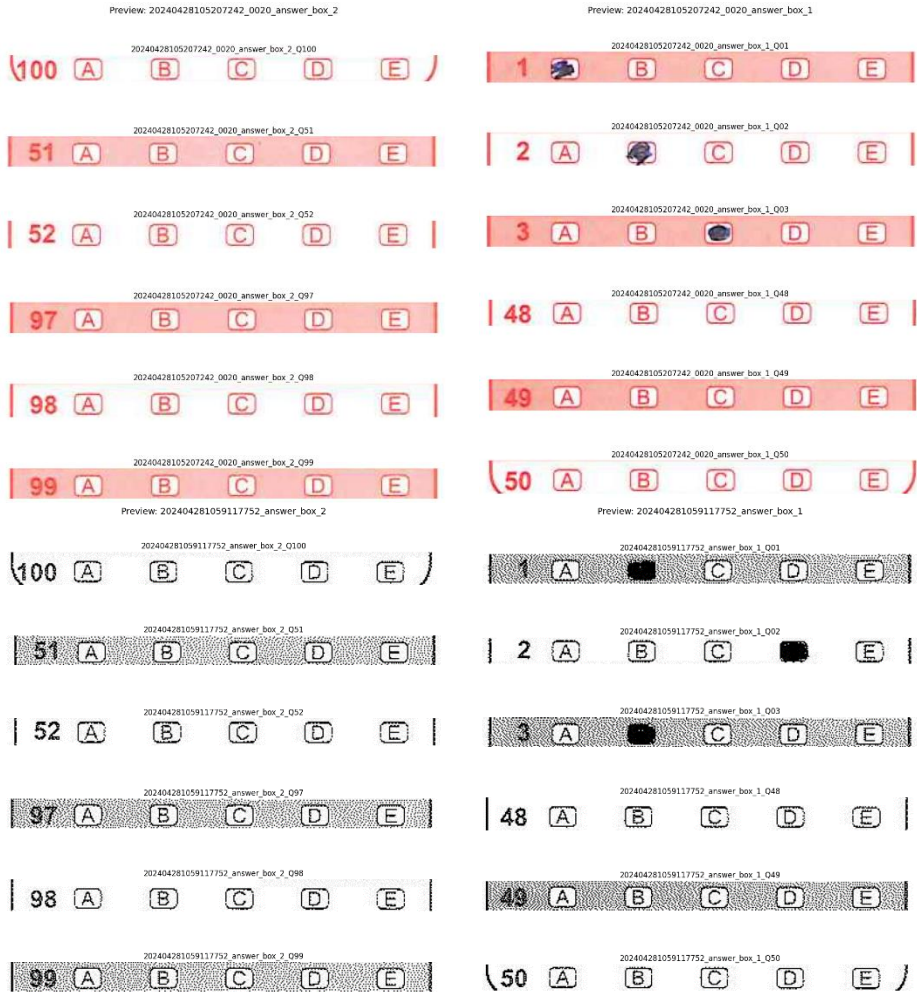
الشكل 4 - صور توضيحية لنتائج صناديق الإجابة المقطوعة من الصور الأصلية

6.5. نتائج تطبيق خوارزمية الإسقاط الأفقي والتقسيم الصفّي

أظهرت خوارزمية الإسقاط الأفقي والتقسيم الصفّي فعالية عالية في فصل صندوق الإجابة إلى صفوف أسئلة بشكل دقيق وموثوق. نجحت الخوارزمية في تحديد معظم الحدود الفاصلة بين الصفوف حتى في حالات اختلاف الطباعة أو وجود ضجيج بصري، كما أن آلية fallback تضمنت استمرار عملية التقطيع بشكل صحيح في الحالات الصعبة. أدى ذلك إلى تحقيق معدل دقة مرتفع في استخراج صفوف الأسئلة بشكل مستقل، مما سهل لاحقاً عمليات اكتشاف الفقاعات وتصنيفها، وساهم في تحسين جودة البيانات المدخلة للمراحل اللاحقة من النظام.


توضح المخرجات المعروضة في الشكل 5 إظهار اقتطاع أول 3 صناديق أسئلة وآخر 3 صناديق أسئلة من صور صناديق الإجابة الخاصة بعدة أوراق امتحانية

استخراج فقاعات الإجابة من أوراق الإجابة متعددة الخيارات باستخدام نموذج SegFormer وتقنيات تحليل الصورة



الشكل 5 - صور توضيحية لنتائج تطبيق خوارزمية الإسقاط الأفقي والتقسيم الصفّي

توضح المخرجات المعروضة في الشكل 6 إظهار الصناديق الخاصة بكل الأسئلة مرسومة بشكل كامل على صور صناديق الإجابة الخاصة بعدة أوراق امتحانية



الشكل 6 - صور توضيحية لنتائج تطبيق خوارزمية الإسقاط الأفقي والتقسيم الصفّي على الصور الخاصة بصناديق الإجابة كاملة

7.5. نتائج تطبيق خوارزمية اكتشاف الفقاعات DBSCAN

أثبتت خوارزمية DBSCAN فعالية كبيرة في اكتشاف وتحديد مواقع الفقاعات داخل كل صف من صفوف الإجابة، حتى في ظل وجود تداخل أو تشويش ناتج عن اختلاف الطباعة أو جودة المسح الضوئي. نجحت الخوارزمية في تجميع المراكز الحقيقية للفقاعات وفصلها عن العلامات الوهمية أو الضجيج، ما أدى إلى رفع دقة النقطيع واستخلاص الفقاعات بشكل مستقل وواضح. كما ساعدت في ضبط حدود الفقاعات بدقة عالية بغض النظر عن شكلها أو تباين الإضاءة داخل


استخراج فقاعات الإجابة من أوراق الإجابة متعددة الخيارات باستخدام نموذج SegFormer وتقنيات تحليل الصورة

العمود، وساهمت في إنتاج صور فقاعات جاهزة لمرحلة التصنيف الآلي بدقة وموثوقية عالية، كما هو مبين في الصورة المرفقة في الشكل 7.



الشكل 7 - صور توضيحية لنتائج تطبيق خوارزمية اكتشاف الفقاعات DBSCAN

وبين الشكل 8 صور الفقاعات الناتجة التي سيتم تمريرها لاحقاً إلى المصنف الذي سوف يصنف كل صورة فقاعة ضمن 3 صفوف (مشطوبة - مملوءة - فارغة)



الشكل 8 - صور للفقاعات الناتجة ضمن 3 صفوف

6. الاستنتاجات والتوصيات

أظهرت نتائج هذه الدراسة أن توظيف النماذج الحديثة للتقسيم الدلالي، وتحديدًا نموذج SegFormer-B0، يشكل نقلة نوعية في معالجة أوراق الإجابة متعددة الخيارات، خصوصاً في المهام المتعلقة باستخراج صناديق الإجابة بدقة عالية بغض النظر عن اختلاف جودة الطباعة أو ظروف التصوير. لقد بينت التجارب أن استخدام SegFormer يمكن النظام من تحقيق عزل شبه تام لصندوق الإجابة، مما وفر أساساً قوياً ودقيقاً لبقية مراحل التحليل والتقطيع اللاحقة.

كما أثبتت خوارزمية الإسقاط الأفقي والتقسيم الصفّي فاعليتها في تقسيم صندوق الإجابة إلى صفوف متجانسة حتى في حالات وجود ضجيج أو عدم وضوح الحدود الطباعية، مستفيدة من

آليات التكيف والحسابات الإحصائية الديناميكية. وعززت آلية fallback من مرونة النظام، حيث ضمنت استمرارية التقطيع وجودته في الحالات الاستثنائية، مما ساعد على توليد بيانات منظمة وموثوقة لمرحلة اكتشاف الفقاعات.

أما على مستوى اكتشاف الفقاعات، فقد أظهرت خوارزمية DBSCAN قدرة كبيرة على تجميع مراكز الفقاعات الحقيقية وفصلها عن الضجيج أو العلامات غير المقصودة، حتى في الصور منخفضة الجودة أو ذات التباين الضوئي الحاد. وكنتيجة لذلك، أمكن استخراج الفقاعات الفردية بشكل دقيق، مما مهد لمرحلة التصنيف الآلي دون الحاجة لتدخل يدوي أو تصحيحات لاحقة.

انطلاقاً من هذه النتائج، توصي الدراسة بما يلي:

- اعتماد نهج التقسيم الدلالي المدعوم بالمحولات مثل SegFormer كخيار أولي في مهام فصل العناصر البنيوية الكبيرة داخل أوراق الإجابة، نظراً لمرونته وقابليته العالية للتعميم على بيانات جديدة.
- الاستمرار في تطوير خوارزميات الإسقاط والتقسيم التكيفي مع دمج مؤشرات إضافية من القنوات اللونية أو أساليب تعزيز التباين لضمان دقة أكبر في أصعب السيناريوهات.
- توظيف خوارزميات التجميع الذكي مثل DBSCAN كأداة موثوقة في فصل الفقاعات، خصوصاً في الأوراق التي تعاني من ضجيج بصري أو تظليل غير منتظم.
- توسيع نطاق التقييم ليشمل مجموعات بيانات أكبر ومتنوعة تغطي مختلف ظروف التصوير والطباعة، من أجل تعزيز ثقة المجتمع البحثي بتعميم النظام واقتراحه كحل قياسي في المؤسسات التعليمية.
- دعم مخرجات النظام بواجهات تحقق بصري (Debug Visualization) لتتيح للمستخدم النهائي مراجعة النتائج وتدقيقها بسهولة، ما يرفع من موثوقية وأمان النظام في بيئة العمل الفعلي.

7. المراجع:

- [1] Mai, J., Gao, C., & Bao, J. (2025). Domain generalization through data augmentation: A survey of methods, applications, and challenges. *Mathematics*, 13(5), 824.
- [2] Shen, Z. (2024). A comparative study of hybrid CNN and Vision Transformer models for facial emotion recognition. *IEEE International Conference on Dependable Systems and Their Applications (DSA)*, 401–408.
- [3] Mondal, S., De, P., Malakar, S., & Sarkar, R. (2024). OMRNet: A lightweight deep learning model for optical mark recognition. *Multimedia Tools and Applications*, 83(5), 14011–14045.
- [4] Obi, J. C. (2023). A comparative study of several classification metrics and their performances on data. *World Journal of Advanced Engineering Technology and Sciences*, 8(1), 308–314.
- [5] Nie, Y., Sommella, P., Carratù, M., O'Nils, M., & Lundgren, J. (2022). A deep CNN transformer hybrid model for skin lesion classification of dermoscopic images using focal loss. *Diagnostics*, 13(1), 72.
- [6] Khan, S., Naseer, M., Hayat, M., Zamir, S. W., Khan, F. S., & Shah, M. (2022). Transformers in vision: A survey. *ACM Computing Surveys (CSUR)*, 54(10s), 1–41.
- [7] DE Elias, E., Tasinaffo, P., & Hirata, R. (2021). Optical mark recognition: Advances, difficulties, and limitations. *SN Computer Science*, 2(5), 367.
- [8] Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., & Ghayvat, H. (2021). CNN variants for computer vision: History, architecture, application, challenges and future scope. *Electronics*, 10(20), 2470.
- [9] Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., & Houshy, N. (2020). An image is worth 16×16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*.

- [10] Afifi, M., & Hussain, K. F. (2019). The achievement of higher flexibility in multiple-choice-based tests using image classification techniques. *International Journal on Document Analysis and Recognition (IJDAR)*, 22, 127–142.
- [11] Gorokhovatskyi, O. (2016). Neocognitron as a tool for optical marks recognition. *IEEE International Conference on Data Stream Mining & Processing (DSMP)*, 169–172.
- [12] Patel, R., Sanghavi, S., Gupta, D., & Raval, M. S. (2015). CheckIt–A low cost mobile OMR system. *IEEE TENCON Region 10 Conference*, 1–5.
- [13] Sanguansat, P. (2015). Robust and low-cost Optical Mark Recognition for automated data entry. *IEEE International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, 1–5.
- [14] Parul, H. M., & Kaur, M. (2012). A novel optical mark recognition technique based on biogeography based optimization. *International Journal of Information Technology and Knowledge Management*, 5(2), 331–333.
- [15] Ting, K. M. (2011). Confusion Matrix. In Sammut, C., & Webb, G. I. (Eds.), *Encyclopedia of Machine Learning* (pp. 209–209). Springer, Boston, USA.
- [16] Zampiroli, F., Gonzalez, J. A. Q., & Neves, R. D. O. (2010). Automatic correction of multiple-choice tests using digital cameras and image processing. *Universidade Federal do ABC, Brazil*.
- [17] Deng, H., Wang, F., & Liang, B. (2008). A low-cost OMR solution for educational applications. *IEEE International Symposium on Parallel and Distributed Processing with Applications*, 967–970.
- [18] Hussmann, S., & Deng, P. W. (2005). A high-speed optical mark reader hardware implementation at low cost using programmable logic. *Real-Time Imaging*, 11(1), 19–30.
- [19] Imran, A.I., Imran, B. 2023 Improved YOLOv3–Tiny model for human detection, *Al-Baath University Journal – Series of Mechanical, Electrical and Informatics Engineering Sciences*, Vol. 45(82), 211–222.

استخراج فقاعات الإجابة من أوراق الإجابة متعددة الخيارات باستخدام نموذج SegFormer وتقنيات تحليل الصورة

اكتشاف وتحليل العناصر البنيوية في أوراق الإجابة متعددة الخيارات باستخدام YOLO v11 – دراسة مطبقة على بيانات واقعية

المهندس محمد أحمد علي¹

إشراف: الدكتورة اليدا إسبر² الدكتور سهيل الحمود³

الملخص

تهدف هذه الدراسة إلى تطوير نظام آلي لاكتشاف وتحليل العناصر البنيوية في أوراق الإجابة متعددة الخيارات، باستخدام تقنيات الرؤية الحاسوبية ونموذج YOLO v11. يركز النظام على كشف أربعة عناصر أساسية داخل الورقة الامتحانية: المعلّات العمودية والمعلّات الأفقية وصندوق رقم الطالب وصندوق نموذج الامتحان. كما يتضمن آلية تصحيح هندسي مزدوج (Affine + Perspective) تعتمد على مجموعة من المعلّات المرجعية ضمن 69 معلمة داخلية، بهدف تسوية الورقة وإزالة الانحرافات الناتجة عن ظروف التصوير غير المثالية.

تم تدريب النموذج على أوراق من مجموعة بيانات حقيقية من جامعة حمص، وتضم حوالي 9400 ورقة امتحانية تم تصويرها باستخدام مساحات ضوئية وكاميرات هواتف محمولة واستخدمت أداة Label Studio في عملية تسمية البيانات وسرعت العملية بالاعتماد على التسمية المدعومة بالتعلم الآلي (ML-Assisted Labeling). أظهرت النتائج أن متوسط الدقة (mAP) عند عتبة التقاطع على الاجتماع (IoU=0.5) بلغ 99.5%، في حين وصل المتوسط الحسابي للدقة عند عتبات IoU ضمن النطاق [0.5:0.95] إلى 93.64% حيث بينت هذه النتائج كفاءة النظام في التكيف مع اختلاف تصميمات أوراق الإجابة وتنوع ظروف التصوير.

الكلمات المفتاحية: التعرف الآلي على العلامات (OMR)، تسمية البيانات (Data Labeling)، YOLO v11، تصحيح الميل، الرؤية الحاسوبية.

¹ طالب دكتوراه - قسم هندسة البرمجيات ونظم المعلومات - كلية الهندسة المعلوماتية - جامعة حمص - سورية

² أستاذ مساعد - قسم هندسة البرمجيات ونظم المعلومات - كلية الهندسة المعلوماتية - جامعة حمص - سورية

³ مدرس - قسم هندسة البرمجيات ونظم المعلومات - كلية الهندسة المعلوماتية - جامعة حمص - سورية

Detection and Analysis of Structural Elements in Multiple-Choice Answer Sheets Using YOLO v11 – An Applied Study on Real-World Data

Eng. Mohammad Ahmad Ali

Supervision: Dr. Alida Isber

Dr. Suhel Hammoud

ABSTRACT

This study aims to develop an automated system for detecting and analyzing structural elements in multiple-choice answer sheets using computer vision techniques and the YOLO v11 model. The system focuses on detecting four essential components within the exam sheet: vertical markers, horizontal markers, the student ID box, and the exam test form box. It also incorporates a dual-stage geometric correction mechanism (Affine + Perspective) based on a set of 69 internal reference markers, with the goal of rectifying the sheet and eliminating distortions caused by suboptimal imaging conditions.

The model was trained on a real-world dataset from the University of Homs, comprising approximately 9,400 exam sheets captured using scanners and mobile phone cameras. The data labeling process utilized the Label Studio tool, and the annotation process was expedited by leveraging machine learning-assisted labeling (ML-Assisted Labeling). The results showed that the mean Average Precision (mAP) at an Intersection over Union threshold of 0.5 (IoU=0.5) reached 99.5%, while the mean Average Precision across IoU thresholds in the range [0.5:0.95] reached 93.64%. These results demonstrate the system's effectiveness in adapting to variations in answer sheet designs and diverse imaging conditions.

Keywords: YOLO v11, answer sheets, skew correction, computer vision, Label Studio

1. مقدمة

أصبحت الحاجة إلى أنظمة تصحيح مؤتمتة وموثوقة لأوراق الإجابة متعددة الخيارات أمر ملح وهام خصوصاً مع الاهتمام المتزايد في التحول الرقمي حول العالم والتقدم المتسارع له بكل القطاعات بما فيها القطاع الأكاديمي وفي مؤسسات التعليم العالي ومع التضخم الكبير لأعداد الطلاب. وتعتمد أنظمة أتمتة الاختبارات على تقنيات تقليدية في معالجة صور أوراق الإجابة وتقييمها رغم توافر تقنيات التعرف الآلي على العلامات (OMR) منذ عشرات السنوات، بسبب اعتمادها على الكثير من الشروط التي تحد من استخدامها في الواقع ومن دقة تقييمها كأن تكون الورقة ممسوحة بدقة مثالية[1].

تعيق دقة هذه الأنظمة مجموعة من التحديات تجعلها معرضة لأخطاء متكررة في المؤسسات التعليمية التي تعتمد لغات مختلفة ويكون النظام غير مجهز مسبقاً للتعامل معها مثل مشاكل الانحراف الهندسي، وتنوع تخطيط الورقة، والتصوير غير المثالي باستخدام الهواتف المحمولة [1,9]. بالإضافة إلى اعتماد العديد منها على تقنيات OCR لاستخلاص رقم الطالب أو النموذج [2].

وتظهر مجموعة من التحديات عند تطوير نماذج ذكاء اصطناعي تعيق العمل على تطوير النماذج الذكية في القطاع التعليمي مثل عملية تجهيز بيانات التدريب من خلال تسمية عناصر الورقة يدوياً كمشكلة حقيقية تتطلب وقتاً وجهداً مضاعف [3].

تقدم هذه الدراسة مقترح عملي متكامل للتعرف على العناصر الأساسية في أوراق الإجابة متعددة الخيارات باستخدام الذكاء الاصطناعي وتجهيزها للتصحيح الآلي لاحقاً، يجمع النظام المقترح بين قوة أداء نموذج YOLOv11 للكشف الدقيق [4]، وتقنيات الرؤية الحاسوبية في التصحيح الهندسي (Affine + Perspective) [5,6]، وخوارزميات متخصصة لاستخراج رقم الطالب ونموذج الامتحان مباشرة حسب تظليل الفقاعات.

اختبرنا النظام على مجموعة من أوراق إجابة امتحانية حقيقية من ضمن 9400 ورقة جُمعت من جامعة حمص، غنية بتنسيقات طباعة مختلفة وتم تصويرها باستخدام ماسحات ضوئية وكاميرات موبايل في ظروف إضاءة متنوعة.

يتميز هذا البحث عن غيره بعدة مزايا تشمل جمع قاعدة بيانات واقعية في ظروف متعددة، استخدام 9 معلمات عمودية و6 معلمات أفقية من أصل 69 معلمة داخلية متوزعة على طول

وعرض الورقة لضمان دقة تصحيح الميلان، ودمجنا أداة Label Studio مع نموذج YOLO لتسمية البيانات (Semi-auto Labeling) [7]، لتوليد مخرجات منظمة وقابلة للتكامل البرمجي مع أنظمة إدارة التعليم.

يعمل النظام على التعرف على الانحراف الفعلي لكل ورقة بناءً على معطياتها الخاصة ويقدم حلولاً مرنة لتصحيحه وتجاوز حالات التصوير غير المثالية بدلاً من اعتمادها أن الفرضيات الهندسية محققة افتراضياً عند التصحيح.

يهدف البحث إلى سد فجوة علمية حقيقية في مجال تصحيح أوراق OMR، عبر بناء نظام ذكي متكامل قادر على التعامل مع أوراق متنوعة ومصورة في ظروف مختلفة، وتحليلها بدقة عالية دون الحاجة لتدخل بشري، مما يُمهّد لتبني أنظمة تصحيح ذكية أكثر موثوقية في المؤسسات التعليمية.

2. أهداف وأهمية البحث

تهدف هذه الدراسة إلى بناء نظام ذكي للتعرف على العناصر البنيوية في أوراق الإجابة متعددة الخيارات، يستخدم تقنيات الذكاء الاصطناعي ويُراعي التحديات الواقعية المرتبطة بتنوع تصميم الورقة وظروف التصوير المختلفة ويسعى إلى تطوير إطار تقني قابل للتطبيق العملي في المؤسسات التعليمية، حيث يحقق ما يلي:

- تطوير نموذج كشف ذكي باستخدام YOLOv11 لتحديد العناصر البنيوية الهامة في الورقة الامتحانية، بما يشمل المَعْلَمَات العمودية والأفقية وصندوق رقم الطالب وصندوق نموذج الامتحان.
- تصحيح الميلان الهندسي بدقة عالية من خلال خوارزمية تعتمد على 15 معلمة موزعين عمودياً وأفقياً من بين 69 معلمة داخلية، مع استخدام تحويل هندسي (Affine + Perspective).
- استخراج رقم الطالب والنموذج باستخدام تحليل فقاعات مخصص يعتمد على التظليل.

- إعداد نظام معالجة مؤتمت يبدأ من الكشف عن العناصر وتحديد مواقعها بدقة وصولاً إلى الحصول على ملفات نتائج بالمعلومات المستخرجة (CSV) قابلة للتكامل مع أنظمة إدارة التعليم.
 - تسريع عملية إعداد بيانات التدريب باستخدام التسمية بمساعدة نموذج تعلم آلي (ML-Assisted Labeling) من خلال استخدام نموذج YOLO ضمن أداة Label Studio. تأتي أهمية هذا البحث من عدة اعتبارات علمية وتقنية، أبرزها [1]:
 - تعتمد بنية أنظمة OMR الحالية على افتراضات هندسية مثالية تفشل في التعاطي مع أوراق ممسوحة أو مصورة بزوايا ميل مختلفة أو جودة منخفضة.
 - تفتقر الحلول المنتشرة إلى المرونة في التعامل مع تصاميم ورقية غير موحدة.
 - تظهر عوائق إعداد مجموعات التدريب بشكل يدوي أمام تعميم هذه الأنظمة، حيث يُقدّم هذا البحث حل متكامل لتسريع عملية تسمية البيانات بجودة عالية.
- تُلخص مساهمات البحث بالنقاط التالية:

- (1) جمع مجموعة بيانات كبيرة ومخصصة تشمل 9400 ورقة امتحانية ممسوحة ومصورة في بيئة تعليمية فعلية وبأنماط طباعة متعددة.
- (2) تصميم خوارزميات كشف وتصحيح هندسي مزدوج أثبتت كفاءتها على كل من الصور الممسوحة والصور الملتقطة بكاميرا رقمية مثل كاميرات الهاتف المحمول.
- (3) تقديم خوارزمية لاستخلاص رقم الطالب من شبكة الفقاعات.
- (4) دمج التسمية اليدوية مع التسمية شبه الآلية (Semi-auto Labeling) باستخدام نموذج YOLO عند تجهيز البيانات، لتسريع تسمية البيانات وتحسين التعامل معها.
- (5) تحقيق أتمتة شاملة للعملية، حيث يتم إعداد نتائج مخزنة قابلة للتكامل بشكل آلي.

3. دراسة مرجعية

نستعرض في هذه الفقرة العديد من الدراسات المرجعية المرتبطة بمشكلة البحث في اكتشاف العناصر البنوية الأساسية في أوراق الإجابة وتصحيح الميلان الهندسي واستخلاص المعلومات الخاصة برقم الطالب ونموذج الامتحان. وركزت على مناقشة الأساليب التقليدية والحديثة مع إبراز

الثغرات التقنية التي تمت معالجتها عبر دمج تقنيات حديثة مثل YOLOv11 وخوارزميات تصحيح الميلان، والاعتماد على بيانات واقعية ونظام تسمية بيانات شبه آلي.

