

# مجلة جامعة البعث

سلسلة العلوم الهندسية الميكانيكية  
والكهربائية والمعلوماتية



مجلة علمية محكمة دورية

المجلد 45 . العدد 24

1445 هـ . 2023 م

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

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

مديرة مكتب مجلة جامعة البعث  
م. هلا معروف

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

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

الاتصال بالعنوان التالي:

رئيس تحرير مجلة جامعة البعث

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

. هاتف / فاكس : 963 31 2138071 ++

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

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

**ISSN: 1022-467X**

## شروط النشر في مجلة جامعة البعث

الأوراق المطلوبة:

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

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

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

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

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

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

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

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

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

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

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

## رسوم النشر في مجلة جامعة البعث

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

## المحتوى

الصفحة	اسم الباحث	اسم البحث
32-11	م. طارق جردي د. ألفت جولحة	بناء شبكة عصبونية التفاضلية جديدة للتنبؤ بزواوية التوجيه للسيارات ذاتية القيادة
62-33	م. لارا أمون د. غادة سعد	دراسة فعالية كل من خوارزميتي الجار الأقرب والانحدار اللوجستي في تصنيف الأورام الحميدة والخبيثة لمرضى سرطان الثدي باختلاف السمات المدروسة
96-63	م. ليليان صليبي	دراسة ومحاكاة تقنيات تخمين القناة في نظام Massive MIMO وتحسينها باستخدام التخمين شبه الأعمى القائم على الفضاء الجزئي في أنظمة (5G)
120-97	م. محمد حمدان د. محمد العصوره	تحسين أداء نظم كشف الاختراق باستخدام المنطق العصبي الضبابي والخوارزمية الجينية مقارنة مع SNORT
144-121	م. نسيم الضاهر د. علي هتره د. أحمد سلامة	إعداد الحسابات اللازمة لتشكيل سبيكة خاصة بالتطبيقات الشاقفة بصهر الفولاذ والكروم والموليبدنوم في فرن تحريضي
172-145	م. ياسر قره فلاح د. رامي منصور د. هادي معلا	تشكيل مادة مركبة مقاومة لرصاص البندقية الآلية كلاشينكوف عيار 7.62mm





# بناء شبكة عصبونية التفاضلية جديدة للتنبؤ بزواوية التوجيه للسيارات ذاتية القيادة

إعداد الباحثين

د. م. ألفت جولحة

م. طارق جردي

أستاذ مساعد في قسم هندسة الحاسبات

طالب دراسات عليا (ماجستير) في قسم هندسة

والتحكم الآلي، اللاذقية، سوريا.

الحاسبات والتحكم الآلي، اللاذقية، سوريا.

## المخلص

مع تطور تقنيات الذكاء الاصطناعي شهد مجال السيارات ذاتية القيادة تقدماً كبيراً، يتم استخدام الذكاء الاصطناعي بشكل أساسي لتحديد القرار المتمثل بقيمة السرعة وزاوية التوجيه المناسبة لضمان تحرك السيارة بالشكل الصحيح. في السنوات الأخيرة تم الاعتماد بشكل كبير على الشبكات العصبونية الالتفافية Convolutional Neural Network للتنبؤ بزواوية التوجيه للسيارات ذاتية القيادة، يركز هذا البحث على تطوير نظام تعلم عميق من أجل تحسين دقة التنبؤ بزواوية التوجيه من خلال بناء نموذج شبكة عصبونية التفاضلية عميقة جديدة. تم اقتراح استخدام نماذج نقل التعلم Transfer Learning models لرفع كفاءة الشبكة العصبونية الالتفافية المستخدمة بعملية التنبؤ حيث تم الاستفادة من المعرفة المخزنة في نماذج نقل التعلم بعد إعادة تدريبها على بيانات Udacity المتضمنة مجموعة صور لطريق مألوفة باستخدام محاكي وكل صورة ملتقطة من الطريق مرفقة بزواوية التوجيه اللازمة. تم بناء أربع نماذج لشبكات عصبونية التفاضلية مختلفة باستخدام نماذج ResNet50 و Inception و VGG16 و VGG19 وجميعها تفوقت على نموذج DAVE2 الخاص بشركة NVIDIA وحقق نموذج الشبكة المعتمدة على نموذج VGG16 أدنى قيمة خطأ.