1.3. مرونة التخطيط وتصحيح الميلان (Robust Alignment)

ظهرت أهمية مرونة أنظمة التصحيح الآلية في التعامل مع الاختلافات الهندسية لأوراق الامتحانات، حيث تكون الصور الواقعية للأوراق مصورة بزاوية ميل، أو تتضمن انزياحاً ناتجاً عن المسح غير المحوري أو الانقاط اليدوي باستخدام الكاميرات الرقمية مثل الهواتف المحمولة. ولهذا فإن الخطوة الأولى الحاسمة في النظام هي تصحيح الميل والانحراف الهندسي وإعادة تسوية الورقة قبل البدء في تحليلها [8].

أظهرت الدراسات المرجعية هذه المشكلة بطرق متعددة، مثل دراسة Jain وزملاؤه [8] التي اعتمدت على استخلاص النقاط الطرفية من حواف الورقة باستخدام مرشح Canny، ثم اكتشاف الحدود المستطيلة الخاصة بصناديق الإجابة باستخدام خوارزمية Ramer–Douglas–Peucker، ليتم بعد ذلك تطبيق تحويل Homography لتسوية الورقة، حقق هذا الأسلوب دقة تصحيح زاوية بلغت 99.33% بزمان معالجة لم يتجاوز 0.5 ثانية لكل صورة دون الحاجة لأي معلمات مرجعية مطبوعة على الورقة ما يجعله ملائم للأوراق القياسية المطبوعة.

وقدم Hafeez وآخرون [9] نهجاً اعتمد على البنية الداخلية للورقة دون استخدام أي معلمات مرجعية أيضاً، بدلاً من ذلك قاموا باستخدام Hough Circle Transform لاكتشاف الفقاعات ثم تحليل توزعها لتحديد اتجاه الورقة وتصحيح ميلها، أظهر هذا النهج مرونة في الأوراق التي لا تحتوي على معلمات واضحة لكنه بالمقابل يتطلب انتظاماً عالياً في توزيع الفقاعات حتى لا تؤثر الانحرافات أو الفقاعات المفقودة على النتيجة النهائية، قللت هذه الاستراتيجية معدل الخطأ في تصحيح الأوراق المعرضة لطباعة أو مسح ضوئي مشوش أو تالف حيث انخفض من 13.41% و 7.22% في الأنظمة التقليدية إلى 0.44% باستخدام النظام المقترح.

واستخدمت تقنية الكشف عن الأشياء في دراسات أخرى حديثة لتحديد المعلمات واستخدامها في تصحيح الميل، حيث طور Tinh وآخرون [10] نموذج YOLOv8 تعرفت من خلاله على أقسام الصورة بما فيها معلومات الطالب وصناديق الإجابة. عمل النموذج على اكتشاف ثلاث معلمات داخلية في (الزاوية العليا اليسرى، الزاوية العليا اليمنى، والزاوية السفلى اليسرى) من ورقة

الامتحان وتم تحديد الميل وتصحيحه، كذلك تم التعرف على رقم الطالب بواسطة 10 تسميات يتعرف عليها النموذج وهي أرقام صحيحة من 0 إلى 9، وحقق النموذج دقة في اكتشاف رقم الطالب وإجاباته المختارة بلغت 99.5%.

2.3. التشغيل باستخدام الهواتف المحمولة ودعم ظروف التصوير المتنوعة

ظهرت الحاجة إلى تطوير أنظمة OMR قادرة على التعامل مع صور ملقطة باستخدام كاميرات الهواتف المحمولة في ظل ظروف إضاءة غير متجانسة وزوايا ميل متفاوتة. وفرضت تحديات إضافية على الأنظمة التقليدية التي غالباً ما تكون مصممة لمعالجة صور ممسوحة ضوئياً على خلفية موحدة وبزوايا مثالية [11].

ركز Largo وآخرون [11] في دراستهم على تطوير تطبيق محمول يسمح بتصوير الورقة وتحليلها في الزمن الحقيقي، وقد تضمنت المنظومة وحدة تصحيح تلقائي للميل، ثم مرحلة تعزيز بصري تعتمد على CLAHE (Contrast Limited Adaptive Histogram Equalization) لتسوية التباين داخل الصورة مما يسمح بتحسين نتائج التظليل حتى في الصور منخفضة الجودة، ثم اعتمدت الدراسة على تحليل كثافة التظليل داخل فقاعات الإجابة.

في دراسة أخرى للباحث Hafeez وآخرون [12] اختبروا نموذجهم على صور مأخوذة بكاميرات هواتف محمولة في ظروف مختلفة من الإضاءة والميلان (ميل بزاوية 10 إلى 20 درجة). واعتمدت الدراسة على خوارزمية Hough Circle لاكتشاف دوائر نصف قطرها 15 بكسل داخل الورقة ثم رسم خطوط تمر بمراكز هذه الدوائر؛ حيث تُحسب الزاوية بينها وبين المحور الأفقي لتحديد زاوية الميل وتصحيحها واستخدم (Pixel Projection) لتحديد الإجابات المختارة. أظهرت النتائج أن النموذج حقق معدل خطأ بمقدار 3.33%.

3.3. استخدام تسمية البيانات (Labeling)

ظهرت أهمية تجهيز مجموعة البيانات وتسميتها كخطوة أساسية في تطوير أنظمة OMR المبنية على التعلم العميق، وإن نجاح النماذج مثل YOLO و Transformer على الرغم من التقدم الكبير في بنيتها لا يتحقق إلا إذا تُربت على بيانات مسماة بشكل جيد ومتناسق. لكن في معظم الدراسات السابقة تم التعامل مع عملية التسمية إما يدوياً بالكامل أو بأساليب محدودة، مما جعل المرحلة مكلفة من حيث الوقت والجهد [10].

تظهر ندرة ملحوظة في الدراسات التي اعتمدت على دمج التعلم الآلي مع التسمية، حيث اعتمدت غالبية الأعمال مثل تلك التي قدمها Tinh وآخرون [10] على التسمية اليدوية باستخدام أدوات مثل LabelImg.

كذلك في دراسة Hafeez وآخرون [9]، تم إجراء التسمية يدوياً بالكامل على أكثر من 86 ألف حالة ضمن الأوراق المتعددة الخيارات، ولم يدمج أي من هذه الأعمال آليات مدعومة بنماذج التعلم الآلي في عملية التسمية مما يمثل جهد بشري هائل ويطرح تساؤلات حول الاتساق الداخلي والموثوقية بين المسميات المختلفة، خصوصاً عند وجود حالات معقدة مثل الفقاعات المشطوبة أو الجزئية.

4. مواد وطرائق البحث

يستعرض هذا القسم المنهجية المفصلة التي تم اتباعها في تطوير نظام يتعرف على العناصر البنيوية (المعلّقات والنموذج الإمتحاني ورقم الطالب) ضمن أوراق الإجابة متعددة الخيارات باستخدام الذكاء الاصطناعي بدءاً من عملية جمع البيانات وتسميتها لاستخدامها في تدريب نموذج الكشف واستخلاص المعلومات الخاصة برقم الطالب والنموذج الامتحاني وتصحيح الانحراف الهندسي للورقة.

1.4. توصيف مجموعة البيانات Dataset

بدأ العمل بجمع أوراق امتحانية حقيقية من جامعة حمص، شملت نماذج متعددة لمقررات واختصاصات من السنوات الأولى وحتى الخامسة. كان الهدف من تنويع البيانات هو محاكاة سيناريوهات حقيقية متنوعة تعكس الفوارق في التنسيق الطباعي وعدد الأسئلة وتصميم شبكة الفقاعات وحالات التظليل الجزئي.

تم جمع الأوراق باستخدام طريقتين:

- المسح الضوئي باستخدام جهاز Ricoh 5400 Auto Feeder Scanner : تصوير 6400 صورة لأوراق إجابة متعددة الخيارات.
- التصوير اليدوي باستخدام هواتف محمولة: تصوير 3000 صورة لأوراق إجابة متعددة الخيارات بزوايا ميل مختلف وفي ظروف إضاءة متنوعة.

تضمنت الأوراق على أربع عناصر بنيوية رئيسية:

- (1) معلمات عمودية (v_markers): عددها 63 معلمة مصطفة على الحافة اليسرى لورقة الإجابة متعددة الخيارات، واستخدمت كمرجع هندسي لتقدير الميل العمودي.
 - (2) معلمات أفقية (h_markers): عددها 6 معلمة (من ضمنها أول معلمة عمودية)، مصطفة أعلى ورقة الإجابة متعددة الخيارات واستخدمت لضبط المحاذاة الأفقية.
 - (3) صندوق رقم الطالب: يحتوي شبكة من 10 أعمدة \times 10 صفوف لتمثيل الرقم الجامعي.
 - (4) صندوق نموذج الامتحان: يتضمن أربع فقاعات (A, B, C, D) لتحديد نسخة النموذج.
- صنفت الأوراق وخزنت ضمن مجلدات وفق نوع الجهاز المستخدم (ماسح أو كاميرا)، لاستخدامها لاحقاً في عينات التدريب والتحقق.

2.4. تسمية البيانات (Labeling)

استخدمت أداة Label Studio لتسمية البيانات على مرحلتين كما يلي:

1.2.4 التسمية اليدوية (Manual Labeling)

- جهزنا مجموعة البيانات الأولية بشكل يدوي باستخدام أداة Label Studio واخترنا 200 صورة امتحانية متنوعة من حيث ظروف التصوير وتصاميم الطباعة.
- شملت عملية التسمية 4 فئات بنيوية رئيسية داخل ورقة الإجابة:
- h_marker: المعلمات الأفقية (6 معلمات في أعلى الورقة)
 - v_marker: المعلمات العمودية (9 ملصقات متوزعة على يسار الورقة)
 - student_info_box: صندوق رقم الطالب
 - test_form_box: صندوق نموذج الامتحان

2.2.4 التسمية شبه الآلية (Semi-Auto Labeling) باستخدام YOLO

اعتمدت منهجية التسمية بمساعدة التعلم الآلي (ML-Assisted Labeling) ضمن أداة Label Studio، تسمح باستخدام نموذج مدرب مسبقاً لتسريع عملية التسمية ضمن الخطوات التالية:

- (1) تدريب نموذج YOLOv8-L على مجموعة الصور التي تم تسميتها يدوياً في الخطوة السابقة (200 صورة) وقسمت (160 صورة للتدريب، 20 للتحقق، و 20 للاختبار).

(2) إجراء عملية تسمية تلقائية لـ 100 صورة جديدة من خلال كشف العناصر باستخدام نموذج YOLO المدرب.

(3) إعادة ضبط النتائج يدوياً ضمن Label Studio في حال حدوث أخطاء بسيطة في المواضع أو التسمية لضمان دقة النتائج.

3.4. النماذج والخوارزميات المستخدمة

يعتمد النظام المقترح على بنية متكاملة من النماذج العميقة والخوارزميات الهندسية، تهدف إلى اكتشاف العناصر البنيوية الأساسية داخل ورقة الإجابة ومعالجة المشكلات الناتجة عن الميل أو التشوه البصري أثناء التصوير.

1.3.4. نموذج YOLOv11-m لاكتشاف العناصر البنيوية

تم اختيار نموذج YOLOv11-m في هذه الدراسة بناءً على التحسينات المتميزة التي يقدمها من حيث الهيكل والأداء، مما يجعله مناسباً جداً لاكتشاف العناصر الأساسية الدقيقة داخل أوراق الإجابة، مثل المعلّات وصناديق المعلومات. يعتمد هذا النموذج على تحسينات تم إدخالها على الإصدارات السابقة من YOLO، حيث تم استبدال الوحدة التقليدية المسماة C2f بوحدة جديدة تُعرف بـ C3K2، وهي عبارة عن طبقة مدمجة تحتوي على تلافيف أصغر حجماً وأكثر كفاءة. هذا التعديل يساعد النموذج على تنفيذ العمليات بسرعة أكبر، مع الحفاظ على جودة التمثيل البصري للمعلومات المهمة في الصورة [13,14].

كذلك، يحتفظ YOLOv11 بوحدة معروفة من الإصدار السابق YOLOv8 تُدعى SPPF (Spatial Pyramid Pooling Fast)، والتي تعمل على توسيع مدى الرؤية للنموذج (receptive field) وتعزيز قدرته على اكتشاف الكائنات الصغيرة داخل الصورة، مثل المعلّات الصغيرة والحدود الدقيقة لصناديق البيانات [13,14].

من أبرز الإضافات الجديدة في YOLOv11 هي وحدة C2PSA، والتي تستخدم تقنية تُعرف باسم "الانتباه متعدد الرؤوس" (Multi-Head Attention) لدمج المعلومات من مختلف القنوات والمناطق داخل الصورة. هذا يتيح للنموذج التركيز على المواضع المهمة بدقة أعلى، خاصة تلك التي تحتوي على العناصر البنيوية داخل الورقة [13,14].

كما تم تحسين آلية حساب المربعات التوجيهية (anchor boxes) بشكل يجعلها تتكيف تلقائياً مع حجم وشكل الكائنات المختلفة الموجودة في الصور، وهو أمر مهم لأن عناصر مثل صندوق رقم الطالب وصندوق نموذج الامتحان قد تختلف أبعادها من ورقة لأخرى [13,14].

اعتماداً على هذه التحسينات، قمنا بتدريب نموذج YOLOv11-m على صور عالية الدقة (1920×1920 بكسل)، وباستخدام حجم دفعة تدريبية (batch size) يساوي 8. صُمم التدريب لاكتشاف أربع فئات رئيسية هي: المَعْلَمَات العمودية، المَعْلَمَات الأفقية، صندوق رقم الطالب، وصندوق نموذج الامتحان. وأظهرت نتائج الاختبار أن النموذج يعمل بكفاءة عالية في ظروف تصوير متنوعة تشمل صور مأخوذة من ماسحات ضوئية أو كاميرات هواتف، مما يجعله جزءاً أساسياً في مرحلة معالجة الورقة وتصحيح انحرافها.

2.3.4. خوارزمية تصحيح الميل والتسوية الهندسية

يُعد تصحيح الميل والانحراف (Skew & Perspective Correction) من أهم مراحل معالجة أوراق الإجابة، حيث إن الانحرافات الكبيرة في الصورة يمكن أن تؤدي إلى فشل تام في استخراج المعلومات من الحقول الثابتة. تم تطوير خوارزمية تعتمد على تحليل مواضع المَعْلَمَات المرجعية h_marker و v_marker لتقدير الزاويتين الهندسيتين وتصحيحهما بتسلسل دقيق.

تعتمد الطريقة المقترحة على ركيزتين:

- المحاذاة العمودية (Vertical Alignment): باستخدام 9 مَعْلَمَات عمودية.
- المحاذاة الأفقية (Horizontal Alignment): باستخدام 6 مَعْلَمَات أفقية.

أولاً يتم حساب الزاويتين باستخدام تحليل الانحدار الخطي، ثم تطبيق تحويلين هندسيين:

(1) Affine Transform لتصحيح الدوران.

(2) Perspective Transform لتسوية الصورة هندسياً بالكامل.

معاملات خوارزمية تصحيح الميل والتسوية الهندسية (Deskew & Dewarp) كما هو موضح في الجدول 1:

اكتشاف وتحليل العناصر البنيوية في أوراق الإجابة متعددة الخيارات باستخدام YOLO v11 -
دراسة مطبقة على بيانات واقعية

الجدول 1 - معاملات خوارزمية تصحيح الميل والتسوية الهندسية

الباراميتر	القيمة	الاستخدام	الشرح
pad_left	45	حدود اليسار لصندوق التصحيح	لضمان عدم اقتطاع الزاوية اليسرى من الورقة المصححة
pad_right	40	حدود اليمين لصندوق التصحيح	ضمان تغطية كل منطقة في الزاوية اليمنى
pad_top	45	أعلى الورقة	حشوة علوية لمنع القطع من الأعلى
pad_bottom	45	أسفل الورقة	حشوة سفلية
blockSize	—	غير مستخدم في مباشرة deskew	—
threshold	—	—	—
ملاحظات			نقاط الزوايا تُحسب حسب مواقع الماركات وصناديق الكشف، ثم تُضاف الحشوات المذكورة
			حول "margin" معظم القيم هنا لضمان الصورة المصححة وعدم فقد بيانات مهمة

تعتمد خوارزمية المعالجة الهندسية على سلسلة خطوات دقيقة لضمان تسوية الورقة مبينة في
الخوارزمية 1:

— المدخلات: صورة ورقة الإجابة كما تم التقاطها بالماسح الضوئي أو الكاميرا المحمولة.

— المخرجات: صورة مصححة ومستوية هندسياً جاهزة للتحليل.

1. بداية الخوارزمية

2. تطبيق نموذج YOLOv11 للكشف عن العناصر البنيوية التالية:

• العلامات العمودية (v_markers) و العلامات الأفقية (h_markers)

• صندوق رقم الطالب (student_info_box)

• صندوق نموذج الامتحان (test_form_box)

3. استخراج إحداثيات مراكز v_markers وتخزينها في القائمة: $V = [(x_1, y_1), \dots, (x_n, y_n)]$

4. حساب زاوية الميلان θ_v باستخدام خوارزمية linear regression على النقاط V

5. تدوير الصورة بمقدار θ_v حول مركز الصورة للحصول على image_rot1

6. إعداد قائمة نقاط أفقية للتدوير تضم أول v_marker + h_markers لتعزيز الثبات في أعلى

الورقة $H_{extended} = h_markers + v_markers[0]$

7. حساب زاوية الميل الأفقي θ_h عبر linear fit على نقاط $H_{extended}$

8. تدوير image_rot1 بمقدار $-\theta_h$ حول مركز الصورة للحصول على image_rot2

9. ترتيب v_markers تصاعدياً حسب إحداثيات y من الأعلى إلى الأسفل

10. ترتيب h_markers تصاعدياً حسب إحداثيات x من اليسار إلى اليمين

11. حساب النقاط الأربعة لزوايا الورقة:

$top_left = (x \text{ لأول } h_marker, y \text{ لأعلى } v_marker) + (Padding)$

$bottom_left = (x \text{ لآخر } v_marker, y \text{ لأدنى } v_marker) + (Padding)$

$top_right = \text{نسبة مئوية من } test_form_box + Padding$

$bottom_right = \text{نسبة مئوية من } test_form_box + Padding$

12. تعريف النقاط: $src_pts = [top_left, top_right, bottom_right, bottom_left]$

13. حساب أبعاد الصورة المصححة (العرض والارتفاع) بشكل ديناميكي من src_pts

14. تحديد نقاط الهدف: $dst_pts = [(0, 0), (width, 0), (width, height), (0, height)]$

15. حساب التحويل المنظوري: $P = getPerspectiveTransform(src_pts, dst_pts)$

16. تطبيق التحويل على image_rot2:


$image_corrected = warpPerspective(image_rot2, P)$

17. إرجاع النتيجة: Return image_corrected

18. نهاية الخوارزمية

3.3.4. خوارزمية استخراج رقم الطالب

بعد تطبيق خوارزمية تصحيح الميل الهندسي وتسوية منظور ورقة الإجابة باستخدام التحويلات Affine و Perspective، يصبح صندوق رقم الطالب (student_info_box) المخصص لتعبئة رقم الطالب باستخدام الفقاعات مهياً بشكل دقيق للاقتصاص والمعالجة. تحتوي هذه المنطقة على شبكة منتظمة تتألف من 10 أعمدة عمودية، يمثل كل عمود خانة عددية من الرقم الجامعي (من الآحاد إلى عشرات الملايين)، ويحتوي كل عمود على 10 فقاعات مرقمة من 0 إلى 9. تبدأ العملية بقص المنطقة المكتشفة اعتماداً على إحداثيات الكشف من YOLO، يلحق ذلك سلسلة من المعالجات لتحسين وضوح الفقاعات وتحديدتها حتى الحصول على الرقم الجامعي النهائي. يبين الشكل 1 صورة صندوق رقم الطالب في أحد الأوراق الامتحانية:



الشكل 1 - صندوق رقم الطالب في أحد الأوراق الامتحانية

وكما يبين الجدول 2 معاملات خوارزمية استخراج رقم الطالب

الجدول 2 - معاملات خوارزمية استخراج رقم الطالب

البارامتر	القيمة	الاستخدام	الشرح
blockSize	13	adaptiveThreshold	حجم النافذة لعزل الخطوط/الخلفية
C	5	adaptiveThreshold	تعويض للعتبة التكيفية (يخفض/يرفع الحساسية)
clipLimit	2.7	CLAHE	تعزيز التباين قبل العتبة
tileGridSize	(8, 8)	CLAHE	حجم شبكة تعزيز التباين
threshold	من 0.6 max	عتبة في إسقاط الصفوف	تستخدم لتحديد أماكن الفواصل الأفقية
gaps	20, 10	لاكتشاف الفواصل بين الأسطر	المسافة الدنيا المقبولة بين الفواصل
padding	-5	عند تحديد بداية منطقة الإجابة	ليأخذ القليل قبل الخط
x_trim	من 1% العرض	إزالة هامش جانبي	التخلص من حواف جانبية غير مهمة
spacing_range	(0.040, 0.050)	في كشف قمم الفقاعات	مجال متوقع بين الفقاعات
widen_ratio	0.2	لتوسيع صورة الفقاعة	زيادة عرض القص %بنسبة 20
kernel	(2, 2)	closing (morphologyEx)	إغلاق فراغات بسيطة بعد threshold
ملاحظات			تستخدم هذه القيم لجعل استخراج كل عامود/سطر دقيق ومستقر في ظروف طباعة مختلفة

تبين الخوارزمية 2 تسلسل خطوات خوارزمية استخراج رقم الطالب:

اكتشاف وتحليل العناصر البنيوية في أوراق الإجابة متعددة الخيارات باستخدام YOLO v11 - دراسة مطبقة على بيانات واقعية

- المدخلات: الصورة المصححة ومستوية هندسياً (image_corrected)
- المخرجات: سلسلة مكونة من 10 أرقام تمثل الرقم الجامعي الكامل للطالب.
1. بداية الخوارزمية
 2. تطبيق نموذج YOLO 11 لاكتشاف إحداثيات صندوق رقم الطالب (student_info_box) من الصورة المصححة (image_corrected).
 3. قص صندوق رقم الطالب المكتشف.
 4. تطبيق المعالجة المسبقة:
 - تحويل الصورة إلى تدرج رمادي (grayscale).
 - تطبيق Gaussian Blur لتقليل الضجيج.
 - تطبيق CLAHE لتعزيز التباين.
 - تطبيق adaptive thresholding للحصول على صورة ثنائية تُظهر الفقاعات بوضوح.
 5. استخراج الجزء السفلي من صندوق رقم الطالب الذي يحتوي الشبكة الفعلية للرقم، ويتم ذلك بتحليل الإسقاط الأفقي (horizontal projection) للبكسلات السوداء.
 6. قص المنطقة السفلى، ثم تقسيمها أفقياً إلى 10 أعمدة متساوية:
 - كل عمود يمثل خانة رقمية من رقم الطالب (الآحاد، العشرات...).
 7. لكل عمود من الأعمدة العشرة:
 - حساب الإسقاط العمودي (vertical projection) لاكتشاف مواقع الفقاعات.
 - استخدام خوارزمية كشف القمم (peak detection) لاستخراج مواقع 10 فقاعات مرشحة.
 - في حال الفشل، تطبيق تقسيم ثابت للعمود إلى 10 مناطق أفقية متساوية.
 8. لكل فقاعة (bubble):
 - حساب العتبة (threshold) باستخدام طريقة Otsu من صورة صندوق الإجابة كاملاً.
 - حساب نسبة البكسلات السوداء داخل الفقاعة.
 - اختيار الفقاعة ذات أعلى كثافة مظلمة كممثل للرقم في هذا العمود.
 9. جمع نتائج الفقاعات المظلمة لكل عمود من الأعمدة وتكوين رقم الطالب النهائي من اليمين إلى اليسار.
 10. حفظ نسخة من الصورة مع إعادة التسمية بالرقم المستخرج exam_id في مجلد النتائج
 11. نهاية الخوارزمية

الخوارزمية 2 - خوارزمية استخراج رقم الطالب

4.3.4. استخراج نموذج الامتحان (Test Form Identification)

بعد معالجة الصورة وتصحيح انحرافها وتسويتها، يصبح بالإمكان تحليل صندوق نموذج الامتحان (test_form_box) بشكل آلي وبدقة عالية. يحتوي هذا الصندوق عادةً على أربع فقاعات عمودية مرتبة من الأعلى إلى الأسفل، كل منها تمثل أحد النماذج المتاحة (A, B, C, D) (يطلب من الطالب تظليل واحدة فقط لتحديد النموذج الخاص بورقته). تهدف هذه المرحلة إلى تحديد الفقاعة التي تم تظليلها من قبل الطالب من خلال تحليل دقيق للكثافة داخل كل فقاعة بعد قصها واستخراجها. يبين الشكل 2 صندوق نموذج امتحان لأحد أوراق الإجابة:



الشكل 2 - صندوق نموذج امتحان لأحد أوراق الإجابة

ويبين الجدول 3 معاملات خوارزمية استخراج نموذج الامتحان:

الجدول 3 - معاملات خوارزمية استخراج نموذج الامتحان

البارامتر	القيمة	الاستخدام	الشرح
blockSize	21	adaptiveThreshold	عتبة تكيفية في مرحلة line detection
C	19	adaptiveThreshold	تعويض للعتبة التكيفية
clipLimit	2.9	CLAHE	تعزيز التباين قبل العتبة
tileGridSize	(8, 8)	CLAHE	حجم شبكة CLAHE

اكتشاف وتحليل العناصر البنيوية في أوراق الإجابة متعددة الخيارات باستخدام YOLO v11 -
دراسة مطبقة على بيانات واقعية

البارامتر	القيمة	الاستخدام	الشرح
threshold	من 0.6 max	في إسقاط الصفوف	لكشف الفاصل أسفل رأس الصندوق
gaps	20, 10	لاكتشاف الفواصل	Fallback gap = للصور الصعبة 10
top	من 0.17 h	نسبة اقتصاص الجزء العلوي	حدود اقتصاص الصندوق
bottom	من 0.83 h	نسبة اقتصاص الجزء السفلي	حدود اقتصاص الصندوق
left	من 0.30 w	اقتصاص جانبي	إزالة حواف جانبية
right	من 0.70 w	اقتصاص جانبي	إزالة حواف جانبية
region_height	h // 4	تقسيم لمناطق الفقاعات	له bubble كل خيار ربع المسافة
otsu_threshold	متغير (0.40+)	يتم حسابه لكل صورة فرعية	يُحسب Otsu مباشرة، ويستخدم كحد لتمييز الفقاعة
ملاحظات			الاقتصاص النهائي/المعالجة مُعتمدة على اكتشاف خطوط أو اقتصاص نسبي يدوي

وتبين الخوارزمية 3 آلية استخراج نموذج الامتحان

— المدخلات: الصورة المصححة والمستوية هندسياً (image_corrected) وتحتوي على صندوق نموذج الامتحان.

— المخرجات: المحرف الذي يمثل نموذج الامتحان المختار (A, B, C, D).
الخطوات:

1. بداية الخوارزمية
2. تطبيق نموذج YOLO 11 لاكتشاف إحداثيات صندوق نموذج الامتحان (test_form_box) من الصورة المصححة (image_corrected) واقتصاص الصندوق.
3. تحسين الصورة للكشف عن الخطوط والفواصل:
 - تحويل المنطقة إلى تدرج رمادي (grayscale).
 - تطبيق Gaussian Blur لتقليل الضجيج وتحسين وضوح الفقاعات.
 - تطبيق CLAHE لتعزيز التباين في ظروف الإضاءة المختلفة.
 - تطبيق adaptive thresholding لتحويل الصورة إلى صورة ثنائية ثُمّكن من تمييز الفقاعات المظلمة.
4. حساب الإسقاط الأفقي لمحتوى الصورة الثنائية (المناطق السوداء)، وتحديد الفواصل الأفقية ذات الفجوات الكبيرة في الإسقاط لتحديد بداية منطقة الفقاعات (bubble_area).
5. قص منطقة الفقاعات بدقة، مع تقليص نسبي من الحواف لضمان عزل الخيارات فقط.
6. تطبيق Otsu threshold على الصورة الأصلية لاستخراج عتبة مناسبة لفصل الفقاعات عن الخلفية.
7. تقسيم المنطقة إلى 4 أقسام أفقية متساوية، كل منها يمثل خياراً من خيارات النموذج A و B و C و D.
8. يتم تطبيق كل مما يلي على كل قسم (خيار):
 - تطبيق threshold ثابت يتم حسابه على كامل الجزء الخاص بالنموذج الامتحاني.
 - حساب نسبة التظليل (البكسلات السوداء) داخل الفقاعة.
9. اختيار الخيار الذي تجاوز العتبة وكان الأعلى في نسبة التظليل ك form_version.
10. إذا لم يتجاوز أي خيار العتبة، يتم اختيار الفقاعة الأعلى كثافة كمحاولة بديلة.
11. إرجاع النتيجة: إعادة نموذج الاختبار form_version
12. نهاية الخوارزمية

الخوارزمية 3 - استخراج نموذج الامتحان

5. التجارب والنتائج ومناقشتها

1.5. بيئة التدريب

تم تنفيذ عملية تدريب النماذج واختبارها ضمن بيئة Google Colab Pro، والذي بدوره وفر إمكانيات مناسبة للتعامل مع النماذج العميقة والبيانات بدقة عالية، تضمنت البيئة التقنية المستخدمة وحدة معالجة مركزية Intel Xeon سداسية النوى (6 cores) مع 12 خيط معالجة (threads) بسرعة 2.2 جيجاهرتز، مما أتاح معالجة متوازية فعالة خلال تحميل البيانات والتدريب. كما تم تخصيص 83.5 جيجابايت من الذاكرة العشوائية (RAM) مما ساهم في تسريع عمليات التخزين المؤقت وتخفيض معدلات التباطؤ الناتجة عن نقص الذاكرة أثناء التدريب.

أما فيما يخص وحدة المعالجة الرسومية (GPU) فقد تم استخدام بطاقة NVIDIA A100 ذات ذاكرة من نوع HBM2 بسعة 40 جيجابايت، والتي تعتبر من أقوى بطاقات المعالجة المخصصة لتدريب نماذج التعلم العميق، وخاصة مع الصور الكبيرة ومعالجة المهام المتعددة. ساهمت هذه البيئة في تسريع التدريب بشكل كبير مما سمح بتحقيق كفاءة حسابية عالية أثناء تنفيذ جميع مراحل ضبط النموذج وتقييمه.

2.5. مقاييس تقييم الأداء

لقياس فعالية النماذج المدربة على كشف عناصر بنيوية في الورقة الامتحانية، تم اعتماد مجموعة من المعايير المعروفة في مجال الرؤية الحاسوبية والتي تمثل الأساس في تقييم نماذج التعرف على الأشياء. شملت هذه المقاييس:

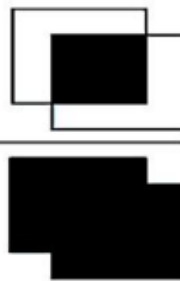
1) مصفوفة الالتباس (Confusion Matrix)

تُستخدم مصفوفة الالتباس لعرض نتائج اكتشاف النموذج ضمن أربع حالات رئيسية [15]:

- TP (True Positive): اكتشف النموذج العنصر بشكل صحيح.
- TN (True Negative): لم يكتشف النموذج العنصر وكان فعلاً غير موجود.
- FP (False Positive): اكتشف النموذج عنصر لم يكن موجود.
- FN (False Negative): لم يكتشف النموذج العنصر رغم أنه كان موجود بالفعل.

2) التقاطع على الاجتماع (IoU - Intersection over Union)

ظهر تحديد موقع العناصر بأفضل دقة ممكنة كمهمة رئيسية عند استخدام نماذج التعرف على الأشياء. يوضح الشكل 3 وجود صندوقين محاطين أحدهما باللون الأسود يمثل المربع المحيط بقاعدة الحقائق الأساسية للعنصر، والآخر باللون الأبيض يمثل ناتج تنبؤ نموذج الكشف، نلاحظ أنهما لا يتداخلان بشكل تام لذلك نحتاج إلى قياس مدى تطابق أو سوء تطابقهما كنتيجة دقة اكتشاف حدود العنصر، لذا يتم حساب التقاطع على الاجتماع IoU بقسمة مساحة تقاطع الصندوقين على مساحة اجتماعهما كما هو موضح في الشكل، ويتم اعتبار التعرف أفضل كلما اقتربت قيمة IoU من 1، ويتم اعتبار التوقع جيد عندما تتجاوز قيمة IoU عتبة محددة (مثل 0.5) [15]:

$$IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$


الشكل 3 - علاقة التقاطع على الاجتماع (IoU) [15]

(3) متوسط الدقة (mean Average Precision – mAP)

عند تقييم جودة نماذج الكشف عن الأشياء يُعد مقياس mAP من أكثر مؤشرات الأداء استخداماً، يقيس متوسط دقة التوقعات عبر جميع الفئات بناءً على مدى تطابق الصناديق المتوقعة مع الصناديق الحقيقية ضمن مستويات مختلفة من التداخل الهندسي. تم في هذه الدراسة استخدام معيارين رئيسيين [15]:

- $mAP@0.5$: يتم اعتبار التوقع صحيح عندما يكون تقاطع المساحة بين الصندوق المتوقع والحقيقي $(IoU) \geq 0.5$.
 - $mAP@0.5:0.95$: وهو متوسط الدقة عند عشر عتبات مختلفة من IoU (من 0.5 إلى 0.95 بفواصل 0.05)، ويُعتبر المقياس الأكثر صرامة لقياس دقة التحديد.
- يمكن حساب متوسط الدقة الكلي mAP من أجل n فئة وفق العلاقة (1) [15]:

$$mAP = \frac{\sum_{i=0}^n AP_i}{n}$$

حيث أن AP متوسط الدقة للفئة i ، وتقاس قدرة النموذج على اكتشاف الإيجابيات الحقيقية (TP) من بين جميع التوقعات الإيجابية (TP+FP) لها وتحسب وفق العلاقة (2):

$$AP = \frac{TP}{TP + FP}$$

(4) مقاييس أخرى

يستخدم البحث أيضاً عدد من المقاييس وهي: الدقة Accuracy والإحكام Precision والاستدعاء Recall ومقياس إف F1-Score. تُحسب هذه المقاييس وفق المعادلات التالية [16]:

$$\frac{TP + TN}{TP + TN + FP + FN} = \text{الدقة}$$

$$\frac{TP}{TP + FP} = \text{الإحكام}$$

$$\frac{TP}{TP + FN} = \text{الاستدعاء}$$

$$2 \times \frac{Precision \times Recall}{Precision + Recall} = \text{مقياس إف 1}$$

3.5. تدريب نموذج YOLOv8 لتسمية البيانات (Semi-auto Labeling)

تم تطوير نموذج أولي باستخدام YOLOv8-1 في المرحلة الأولى من تجهيز مجموعة البيانات بهدف تسريع عملية التسمية اليدوية من خلال التسمية شبه الآلية التي تتيحها أداة Label Studio حيث يتم دمج النموذج المدرب داخلها لتوليد اقتراحات أولية. تم تدريب النموذج على مجموعة بيانات تحتوي على 200 صورة تم تسميتها يدوياً، تم تقسيم هذه المجموعة إلى 160 صورة

للتدريب و 20 صورة للتحقق و 20 صورة للاختبار ، وشملت عملية التسمية أربع فئات بنوية أساسية:


h_marker و v_marker و student_info_box و test_form_box.

أدت عملية التسمية شبه الآلية إلى إعداد 100 صورة جديدة خلال وقت قياسي، وساهمت في تقليل الجهد اليدوي بنسبة ملحوظة. وقد أظهرت نتائج النموذج التجريبي دقة عالية بلغت 98.10 %، كما أظهرت مصفوفة الالتباس ومؤشرات الأداء لكل فئة على حدة تميز النموذج في الكشف عن student_info_box و test_form_box بنسبة mAP@0.5 بلغت 0.995، بينما كانت النتائج أقل نسبياً لفئة h_marker بسبب صغر حجمها النسبي. تظهر هذه النتائج في الشكل 4 وفي الجدول 1 كما يلي:

الجدول 1 - نتائج اختبار تدريب نموذج yolo-v8 على 200 ورقة

الفئات	عدد الصور	عدد الحالات	الإحكام Precision	الاستدعاء Recall	mAP @ 0.5	mAP@ 0.5: 0.95
h_marker	20	100	1.000	0.940	0.970	0.762
v_marker	20	181	1.000	0.928	0.964	0.853
student_info_box	20	20	1.000	1.000	0.995	0.991
test_form_box	20	20	1.000	1.000	0.995	0.988
إجمالي الفئات	20	321	1.000	0.967	0.981	0.898

اكتشاف وتحليل العناصر البنيوية في أوراق الإجابة متعددة الخيارات باستخدام YOLO v11 - دراسة مطبقة على بيانات واقعية



الشكل 4 - مصفوفة الالتباس لنتائج اختبار تدريب نموذج yolo-v8 على 200 ورقة

يظهر الشكل 5 صور توضيحية لعملية الكشف في الكشف شبه الآلي باستخدام YOLO داخل الأداة:



الشكل 5 - صور توضيحية لاقتراحات التسمية في الكشف شبه الآلي باستخدام YOLO

4.5. تقسيم مجموعة البيانات

تم تقسيم مجموعة البيانات المكونة من 300 صورة تضم أوراق الإجابة التي سميت في مرحلة تحضير البيانات (200 منها بشكل يدوي و 100 صورة تم تسميتها بشكل شبه آلي) إلى ثلاث مجموعات وهي مجموعة التدريب Training (70% من مجموعة البيانات الكلية) ومجموعة التحقق Validation (15%) ومجموعة الاختبار Testing (15%).

5.5. الضبط الدقيق لنموذج YOLO v11m

لتحقيق أفضل أداء لنموذج YOLOv11-m استخدمنا الضبط التلقائي للمعاملات (Hyperparameter Tuning) باستخدام مكتبة Optuna، وهي مكتبة مفتوحة المصدر تعتمد على تحسين بيزياني (Bayesian Optimization) حيث تعمل على البحث العشوائي التتابعي وتوجه التجارب السابقة لتسريع الوصول إلى أفضل القيم [17]. عملت Optuna على اختبار مئات القيم المختلفة للمعاملات، واختيرت الإعدادات التي تحقق أعلى قيمة لمقياس $mAP@0.5:0.95$ على مجموعة التحقق.

شملت عملية الضبط معاملات متعددة، منها ما يتعلق بخصائص التعلم مثل معدل التعلم الأساسي (lr0) والزخم (momentum)، ومنها ما يتعلق بتعزيز البيانات مثل Mosaic، ودرجة الميل (shear)، والتغيرات اللونية (hsv)، بالإضافة إلى معاملات الثقة (confidence) وال IoU المطلوب لقبول التوقعات. يبين الجدول 2 أفضل إعدادات ضبط نتجت عن Optuna:

اكتشاف وتحليل العناصر البنيوية في أوراق الإجابة متعددة الخيارات باستخدام YOLO v11 -
دراسة مطبقة على بيانات واقعية

الجدول 2 -أفضل قيم Hyperparameter Tuning لتدريب نموذج YOLO v11m

المعامل	توصيف	القيمة
Lr0	معدل التعلم الأساسي (Learning rate)	0.000236
Momentum	الزخم في تحديث الأوزان (Momentum)	0.9336
Dropout	نسبة الإسقاط في الشبكة لتجنب overfitting	0.0638
Scale	حجم التغيرات العشوائية في الصورة أثناء التدريب	0.0878
Mosaic	نسبة استخدام تقنية Mosaic augmentation	0.567
Shear	درجة الانحراف الزاوي للصورة	17
lou	العتبة المطلوبة لاحتساب تقاطع المربعات	0.5829
Conf	الحد الأدنى للثقة لقبول التنبؤ	0.473
hsv_h/s/v	التغيرات اللونية العشوائية في الصور لتعزيز	0.04 / 0.79 / 0.31
Patience	عدد الدورات بدون تحسن قبل التوقف المبكر	50
Batch	حجم العينة في كل خطوة تدريبية	8

تم استخدام الإعدادات المبينة في الجدول السابق لتدريب النموذج النهائي وفقاً للمعلّمات التالية المبينة في الجدول 3 التالي:

الجدول 3 -إعدادات تدريب نموذج YOLO v11m


المكوّن	القيمة / التهيئة
عدد الدورات (Epochs)	500-دورة (301 بسبب التوقف المبكر)
حجم الصورة (imgsz)	1920 × 1920 بكسل
المحسن (Optimizer)	AdamW
التسريع المختلط (AMP)	مُفَعَّل (Automatic Mixed Precision)
عدد العمليات المتوازية (workers)	8
فاصل الحفظ الدوري (save_period)	حفظ النموذج كل 25 دورة

6.5. نتائج أداء نموذج YOLO v11m المدرب

تم تقييم أداء النموذج النهائي YOLOv11-m المدرب على مجموعة اختبار تتألف من 30 صورة تنوعت من حيث جودة التصوير ووجود الميلان، اعتمد التقييم على إعدادات صارمة بعتبة $(IoU \geq 0.75)$ وحد أدنى للثقة $(Confidence = 0.3)$ ، وذلك لضمان الموثوقية العالية في الكشف.

1.6.5. مصفوفة الالتباس الخاصة بأداء نموذج الكشف YOLO v11m

أظهرت مصفوفة الالتباس أداء ممتاز لجميع الفئات كما هو مبين في الشكل 6:



الشكل 6 - مصفوفة الالتباس الخاصة بنتائج اختبار YOLO v11m على 300 ورقة

2.6.5. نتائج اختبار أداء نموذج YOLO v11m حسب الفئات

اكتشاف وتحليل العناصر البنيوية في أوراق الإجابة متعددة الخيارات باستخدام YOLO v11 -
دراسة مطبقة على بيانات واقعية

حقق النموذج معدلات دقة واسترجاع كاملة (100%) لمعظم الفئات كما هو مبين في الجدول

4:

الجدول 4 - نتائج اختبار أداء نموذج YOLO v11m حسب الفئات على 300 ورقة

الفئات	عدد الصور	عدد الحالات	الإحكام Precision	الاستدعاء Recall	mAP @ 0.5	mAP@ 0.5: 0.95
h_marker	30	150	1	1	0.995	0.852
v_marker	30	271	1	0.996	0.995	0.914
student_info_box	30	30	1	1	0.995	0.995
test_form_box	30	30	1	1	0.995	0.984
إجمالي الفئات	30	481	1	0.999	0.995	0.936


3.6.5. الأداء الإجمالي للنموذج

أظهرت النتائج أداء مميز في جميع المقاييس كما هو موضح في الجدول 5 أدناه:

الجدول 5 - نتائج اختبار الأداء الإجمالي YOLO v11m على 300 ورقة

المقياس	القيمة
Precision (mAP@0.5)	0.9950
Recall (mAP@0.75)	0.9950
mAP@0.5:0.95	0.9364
F1 Score	0.9950

توضح الصور التالية المبينة في الشكل 7 نتائج الكشف على ثلاث أوراق من مجموعة الاختبار، وأظهرت الصور المخرجة دقة تحديد ممتازة لجميع العناصر البنوية الأربعة المستهدفة في النظام:



الشكل 7 - صور توضيحية لنتائج اختبار أداء نموذج الكشف YOLO v11m

7.5. نتائج تطبيق خوارزمية تصحيح الميل والتسوية الهندسية

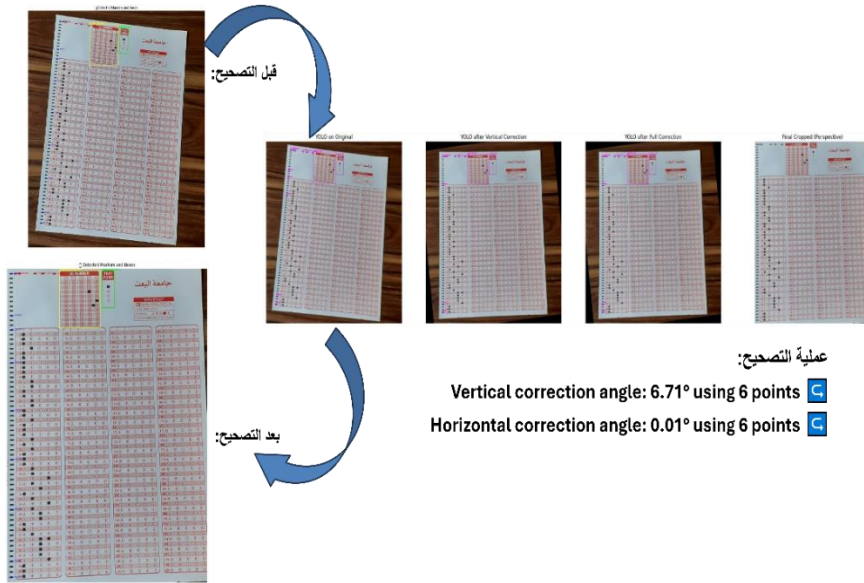
تم تنفيذ خوارزمية تصحيح الميلان والتسوية الهندسية لأوراق إجابة تم اختيارها من مجموعة البيانات بالاعتماد على نتائج نموذج YOLOv11 في اكتشاف العناصر البنوية للورقة يُظهر المثال الموضح في الشكل 8 كيف تبدأ العملية بصورة ملتقطة بواسطة كاميرا الهاتف المحمول بزاوية ميل واضحة، حيث يتم تطبيق مرحلتين من التصحيح الهندسي:

- المرحلة الأولى: تدوير عمودي يتم حساب زاويته عبر تحليل محاور المَعْلَمَات العمودية.
- المرحلة الثانية: تدوير أفقي دقيق اعتماداً على اصطفاف المَعْلَمَات الأفقية وأول معلمة .v_marker

بعد التصحيح السابق يتم تطبيق عملية تسوية منظور (Perspective Flattening) للحصول على صورة مستوية بالكامل جاهزة لعمليات القص والتحليل.

توضح المخرجات المعروضة في الشكل 8 انتقال الورقة من حالتها الأصلية التي تحوي على ميلان كبير إلى صورة مستوية بشكل أفضل وجاهزة لاستخراج المعلومات منها بدقة أفضل.


اكتشاف وتحليل العناصر البنيوية في أوراق الإجابة متعددة الخيارات باستخدام YOLO v11 -
دراسة مطبقة على بيانات واقعية



الشكل 8 - صور توضيحية لنتائج تطبيق خوارزمية تصحيح الميل والتسوية الهندسية

8.5. نتائج تطبيق خوارزمية استخراج رقم الطالب

أظهرت نتائج تطبيق الخوارزمية على مجموعة من الصور الواقعية عن قدرة جيدة في استخراج الرقم الجامعي الكامل من الفقاعات المخصصة لذلك، وأظهرت الصور الناتجة انتظام واضح في تحديد الخانات الرقمية مع تمييز دقيق للفقاعات المختارة. وقد تبين أن الخوارزمية تتكيف مع تفاوت الإضاءة وجودة الطباعة، كما هو مبين في الصورة المرفقة في الشكل 9:




20240528103424147_0021_corrected_student_info.png → Predicted Exam ID: 0000003513

الشكل 9 - صور توضيحية لنتائج تطبيق خوارزمية استخراج رقم الطالب

9.5. نتائج تطبيق خوارزمية استخراج نموذج الامتحان

أظهرت الخوارزمية المخصصة لاستخراج نموذج الامتحان (A/B/C/D) فاعلية جيدة في تحديد الفقاعة المملوءة فعلياً، رغم الاختلافات الطفيفة في طرق تعبئة الطلاب لها والفروقات اللونية بين الصور المختلفة. توضح النتائج المصورة المبينة في الشكل 10 قدرة النموذج على تجاهل العلامات غير المكتملة أو التظليل الجزئي أو التشويه في الطباعة، وتحديد النسخة الصحيحة بشكل متناسق عبر مختلف الصور.



الشكل 10 - صور توضيحية لنتائج تطبيق خوارزمية استخراج نموذج الامتحان

6. مقارنة مع الدراسات المرجعية السابقة:

أن معظم الدراسات المرجعية التي تم استعراضها في هذا البحث ([8-12]) انحصرت في تقييم أداء أنظمة التصحيح الآلي لأوراق الإجابة بناءً على معيار دقة تصنيف الفقاعات (Bubble Classification Accuracy)، أي قدرة النظام على التمييز بين الفقاعات المظلمة وغير المظلمة، دون أن تنطرق إلى تقديم نتائج تفصيلية أو مؤشرات أداء رقمية لاكتشاف العناصر البنيوية داخل الورقة الامتحانية مثل المعلومات العمودية والأفقية أو صناديق المعلومات (student_info_box و test_form_box)، كما لم تقدم هذه الدراسات تقييمات مستقلة لمراحل التصحيح الهندسي (Skew & Perspective Correction) باستخدام الخوارزميات الثلاث (YOLO)، تصحيح الميل الهندسي، وخوارزميات استخراج صناديق المعلومات).

بالتالي، لم تتوفر في الأدبيات المنشورة نتائج كمية مباشرة حول كفاءة اكتشاف وتحديد هذه العناصر البنيوية أو دقة التصحيح الهندسي كمهام منفصلة، بل انحصرت معظم التقارير على عرض معدل الدقة النهائي للنظام في تصنيف إجابات الطلاب، وهو ما لا يتيح إجراء مقارنة مباشرة مع النظام المقترح في هذه الدراسة.