**الكلمات المفتاحية:** الشبكات العصبونية الالتفافية- نماذج نقل التعلم -زاوية التوجيه - السيارات ذاتية القيادة-استتساخ سلوكي.

# Building a New Convolutional Neural Network Architecture to Predict the Steering Angle of Self-Driving Cars

**Dr. OULFAT JOLAHA**

Associate Professor, Department of  
Computers and Automatic Control  
Engineering, Latakia, Syria.

**Eng. TAREK JURDI**

Master Student, Department of  
Computers and Automatic Control  
Engineering, Latakia, Syria.

## Abstract

With the advancement of artificial intelligence technologies, the field of self-driving cars has made significant progress. Artificial intelligence is primarily used to determine the appropriate speed value and steering angle to ensure the correct movement of the vehicle. In recent years, there has been a significant reliance on Convolutional Neural Networks (CNNs) to predict the steering angle of self-driving cars. This research focuses on developing a deep learning system to improve the accuracy of steering angle prediction by building a new deep Convolutional Neural Network model. The use of Transfer Learning models has been proposed to enhance the efficiency of the CNN used in the prediction process. By leveraging the knowledge stored in Transfer Learning models, which have been retrained on Udacity dataset consisting of generated road images captured by a simulator, along with their corresponding steering angles. Four different models of CNNs were built using ResNet50, Inception, VGG16, and VGG19 architectures. All of them outperformed the DAVE2 model developed by NVIDIA, with the VGG16-based network achieving the lowest error value.

**Key words:** Convolutional Neural Networks - Transfer Learning - Steering Angle - Self-Driving Cars - Behavioral Cloning.

1- مقدمة

احتلت السيارات ذاتية القيادة حيزاً هاماً في العديد من الأبحاث نظراً لكثرة التحديات والمتطلبات التي تحتاجها عملية إنشاء نظام قيادة ذاتي متكامل. إن السيارات ذاتية القيادة هي مركبات تعتمد على الحساسات ومجموعة من الوحدات الوظيفية وخوارزميات الذكاء الاصطناعي للقيام بكافة العمليات المرتبطة بالقيادة مثل تحديد السرعة وزاوية التوجيه وحالة المكابح بشكل مستقل عن التدخل البشري بحيث تصبح قادرة على القيادة والتنقل ضمن البيئة [1]. يعد أسلوب القيادة end-to-end المندرج تحت التعلم العميق النموذج الأنسب للتعامل مع البيانات الضخمة في بيئات القيادة البسيطة فيما يعتبر أسلوب القيادة mid-to-mid أكثر فاعلية في بيئات القيادة المعقدة [2]. يتم في خوارزميات التعلم العميق تقسيم المشكلة إلى مشكلات جزئية وتُحل كل منها بشكل مستقل ومن ثم يتم الجمع بين النواتج والوصول إلى القرار النهائي. وتحاول العديد من شركات السيارات مثل هيونداي وتيسلا وغيرها إنتاج الملايين من السيارات ذاتية القيادة من خلال استخدام خوارزميات التعلم العميق [3, 4, 5, 6]. في هذا السباق السريع للتوصل إلى سيارات ذاتية القيادة آمنة تماماً، تتبع بعض الشركات مثل NVIDIA نهج القيادة end-to-end [7] ، في حين أن جوجل تتبع نهج mid-to-mid [8]. يشار إلى عملية إعادة بناء مهارات المعرفة البشرية من خلال برنامج حاسوبي بعملية نسخ السلوك behavioral cloning، حيث تسجل الأفعال البشرية مع الحالة التي أدت إلى هذا العمل [9]. توجد طريقتان شائعتان لنسخ السلوك، في الطريقة الأولى يمكن التعلم من خلال مجموعة من الحوارات مع المشغل، ففي حالة المركبات ذاتية القيادة يكون المتوقع من المشغل شرح العديد من المهارات المفيدة من أجل التحكم بالمركبة، تواجه هذه الطريقة تحديات عديدة وذلك لأن الشرح التقليدي للمهارات ليس