لذا، جاء هذا البحث ليسد هذه الفجوة المنهجية، إذ يقدم ولأول مرة تقارير رقمية دقيقة لمقاييس اكتشاف العناصر البنيوية وتصحيح الانحراف الهندسي، ويوثق نتائج مفصلة باستخدام نموذج YOLOv11 ومعالجة هندسية متقدمة ضمن بيئة بيانات واقعية متباينة، مما يعزز من أهمية نتائجه العلمية.

7. الاستنتاجات والتوصيات

يوضح البحث الحالي أن النظام يعالج أوراق الإجابة كما هي، ويُخرج النتائج بناءً على ما هو مظهر فعلياً من قبل الطالب دون التدخل في صحة البيانات أو اكتشاف الأخطاء المنطقية الناتجة عن سوء التظليل أو السهو (مثل ترك النموذج الامتحاني دون تظليل، أو وجود أكثر من فقاعة مظلمة في خانة واحدة من الرقم الجامعي). في حال عدم تمكن النظام من استخراج النتائج بشكل

كامل (نتيجة لخطأ في الإدخال أو فشل في الاستخراج)، يتم ترك الحقل فارغاً أو تعيين قيمة افتراضية (إرجاع "0" في الرقم الجامعي)، مع تمييز هذه الحالات في سجل النتائج. لا يتضمن النظام في نسخته الحالية آلية تلقائية للتحقق من صحة أو منطقية القيم المستخرجة أو إصدار تنبيهات حول أخطاء الإدخال البشري، وإنما يعتمد على توفير معلومات كافية (صور، نتائج فارغة، علامات فشل) ليتمكن المستخدم من مراجعتها يدوياً عند الحاجة.

من الممكن مستقبلاً دمج وحدات تحقق تلقائي (validation) تقوم بفحص صحة الرقم الجامعي (عدد الخانات، تميز خانة واحدة فقط في كل عمود)، والتحقق من وجود تظليل لنموذج الامتحان، مع إصدار تقارير عن الحالات الشاذة أو الناقصة.

أثبت هذا البحث فعاليته في معالجة العديد من الإشكاليات المنهجية والتطبيقية المرتبطة بأنظمة تصحيح أوراق الإجابة متعددة الخيارات (OMR)، وذلك من خلال تقديم إطار متكامل يدمج بين الرؤية الحاسوبية والتعلم العميق ضمن بنية قابل للتطبيق العملي.

أولاً، يمثل توفير مجموعة بيانات ضخمة وحقيقية إحدى أهم المساهمات العلمية في هذا البحث، إذ إن غالبية الدراسات السابقة كانت تعتمد على مجموعات بيانات مصغرة، غالباً ما تكون صناعية أو غير منشورة. إن طبيعة هذه البيانات - التي جُمعت من أوراق ممسوحة أو مصورة بكاميرا رقمية مثل كاميرات الهواتف المحمولة، وتحتوي على تباين حاد في جودة التظليل والانحراف الزاوي - مكنت من اختبار النموذج في ظروف قريبة من الواقع العملي، وساهمت في تحسين قدرة النماذج على التعميم.

ثانياً، تم تطبيق منهج التسمية شبه الآلية (Semi-Auto Labeling) باستخدام نموذج YOLO أولي للمساعدة في عملية تجهيز مجموعة التدريب، مما ساعد في تسريع الإعداد وتخفيض نسبة الخطأ البشري، مع الحفاظ على تناسق البيانات المسماة. تمثل هذه المنهجية حل عملي لتوسيع مجموعات البيانات بدون كلفة بشرية مرتفعة، وهي قابلة للتكرار في مجالات متعددة من تطبيقات الرؤية الحاسوبية.

ثالثاً، أثبت نموذج YOLOv11 تفوق ملحوظ مقارنةً بنموذج YOLOv8 وهو النموذج المستخدم في معظم الدراسات السابقة سواء من حيث القدرة على اكتشاف العناصر الدقيقة (مثل المعالم المرجعية وصناديق البيانات) أو من حيث الدقة الإجمالية. وقد بينت اختبارات النموذج

اكتشاف وتحليل العناصر البنوية في أوراق الإجابة متعددة الخيارات باستخدام YOLO v11 - دراسة مطبقة على بيانات واقعية

تحسن فعلي في مقاييس mAP و precision عند استخدامه في بيئة بيانات واقعية، وهو ما يضعه ضمن الخيارات الواعدة لنماذج OMR الحديثة.

رابعاً، اعتمد البحث على منهجية تصحيح مزدوجة الميلان باستخدام المعالم الهيكلية المكتشفة (h_markers, v_markers)، وهو ما تجاوز ضعف معالجة الانحراف الزاوي في العديد من الدراسات السابقة التي اعتمدت على حواف الورقة فقط. حسّنت هذه المنهجية بشكل مباشر من جودة تسوية الورقة وبالتالي من دقة جميع المهام اللاحقة مثل الاستخراج والتصنيف.

خامساً، تم تطوير خوارزميات دقيقة لاستخراج كل من رقم الطالب ونموذج الامتحان عبر تحليل الفقاعات مباشرة دون الاعتماد على OCR أو إدخال يدوي، مما جعل النظام أكثر توافق مع أوراق لا تتضمن أرقاماً مكتوبة أو تحتوي على تشويش في الطباعة أو المسح، وقد حققت الخوارزميات نتائج قوية في الاكتشاف.

توصيات بحثية مستقبلية:

- إعادة تصميم المعمارية على هيئة نموذج واحد متعدد المهام (Multi-task Learning) (لتقليل عدد المراحل المنفصلة وتحقيق تعلم مشترك بين المهام (مثل الكشف، التصنيف، التصحيح).
- التوسع في تصميم النموذج ليشمل تصاميم أوراق امتحانية مختلفة (غير موحدة)، بما في ذلك تعدد المواقع المحتملة لصندوق المعلومات أو أنماط تظليل مختلفة للفقاعات.
- دمج النظام داخل واجهة إلكترونية كاملة تشمل رفع الصور واكتشاف النماذج وتصحيح ميلان الورقة واستخراج بيانات الطالب والورقة وتوليد النتائج النهائية، مما يمهد لاعتماد النظام في بيئة مؤسسية حقيقية (جامعة أو مدرسة).

8. المراجع

- [1] de Elias, E. M., Tasinaffo, P. M., & Hirata Jr, R. 2021 Optical mark recognition: Advances, difficulties, and limitations, SN Computer Science, Vol. 2(5), 367.
- [2] Mahmud, S., Biswas, K., Alam, A., Rudro, R. A. M., Anannya, N. J., Mouri, I. J., & Nur, K. 2024 Automatic multiple choice question

- evaluation using tesseract ocr and yolov8, 2024 IEEE Conference on Artificial Intelligence (CAI), pp. 246–252, IEEE.
- [3] Huang, Q., & Zhao, T. 2024 Data collection and labeling techniques for machine learning, arXiv preprint arXiv:2407.12793.
- [4] Khanam, R., & Hussain, M. 2024 Yolov11: An overview of the key architectural enhancements, arXiv preprint arXiv:2410.17725.
- [5] Erkelens, C. J. 2015 The perspective structure of visual space, i-Perception, Vol. 6(5), 2041669515613672.
- [6] Wagner, M., & Gambino, A. J. 2016 Variations in the anisotropy and affine structure of visual space: A geometry of visibles with a third dimension, Topoi, Vol. 35(2), 583–598.
- [7] Label Studio Documentation. (n.d.) <https://labelstud.io/guide/>
- [8] Jain, V., Malik, S., & Bhatia, V. 2022 Robust image processing based real-time optical mark recognition system, 2022 IEEE 6th Conference on Information and Communication Technology (CICT), pp. 1–5, IEEE.
- [9] Hafeez, Q., Aslam, W., Lali, M. I., Ahmad, S., Alqahtani, M., & Shafiq, M. 2023 Fault Tolerant Optical Mark Recognition, Computers, Materials & Continua, Vol. 74(2).
- [10] Tinh, P. D., & Minh, T. Q. 2024 Automated Paper-based Multiple Choice Scoring Framework using Fast Object Detection Algorithm, International Journal of Advanced Computer Science & Applications, Vol. 15(1).
- [11] Largo, L. D., Guillermo, J., Jancinal, A. R., & Wata, M. 2022 Bubble sheet multiple choice mobile checker with test grader using optical mark recognition (omr) algorithm, 2022 5th International Conference on Electronics and Electrical Engineering Technology (EEET), pp. 27–33, IEEE.
- [12] Hafeez, Q., Aslam, W., Aziz, R., & Aldehim, G. 2024 An Enhanced Fault Tolerance Algorithm for Optical Mark Recognition Using Smartphone Cameras, IEEE Access.
- [13] Mao, M., & Hong, M. 2025 YOLO Object Detection for Real-Time Fabric Defect Inspection in the Textile Industry: A Review of YOLOv1 to YOLOv11, Sensors (Basel, Switzerland), Vol. 25(7), 2270.
- [14] He, Z., Wang, K., Fang, T., Su, L., Chen, R., & Fei, X. 2024 Comprehensive Performance Evaluation of YOLOv11, YOLOv10, YOLOv9, YOLOv8 and YOLOv5 on Object Detection of Power Equipment, arXiv preprint arXiv:2411.18871.

- [15] Imran, A.I., Imran, B. 2023 Improved YOLOv3–Tiny model for human detection, Al-Baath University Journal – Series of Mechanical, Electrical and Informatics Engineering Sciences, Vol. 45(82), 211–222.
- [16] Obi, J.C. 2023 A comparative study of several classification metrics and their performances on data, World Journal of Advanced Engineering Technology and Sciences, Vol. 8(1), 308–314.

تقييم أداء خوارزميات الجدولة RR, SJF, MQL, FCFS

الباحث: م. قمر سباعي

المشرف العلمي:

أ.د. إبراهيم الشامي

المشرف المشارك:

أ.د. عمار زقزوق

الملخص:

يهدف هذا البحث إلى تقييم أداء أربع خوارزميات جدولة وهي First Come First Serve (FCFS)، Shortest Job First (SJF)، Round Robin (RR)، و Multilevel Queue (MQL)، من خلال تحليل ثلاث حالات دراسية مختلفة. تضمنت الحالة الأولى عمليات قصيرة، بينما ركزت الحالة الثانية على مزيج من العمليات الطويلة والقصيرة، في حين تناولت الحالة الثالثة العمليات الطويلة. قُيِّمت الخوارزميات من حيث متوسط زمن الانتظار ومتوسط زمن المعالجة الكلي.

أظهرت النتائج أن خوارزمية SJF كانت الأكثر كفاءة في تقليل زمن الانتظار وزمن المعالجة في الحالة الأولى بسبب إعطائها الأولوية للعمليات القصيرة. أما في الحالة الثانية، فقد تفوقت خوارزمية MQL نظراً لقدرتها على تقسيم العمليات إلى مستويات ومعالجتها وفقاً لأولويات محددة. في الحالة الثالثة، قدمت خوارزمية RR أداءً جيداً لتوزيعها العادل للوقت بين العمليات الطويلة.

الكلمات المفتاحية:

نظم التشغيل، زمن الانتظار، زمن المعالجة الكلي، FCFS، SJF، Round Robin، MQL.

Performance Evaluation of RR, SJF, MQL, FCFS Scheduling Algorithms

Abstract:

This research evaluates the performance of four scheduling algorithms: First Come First Serve (FCFS), Shortest Job First (SJF), Round Robin (RR), and Multilevel Queue (MQL), through the analysis of three different case studies. The first case examines short processes, the second case focuses on a mix of long and short processes, while the third case deals with long processes. The algorithms were evaluated based on the average waiting time and the average turnaround time.

The findings reveal that the SJF algorithm is the most efficient in the first case, achieving the lowest waiting and turnaround times due to its prioritization of short processes. In the second case, the MQL algorithm outperforms the others, leveraging its ability to classify processes into levels and manage them based on specific priorities. Meanwhile, in the third case, the RR algorithm demonstrates strong performance by ensuring a fair distribution of processing time among long processes.

Keywords:

Operating Systems, Waiting Time, Turnaround Time, FCFS, SJF, Round Robin, MQL.

1. مقدمة:

نظم التشغيل (Operating Systems) هي البرمجيات الأساسية التي تدير موارد الحاسوب. وتعمل كحلقة وصل بين المستخدم والأجهزة. تقوم هذه النظم بتشغيل التطبيقات، وتضمن تواصلًا فعالاً مع مكونات الحاسوب مثل المعالجات والذاكرة وأجهزة الإدخال والإخراج. وتتميز نظم التشغيل بتوفير بيئة مستقرة وآمنة لتشغيل البرامج وتنفيذ العمليات على نحو متزامن وفعال [1].

تُعد الجدولة (Scheduling) إحدى الوظائف الأساسية لنظم التشغيل، حيث تنظم توزيع المهام والعمليات على الموارد المختلفة لضمان الأداء المتوازن والكفاءة العالية. تقوم خوارزميات الجدولة بتنظيم تخصيص وحدة المعالجة المركزية (CPU) مع الأخذ في الاعتبار معايير مثل زمن الوصول، أولوية العمليات، وزمن التنفيذ. تختلف كفاءة النظام بناءً على الخوارزمية المختارة، حيث تؤثر بشكل مباشر على سرعة استجابة النظام [2].

طُور العديد من خوارزميات الجدولة لتلبية أهداف متعددة، ومنها خوارزمية الواصل أولاً يخدم أولاً (First Come First Serve – FCFS)، وخوارزمية مهمة أقصر أولاً (Shortest Job First – SJF)، وخوارزمية راوند روبن (Round Robin – RR)، كذلك خوارزمية الأولوية (Priority). يختلف دور كل خوارزمية حسب طبيعة النظام ومتطلبات الأداء [3].

2. هدف البحث:

يهدف هذا البحث إلى مقارنة كفاءة أربع خوارزميات (RR، MQL، SJF، FCFS) من خلال دراسة حالة تستند إلى مجموعة من العمليات ذات أزمنة وصول وأزمنة تنفيذ مختلفة. تُقيّم كل خوارزمية وفقاً لمتوسط زمن الانتظار، ومتوسط زمن المعالجة الكلي. تسعى هذه المقارنة إلى تحديد الخوارزمية الأكثر كفاءة في ظل ظروف محددة وتقديم رؤية حول متى يمكن استخدام كل خوارزمية لتحقيق أفضل أداء للنظام.

3. الدراسات المرجعية:

قدم الباحث [4] مراجعة شاملة لتقنيات جدولة وحدة المعالجة المركزية (CPU). ركز على تحسين الأداء من خلال تقليل زمن الانتظار وتبديلات السياق باستخدام استراتيجيات مبتكرة مثل الوقت الديناميكي وخوارزميات هجينة.

أجرى الباحث [5] مقارنة بين عشر خوارزميات للجدولة، حيث قدم مجموعة متنوعة من المعايير مثل الأداء، وتعقيد الخوارزمية، والمشكلات المرتبطة بها، ومتوسط أوقات الانتظار، بالإضافة إلى مزايا وعيوب كل خوارزمية، وطريقة التخصيص، وغيرها. يهدف هذا البحث إلى تحليل خصائص خوارزميات جدولة وحدة المعالجة المركزية بهدف تحديد الخوارزمية الأفضل التي تحقق أقصى استفادة من وحدة المعالجة المركزية.

يهدف البحث [6] إلى مراجعة الدراسات المتعلقة بخوارزميات جدولة وحدة المعالجة المركزية لتحديد أيها الأكثر كفاءة. بعد تحليل لخوارزميات Round Robin و Shortest Job First و First Come First Served و Priority، تبين أن العديد من الباحثين قدموا توصيات متباينة لتحسين مقاييس الأداء لوحدة المعالجة المركزية الأمثل من خلال خوارزميات مختلفة، مما يسهم في تقليل وقت الانتظار ووقت الاستجابة ووقت التنفيذ. ومع ذلك، لم يتوصل إلى خوارزمية واحدة تتفوق في المعايير جميعهم.

تناولت الأبحاث السابقة مراجعة نظرية للخوارزميات. لكنها لم تقدم تحليلاً مفصلاً لحالات دراسية متنوعة. بالمقابل، يركز هذا البحث على تحليل عملي لأداء هذه الخوارزميات من خلال استخدام بيانات لحالات دراسية معينة، بهدف تقديم رؤية واضحة حول الأنسب لكل حالة.

4. معايير تقييم الأداء:

تشمل المعايير مجموعة من المؤشرات التي تُستخدم لتقييم كفاءة وسرعة أنظمة الحوسبة، مثل أنظمة التشغيل وخوارزميات الجدولة. تساعد هذه المعايير في تحليل فعالية النظام في توزيع الموارد، وتنفيذ العمليات، وتحقيق الأهداف المطلوبة.

فيما يلي أبرز معايير تقييم الأداء الشائعة في أنظمة التشغيل وخوارزميات الجدولة [7]:

1. استخدام وحدة المعالجة المركزية (Utilization of CPU): يشير إلى النسبة المئوية للوقت التي تكون فيه وحدة المعالجة المركزية مشغولة بتنفيذ العمليات مقارنةً بالوقت التي تكون فيه غير نشطة (خاملة). الهدف هو إبقاء وحدة المعالجة المركزية مشغولة لأقصى حد ممكن لضمان تحقيق أفضل أداء.
2. الإنتاجية (Throughput): تشير إلى عدد العمليات التي تكتمل وتنجز بنجاح خلال فترة زمنية محددة.
3. زمن الرشقة (Burst Time): هو المدة الكاملة التي تحتاجها العملية لإتمام جميع تعليماتها على وحدة المعالجة المركزية. يُسمى أيضاً بـ "CPU Time" أو "Execution Time".
4. زمن الإتمام (Completion Time): هو الفترة التي تستغرقها العملية حتى تنفذ بشكل كامل. يُقاس هذا الوقت من لحظة بدء العملية حتى لحظة إتمامها.
5. زمن الدورة (Turnaround Time): هو الوقت الكلي الذي تحتاجه العملية من لحظة تقديمها للنظام حتى لحظة إتمامها. يُحسب بالطريقة التالية:

$$\text{Turnaround Time} = \text{Arrival Time} - \text{Completion Time}$$

6. زمن الانتظار (Waiting Time): هو الوقت الكلي الذي تستغرقه العملية في انتظار تخصيص وحدة المعالجة المركزية لها بعد أن قدمت للنظام. يُحسب بالطريقة التالية:

$$\text{Waiting Time} = \text{Burst Time} - \text{Turnaround Time}$$

7. زمن الاستجابة (Response Time): هو الفترة الزمنية التي تستغرقها العملية من تقديم طلب إلى نظام التشغيل، حتى استلام أول استجابة، وليس حتى انتهاء العملية بالكامل.

8. العدالة (Fairness): هو المبدأ الذي يضمن حصول كل عملية على حصة عادلة من وحدة المعالجة المركزية دون تمييز غير مبرر لصالح عملية معينة على حساب غيرها. يهدف هذا المبدأ إلى تحقيق توزيع متوازن للموارد، مما يضمن أن تتمتع العمليات جميعهن بفرص متساوية للتنفيذ.

تُعتبر معايير تقييم الأداء ضرورية لتقييم كفاءة النظام وخوارزميات الجدولة. تحقيق توازن جيد بين هذه المعايير يضمن تحسين أداء النظام بشكل عام ويقلل من زمن الانتظار، زمن الاستجابة، ويحسن من استخدام الموارد.

5. خوارزميات الجدولة المدروسة:

1. الواصل أولاً يخدم أولاً (First Come First Serve – FCFS) [8]:

تعتبر هذه الخوارزمية من أبسط خوارزميات الجدولة في أنظمة التشغيل. تعتمد على مبدأ الرتل، حيث تجدر العمليات بناءً على ترتيب وصولها إلى قائمة الانتظار. العملية التي تصل أولاً تُنفذ أولاً، وتتم معالجة كل عملية حتى الانتهاء قبل بدء العملية التالية. خوارزمية FCFS تعتبر خوارزمية غير قابلة للمقاطعة، مما يعني أنه بمجرد بدء تنفيذ المهمة، تستمر هذه المهمة حتى تنتهي بالكامل دون توقف. ورغم بساطتها وسهولة تنفيذها، إلا أنها قد تؤدي إلى مشكلة تُعرف بتأثير القافلة (Convoy Effect)، حيث يمكن أن تتسبب العمليات الطويلة في تأخير جميع العمليات الأخرى اللاحقة، مما يزيد زمن الانتظار والاستجابة.

2. مهمة أقصر أولاً (Shortest Job First – SJF) [9]:

تعطي هذه الخوارزمية الأولوية للمهام التي تحتاج إلى أقل وقت ممكن للتنفيذ. الهدف الأساسي هو تقليل إجمالي زمن الانتظار، حيث تعطى الأولوية للعمليات القصيرة، مما يسهم في تحسين كفاءة نظام بشكل عام.

تنقسم خوارزمية SJF إلى نوعين: النوع الأول هو خوارزمية غير قابلة للمقاطعة (Non-Preemptive)، حيث تُنفذ العملية بشكل تام دون انقطاع حتى النهاية، والنوع الثاني هو خوارزمية قابلة للمقاطعة (Preemptive)، والتي تتيح إيقاف العملية الحالية في حال وصول عملية جديدة تحتاج إلى وقت تنفيذ أقصر.

على الرغم من أن SJF فعالة في تقليل زمن الانتظار وزمن المعالجة الكلي، إلا أنها تواجه مشكلة الجوع (Starvation)، حيث قد تبقى العمليات الطويلة عالقة في قائمة الانتظار إذا استمرت العمليات القصيرة في الوصول. وتعتمد كفاءة SJF على معرفة زمن التنفيذ مسبقاً، مما يحد من استخدامها في بعض الأنظمة.

3. راوند روبين (Round Robin – RR) [9]:


تعتمد خوارزمية على تخصيص زمن متساوٍ (Time Quantum) لكل عملية. تعطى كل عملية وقت معين لتنفيذ جزء منها، وإذا لم تكمل العملية في هذا الوقت المحدد، تعاد إلى قائمة الانتظار لاستئناف التنفيذ في الجولة التالية. تساهم هذه الطريقة في جعل خوارزمية RR عادلة، حيث تضمن عدم استحواذ عملية واحدة على الموارد لفترات طويلة. تُعتبر هذه الخوارزمية ملائمة للأنظمة التفاعلية، مثل أنظمة التشغيل ذات المهام المتعددة، حيث تحتاج العمليات إلى استجابة سريعة. ومع ذلك، يتأثر أداء خوارزمية RR بشكل كبير على اختيار حجم الزمن المخصص (Quantum). إذا كان الزمن المخصص صغيراً جداً، فإن ذلك يؤدي إلى تكرار تبديل السياق (Context Switching)، مما ينتسب في زيادة العبء على النظام. أما إذا كان الزمن كبيراً جداً، يصبح النظام مشابهاً لخوارزمية FCFS، مما يتسبب في تأخير العمليات القصيرة.

4. خوارزمية متعددة المستويات (Multilevel Queue Scheduling–MQL) [7]:

تعتمد على تقسيم العمليات إلى قوائم متعددة (Queues) تبعاً لخصائص محددة. مثل الأولوية أو نوع العملية (تفاعلية أو حسابية). يتم جدولة كل قائمة باستخدام خوارزمية معينة، مثل Round Robin للعمليات التفاعلية التي تحتاج إلى استجابة سريعة، و FCFS للعمليات التي تتطلب وقت معالجة أطول.

تعالج القوائم بطريقة هرمية، حيث تعطى الأولوية للعمليات الموجودة في القوائم ذات الأولوية الأعلى لتنفيذها قبل العمليات في القوائم ذات الأولوية الأدنى. تنفذ العمليات في كل قائمة بشكل

مستقل كما في الشكل (1) ، وعادةً لا تنتقل العمليات بين القوائم، على عكس خوارزمية الجدولة متعددة المستويات مع التغذية العكسية.



الشكل (1): خوارزمية جدولة متعددة المستويات [5] Multilevel Queue Scheduling

6. المناقشة:

سيتم مناقشة ثلاث دراسات مقارنة تتعلق بالخوارزميات المذكورة سابقاً. كل عملية لها زمن وصول وأيضاً زمن التنفيذ. فيما يلي مناقشة لكل منها:

1- الحالة الأولى:

تم اختيار الحالة الأولى لتحليل أداء الخوارزميات مع العمليات القصيرة، بهدف تقييم كفاءة كل خوارزمية في تقليل زمن الانتظار وزمن المعالجة الكلي. نفترض أن لدينا أربع عمليات بأوقات وصول وأوقات تنفيذ كما هو موضح في الجدول (1):

الجدول (1) : مجموعة من العمليات مع وقت وصول ووقت تنفيذ

العملية	زمن الوصول (Sec)	زمن التنفيذ (Sec)
P1	0	4
P2	2	3
P3	4	6
P4	6	5

خوارزمية FCFS :

بعد تحليل زمن الوصول، نحصل على مخطط جاننت كما في الشكل (2)، ينتهي مخطط جاننت عند 18s.

P1	P2	P3	P4	
0	4	7	13	18

الشكل (2): تحليل مخطط جاننت

بناءً على تحليل مخطط جاننت في الشكل (2)، نحصل على جدول تحليل الأداء (2):

الجدول (2): تحليل الأداء للخوارزمية FCFS

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	4	0	4	4
P2	2	3	4	7	5
P3	4	6	7	13	9
P4	6	5	13	18	12

خوارزمية SJF :

تقييم أداء خوارزميات الجدولة RR, SJF, MQL, FCFS

بعد تحليل زمن الوصول، نحصل على مخطط جانت كما في الشكل (3)، ينتهي مخطط جانت عند 18s.

P1	P2	P4	P3	
0	4	7	12	18

الشكل (3): تحليل مخطط جانت

بناءً على تحليل مخطط جانت في الشكل (3)، نحصل على جدول تحليل الأداء (3):

الجدول (3): تحليل الأداء للخوارزمية SJF

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	4	0	4	4
P2	2	3	4	7	5
P3	4	6	12	18	14
P4	6	5	7	12	6

خوارزمية RR :

بعد تحليل زمن الوصول مع تخصيص زمني يساوي 3 ، نحصل على مخطط جانت كما في الشكل (4)، ينتهي مخطط جانت عند 18s.

P1	P2	P3	P4	P1	P3	P4	
0	3	6	9	12	13	16	18

الشكل (4): تحليل مخطط جانت

بناءً على تحليل مخطط جانت في الشكل (4)، نحصل على جدول تحليل الأداء (4):

الجدول (4): تحليل الأداء للخوارزمية RR

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	4	0	13	13
P2	2	3	3	6	4
P3	4	6	6	16	12
P4	6	5	9	18	12

خوارزمية MQL:

تظهر الأولوية كما في الجدول (5) مدى أهمية العمليات، حيث يتم إعطاء العمليات ذات الأولوية الأعلى (1) الأفضلية في التنفيذ مقارنة بالأولوية الأقل (2).

الجدول (5): أولوية العمليات للخوارزمية MQL

العملية	زمن الوصول (S)	زمن التنفيذ (S)	الأولوية
P1	0	4	1
P2	2	3	1
P3	4	6	2
P4	6	5	2

تُجدول العمليات ذات الأولوية الأعلى باستخدام خوارزمية RR مع تخصيص زمني قدره 3، بينما تجدول العمليات الأقل أولوية باستخدام خوارزمية FCFS، وبهذا نحصل على مخطط جاننت كما هو موضح في الشكل (5):

تقييم أداء خوارزميات الجدولة RR, SJF, MQL, FCFS

P1	P2	P1	P3	P4	
0	3	6	7	13	18

الشكل (5): تحليل مخطط جانت


بناءً على تحليل مخطط جانت في الشكل (5)، نحصل على جدول تحليل الأداء (6):

الجدول (6): تحليل الأداء للخوارزمية MQL

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	4	0	7	7
P2	2	3	3	6	4
P3	4	6	7	13	9
P4	6	5	13	18	12

من تحليل أداء الجداول ومخططات جانت أعلاه، نحصل على متوسط زمن الانتظار ومتوسط

زمن المعالجة الكلي، كما في الشكل (6):



الشكل (6): مقارنة بين خوارزميات الجدولة للحالة الأولى

نلاحظ أن خوارزمية SJF حققت أداءً أفضل مقارنةً بالخوارزميات الأخرى، حيث سجلت أقل متوسط زمن انتظار وأقل متوسط زمن معالجة. هذا يعكس فعالية خوارزمية SJF في التعامل مع العمليات القصيرة، إذ تعطي الأولوية للعمليات ذات زمن التنفيذ الأقصر، مما يقلل زمن الانتظار الكلي في النظام. كما أن خوارزمية RR أقل كفاءة، لأنها خصصت وقتاً متساوياً لكل عملية، مما أدى إلى زيادة زمن الانتظار.

2- الحالة الثانية:

تم اختيار الحالة الثانية لدراسة أداء الخوارزميات مع عمليات متباينة بين الطويلة والقصيرة لتحليل كيفية تعامل كل خوارزمية مع أعباء معالجة متنوعة وتقييم قدرتها على تحقيق التوازن في زمن الانتظار وزمن المعالجة الكلي.

نفترض أن لدينا أربع عمليات بأوقات وصول وأوقات تنفيذ، كما هو موضح في الجدول (7):

الجدول (7): مجموعة من العمليات مع وقت وصول ووقت تنفيذ

العملية	زمن الوصول (Sec)	زمن التنفيذ (Sec)
P1	0	10
P2	2	1
P3	4	8
P4	6	3

خوارزمية FCFS:

بعد تحليل زمن الوصول، نحصل على مخطط جانت كما في الشكل (7)، ينتهي مخطط جانت عند 22s.

P1	P2	P3	P4
0	10	11	19
			22

الشكل (7): تحليل مخطط جانت

تقييم أداء خوارزميات الجدولة RR, SJF, MQL, FCFS

بناءً على تحليل مخطط جانتي في الشكل (7)، نحصل على جدول تحليل الأداء (8):

الجدول (8): تحليل الأداء للخوارزمية FCFS

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	10	10
P2	2	1	10	11	9
P3	4	8	11	19	15
P4	6	3	19	22	16

خوارزمية SJF :

بعد تحليل زمن الوصول، نحصل على مخطط جانتي كما في الشكل (8)، ينتهي مخطط جانتي عند 22s.

P1	P2	P4	P3	
0	10	11	14	22

الشكل (8): تحليل مخطط جانتي

بناءً على تحليل مخطط جانتي في الشكل (8)، نحصل على جدول تحليل الأداء (9):

الجدول (9): تحليل الأداء للخوارزمية SJF

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	10	10
P2	2	1	10	11	9
P3	4	8	14	22	18
P4	6	3	11	14	8

بعد تحليل زمن الوصول مع تخصيص زمني يساوي 3 ، نحصل على مخطط جانت كما في الشكل (9)، ينتهي مخطط جانت عند 22s.

P1	P2	P3	P4	P1	P3	P1	P3	P1	
0	3	4	7	10	13	16	19	21	22

الشكل (9): تحليل مخطط جانت

بناءً على تحليل مخطط جانت في الشكل (9)، نحصل على جدول تحليل الأداء (10):

الجدول (10): تحليل الأداء للخوارزمية RR

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	22	22
P2	2	1	3	4	2
P3	4	8	4	21	17
P4	6	3	7	10	4

خوارزمية MQL:

تظهر الأولوية كما في الجدول (11) مدى أهمية العمليات، حيث يتم إعطاء العمليات ذات الأولوية الأعلى (1) الأفضلية في التنفيذ مقارنة بالأولوية الأقل (2).

الجدول (11): أولوية العمليات للخوارزمية MQL

العملية	زمن الوصول (Sec)	زمن التنفيذ (Sec)	الأولوية
P1	0	10	2
P2	2	1	1
P3	4	8	2
P4	6	3	1

تقييم أداء خوارزميات الجدولة RR, SJF, MQL, FCFS

تُجدول العمليات ذات الأولوية الأعلى باستخدام خوارزمية RR مع تخصيص زمني قدره 3، بينما تُجدول العمليات الأقل أولوية باستخدام خوارزمية FCFS، وبهذا نحصل على مخطط جانت كما هو موضح في الشكل (10):

P1	P2	P1	P4	P1	P3	
0	2	3	6	9	14	22


الشكل (10): تحليل مخطط جانت

بناءً على تحليل مخطط جانت في الشكل (10)، نحصل على جدول تحليل الأداء (12):

الجدول (12): تحليل الأداء للخوارزمية MQL

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	14	14
P2	2	1	2	3	1
P3	4	8	14	22	18
P4	6	3	6	9	3

من تحليل أداء الجداول ومخططات جانت أعلاه، نحصل على متوسط زمن الانتظار ومتوسط زمن المعالجة الكلي، كما في الشكل (11):



الشكل (11): مقارنة بين خوارزميات الجدولة للحالة الثانية

نلاحظ من هذا الرسم البياني أن خوارزمية MLQ تعتبر الأفضل في التعامل مع العمليات المتباينة بين قصيرة وطويلة، حيث سجلت أقل متوسط زمن انتظار وأقل متوسط زمن معالجة. في هذه الحالة، تختلف العمليات بين القصيرة والطويلة، مما يستدعي إجراء تحليل دقيق لأداء الخوارزميات في ظل هذه الأزمنة. سنقوم الآن بالتحليل المتعمق لتأثير توازن العمليات الطويلة والقصيرة على أداء الخوارزميات المختلفة.

أ. معدل العمليات الطويلة أعلى:

نفترض أن لدينا أربع عمليات بأوقات وصول وأوقات تنفيذ، كما هو موضح في الجدول (13):

الجدول (13): مجموعة من العمليات مع وقت وصول ووقت تنفيذ

العملية	زمن الوصول (Sec)	زمن التنفيذ (Sec)
P1	0	10

تقييم أداء خوارزميات الجدولة RR, SJF, MQL, FCFS

1	2	P2
8	4	P3
12	6	P4

خوارزمية FCFS:

بعد تحليل زمن الوصول، نحصل على مخطط جانت كما في الشكل (12)، ينتهي مخطط جانت عند 31s.

P1	P2	P3	P4
0	10	11	19
			31

الشكل (12): تحليل مخطط جانت

بناءً على تحليل مخطط جانت في الشكل (12)، نحصل على جدول تحليل الأداء (14):

الجدول (14): تحليل الأداء للخوارزمية FCFS

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	10	10
P2	2	1	10	11	9
P3	4	8	11	19	15
P4	6	12	19	31	25

خوارزمية SJF :

بعد تحليل زمن الوصول، نحصل على مخطط جانت كما في الشكل (13)، ينتهي مخطط جانت عند 31s.

P1	P2	P3	P4	
0	10	11	19	31

الشكل (13): تحليل مخطط جاننت

بناءً على تحليل مخطط جاننت في الشكل (13)، نحصل على جدول تحليل الأداء (15):

الجدول (15): تحليل الأداء للخوارزمية SJF

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	10	10
P2	2	1	10	11	9
P3	4	8	11	19	15
P4	6	12	19	31	25

خوارزمية RR :

بعد تحليل زمن الوصول مع تخصيص زمني يساوي 3 ، نحصل على مخطط جاننت كما في الشكل (14)، ينتهي مخطط جاننت عند 31s.

P1	P2	P3	P4	P1	P3	P4	P1	P3	P4	P1	P4	
0	3	4	7	10	13	16	19	22	24	27	28	31

الشكل (14): تحليل مخطط جاننت

بناءً على تحليل مخطط جاننت في الشكل (14)، نحصل على جدول تحليل الأداء (16):

الجدول (16): تحليل الأداء للخوارزمية RR

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	28	28

تقييم أداء خوارزميات الجدولة RR, SJF, MQL, FCFS

2	4	3	1	2	P2
20	24	4	8	4	P3
25	31	7	12	6	P4

خوارزمية MQL:

تظهر الأولوية كما في الجدول (17) مدى أهمية العمليات، حيث يتم إعطاء العمليات ذات الأولوية الأعلى (1) الأفضلية في التنفيذ مقارنة بالأولوية الأقل (2).

الجدول (17): أولوية العمليات للخوارزمية MQL

الأولوية	زمن التنفيذ (Sec)	زمن الوصول (Sec)	العملية
2	10	0	P1
1	1	2	P2
2	8	4	P3
2	12	6	P4

تُجدول العمليات ذات الأولوية الأعلى باستخدام خوارزمية RR مع تخصيص زمني قدره 3، بينما تُجدول العمليات الأقل أولوية باستخدام خوارزمية FCFS، وبهذا نحصل على مخطط جانت كما هو موضح في الشكل (15):

P1	P2	P1	P3	P4	
0	2	3	11	19	31


الشكل (15): تحليل مخطط جانت

بناءً على تحليل مخطط جانت في الشكل (15)، نحصل على جدول تحليل الأداء (18):

الجدول (18): تحليل الأداء للخوارزمية MQL

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	11	11
P2	2	1	2	3	1
P3	4	8	11	19	15
P4	6	12	19	31	25

من تحليل أداء الجداول ومخططات جانت أعلاه، نحصل على متوسط زمن الانتظار ومتوسط زمن المعالجة الكلي، كما في الشكل (16):



الشكل (16): مقارنة بين خوارزميات الجدولة للحالة الثانية (أ)

تُظهر النتائج في هذه الحالة، التي تتسم بزيادة نسبة العمليات الطويلة، تفوق خوارزمية MLQ مقارنة بباقي الخوارزميات.

ب. معدل العمليات القصيرة أعلى:

نفترض أن لدينا أربع عمليات بأوقات وصول وأوقات تنفيذ، كما هو موضح في الجدول (19):

تقييم أداء خوارزميات الجدولة RR, SJF, MQL, FCFS

الجدول (19): مجموعة من العمليات مع وقت وصول ووقت تنفيذ

العملية	زمن الوصول (Sec)	زمن التنفيذ (Sec)
P1	0	10
P2	2	1
P3	4	2
P4	6	3

خوارزمية FCFS:

بعد تحليل زمن الوصول، نحصل على مخطط جانت كما في الشكل (17)، ينتهي مخطط جانت عند 16s.

P1	P2	P3	P4
0	10	11	13
16			

(17): تحليل مخطط جانت

بناءً على تحليل مخطط جانت في الشكل (17)، نحصل على جدول تحليل الأداء (20):

الجدول (20): تحليل الأداء للخوارزمية FCFS

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	10	10
P2	2	1	10	11	9
P3	4	2	11	13	9
P4	6	3	13	16	10

خوارزمية SJF :

بعد تحليل زمن الوصول، نحصل على مخطط جانت كما في الشكل (18)، ينتهي مخطط جانت عند 16s.

P1	P2	P3	P4	
0	10	11	13	16

الشكل (18): تحليل مخطط جاننت

بناءً على تحليل مخطط جاننت في الشكل (13)، نحصل على جدول تحليل الأداء (21):

الجدول (21): تحليل الأداء للخوارزمية SJF

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	10	10
P2	2	1	10	11	9
P3	4	2	11	13	9
P4	6	3	13	16	10

خوارزمية RR :

بعد تحليل زمن الوصول مع تخصيص زمني يساوي 3 ، نحصل على مخطط جاننت كما في الشكل (19)، ينتهي مخطط جاننت عند 16s.

P1	P2	P3	P4	P1	P1	P1	
0	3	4	6	9	12	15	16

الشكل (19): تحليل مخطط جاننت

بناءً على تحليل مخطط جاننت في الشكل (19)، نحصل على جدول تحليل الأداء (22):

الجدول (22): تحليل الأداء للخوارزمية RR

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	16	16

تقييم أداء خوارزميات الجدولة RR, SJF, MQL, FCFS

2	4	3	1	2	P2
2	6	4	2	4	P3
3	9	6	3	6	P4

خوارزمية MQL:

تظهر الأولوية كما في الجدول (23) مدى أهمية العمليات، حيث يتم إعطاء العمليات ذات الأولوية الأعلى (1) الأفضلية في التنفيذ مقارنة بالأولوية الأقل (2).

الجدول (23): أولوية العمليات للخوارزمية MQL

الأولوية	زمن التنفيذ (Sec)	زمن الوصول (Sec)	العملية
2	10	0	P1
1	1	2	P2
1	2	4	P3
1	3	6	P4

تُجدول العمليات ذات الأولوية الأعلى باستخدام خوارزمية RR مع تخصيص زمني قدره 3، بينما تُجدول العمليات الأقل أولوية باستخدام خوارزمية FCFS، وبهذا نحصل على مخطط جانت كما هو موضح في الشكل (20):

P1	P2	P1	P3	P4	P1	
0	2	3	4	6	9	16


الشكل (20): تحليل مخطط جانت

بناءً على تحليل مخطط جانت في الشكل (20)، نحصل على جدول تحليل الأداء (24):

الجدول (24): تحليل الأداء للخوارزمية MQL

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	16	16
P2	2	1	2	3	1
P3	4	2	4	6	2
P4	6	3	6	9	3

من تحليل أداء الجداول ومخططات جاننت أعلاه، نحصل على متوسط زمن الانتظار ومتوسط زمن المعالجة الكلي، كما في الشكل (21):



الشكل (21): مقارنة بين خوارزميات الجدولة للحالة الثانية (ب)

تُظهر النتائج أن MLQ قادرة على إعطاء الأولوية للعمليات القصيرة في صفوف معينة، مما يقلل بشكل كبير من متوسط زمن الانتظار والمعالجة مقارنة بالخوارزميات الأخرى.

إذاً أظهرت خوارزمية MLQ تفوقاً ملحوظاً في جميع الحالات الثلاث (المتباينة، ذات الأغلبية الطويلة، وذات الأغلبية القصيرة) بفضل مرونتها في تخصيص الموارد والتعامل مع العمليات المختلفة بفعالية.

3- الحالة الثالثة:

تم اختيار الحالة الثالثة لدراسة أداء الخوارزميات مع العمليات الطويلة بهدف تقييم كفاءة كل خوارزمية في التعامل مع أعباء معالجة كبيرة وتحليل تأثيرها على زمن الانتظار وزمن المعالجة الكلي في بيئات تتطلب تنفيذ عمليات طويلة الأمد.

نفترض أن لدينا أربع عمليات بأوقات وصول وأوقات تنفيذ، كما هو موضح في الجدول (25):

الجدول (25): مجموعة من العمليات مع وقت وصول ووقت تنفيذ

العملية	زمن الوصول (Sec)	زمن التنفيذ (Sec)
P1	0	10
P2	2	15
P3	4	20
P4	6	20

خوارزمية FCFS :

بعد تحليل زمن الوصول، نحصل على مخطط جاننت كما في الشكل (22)، ينتهي مخطط جاننت عند 65s.

P1	P2	P3	P4
0	10	25	45
			65

الشكل (22): تحليل مخطط جاننت

بناءً على تحليل مخطط جاننت في الشكل (22)، نحصل على جدول تحليل الأداء (26):

الجدول (26): تحليل الأداء للخوارزمية FCFS

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	10	10

23	25	10	15	2	P2
41	45	25	20	4	P3
59	65	45	20	6	P4

خوارزمية SJF :

بعد تحليل زمن الوصول، نحصل على مخطط جانتي كما في الشكل (23)، ينتهي مخطط جانتي عند 65s.

P1	P2	P3	P4	
0	10	25	45	65

الشكل (23): تحليل مخطط جانتي

بناءً على تحليل مخطط جانتي في الشكل (23)، نحصل على جدول تحليل الأداء (27):

الجدول (27): تحليل الأداء للخوارزمية SJF

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	10	10
P2	2	15	10	25	23
P3	4	20	25	45	41
P4	6	20	45	65	59

خوارزمية RR :

بعد تحليل زمن الوصول مع تخصيص زمني قدره 5 ، نحصل على مخطط جانتي كما في الشكل (24)، ينتهي مخطط جانتي عند 65s.

تقييم أداء خوارزميات الجدولة RR, SJF, MQL, FCFS

P1	P2	P3	P4	P1	P2	P3	P4	P2	P3	P4	P3	P4	
0	5	10	15	20	25	30	35	40	45	50	55	60	65

الشكل (24): تحليل مخطط جاننت

بناءً على تحليل مخطط جاننت في الشكل (24)، نحصل على جدول تحليل الأداء (28):

الجدول (28): تحليل الأداء للخوارزمية RR

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	25	25
P2	2	15	5	45	43
P3	4	20	10	60	56
P4	6	20	15	65	59

خوارزمية MQL:

تظهر الأولوية كما في الجدول (29) مدى أهمية العمليات، حيث يتم إعطاء العمليات ذات الأولوية الأعلى (1) الأفضلية في التنفيذ مقارنة بالأولوية الأقل (2).

الجدول (29): أولوية العمليات للخوارزمية MQL

العملية	زمن الوصول (Sec)	زمن التنفيذ (Sec)	الأولوية
P1	0	10	1
P2	2	15	1
P3	4	20	2
P4	6	20	2

يتم جدولة العمليات ذات الأولوية الأعلى وفقاً لخوارزمية RR والعمليات ذات الأولوية الأدنى وفقاً لخوارزمية FCFS، نحصل على مخطط جاننت كما في الشكل (25):

P1	P2	P1	P2	P2	P3	P4	
0	5	10	15	20	25	45	65

الشكل (25) تحليل مخطط جانتي

بناءً على تحليل مخطط جانتي في الشكل (25)، نحصل على جدول تحليل الأداء (30):

الجدول (30) تحليل الأداء للخوارزمية MQL

العملية	زمن الوصول	زمن التنفيذ	زمن البدء	زمن الانتهاء	زمن الدورة
P1	0	10	0	15	15
P2	2	15	5	25	23
P3	4	20	25	45	41
P4	6	20	45	65	59

من تحليل أداء الجداول ومخططات جانتي أعلاه، نحصل على متوسط زمن الانتظار ومتوسط

زمن المعالجة الكلي، كما في الشكل (26):



الشكل (26): مقارنة بين خوارزميات الجدولة للحالة الثالثة

في حالة العمليات الطويلة، لا توجد خوارزمية توفر أداءً مثالياً بالكامل، حيث تعاني كل خوارزمية من تحديات مختلفة.

أظهرت الخوارزميات أداءً متقارباً باستثناء خوارزمية Round Robin، يبدو أن خوارزمية Round Robin (RR) قد تكون الخيار الأفضل نسبياً في هذه الحالة، للأسباب التالية:

التوزيع العادل للوقت: خوارزمية RR توزع وقت المعالجة بالتساوي بين جميع العمليات، مما يمنع العمليات الطويلة من احتكار المعالج لفترات طويلة. هذا يجعلها أكثر عدالة مقارنة بخوارزميات مثل FCFS و SJF، حيث قد تنتظر بعض العمليات طويلاً حتى تحصل على دورها. زمن الانتظار: بالرغم من أن RR قد لا تقلل زمن المعالجة الكلي مثل SJF، إلا أنها تمنع التفاوت الشديد في زمن الانتظار بين العمليات. العمليات الطويلة تحصل على وقت معالجة بشكل دوري، مما يحقق توازناً جيداً.

إمكانية تعديل التوقيت الزمني: إحدى ميزات RR هي القدرة على ضبط "التوقيت الزمني" بما يتناسب مع طول العمليات. فإذا كانت العمليات جميعها طويلة، يمكن زيادة التوقيت الزمني لتحسين الأداء وتقليل زمن الانتظار الكلي.

7. النتائج:

يوضح الجدول (31) ملخصاً لتحليل الأداء المقارن بين الخوارزميات المختلفة.

الجدول (31) ملخص تحليل الأداء للخوارزميات

الخوارزمية	متوسط زمن الانتظار	متوسط زمن المعالجة الكلي	
FCFS	3	7.5	دراسة الحالة 1
SJF	2.75	7.25	
RR	5.75	10.25	
MQL	3.5	8	
FCFS	7	12.5	دراسة الحالة 2
SJF	5.75	11.25	
RR	5.75	11.25	
MQL	3.5	9	
FCFS	7	14.75	دراسة الحالة أ
SJF	7	14.75	
RR	11	18.75	
MQL	5.25	13	
FCFS	5.5	9.5	دراسة الحالة ب
SJF	5.5	9.5	
RR	1.75	5.75	
MQL	1.5	5.5	
FCFS	17	33.25	دراسة الحالة 3
SJF	17	33.25	
RR	29.5	45.75	
MQL	18.25	34.5	

8. الاستنتاج:

في هذا البحث، حُلَّ أداء أربع خوارزميات جدولة RR، SJF، FCFS، وMLQ، من خلال ثلاث حالات متنوعة لاختبار تأثير توزيع العمليات (عمليات طويلة، عمليات قصيرة، وتوزيع متباين بينهما). أظهرت النتائج أن أداء الخوارزميات يتفاوت حسب نمط العمليات. حيث تفوقت خوارزمية SJF في التعامل مع العمليات القصيرة بفضل قدرتها على تقليل متوسط زمن الانتظار. بينما أثبتت خوارزمية MLQ كفاءتها في إدارة التوزيع المتباين للعمليات بفضل مرونتها في التعامل مع الأولويات المختلفة. أما بالنسبة للعمليات الطويلة، فقد كانت خوارزمية RR الأكثر كفاءة؛ نظراً لتحقيقها عدالة في تخصيص الموارد.

تظهر الخوارزميات الأربعة المدروسة (MQL، RR، SJF، FCFS) مستويات مختلفة من الكفاءة. وذلك وفقاً لطبيعة العمليات وأوقات التنفيذ.