حالة مثالية بالنسبة للقدرات البشرية. أما الطريقة الثانية فتعتمد على إعادة بناء المهارات من خلال الإجراءات المسجلة التي يتم الحفاظ عليها بطريقة منظمة باستخدام خوارزميات التعلم في مظاهر تتبع مختلفة وذلك لإعادة إنتاج سلوك أكثر مهارة [10, 11, 12, 13]. في عام 1989 تم بناء مركبة أرضية مستقلة باستخدام نموذج الشبكات العصبونية ALVINN والتعلم العميق، حيث أمكن توجيه السيارة من خلال شبكة عصبونية عميقة [14]. فيما بعد وفي عام 2016 توصلت شركة NVIDIA لحل مثير للاهتمام للتنبؤ بزوايا التوجيه للسيارات ذاتية القيادة حيث بنت نموذج بسيط لشبكة عصبونية التفاضلية تحت نهج end-to-end وأطلقت الشركة على نموذج الشبكة العصبونية تسمية DAVE2 [15]، حيث تم تدريب النموذج على إطارات فيديو ملتقط عن طريق ثلاث كاميرات مستقلة لعملية قيادة يقوم بها سائق بشري وقد حقق هذا النموذج نتائج جيدة. في الآونة الأخيرة حاولت العديد من الأبحاث استخدام الشبكات العصبونية الالتفافية والشبكات العصبونية المتكررة Recurrent Neural Network لحل المسائل المرتبطة بتصنيف الفيديو [16] وتحليل المشهد [17] وكشف الكائنات [18]. لقد ساعد هذا الاتجاه الباحثين على بناء نماذج أكثر تعقيدا في مجال السيارات ذاتية القيادة. وفي سبيل تحسين نموذج NVIDIA تم استخدام تقنيات مختلفة مثل استخدام نماذج نقل التعلم Transfer Learning والذاكرة الطويلة القصيرة الأمد LSTM وأخذ معلومات تتعلق بالإزاحة والحركة والتسلسل الزمني لعملية القيادة [19]. كما استخدمت العديد من الأبحاث تقنيات التعلم المعزز Reinforcement Learning في مجال السيارات ذاتية القيادة [20, 21] والمشكلة الأساسية التي واجهتها هذه التقنيات الكلفة الحسابية العالية [22].

## 2- هدف البحث

يهدف البحث إلى تطوير نظام تعلم عميق للتنبؤ بزوايا التوجيه للسيارات ذاتية القيادة وفق نهج end-to-end باستخدام نماذج نقل التعلم ومقارنته مع نموذج DAVE2 الخاص بشركة NVIDIA. تتجلى أهمية البحث بشكل أساسي بتحسين عملية التنبؤ بزوايا التوجيه للسيارات ذاتية القيادة بما يحقق قيادة سليمة وضمان سير السيارة بالشكل الصحيح مما يساهم في زيادة الموثوقية والأمان، مع توضيح أهمية استخدام نماذج نقل التعلم للاستفادة من نماذج شبكات عصبونية عالية الأداء وإعادة تدريبها وتوظيفها بشكل فعال للعديد من المهام ضمن البيئة المحلية.

## 3- مواد وطرق البحث

تم الانطلاق من نموذج شركة NVIDIA المسمى DAVE2 كونه أول نموذج يستخدم شبكة عصبونية التفاضلية للتنبؤ بزوايا التوجيه للسيارات ذاتية القيادة بالاعتماد على الصور فقط، لذلك تم استخدامه كنموذج مقارنة مرجعي ومن خلال الاطلاع على أكثر نماذج الشبكات العصبونية استخداماً كنماذج نقل تعلم تم بناء 4 نماذج لشبكات عصبونية عميقة جديدة بالاعتماد على نماذج ResNet50 و VGG16 و VGG19 و Inception . تم تدريب كافة النماذج 10 دورات تدريبية فقط بهدف المقارنة وانتقاء النموذج الأفضل بالإضافة إلى أن استخدام 10 دورات تدريبية كان كافٍ للوصول نموذج على الأقل للأداء المطلوب من ناحية تحديد زاوية التوجيه المناسبة حيث أن الاعتماد على أساليب نقل التعلم يقلل من عدد دورات التدريب اللازمة للوصول إلى النتائج المرغوبة. تم إعادة تدريب نموذج DAVE2 على نفس البيانات ونفس عدد دورات التدريب من أجل المقارنة.