9. المراجع:

- 1- BHATIA, J., MATHURIA, S., LADWANI, V. M., & PADMANABHAN, S. 2024– Optimised Round Robin with Virtual Runtime for CPU Scheduling. Lecture Notes in Networks and Systems, Springer, 1st ed., Switzerland, 17p.
- 2- MAHBANI, R., & OMRAN, B.M. 2021 – Improving the Relative Length of the Task Schedule on Heterogeneous Data Processing Units. Al-Baath University Journal – Series of Mechanical, Electrical,

- and Informatics Engineering Sciences, Vol. 43, No. 26. (References In Arabic)
- 3- KISHOR, L., & GOYAL, D. 2013 – Comparative Analysis of Various Scheduling Algorithms. International Journal of Advanced Research in Computer Engineering & Technology (IJARCET), Vol. 2, No. 4, 1488p.
- 4- HARKI, N., AHMED, A., & HAJI, L. 2020 – CPU Scheduling Techniques: A Review on Novel Approaches Strategy and Performance Assessment. Journal of Applied Science and Technology Trends, Vol. 1, No. 2, 48–55.
- 5- OMAR, H. K., JIHAD, K. H., & HUSSEIN, S. F. 2021 – Comparative Analysis of the Essential CPU Scheduling Algorithms. Bulletin of Electrical Engineering and Informatics, Vol. 10, No. 5, 2742–2750.
- 6- ALI, S. M., ALSHAHRANI, R. F., HADADI, A. H., ALGHAMDI, T. A., ALMUHSIN, F. H., & EL-SHARAWY, E. E. 2021 – A Review on the CPU Scheduling Algorithms: Comparative Study. International Journal of Computer Science & Network Security, Vol. 21, No. 1, 19–26.
- 7- GONZÁLEZ-RODRÍGUEZ, M., OTERO-CERDEIRA, L., GONZÁLEZ-RUFINO, E., & RODRÍGUEZ-MARTÍNEZ, F. J. 2024 – Study and Evaluation of CPU Scheduling Algorithms. Heliyon, e29959–e29959.
- 8- KHIRBEK, F. G. 2023 – A Comparative Study of Task Scheduling Algorithms in Cloud Computing. Al-Baath University Journal – Series of Mechanical, Electrical, and Informatics Engineering Sciences, Vol. 45, No. 1. (References In Arabic)

- 9- SREENATH, M., & VIJAYA, P. A. 2022 – Analysis of Energy Saving Scheduling Algorithms for Multiprocessor Systems. International Journal of Science and Research Archive, Vol. 7, No. 2, 614–623.

دراسة المؤشرات الترموديناميكية لدارة محول حراري مبتكر وتقييم

أدائه

محمد أحمد محمد*

محمد عبده باكير**

الملخص

تعتبر المحولات الحرارية الإمتصاصية من الآلات الحرارية المشغلة حرارياً بواسطة منبع حراري منخفض درجة الحرارة. تطورت هذه الآلات كثيراً من الآلات الهجينة الى دارة المفاعل لتخفيف الاستهلاك الكهربائي، والإعتماد على الحرارة لتشغيل الدارة. قمنا في هذا البحث بدراسة المؤشرات الترموديناميكية لنموذج جديد مطور من دارة محول حراري (مفاعل)، تستخدم مزيج من الماء والأمونيا كوسيط عامل في الدارة بغرض تقييم أدائها.

توصلنا في هذا البحث إلى أهمية مؤشرات ضغط التشغيل، ودرجة حرارة المزيج الخارج من المفاعل على معاملات الأداء في الدارة، بالإضافة الى دور هذه المؤشرات في تحديد الغاية من استخدام المحول الحراري (كمضخة حرارية، أو آلة تبريد). كما تبين من الدراسة عدم تأثير مؤشرات مدى التدرج الحراري في المفاعل، أو درجة حرارة قاع المفاعل، أو حمل التبريد على معاملات أداء الدارة.

كما توصلنا في هذا البحث إلى أنه، وبسبب العمليات الكيميائية التي تحصل في المفاعل (امتصاص الأمونيا، وعملية الفصل الثقالي للمكونات) سوف تتأثر المؤشرات الترموديناميكية فيه، حيث تنتج حرارة ضمن المفاعل يجب التخلص منها بغرض ابقاء المفاعل في حالة مشحونة، والدارة في حالة عمل. تتعلق كميات الحرارة المطروحة في المفاعل بمؤشرات تشغيل المفاعل، وبحمل التبريد، والاستطاعة الكهربائية المستهلكة في الدارة.

كلمات مفتاحية: المحول الحراري، المفاعل الحراري، الدارات الإمتصاصية، المزيج الزيتروبي.

* أستاذ في قسم هندسة القوى- كلية الهندسة- جامعة حمص


** طالب دكتوراة في قسم هندسة القوى-كلية الهندسة- جامعة حمص

المحولة الحرارية الإمتصاصية (Absorption Heat Transformer)

يعرف المحول الحراري بأنه آلة حرارية امتصاصية تتبع دوران عقارب الساعة للوسيط العامل كما يبين الشكل (1)، حيث تُستخدم المصادر الحرارية (Q_{ev} , Q_{de}) ذات درجات الحرارة

المعتدلة (T_e , T_d)

لتشغيل كل من (المولد Desorber) و (المبخر Evaporator) على التوالي من أجل توليد بخار الوسيط العامل بضغط عالي (P_e) ضغط المبخر (Evaporator) بهدف الحصول على درجة حرارة مرتفعة (T_a) (درجة حرارة الماص Absorber). يتم




الشكل (1) مخطط لوغاريتمي (P-T) محولة حرارية

امتصاص البخار الناتج عن المبخر في الماص (Absorber)، وتضاف الحرارة الكامنة في البخار إلى حرارة المحلول (تفاعل الإمتصاص ناشر للحرارة) رافعة درجة حرارة الماص إلى درجة حرارة الخرج العالية (T_a). يتم طرح كمية من الحرارة من المكثف (Q_{co}) مما يقلل من معامل أداء هذه الآلة، وتكون عملية ضخ الحرارة (رفع درجة الحرارة) ليست فعالة بشكل كبير. تعتبر الفائدة الكبرى من استخدام هذه الآلات كمضخات حرارية هي في الاستفادة من الحرارة المهدورة في المنابع المتميزة بدرجات حرارة متوسطة، والتي غالباً ما تكون متوفرة بكثرة، إضافة إلى أن استخدام مضخات السائل تستهلك طاقة أقل بمرتين على الأقل من الحرارة المتدفقة في الدارة. تجدر الملاحظة إلى أن جريان الوسيط العامل (البخار - السائل) يسير مع دوران عقارب الساعة، حيث يكون المبخر، والماص عند ضغط عالي بخلاف الآلات الامتصاصية التقليدية، وتشابهها في خاصية التدرج الكبير للتركيز ودرجة الحرارة ضمن (الماص Absorber، المولد Desorber). استخدمت هذه الآلات بكثرة في العديد من التطبيقات الاقتصادية، وعلى رأسها البرك المائية الشمسية (solar pond).

درس Rivera [1] المؤشرات الترموديناميكية لمحولة حرارية تقليدية وحيدة المرحلة تعمل على ضخ كمية حرارة عند الدرجة (125°C)، من بركة مائية شمسية تمتاز بمدى (80 $^{\circ}\text{C}$ -30) لدرجات الحرارة، وقد استثمرت هذه الآلة في توليد البخار الصناعي. تميزت هذه الآلة برفع درجة الحرارة بحدود (50°C)، وبمعامل أداء ($\text{COP}=0.35$)، وهذا يعني أن (35%) من الحرارة المنتزعة من البركة ذات درجة الحرارة المعتدلة، قد سلمت بدرجة حرارة (125°C) في الماص (Absorber) لاستخدامها لأغراض صناعية. في حين قام Kurem [2] بدراسة مقارنة بين المحولات الحرارية التقليدية العاملة على (بروميد الليثيوم - الماء) مع الدارات العاملة على (الأمونيا - الماء)، وتوصل إلى أن

معامل أداء المحولة الحرارية يتعلق بشكل قوي بالمؤشرات الترموديناميكية لوسيط (التبريد - الامتصاص)، حيث أظهرت المحولات التي تعتمد على (الماء-بروميد الليثيوم) كوسيط عامل معامل أداء أعلى من الأنظمة التي تعتمد على (الأمونيا - الماء)، غير أن محلول (الماء-بروميد الليثيوم) أبدى سلبيات تتلخص بـ: اللزوجة العالية، التآكل، محدودية الانحلال عند بعض شروط التشغيل، محدودية درجات الحرارة العملية أثناء التشغيل، بلورة بروميد الليثيوم. في حين تميز محلول (الأمونيا- الماء) بقابلية انحلال كبيرة عند مجال واسع من شروط التشغيل، وهو يملك استقرار تجاه المعادن ما عدا النحاس، وخصائصه، بالإضافة إلى امتلاكه حرارة كامنة مرتفعة. كما قام Parham [3] من خلال إطروحة دكتوراة في الهندسة الميكانيكية في (Eastern Mediterranean University) بدراسة المؤشرات الترموديناميكية لإمكانية استخدام المحولات الحرارية التقليدية في تحلية مياه البحر حيث توصل إلى نتيجة مفادها أن زيادة كمية الماء النقي المنتجة كلما زاد معامل الاداء (COP)، والذي تبين أنه يرتبط عكسياً مع درجة حرارة التكثيف، ودرجة حرارة المصدر الحراري، وطرذاً مع حجم التدرج الحراري في الدارة. وقدّر كمية الماء النقي المنتج بحدود $(0.2435 \frac{kg}{s})$ عند أفضل معامل أداء للدارة المستخدمة (COP=0.38). نلاحظ مما سبق أنه على الرغم من انخفاض معامل أداء هذا النمط من المحولات الحرارية، إلا أنها تعتبر فعالة اقتصادياً، بسبب توفر كميات وفيرة من الحرارة في المسطحات المائية المسخنة بواسطة الطاقة الشمسية بدرجة حرارة منخفضة، وبتكلفة منخفضة. ولتحسين عامل أداء هذا النمط من المحولات الحرارية فقد جرى تاريخياً تحسينات كثيرة على هذه الدارات من قبيل ما قام به Kiatsiriroat [4]، حيث عمد إلى إضافة مضخة حرارية من نوع ضاغط البخار بين مكثف الدارة الامتصاصية ومبخرها، لاسترداد كل الحرارة الكامنة في البخار المتدفق من المولد (Desorber) إلى المكثف، وضح هذه الحرارة إلى المبخر، جاعلاً الفاقد الحراري في المكثف (Q_{co}) معدوم. بهذا



الشكل (2) دائرة Osenbrück

التعديل تم توثيق قيمة كبيرة لمعامل الأداء ليزداد إلى $(COP=0.8)$ ، وهو ما يشكل ميزة اقتصادية كبيرة لهذه الدارات. كما وثق Heredia [5] زيادة في معامل الأداء بحدود (14-30%) باستخدام حاقن

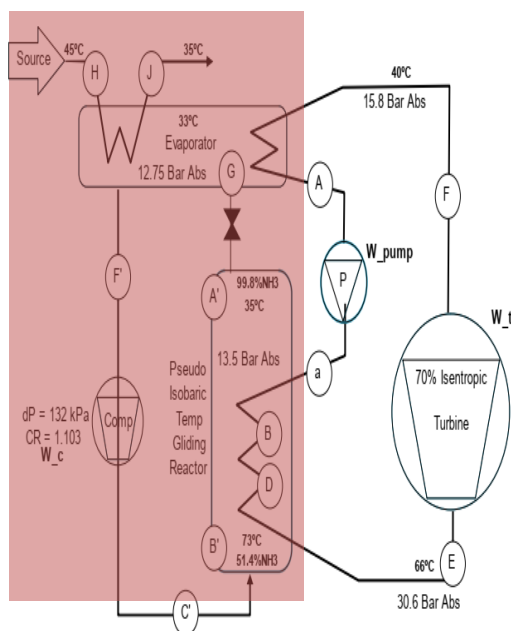
للبخار قبل دخوله إلى الماص (Absorber)، كما اقترح الباحث في بحثه استرداد حرارة المكثف باستخدام مجموعة من الأنابيب الحرارية بين المكثف، والمبخر، وزاد هذا التعديل أيضاً من معامل الأداء بحدود (20%) ليسجل قيمة لمعامل الأداء بحدود $(COP=0.6)$ ، وهي قيمة اقتصادية هامة إلى حد بعيد.

توالى التحسينات المدخلة على هذه الدارات عن طريق تهجينها بواسطة الدارات الانضغاطية ذات معامل الاداء العالي، حيث عمل Sveine [6] على تصميم محولة حرارية هجينة (امتصاصية / ضاغطة) تعمل بوسيط (الماء-الأمونيا) معتمداً على تصميم دائرة (Osenbrück) الهجينة كما يبين الشكل (2)، حيث دلت المؤشرات الترموديناميكية إلى أن أعلى ضغط في الدارة يُحقق (19 bar)، وأدى هذا التصميم إلى رفع درجة الحرارة من $(53^{\circ}C)$ (درجة حرارة المصدر الحراري) إلى $(117^{\circ}C)$ (درجة حرارة الوسط المحيط (البالوعة)) بمعامل أداء $(COP=3.8)$ ، وقد كان للمبادل الحراري للمحلول بين (المولد والماص) تأثير كبير على معامل أداء النظام. وفي مقارنة بين المحولات الحرارية الهجينة، والتقليدية عرض Jian [7] في مؤتمر خاص بالمضخات الحرارية مجموعة من

المحددات الخاصة لعمل كلا النوعين حيث بين أن أقل درجة حرارة يمكن استخدامها في مبخّر المحول الحراري التقليدي هي (17°C) في حين تبلغ (8°C) في المحول الهجين، في حين بلغت أعلى درجة حرارة يمكن استخدامها في مكثف المحول الحراري التقليدي (-22°C)، بينما في المحول الحراري الهجين (-6°C)، كما سجلت استطاعة التسخين للمحول التقليدي قيمة أقل بـ (50%) من استطاعة المحول الحراري الهجين عند نفس الشروط. وفي سبيل تطوير الدارات الهجينة قام Zhou [8] بدراسة المؤشرات الترموديناميكية لمضخة حرارية ضاغطة بخار تعمل بدارة محلول ثنائي، وتبادل حراري بين جهازي الماص والمولد، بمرحلة واحدة، ومرحلتين امتصاص. أشارت النتائج إلى أن النظام أحادي المرحلة يؤمن (COP) مرتفع، وارتفاع منخفض في درجة الحرارة (التدرج الحراري)، أما النظام ثنائي المرحلة تكون قيمة (COP) منخفضة بينما زاد ارتفاع درجة الحرارة بشكل كبير (التدرج الحراري). كما حقق Borgås [9] قيمة عالية لمعامل الأداء ($\text{COP}=1.6-1.8$) من خلال تطوير محول حراري هجين من نمط (Compression/Absorption Heat Transformer) (CAHT) باستخدام تدرج بدرجة حرارة (50°C) في الماص (Absorber)، وتدرج بحدود (40°C) في المولد (Generator). حيث كانت القيم التجريبية لتسخين الماء في المبادل الحراري للماص (البالوعة الحرارية) ضمن المجال ($110 - 160^{\circ}\text{C}$)، وتبريد الماء في المبادل الحراري للمولد (المصدر الحراري) ضمن المجال ($5 - 45^{\circ}\text{C}$)، وقد قام الضاغط بضغط بخار يحوي حوالي (95-98%) نسبة كتلية من (NH_3) ممزوجة بنسبة مئوية صغيرة جداً من بخار الماء، اختلف تصميم (Borgås) عن (Osenbrück) في الاستغناء عن الموفر بين المولد والماص، بالإضافة إلى اختلاف قيم الضغوط في الدارة حيث يرتبط معامل الأداء بالضغوط العاملة في الدارة. كما حقق Jensen [10] معامل أداء (COP) مشابه لنموذج (Borgås)، مختبراً ارتفاع في درجة الحرارة بحدود (30°C)

حيث يعمل الماص (Absorber) بمدى تدرج لدرجات الحرارة ($120-150\text{ C}^\circ$) على الرغم من استخدامه تدرج في درجة الحرارة بحدود (10 C°) فقط في المولد (Generator).

من المهم ملاحظة أن دارة (CAHT)، تتميز بفرق ضغط كبير بين الماص (Absorber)، والمولد (Generator)، وهو ما يتطلب استهلاك طاقة كهربائية كبير نسبياً من قبل الضاغط، بدلاً من استهلاك الطاقة الحرارية لتشغيل الآلة. عالج هذا الموضوع Enslin [11] ، حيث لاحظ أنه من المنطقي ضم التيارات المتعكسة للسائل ثنائي المزيج المتدفق في كل من الماص والمولد، والموفر ضمن عمود سائل ثنائي المزيج أطلق عليه اسم (المفاعل). إن هذا التعديل من وجهة نظره سيسمح باتصال مباشر بين التيارين المتعكسين منتجاً معدلات أعلى لانتقال الحرارة، والكتلة. وفي هذا السياق تتم عملية التوليد (Generation) في الجزء العلوي من العمود الثنائي حيث يتم سحب البخار من الأعلى، مبرداً هذا القطاع، بينما توليد الحرارة، وعملية الامتصاص (Absorption) تتم في أسفل العمود الثنائي حيث يدخل البخار المضغوط الناتج في الدارة ضمن المزيج في المفاعل، وهذا بدوره ينتج قطاعات في العمود الثنائي يتم فيها تدرج في درجة الحرارة، وتراكيز الوسيط العامل عند ضغط ثابت نسبياً. إن فقاعات البخار المضغوط سوف تدخل العمود الثنائي من الأسفل لتقوم بفعل ضخ رافع للبخار، مسبباً تدوير تدفق عكسي للسائل. استخدم Enslin [12] هذا النوع من المحولات الحرارية من أجل توليد الطاقة الكهربائية باستخدام دارة ثانوية (رانكين العضوية) الشكل (3). وقد قدم تحليلاً علمياً متكاملاً لإثبات أن نموذجة يعتبر محولاً حرارياً عالي الأداء من حيث تحقيقه مجموعة من المتطلبات الحرارية التي تتميز بها دارات المحول الحراري. وكانت المؤشرات الترموديناميكية للدارة كما هو موضح في الشكل (3).

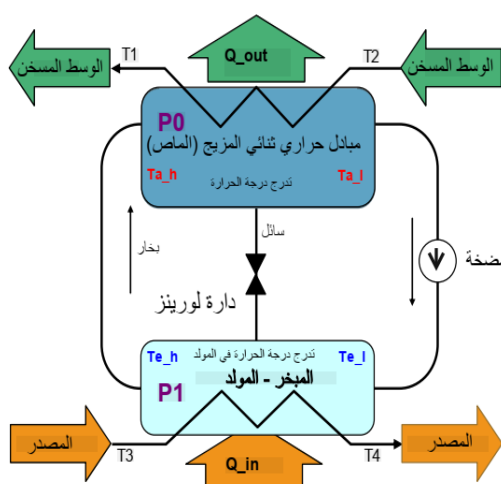


Position	Temp (Celsius)	Press (kPa)	Mass (kg/s)	Enthalpy (kJ/kg)	Entropy (kJ/kg.K)	Quality (x)	Media
A	40	1575	1.0	191.1	0.626	0%	NH3
a	40	3058	1.0	196.2	0.652	0%	NH3
B	66	3058	1.0	324.0	1.046	0%	NH3
D	66	3058	1.0	1286.6	3.884	100%	NH3
E	66	3058	1.0	1286.6	3.884	100%	NH3
F	40	1575	1.0	1231.9	3.968	94.71%	NH3
W_turbine = 54.7 kW					η_ORC = 4.4%		
W_pump = 5.1 kW					% Carnot = 57.0%		

Position	Temp (Celsius)	Press (kPa)	Mass (kg/s)	Enthalpy (kJ/kg)	Entropy (kJ/kg.K)	%NH3 (kg/kg)	Media
A'	35	1352		166.6	0.568	99.80%	NH3-H2O
B'	73	1357		89.9	1.064	51.49%	NH3-H2O
C'	39	1408	1.313	1030.7	4.273	99.80%	NH3-H2O
F'	33	1276	1.313	1026.4	4.230	99.80%	NH3-H2O
G	33	1276	1.313	166.6	0.575	99.80%	NH3-H2O
H	45	200	2.101	188.4	0.639	-	H2O
J	35	195	2.101	146.6	0.505	-	H2O
W_comp = 4.3 kJ/kg				Electrical COP_e = 200			
Q_heatpump = 162.2 kJ/kg				Thermal COP_th = 1.01			
Real Thermodynamic COP (~ 60% Carnot) = 5.19							

الشكل (3) المؤشرات الترموديناميكية لدارة المحول الحراري الهجين /مفاعل لتوليد الكهرباء بمساعدة دارة رانكين العضوية

وعلى الرغم من أن المحولة الحرارية ذات المفاعل- التي درسها Enslin تملك معامل أداء ($COP = 0.9-1$)- وهي تعتبر قيمة اقتصادية- فإن التطبيق العملي ما يزال يتطلب ضاغط بخار مكلف، ولو أنه كان صغير جداً. إن الاستفادة من دارة المفاعل يتطلب فهم السلوك



الشكل (4) دائرة Lorenz المشغلة حرارياً

الترموديناميكي للوسيط العامل ضمن المفاعل، وخواصه الترموفيزيائية ومؤشراته العاملة، وهو ما قام به محمد [14] حيث تم دراسة المؤشرات الترموديناميكية لمفاعل دائرة محول حراري، وسلوك الوسيط العامل ضمنه حيث تبين أنه يمكن استخلاص الامونيا من أعلى المفاعل بمؤشرات كفيلة بإمكانية استخدامها لاحقاً كوسيط

تبريد للهواء الجوي من خلال حقنها في مبادل حراري خاص مهمته تبريد الهواء، حيث بينت المخططات أن الحصول على هذه الدرجات محكوم بشكل مبدئي بضغط التشغيل الابتدائي، وتركيز الامونيا في المفاعل. كما أن فرق درجات الحرارة والتراكيز بين طرفي المفاعل يتبع لضغط التشغيل، وتركيز الامونيا، وكمية الحرارة المقدمة في مرحلة الشحن، في حين تلعب درجة حرارة المصدر الدور الاهم في تحديد درجة حرارة اسفل المفاعل. كما تبين وجود مجموعة من المتطلبات الحرارية للحفاظ على استقرار المفاعل بالحالة العاملة حيث بلغت قيمة كمية الحرارة الواجب امتصاصها من الهواء الجوي $(+20\%\Delta h)$ من انتالبي قاع المفاعل على الأقل. كما توصل إلى أن الحرارة الفائضة المسحوبة من الهواء الجوي يجب التخلص منها عبر مبادل حراري ضمن المفاعل حتى نحافظ على التدرج. للحصول على درجة حرارة أعلى المفاعل بقيم $[0-10\text{ C}^\circ]$ فإنه يجب ان يتراوح ضغط التشغيل $[0.5-5\text{ bar}]$ ، وتركيز للامونيا $[0.25-0.65]$.

وبالتمعن في الدراسات المرجعية السابقة نرى أن استخدام الدارات الهجينة باستخدام الضواغط وتحسيناتها حقق معامل أداء عالي للمحولات الحرارية (التي تعاني من معامل أداء منخفض) على حساب زيادة الاستهلاك الكهربائي، في حين حل نموذج (Enslin) هذه المشكلة جزئياً بتخفيض نسبة الانضغاط في الدارة، واستخدام ضاغط صغير نسبياً يلزم للتغلب على ضغط عمود السائل (المفاعل) فقط. ومن وجهة نظرنا فإنه يمكن استبدال الضاغط بمضخة بالاستفادة من دارة لورينز (Lorenz cycle) الشكل (4) التي تستخدم مضخة سائل لزيادة ضغط السائل الغني بـ (NH₃) البارد بشكل قليل (حوالي 0.5-1 bar) فوق ضغط المفاعل، ليضخ السائل داخل المبخر، حيث الحرارة الخارجية (من المصدر الحراري المهدور) تقوم بتبخيره إلا أن هذه الخطوة تتطلب ممّا استخراج وسيط التبريد بحالة سائلة من أعلى المفاعل، وهو ما يتطلب فهم عميق للسلوك الترموديناميكي لوسيط التبريد المستخدم في الدارة.

هدف البحث

1- دراسة المؤشرات الترموديناميكية لإدارة محول حراري مبتكرة معتمدة على نموذج (Enslin) وبالاستفادة من نموذج (Lorenz cycle)، تعمل على الطاقة الحرارية المحمولة في الهواء الجوي (الوسط المحيط) وتقييم أدائها.

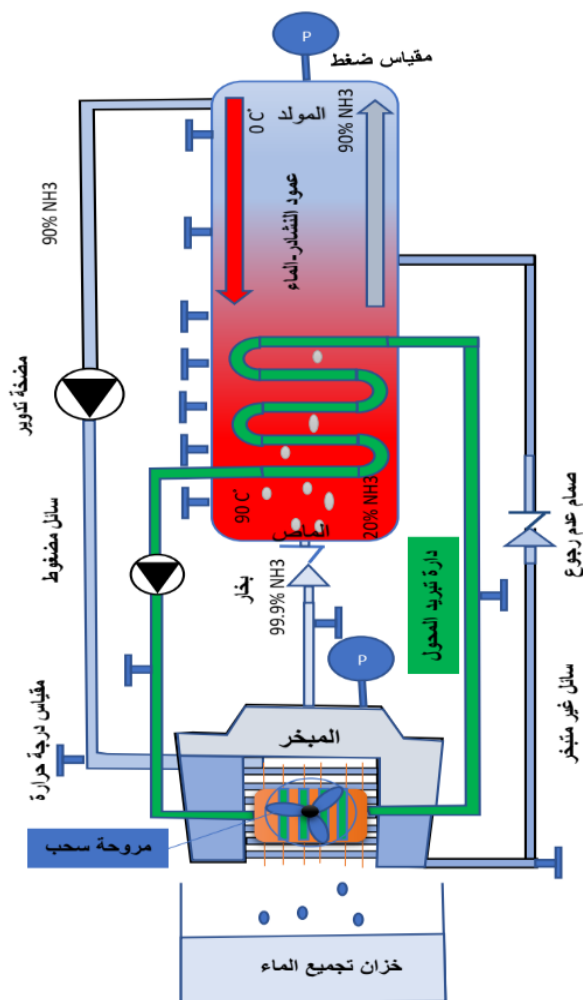
2- البحث في إمكانية استثمار الدارة كآلة تبريد للهواء الجوي.

مواد وطرائق البحث

تم اعتماد المنهج التحليلي الرياضي في هذا البحث، حيث تم بداية توصيف النموذج الفيزيائي، ومن ثم وصف النموذج الرياضي. تم حل المعادلات الواسفة، و تحصيل النتائج بالاعتماد على تطبيق (EES) (Equation Solver Engineering).

النموذج الفيزيائي للدارة


اقترحنا في هذا البحث
تطوير لنموذج مبتكر
من المحولات
الحرارية



الشكل (5) محول حراري بمفاعل محلول ثنائي لإنتاج (NH3)
مشغل حرارياً

(الإمتصاصية/مفاعل) كما هو مبين في الشكل (5) نسعى إلى دراسته، واختباره لاحقاً، وهو نموذج جديد لهذا العمود الثنائي (النشادر-الماء) يعتمد بشكل أساسي على الطاقة الحرارية للهواء الجوي لتشغيله حيث تمتص هذه الطاقة الحرارية في مبخّر الدارة مسببة تبخير الأمونيا عند ضغط المبخّر ليتم ضغطها في أسفل المفاعل، أما الجزء غير المتبخّر يعاد تدويره وإدخاله في نقطة من بدن المفاعل يتم تحديدها حسب المؤشرات الترموديناميكية. الوسيط العامل المستخدم في تبريد الهواء (سحب الطاقة الحرارية اللازمة لتشغيل الدارة) يتم سحبه من أعلى المفاعل، ويتم ضخه عبر مضخة تدوير الى المبخّر. تعمل هذه الدارة كآلة تبريد للهواء الجوي بعد سحب الحرارة الموجودة فيه لتشغيل الدارة، ويمكن الاستفادة منها في تكثيف بخار الماء الموجود في الهواء الجوي عبر التحكم بدرجة حرارة المبخّر (الوسيط العامل الخارج من أعلى المفاعل) إلى ما دون درجة الندى.

في ضوء الدراسات السابقة، وتطوراتها قمنا برسم مخطط (P-T) لدارة المحول الحراري (الإمتصاصي/مفاعل) كما في الشكل (6)، حيث نلاحظ أن الفرق في الضغط بين (P_a)، و (P_d) (فرق الضغط بين (desorber)، و (absorber) في الدارة) هو فقط الضغط الناتج عن عمود السائل في المفاعل طالما تم ضم كل من ((desorber)، و (absorber)) في المفاعل كما أسلفنا سابقاً [11]. تكون درجة الحرارة الباردة في أعلى المفاعل (T_d)، بينما درجة حرارة المبخّر (T_e) تكون أعلى بـ ($1C^\circ$) فقط من درجة حرارة أعلى المفاعل، بضغط اشباع للمبخّر (P_e) أعلى بقليل من ضغط الماص (Absorber) (P_a) يتم تحقيقه بواسطة المضخة، من أجل السماح للبخار بالتدفق من المبخّر إلى المولد دون الحاجة إلى وجود ضاغط. من المفترض أن يبقى المفاعل شاقولي، لأجل الاستفادة من خاصية الفصل الثقالي في توليد التدرجات المطلوبة من درجة الحرارة، وتراكيز الـ (NH_3) على طول قطاعات المفاعل حسب شروط التشغيل، والغاية المطلوبة من النموذج وفق [14].



سوف يدخل سائل

المزيج الغني

بالأمونيا

(NH3)

المشبع ذو

درجة حرارة

منخفضة جداً

إلى

المضخة،

مما يؤدي

إلى زيادة

الضغط

عندما يصل

الشكل (6) مخطط P-T لدارة محول حراري/ مفاعل

الجريان إلى المبخر الأفقي تحت مستوي المفاعل. إن فرق الضغط بين مستوى السائل في المبخر، والمفاعل يجب أن يتم تصميمه بدقة، للتأكيد على أن قيمة ضغط البخار المتولد في المبخر كافية لموازنة الضغط الهيدروليكي لعمود السائل في المفاعل، طالما أنه سيتدفق من المبخر مباشرة إلى داخل المفاعل عبر صمام عدم رجوع أسفل المفاعل. ولكن عند التفكير بالنموذج جيداً، نلاحظ أنه في بداية عمل الجهاز يكون ما يزال الماء، والأمونيا مختلط بشكل منتظم، وتكون كل الأنابيب، والمبخر بالكامل مملوءه بهذا المزيج عند بارامترات التشغيل الأساسية. وعندما يتم تقديم الحرارة إلى ملفات المبخر فإن هذه الحرارة سوف تبخر الأمونيا، وتشكل بعض البخار (NH3 نقي تقريباً)، والتي سوف تملأ الجزء العلوي من المبخر، وأنبوب تسليم البخار إلى المفاعل، ويبدأ بعدها دخول البخار

إلى المفاعل من أسفله. البخار الداخل من أسفل المفاعل على شكل فقاعات سوف يمتص في المنطقة السفلية من المفاعل مولداً حرارة، وهو ما يعتبر بداية لتوليد التدرج (في التركيز، ودرجة الحرارة).

إن المبخر هنا ينجز وظيفتين:

1- مولد البخار، مبخر (NH₃).

2- وعاء يحوي مزيج سائل بتركيز منخفض من (NH₃) غير متبخر، والذي يجب إعادة ضخه إلى المفاعل من جديد بحيث يدخل إلى المفاعل بشكل متناسب مع تركيز، ودرجة حرارة المزيج في المفاعل. خلال إقلاع المفاعل فإن درجة الحرارة الباردة للمزيج في قمة المفاعل يتم إيجادها من خلال تدرج درجة الحرارة المتتالي في المفاعل، والذي تم دراسته من قبل [14]، وبالتالي تدريجياً ستخف درجة الحرارة للسائل المضغوط، ومنه درجة حرارة المبخر، وبالتالي يزداد امتصاص الحرارة من المصدر الخارجي بواسطة المبخر، طالما ستخف درجة حرارة الإشباع للمبخر، حتى الوصول إلى نقطة التشغيل المختارة. يتم وضع ملف مبادل حراري ضمن مفاعل المحول الحراري، وظيفته الأساسية اخراج الحرارة الفائضة من أسفل المفاعل لتحقيق توازن التدفق الحراري ضمن النظام بعد وصول المحول إلى نقطة التشغيل التصميمية. يتم عزل كل من المفاعل مع الأنابيب، والمبخر تماماً، ليتم التبادل الحراري عبر المبادلات الحرارية فقط.

النموذج الرياضي للدارة

يبين الشكل (7) أدناه مخطط تصميمي لدارة المحول الحراري (الامتصاصي/مفاعل)، وبيّن المخطط البارامترات التصميمية التي تم افتراضها، ووفقاً للمرجعيات العلمية للمحولات الحرارية.

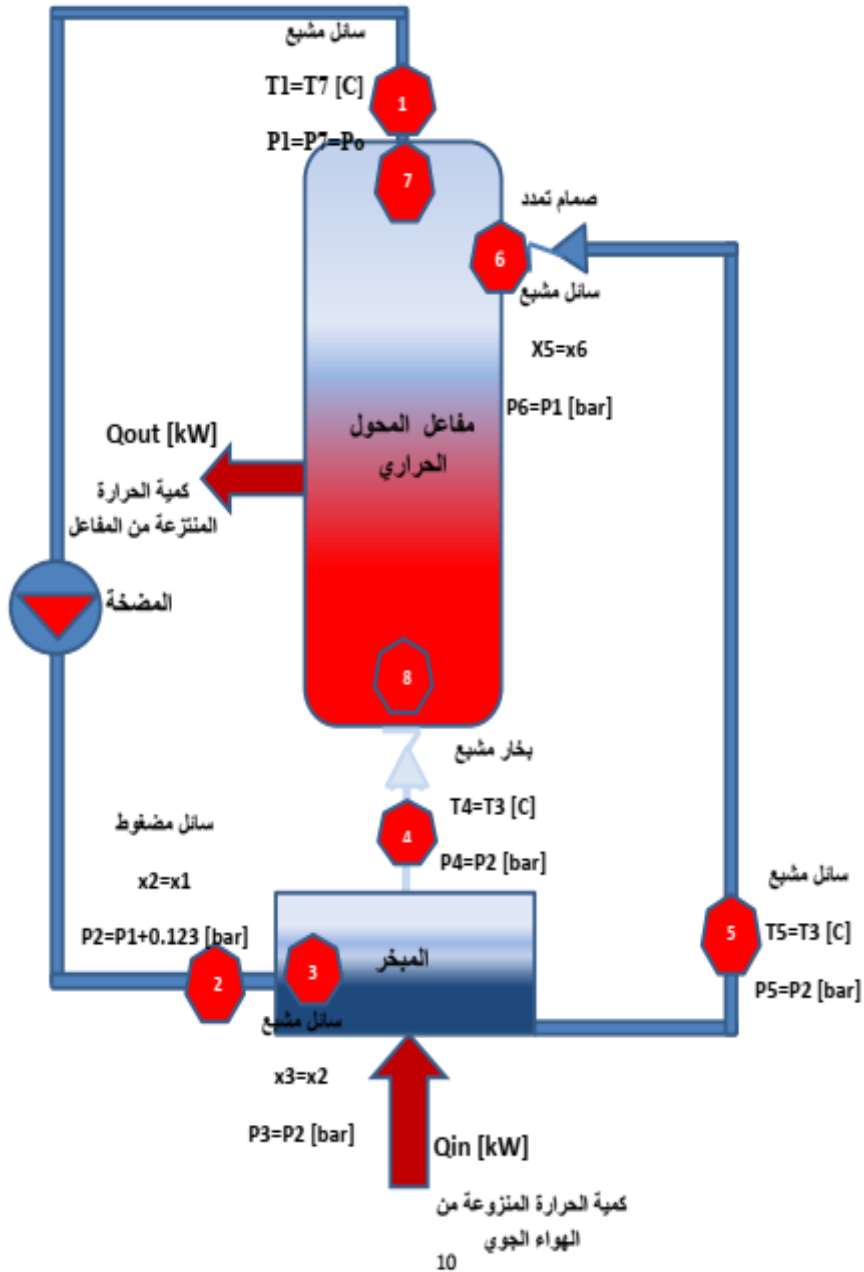
وفيما يلي المعادلات الواصفة:

1- المبخر:

$$\sum m_i = 0 \quad (1) \quad \text{معادلة توازن الكتلة}$$

$$\sum m_i * x_i = 0 \quad (2) \quad \text{توازن المكونات}$$

$$\sum m_i * h_i + Q_{in} = 0 \quad (3) \quad \text{توازن الطاقة}$$



الشكل (7) المخطط التصميمي المقترح لدارة المحول الحراري العاملة على الطاقة الحرارية للهواء الجوي

2- المفاعل:

$$\sum m_i * h_i + Q_{out} = 0 \quad (4)$$

من توازن الكتلة في الدارة ككل لدينا:

$$m_5 = m_6 \quad , \quad m_1 = m_2 = m_3 \quad (5)$$

m_i : التدفق الكتلي عند الموقع (i) $[\frac{kg}{s}]$.

x_i : تركيز الخليط عند الموقع (i).

h_i : انتالبي الخليط عند الموقع (i) $[\frac{kJ}{s}]$.

Q_{in} : استطاعة التبريد الممتصة من قبل مبخر الدارة [kW].

Q_{out} : كمية الحرارة الواجب انتزاعها من أسفل المفاعل بواسطة مبادل حراري [kW].

يتم إيجاد تدرج التراكيز، ودرجات الحرارة في مرحلة شحن المفاعل قبل التشغيل وفق [14].

وفي مرحلة العمل عند شروط التشغيل تأتي الحرارة المنبوضة من المفاعل من حقيقة التفاعلات التي تحصل ضمنه، والتي تعتبر المسؤولة عن المحافظة على التدرجات في قلب المفاعل.

حيث تقسم الحرارة المتولدة في المفاعل إلى قسمين:

1- الحرارة الناتجة عن امتصاص المزيج الغني بالألمونيا القادم من المبخر من قبل خليط أسفل المفاعل الفقير (تفاعل ناشر للحرارة):

$$Q_{ab} = m_i * \Delta h_{ab} \quad (6)$$

2- الحرارة المنبوضة، والناجمة عن التدرج الفيزيائي (الفصل الثقالي) لتركيز المحلول بسبب فرق الكثافات:

$$Q_g = m_i * \Delta h_g \quad (7)$$

Δh_{ab} : فرق الانتالبي بين التيار الماص، والتيار الممتص $[\frac{kJ}{s}]$.

Δh_g : فرق الانتالبي بين التيارين ذو التركيزين المختلفين $[\frac{kJ}{s}]$.

من المفترض في نهاية الحل أن يكون:

$$Q_{ab} + Q_g = Q_{out} \quad (8)$$

تم استخدام المعادلة (8) للتحقق من صحة الحل.

بشكل عام إن هذا التصميم من المحولات الحرارية عالية الأداء المشغلة حرارياً، وكهربائياً يكون معامل الأداء $(COP = \frac{Q_{out}}{Q_{in} + W_{PUMP}})$ قريباً من الواحد، وطالما أن هذه الآلة مشغلة حرارياً، وكهربائياً، فإنه سيتم اعتماد معيارين للأداء من أجل المقارنة، واختبار أداء هذه الآلة (طالما أن الطاقة الحرارية متوفرة بشكل مجاني)، وهما:

$$COP_{th} = \frac{Q_{out}}{Q_{in}} - 1$$

كمية الحرارة التي يجب طرحها من المفاعل الى كمية الحرارة المسحوبة من الهواء الجوي للحفاظ على حالة استقرار المفاعل، والدارة في الحالة المشحونة (العمل) ، والحصول على ما هو مطلوب منه كآلة حرارية.

2- $COP_e = \frac{Q_{out}}{W_{PUMP}}$: ويعتبر معامل للأداء الكهربائي (COP_e) ، وهو يعبر عن الاحتياجات الكهربائية في الدارة لضمان عمل المحول بصورة مستقرة، والحصول على ما هو مطلوب منه كآلة حرارية.

الشروط الحديدية

تم اختيار الشروط الحديدية بناء على ما تم دراسته وفق [14] ، ووفقاً للمرجعيات العلمية للمحولات الحرارية:

1- طول المفاعل (1 [m]) ، قطره (0.135 [m])، يحوي ($m=5.60 \text{ [kg]}$) خليط من الماء، والأمونيا بكثافة ($562 \frac{\text{kg}}{\text{m}^3}$)، وهو ما يسبب ضغط هيدروليكي في قاع المفاعل يقدر ب ($P=0.053 \text{ [bar]}$)، طبعا هذه الشروط لا تؤثر إلا في ضغط قاع المفاعل.

2- المضخة تسبب زيادة في الضغط قدرها (0.123 [bar]).

3- درجة الحرارة في المبخر أعلى بدرجة مئوية واحدة من مدخله.

4- P_1 : يمثل الضغط عند الموقع (1)، وهو يساوي ضغط التشغيل في المفاعل (P_0).

5- P_8 : يمثل الضغط عند الموقع (8)، وهو يساوي ضغط التشغيل في المفاعل مضافاً إليه ضغط عمود السائل في المفاعل.

6- يبين الجدول (1) حالة الوسيط العامل في مواقع الدارة وفق ما سبق شرحه وشروط عمل المفاعل [14].

الجدول (1) حالة الوسيط العامل في نقاط الدارة

الموقع i	الحالة X	الضغط P [bar]	درجة الحرارة T[C]	التركيز x
1	سائل مشبع	[0.2-3.5]	متغير	متغير
2	سائل مضغوط	$P1+0.123$	متغير	متغير
3	سائل مشبع	$P1+0.123$	متغير	متغير
4	بخار مشبع	$P1+0.123$	متغير	متغير
5	سائل مشبع	$P1+0.123$	متغير	متغير
6	سائل بعد صمام تمدد	$P1$	متغير	متغير
7	سائل مشبع	$P0= P1$	متغير	متغير
8	سائل مشبع	$P8=P0+0.053$	متغير	متغير

منهجية الحل

تم استخدام تطبيق (EES) (Engineering Equation Solver) لحل معادلات النموذج الرياضي، وتم استخدام نفس البرنامج من أجل استخلاص النتائج، ورسم المخططات، وإجراء المقارنات.

الدراسة والنتائج

الحالة (1):

تم دراسة أثر تغير ضغط تشغيل المفاعل (ضغط الموقع 1) على مؤشرات الدارة الأساسية


الجدول (2) الشروط الحدية في الحالة (1)

الموقع i	الحالة X	الضغط P [bar]	درجة الحرارة T [C]	التركيز x	Q_{in} [kW]
1	سائل مشبع	[0.2- 3.5]	0,5, -5	متغير	10

عند درجات حرارة مختلفة (0,5 [C] , -5) للمزيج الخارج من قمة المفاعل. كانت كمية

الحرارة المقدمة في الدارة ($Q_{in} = 10 \text{ [kW]}$) حيث يبين الجدول (2) الشروط الحدية المستخدمة في

الدارة. تم اختبار أداء هذه الآلة من خلال رسم مخططات تغيرات معاملات الأداء (الكهربائي والحراري) مع تغير ضغط التشغيل في المفاعل عند درجات حرارة مختلفة $[-5, 0, 5 \text{ C}]$ بشكل يتطابق مع الالوان، يمثل المحور الشاقولي للشكل (8) كل من معامل الأداء الحراري




الشكل (8) أثر تغير ضغط التشغيل على معاملات الأداء عند درجات حرارة مختلفة

(اليميني)، والكهربائي (اليساري) وفق المعايير المعروفة مسبقاً. حيث يوضح الشكل زيادة معامل

الأداء الكهربائي بشكل كبير، وهذه القيم تعبر عن الاحتياحات المنخفضة جداً للطاقة الكهربائية في المجال (1.5-3.5 [bar]) يرافقه انخفاض معامل الأداء الحراري في هذا المجال مما يعني انخفاض الاستهلاك الكهربائي اللازم لتشغيل الدارة، وزيادة الاستهلاك الحراري، والذي غالباً ما يكون حرارة مهدورة لذلك لا يشكل أي خسارة اقتصادية. كما نلاحظ أنه عند درجة حرارة مخرج المفاعل (C -5)، وضغط تشغيل (P=3.5 [bar]) تنخفض جداً المتطلبات الكهربائية لعمل الدارة مما يؤدي الى ارتفاع كبير في قيمة ($COP_e = 375$) يرافقه انخفاض كبير في قيمة ($COP_{th}=1$)، أي زيادة المتطلبات الحرارية اللازمة لعمل الدارة، وهنا الدارة تعمل بشكل تقريبي حرارياً، وهذا يرافقه خروج وسيط التبريد (الامونيا) من قمة المفاعل بصورة نقية.

في المجال (0.2-1.5 [bar]) نلاحظ انخفاض معامل الأداء الكهربائي، وهذا يعني زيادة الاستهلاك الكهربائي اللازم لتشغيل المضخة، وبالتالي تشغيل الدارة، كما نلاحظ زيادة المردود الحراري بشكل كبير مما يعني انخفاض الاستهلاك الحراري اللازم لتشغيل الدارة، وعليه يتيح لنا هذا المخطط اختيار المجال الأمثل لعمل المحول الحراري حسب توفر المصدر الحراري، وكيفية تأمينه (إن كان حرارة مهدورة أو منتجة بطريقة ما بغرض تشغيل المضخة الحرارية)، وحسب تعرفه استهلاك الكيلو واط الكهربائي كما يدخل في الحسابان الغاية من استخدام المحول الحراري. يؤكد هذه النتائج الشكل (9) الذي يمثل العمل اللازم لتشغيل المضخة في الدارة (اليساري)، وكمية الحرارة المنبذة عند درجات حرارة مختلفة (اليمني).




الشكل (9) أثر تغير ضغط التشغيل على استهلاك المضخة وكمية الحرارة المنبوبة عند درجات حرارة مختلفة

حيث نلاحظ من المخطط أنه عند الضغوط المنخفضة يكون العمل المقدم إلى الدارة كبير أي أن الدارة تحتاج إلى متطلبات كهربائية مرتفعة نسبياً وأقل منها حرارياً.


كما يبين الشكل (10) أثر ضغط التشغيل على تدفقات، وتراكيز الوسيط العامل في نقاط الدارة عند درجات حرارة مختلفة. نلاحظ من المخططات انخفاض تدفق الوسيط العامل الخارج من قمة المفاعل، والسائل غير المتبخر المتبقي في المبخر مع زيادة ضغط التشغيل في الحالات الثلاثة مع زيادة طفيفة في كمية البخار المتشكل في المبخر، والمحقون في أسفل المفاعل.


يرجع انخفاض التدفقات إلى الزيادة في تركيز الأمونيا ضمن الوسيط الخارج من قمة المفاعل مع زيادة ضغط التشغيل عند درجة الحرارة المختارة، في حين تعزل الزيادة الطفيفة في

كمية المتبخر الداخل أسفل المفاعل الى ارتباط التبخر بمكون الأمونيا فقط دون الماء (سوى بضع قطرات من الماء)، وكون المتبخر يتعلق بشكل أساسي بكمية الحرارة المسحوبة من الوسط الخارجي (حمل التبريد).



الشكل () أثر ضغط التشغيل على تدفقات الوسيط العامل وتركيزه في الدارة عند درجة حرارة (-5 [C])






تفيد المخططات المرسومة في الشكل (10) بمعرفة مكان ربط أنبوب الوسيط العامل العائد من المبخر إلى بدن المفاعل عند نقطة لها تركيز قريب ضمن المفاعل حتى لا يؤثر على التوازن الحراري ضمن المفاعل [14]. فبحسب ضغط التشغيل، ودرجة حرارة مخرج المفاعل (مؤشرات التشغيل) يتم تحديد تركيز الوسيط العامل (غير المتبخر) في المبخر $x[6]$ ، والذي تجب إعادته إلى نقطة في بدن المفاعل لها تركيز مشابه وفق [14].

الشكل (10) أثر ضغط التشغيل على تدفقات وتراكيز الوسيط العامل في نقاط الدارة عند درجات حرارة تشغيل مختلفة


وهو ما يؤكد الشكل (11) الذي يبين أثر ضغط التشغيل على تركيز الأمونيا في المزيج المشبع الخارج من قمة المفاعل، حيث يبين زيادة التركيز مع زيادة ضغط التشغيل في المفاعل.



الشكل (11) أثر ضغط التشغيل على تركيز الأمونيا في المزيج الخارج من قمة المفاعل و على درجة حرارة العائد من المبخّر عند درجات مختلفة

كما تم رسم الشكل (12) الذي يبين أثر تغير ضغط التشغيل على كمية الحرارة المنتجة بواسطة عملية الإمتصاص ضمن المفاعل، والحرارة الناتجة بسبب الفصل الثقالي للمكونات الذي يسبب تدرج تراكيز الأمونيا على طول المفاعل.