#### 4- نماذج نقل التعلم

تعتبر نماذج نقل التعلم أحد أساليب تعلم الآلة Machine Learning التي تستخدم للاستفادة من المعارف المخزنة لنظم مدربة مسبقاً عن طريق إعادة استخدامها (إعادة تدريبها) على مشاكل جديدة ذات صلة [23]. من أبرز إيجابيات هذا النهج تقليل زمن التدريب والاستفادة من الأداء العالي للشبكات العصبونية العالية الدقة. يتم إعادة استخدام الشبكات العصبونية في هذا النهج بطريقتين:

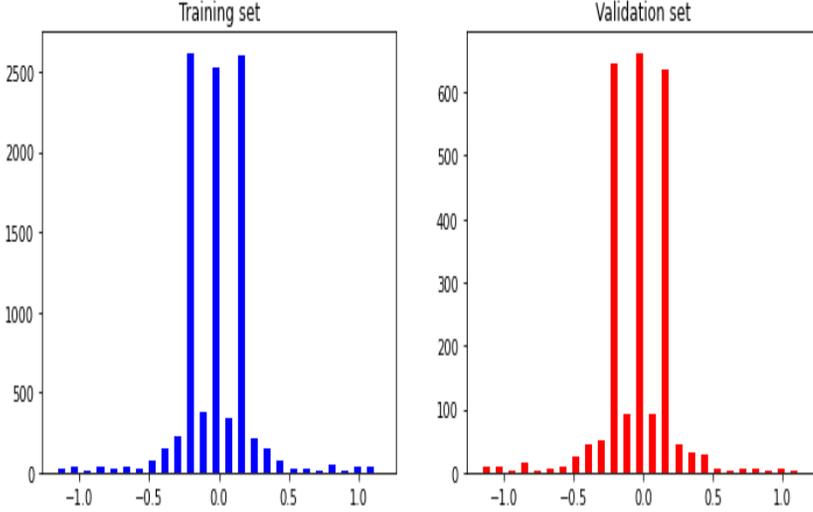
- 1- الاستفادة من الأوزان النهائية واستخدامها كأوزان ابتدائية للنظام الجديد وإعادة تدريب الشبكة بالكامل (عندما تكون البيانات كبيرة وذات صلة).
- 2- حذف الطبقات الأخيرة من الشبكة العصبونية المدربة مسبقاً وإضافة طبقات جديدة ومن ثم إعادة تدريب الشبكة ككل (عندما تكون البيانات قليلة أو بعيدة الصلة).

#### 5- مجموعة البيانات المستخدمة

تم استخدام مجموعة صور [26] مولدة عن طريق محاكي Udacity [25] حيث يتم ربط كل صورة مأخوذة من عملية القيادة بزوايا التوجيه الصحيحة. تحوي قاعدة البيانات على 12159 صورة ملتقطة بواسطة 3 كاميرات متموضعة على يسار ويمين ومنتصف السيارة. تم تقسيم هذه البيانات إلى 9727 صورة للتدريب و2432 صورة للتقييم. مجال قيم زاوية التوجيه ضمن قاعدة البيانات  $[-1, +1]$  يتم تحويله ضمن المحاكى الخاص ب Udacity إلى المجال  $[-25, +25]$  درجة.

يوضح الشكل (1) توزيع قيم زوايا التوجيه لكل من بيانات التدريب وبيانات الاختبار حيث يمثل المحور الأفقي قيمة الزاوية والمحور العمودي عدد الصور التي تتضمن هذه الزاوية ويُلاحظ أن أغلب الزوايا قريبة من الصفر وهذا منطقي وواقعي كون أن

تحرك السيارة في غالب الأحيان لا يتطلب قيم زاوية كبيرة إلا في حالات الانعطاف الشديد.