حيث نلاحظ تناسب عكسي في كميات الحرارة الناتجة ضمن المفاعل لتشكل مجموعها الحرارة



الشكل (12) أثر ضغط التشغيل على حرارة الإمتصاص وحرارة الفصل الثقالي عند درجات حرارة مختلفة

الواجب طرحها عبر المبادل الحراري الداخلي ضمن المفاعل من أجل استقرار عمل المفاعل، والدارة ككل.

يرجع انخفاض حرارة الإمتصاص مع زيادة ضغط التشغيل إلى زيادة ضغط الإشباع في المفاعل مما يقلل من عملية امتصاص الماء للأمونيا بسبب الخواص الترموفيزيائية للمزيج.

وبسبب انخفاض عملية الإمتصاص فإن عملية الفصل الثقالي بين المكونين تصبح أكبر، وأسهل مما ينعكس على زيادة كمية الحرارة المنبوضة بسبب الفصل الثقالي للمكونات.

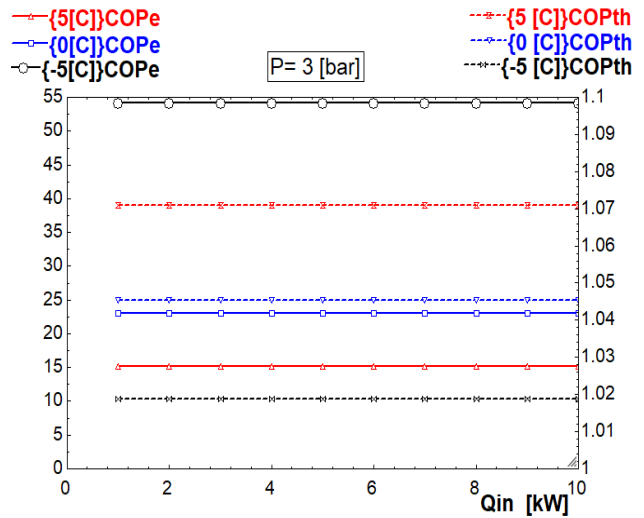


الحالة (2):

تم دراسة أثر تغيير كمية الحرارة (حمل التبريد) المسحوبة من الوسط الخارجي، وهي نفس كمية الحرارة المقدمة لتشغيل الدارة حيث يبين الجدول (3) الشروط الحدية العاملة في الدارة بهذه الحالة.

الجدول (3) الشروط الحدية في الحالة (2)

الموقع i	الحالة X	الضغط P [bar]	درجة الحرارة T[C]	التركيز x	استطاعة التبريد Q _{in} [kW]
1	سائل مشبع	0.25, 1.5, 3	5- , 0,5	متغير	[1, 10]

تم رسم مخططات الأداء لدارة المحول الحراري كما يبين الشكل (13) حيث نلاحظ أن معاملات الأداء الكهربائية، والحرارية لا تتغير مع تغير حمل التبريد إنما تتغير مع ضغط التشغيل، ودرجة حرارة المزيج الخارج من قمة المفاعل حيث تؤكد المخططات زيادة معامل الأداء الكهربائي مع زيادة ضغط التشغيل، ومع انخفاض درجة حرارة المزيج الخارج من أعلى المفاعل. في حين ينخفض معامل الأداء الحراري مع زيادة ضغط التشغيل، ومع انخفاض درجة حرارة المزيج الخارج من أعلى المفاعل، وهذا التناسب المتعاكس بين المعاملين يأتي من حقيقة أن معامل الأداء الكلي يكون قريباً من الواحد بالنسبة لهذه المحولات الحرارية.




الشكل (13) أثر حمل التبريد على معاملات الأداء للدارة عند درجات حرارة مختلفة وضغوط تشغيل مختلفة للمزيج أعلى المفاعل

الحالة (3): تم دراسة معاملات الأداء للدارة عند حالات حدية جديدة وفق الجدول (4) حيث يبين الشكل (14) أثر تغير درجات حرارة المزيج المشبع الخارج من أعلى المفاعل على معاملات الأداء الكهربائية والحرارية عند ضغوط تشغيل مختلفة في المفاعل.

الجدول (4) الشروط الحدية في الحالة (3)

الموقع i	الحالة X	الضغط P [bar]	درجة الحرارة T[C]	التركيز x	استطاعة التبريد $Q_{in} [kW]$
1	سائل مشبع	0.5,1,2,3	[-7,7]	متغير	10

حيث نلاحظ من الشكل (14) زيادة معامل الأداء الحراري، وانخفاض معامل الأداء الكهربائي مع زيادة درجة الحرارة مع ملاحظة التغير الصغير في معامل الأداء الكهربائي ضمن مجال الدراسة بالنسبة للضغوط المنخفضة نوعاً ما، مخالفاً في السلوك التغير الكبير عند ضغط مرتفع (3 bar) عند مجال درجات الحرارة المدروس، وهذا يتعلق بالطبيعة الترموفيزيائية للمزيج حيث عند هذه الضغوط العالية فقط يمكن الحصول على تراكيز عالية للامونيا عند شروط التشغيل المدروسة مما يقلل من استهلاك الكهرباء في ضخ الامونيا، وزيادة معامل الأداء الكهربائي، كما سيكون التغير في قيم المخطط ستبدو أكبر عند مجال لدرجات الحرارة أقل من (-10 [C])، وهذا ما تم ملاحظته مسبقاً في الشكل (8) حيث يصبح اعتماد الآلة أكثر على الطاقة الحرارية للتشغيل، في حين وهو ما أكدته دراسة الحالات السابقة .




الشكل (14) أثر تغير درجة حرارة المزيج الخارج من المفاعل على معاملات الأداء عند ضغوط مختلفة

الحالة (4): تم دراسة المؤشرات الترموديناميكية للمحول الحراري عند تغيير حالة شحن المفاعل (تدرج حراري و تدرج المكونات)، حيث يبين الجدول (5) الشروط الحدية للدراسة:

الجدول (5) الشروط الحدية في الحالة (4)

الموقع i	الحالة X	الضغط P [bar]	درجة الحرارة T [C]	التركيز x	استطاعة التبريد $Q_{in} [kW]$
1	سائل مشبع	3	-8,-5,0,5	متغير	10
8	سائل مشبع	3.053	[45-90]	متغير	

تم رسم أثر تغير درجة حرارة قاع المفاعل على أداء الدارة ككل عند درجات حرارة مختلفة لقمة المفاعل، حيث يبين الشكل (15) إن معامل الأداء الكهربائي، والحراري للدارة لا يتعلق بدرجة حرارة قاع المفاعل، في حين تتعلق بشكل أساسي بدرجة حرارة التشغيل




الشكل (15) أثر تغيير درجة حرارة قاع المفاعل على معاملات الأداء عند درجات تشغيل مختلفة

(درجة حرارة أعلى المفاعل) فمع انخفاض درجة حرارة المزيج المغادر أعلى المفاعل يزداد معها معامل الأداء الكهربائي في حين ينخفض معامل الأداء الحراري وبالعكس، وهو ما يؤكد النتائج التي حصلنا عليها في الشكل (14). وعليه فإنه من ناحية تشغيل المحول الحراري في التبريد فإنه من غير المهم رفع درجة حرارة قاع المفاعل إلى درجات

حرارة مرتفعة مما يوفر الطاقة الحرارية المطلوبة في مرحلة شحن المفاعل لتوليد التدريجات الحرارية، كما يوفر زمن الشحن. وعليه يجب الانتباه فقط إلى أهمية تحقق شرط الحفاظ على التدرج الحراري ضمن المفاعل العامل عند اختيار حدود درجات الحرارة، والتراكيز ضمن المفاعل [14].

تم دراسة أثر تغيير درجة حرارة قاع المفاعل على كمية الحرارة الناتجة عن امتصاص قاع المفاعل للبخار الداخل من المبخر، حيث يبين الشكل (16) انخفاض كمية الحرارة المتحررة عند امتصاص بخار الأمونيا القادم من المبخر مع ارتفاع درجة حرارة المزيج الفقير في قاع المفاعل، وهذا مرده إلى الطبيعة الترموفيزيائية للمزيج، في حين تزداد كمية الحرارة المنبوهة بسبب الفصل الثقالي حيث أن انخفاض الإمتصاص في قاع المفاعل يساعد في عملية الفصل الثقالي مما يزيد من كمية الحرارة المتحررة نتيجة هذه العملية، وهو ما يؤكد الشكل (12).



الشكل (16) أثر تغيير درجة حرارة قاع المفاعل على كمية الحرارة المتحررة ضمن المفاعل عند درجات حرارة تشغيل مختلفة

الحالة (5): تم دراسة حالة دائرة المحول الحراري وفق الشروط الحدية المبينة في الجدول (6).

الجدول (6) الشروط الحدية في الحالة (5)

الموقع i	الحالة X	الضغط P [bar]	درجة الحرارة T[C]	التركيز x	استطاعة التبريد $Q_{in} [kW]$
1	سائل مشبع	3	-8	---	10
8	سائل مشبع	3.053	80	---	

بالحل يبين الشكل (17) النتائج لنقاط الدارة.

يبين الشكل $Q_2 = Q_{out}$ كنتيجة للتحقق من الحل.

Arrays Table: Main

	Q_{u_i} [X]	P_i [bar]	T_i [K]	h_i [kJ/kg]	u_i [kJ/kg]	s_i [kJ/kg·K]	v_i [m³/kg]	x_i	m_i [kg/s]
1	0	3	265.1500	-76.82	-77.26	-0.1256	0.001481	0.94528	1.722E-02
2	-0.001	3.123	266.1614	-73.55	-73.89	-0.1131	0.001092	0.94528	1.722E-02
3	0	3.123	266.1616	-72.25	-72.71	-0.1082	0.001484	0.94528	1.722E-02
4	1	3.123	267.1616	1264	1141	4.765	0.395	0.99998	7.659E-03
5	0	3.123	267.1616	-99.53	-99.98	-0.1159	0.001447	0.90146	9.561E-03
6	0.003607	3	266.1498	-99.53	-100.4	-0.1159	0.002919	0.90146	9.561E-03
7	0	3	265.1500	-76.82	-77.26	-0.1256	0.001481	0.94528	
8	0	3.053	353.1500	200.6	200.2	1.074	0.00113	0.20834	

SOLUTION

Unit Settings: SI K bar kJ mass deg

COP = 1	COP _{carnot} = 4.013	COP _e = 178.9
COP _{th} = 1.006	h1 = -76.82	h2 = -73.55
h3 = -72.25	h4 = 1264	h5 = -99.53
h6 = -99.53	h7 = -76.82	h8 = 200.6
P0 = 3 [bar]	P1 = 3	P2 = 3.123
P6 = 3	P7 = 3	P8 = 3.053
Q2 = 10.05622 [kW]	Q _{ab} = -8.149 [kW]	Q _g = -1.907 [kW]
Q _{in} = 10 [kW]	Q _{out} = -10.05622 [kW]	T1 = 265.2
T11 = -8 [C]	T4 = 267.2	T7 = 265.2
T8 = 353.2	T88 = 80	W _p = 0.05622 [kW]
x1 = 0.9453	x2 = 0.9453	x3 = 0.9453
x4 = 1	x5 = 0.9015	x6 = 0.9015
x7 = 0.9453	x8 = 0.2083	

الشكل (17) نتائج الحل باستخدام تطبيق (EES) للحالة (5)

النتائج والمناقشة

1- تعتبر مؤشرات التدرج (درجات الحرارة، تركيز الأمونيا) في المفاعل هي القوة المحركة الأساسية لعمل المحول الحراري، وعليه إن كمية الحرارة اللازمة لشحن المفاعل قبل تشغيل الدارة مهمة لتوليد هذه التدرجات على طول المفاعل، إلا أن هذا المؤشر (المدى)

لا يملك تأثيراً على معامل أداء الدارة، الذي ينحصر تأثيره بدرجة حرارة قمة المفاعل حيث لوحظ زيادة معامل الأداء الكهربائي مع انخفاض درجة حرارة المزيج المشبع في قمة المفاعل مما يعني بالضرورة انخفاض الاستهلاك الكهربائي اللازم لعمل الدارة، وبشكل أساسي الإستهلاك في المضخة.

2- لا يملك مؤشر درجة حرارة قاع المفاعل أي تأثير على معامل الأداء للدارة في حين ينحصر تأثيرها على كميات الحرارة المطروحة من المفاعل بسبب عملية امتصاص بخار الأمونيا في قاع المفاعل، وعملية الفصل الثقالي الفيزيائي لمكونات العمود الثنائي.

3- يملك مؤشر ضغط التشغيل في المفاعل (الضغط العامل في قمة المفاعل) أثراً كبيراً على معاملات الأداء في الدارة.

4- مؤشر الضغط في قاع أي مفاعل يتبع كثافة المزيج العامل في الدارة، وارتفاع المفاعل، والضغط العامل في قمة المفاعل حسب أدبيات هذا النمط من المفاعلات، وهو ما تم التأكيد عليه عند دراسة المؤشرات الترموديناميكية للوسيط العامل ضمن المفاعلات [14].

5- عند زيادة ضغط التشغيل P_0 تنخفض تدفقات الوسيط العامل في الدارة لكن بالمقابل يزيد تركيز الأمونيا (الوسط المتبخر) في المزيج المتحرك، مما يؤدي إلى انخفاض استهلاك الطاقة في المضخة زيادة معامل الأداء الكهربائي.

6- لا يؤثر مؤشر كمية الحرارة الممتصة من الهواء الخارجي لعمل المحول على معاملات أداء الدارة عند شروط معينة.

7- إمكانية استخدام الدارة كمضخة حرارية تستخدم لأغراض التدفئة عند شروط تشغيلية معينة.

8- إمكانية استخدام الدارة كآلة تبريد يمكن استخدامها في تبريد الهواء الجوي، واستخلاص الماء منه.

Study of thermodynamic parameters of an innovative thermoelectric converter circuit and evaluation of its performance

Mohamed Abdo Bakeer*

Mohamed Ahmed

Mohamed**

Abstract

Absorption Heat Transformer is electrically operated thermal machines, and thermally operated by a low-temperature heat source. These machines have evolved greatly from hybrid machines to reactor circuits to reduce electrical consumption in the circuit. In this research, we studied the thermodynamic indicators to evaluate the performance of a new model developed from a Absorption Heat Transformer (reactor), which uses a mixture of water and ammonia as a working medium in the circuit. The research concluded the importance of operating pressure and the temperature of the mixture exiting the reactor on the performance parameters in the circuit, in addition to the role of these parameters in determining the purpose of using the Heat Transformer (as a heat pump or a cooling machine). The study also showed that the extent of the thermal gradient in the reactor, the temperature of the reactor bottom, or the cooling load are not related to the performance parameters of the circuit. The research also concluded that, due to the chemical processes that occur in

the reactor (absorption of ammonia and the process of gravitational separation of components), heat will be produced within the reactor that must be disposed of in order to keep the reactor in a charged state and the circuit in operation. The amount of heat released in the reactor depends on the reactor operating parameters, the cooling load, and the electrical power consumed in the circuit.

Keywords: Absorption Heat Transformer, thermal reactor, absorption circuits, zeotropic mixture.

* Professor Doctor Engineer in Homs University, Mechanical and Electrical Engineering, Power Engineering

**Doctoral student in Homs University, Mechanical and Electrical Engineering, Power Engineering.

قائمة المصادر والمراجع

- 1– **Rivera Wilfrido** Experimental Evaluation of a single-stage Heat Transformer used to increase [Journal] // Solar Energy Vol 69, No. 5, . - 2000. - pp. 369 - 376.
- 2– **Kurem E. Horuz I.** A comparison between ammonia-water and water-lithium bromide solutions in absorption heat transformers [Journal] // International Communications in Heat and Mass Transfer, Volume 28, Issue 3. - 2001. - pp. 427-438.

- 3- **Parham Kiyan** pplications of Absorption Heat Transformers in Desalination, Cogeneration and the Use of Alternative Working Pairs [Book]. - Gazimağusa, North Cyprus : Eastern Mediterranean University, 2014.
- 4- **Kiatsiriroat Nattaporn Chaiyat and Tanongkiat** Upgrading of Solar Heat by an Absorption Heat Transformer assisting with a Vapor Compression Heat Pump [Journal] // engineering journal -Maejo University. - 2014. - pp. 10-20.
- 5- **Heredia I. J. Siqueiros, J.A. Hernández, D.Juárez-Romero, A. Huicochea, J.G. González-Rodríguez** Energy saving into an absorption heat transformer by using heat pipes between evaporator and condenser [Journal] // Applied Thermal Engineering 128. - 2018. - pp. 737 - 746.
- 6- **Sveine T.** Design of high temperature absorption/compression heat pump [Conference] // IIR-Gustav Lorentzen conference.. - Norway : Natural Working Fluids, 1998.
- 7- **Jian Wang Wei Wu, Xianting Li, Baolong Wang, Wenxing Shi** ,2017, Analysis of a compression-assisted absorption heat transformer , [Conference] // 12th IEA heat pump conference,. - China : Stichting HPC, 2017. - pp. 1-7.
- 8- **Zhou Q. and R. Radermacher** Development of a vapor compression cycle with a solution circuit and desorber/absorber heat exchange [Journal] // International Journal of Refrigeration 20. - 1997. - pp. 85 –95.

- 9- **Borgås Anders** Development of the Hybrid Absorption Heat Pump Process at High Temperature Operation [Book]. - Norway : NTNU Department of Energy and Process Engineering, Norwegian University of Science and Technology, Masters Thesis June 2014.
- 10- **Jensen Jonas Kjaer** Industrial Heat Pumps for High Temperature Process Applications (A numerical study of the ammonia-water hybrid absorption-compression heat pump) [Book]. - Denmark : Kongens Lyngby, DTU Mechanical Engineering, Technical University of Denmark., Ph.D. Thesis, December 2015.
- 11- **Enslin Johan** The Proof-of-Concept (POC) Model of the REHOS Ejector Heat Pump [Report]. - Heidelberg South Africa : micro system company, 2018.
- 12- **Enslin Johan** Rankine Cycle Efficiency Increase by the Regenerative Recovery of Historically Rejected Heat_rev1 . - Heidelberg : [s.n.], 2019.
- 13- **Weed L. Kielasa and G.E.** An Introduction to the Kalina Cycle [Conference] // Proceedings of the International Joint Power Generation Conference. - [s.l.] : PWR- Vol.30, 1996.
- 14- **محمد أحمد محمد، د. محمد عبده باكير** دراسة المؤشرات الترموديناميكية التشغيلية لمفاعل دارة محول حراري [مقالة] // سلسلة الأعداد للعلوم الطبية والهندسية الأساسية والتطبيقية. - حمص، سورية : مجلة جامعة البعث، 2023.

ملحق للمعادلات المستخدمة في الحل في برنامج EES

```

T11=5*([C])
(P0=3{bar})
T1=converttemp(C,K,T11)
{Reactor Top}
T7=T1
P7=P0
{Reactor bottom}
T88=80
T8=converttemp(C,K,T88)
P8=P0+0.035{<=====}
{point1}
P1=P0
Call NH3H2O(128, T1, P1, 0: T[1], P[1], x[1], h[1], s[1], u[1], v[1], Qu[1])
{point2}
x2=x[1]
P2=P1+0.123
Call NH3H2O(238, P2, x2,-0.001: T[2], P[2], x[2], h[2], s[2], u[2], v[2], Qu[2])
{point3}
Call NH3H2O(238, P2, x2, 0: T[3], P[3], x[3], h[3], s[3], u[3], v[3], Qu[3])
{point4}
T4=T[3]+1
Call NH3H2O(128, T4, P2, 1: T[4], P[4], x[4], h[4], s[4], u[4], v[4], Qu[4])
{point5}
Call NH3H2O(128, T4, P2, 0: T[5], P[5], x[5], h[5], s[5], u[5], v[5], Qu[5])
{point6}
P6=P0
x6=x[5]
h6=h[5]
Call NH3H2O(234, P6, x6, h6: T[6], P[6], x[6], h[6], s[6], u[6], v[6], Qu[6])
{point7}
Call NH3H2O(128, T1, P1, 0: T[7], P[7], x[7], h[7], s[7], u[7], v[7], Qu[7])
{point8}
Call NH3H2O(128, T8, P8, 0: T[8], P[8], x[8], h[8], s[8], u[8], v[8], Qu[8])
x1=x[1]
x3=x[3]
x4=x[4]
x5=x[5]
x7=x[7]
x8=x[8]
h1=h[1]
h2=h[2]
h3=h[3]
h4=h[4]
h5=h[5]
h7=h[7]
h8=h[8]
{heat input}
Qin=10
{evaporator}
m[2]=m[4]+m[5]
m[2]*x[2]=m[4]*x[4]+m[5]*x[5]
m[2]*h[2]+Qin=m[4]*h[4]+m[5]*h[5]
m[1]=m[2]
m[2]=m[3]
m[5]=m[6]
{reactor}
m[4]*h[4]+m[6]*h[6]=m[1]*h[1]+Q2{<=====}
(m[4]*x[4]+m[6]*x[6]=m[1]*x[1])
Qg=m[4]*(h[7]-h[8])+m[6]*(h[7]-h[6])
Qab=m[4]*(h[8]-h[4])
Qout=Qg+Qab
{pump}
Wp=m[1]*(h[2]-h[1])
{performance factors}

```

دراسة المؤشرات الترموديناميكية لدارة محول حراري مبتكر وتقييم أدائه

$$\begin{aligned} \text{COP} &= -(Q_{\text{out}} / (Q_{\text{in}} + W_p)) \\ \text{COP}_{\text{th}} &= Q_{\text{out}} / Q_{\text{in}} \\ \text{COPE} &= Q_{\text{out}} / W_p \\ \text{COP}_{\text{carnot}} &= T[8] / (T[8] - T[1]) \end{aligned}$$

Parametric Table: Table 3(P0): T=5C

	P0	m ₁	x ₁	T ₁	m ₄	x ₄	T ₄	m ₅	x ₅
	[bar]	[kg/s]		[K]	[kg/s]		[K]	[kg/s]	
Run 1	0.2	4.940E-01	0.23578	278.1500	3.786E-03	0.96004	288.9489	4.902E-01	0.2307
Run 2	0.4	4.735E-01	0.31770	278.1500	4.114E-03	0.98537	284.8914	4.694E-01	0.3111
Run 3	0.6	4.513E-01	0.36957	278.1500	4.354E-03	0.99224	283.2905	4.469E-01	0.3631
Run 4	0.8	4.287E-01	0.40907	278.1500	4.550E-03	0.99518	282.4193	4.242E-01	0.4027
Run 5	1	4.067E-01	0.44181	278.1500	4.728E-03	0.99673	281.8668	4.020E-01	0.4351
Run 6	1.5	3.533E-01	0.50809	278.1500	5.181E-03	0.99847	281.0946	3.481E-01	0.5007
Run 7	2	3.053E-01	0.56329	278.1500	5.645E-03	0.99915	280.6771	2.997E-01	0.5551
Run 8	2.5	2.533E-01	0.61395	278.1500	6.065E-03	0.99949	280.4173	2.473E-01	0.6041
Run 9	3	2.017E-01	0.66392	278.1500	6.496E-03	0.99968	280.2333	1.952E-01	0.6527
Run 10	3.5	1.486E-01	0.71674	278.1500	6.924E-03	0.99980	280.0970	1.416E-01	0.7021

Parametric Table: Table 3(P0): T=5C

	T ₅	Q2	Q _{ab}	Q _g	Q _{out}	W _p	COP	COP _{carnot}	COP _{th}
	[K]	[kW]	[kW]	[kW]	[kW]	[kW]			
Run 1	288.9489	30.19476	-3.97	-26.22	-30.19476	20.19476	1	4.709	3.019
Run 2	284.8914	21.34974	-4.15	-17.2	-21.34974	11.34974	1	4.709	2.135
Run 3	283.2905	17.72660	-4.398	-13.33	-17.72660	7.72660	1	4.709	1.773
Run 4	282.4193	15.68987	-4.64	-11.05	-15.68987	5.68987	1	4.709	1.569
Run 5	281.8668	14.37719	-4.87	-9.507	-14.37719	4.37719	1	4.709	1.438
Run 6	281.0946	12.57072	-5.458	-7.112	-12.57072	2.57072	1	4.709	1.257
Run 7	280.6771	11.70088	-6.049	-5.652	-11.70088	1.70088	1	4.709	1.17
Run 8	280.4173	11.09543	-6.58	-4.515	-11.09543	1.09543	1	4.709	1.11
Run 9	280.2333	10.70887	-7.116	-3.593	-10.70887	0.70887	1	4.709	1.071
Run 10	280.0970	10.42828	-7.638	-2.79	-10.42828	0.42828	1	4.709	1.043

Parametric Table: Table 3(P0): T=5C

	COPE
Run 1	1.495
Run 2	1.881
Run 3	2.294
Run 4	2.758
Run 5	3.285
Run 6	4.89
Run 7	6.879
Run 8	10.13
Run 9	15.11
Run 10	24.35