الشكل (1) الهيستوغرام الخاص بقيم زوايا التوجيه لكل من بيانات التدريب والتقييم.

## 6- تعزيز البيانات

يمكن أن تحتوي نماذج نقل التعلم التي سيتم استخدامها على ملايين البارامترات، ويتطلب ضبط هذه البارامترات عدد كبير من الحالات التدريبية للبيانات غير المترابطة. ونظرا لمحدودية البيانات، يظهر ما يسمى *over-fitting* للبيانات في الشبكات العصبونية العميقة. لتجنب *over-fitting* نلجأ لعملية تعزيز البيانات *Data Augmentation*. تم تعزيز البيانات عبر أربع طرق وهي [19]:

1. تعزيز السطوع: تم تغيير السطوع بشكل عشوائي لمحاكاة ظروف الإضاءة المختلفة. نقوم بإنشاء صور معززة بسطوع مختلف عن طريق تحويل الصور أولاً إلى النمط اللوني HSV، وتوسيع نطاق قناة V أو خفضها والتحويل مرة أخرى إلى نمط RGB.

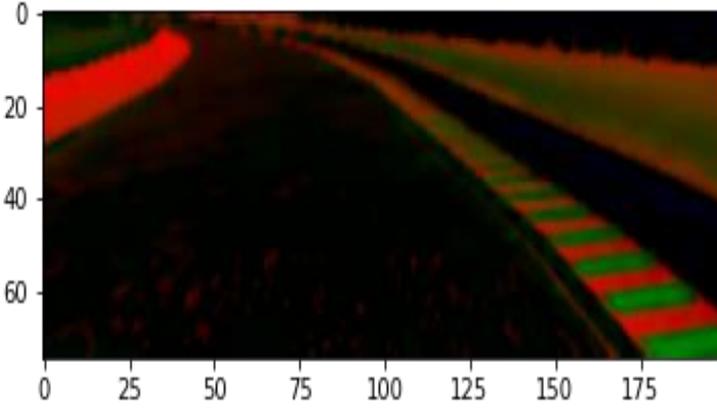
2. التكبير: تم تكبير الصور بمعامل تكبير عشوائي كل مرة لتوليد المزيد من الحالات المختلفة.
  3. عكس اتجاه الصور: تم إجراء عكس اتجاه الصور وعكس قيمة زاوية التوجيه المرافقة نظراً لأن السيارة تمر بمنعطفات مختلفة.
  4. التحويلات الأفقية والعمودية: تم تحريك الصورة بحركة عشوائية على المحور الأفقي والعمودي لمحاكاة تأثير وجود السيارة في مواضع مختلفة على الطريق.
- تخضع الصور المستخدمة في تدريب نماذج نقل التعلم لأحد التحويلات السابقة بشكل عشوائي لتحقيق أكبر قدر من الحالات المختلفة بحيث يمكن تعميم أداء هذه النماذج قدر الإمكان.

#### 7- المعالجة المسبقة للصور

تخضع الصور قبل إدخالها لنماذج نقل التعلم لمجموعة من الخطوات التي تزيد من فاعلية هذه النماذج بالتنبؤ بزوايا التوجيه الصحيحة حيث يتم إجراء عملية اقتطاع للصور لأخذ المنطقة الهامة للطريق فقط وإهمال الأجزاء الغير هامة بالإضافة للقيام بعملية تنعيم باستخدام مرشح غوسي  $3*3$  لتهميش التفاصيل الدقيقة الغير هامة ومن ثم يتم تحويل النمط اللوني للصور من RGB إلى YUV للوصول لأنماط متقاربة قدر الإمكان لصور الطرق بالرغم من اختلافها، كذلك يتم تقبيس كل الصور للمقاس  $200*75$  وفي النهاية يتم إجراء Normalization لقيم بكسلات الصورة وفق العلاقة:

$$\text{New Value} = \text{Old Value}/127.5-1.0 \quad (1)$$

يوضح الشكل (2) صورة كمثال بعد خضوعها لعملية المعالجة المسبقة.

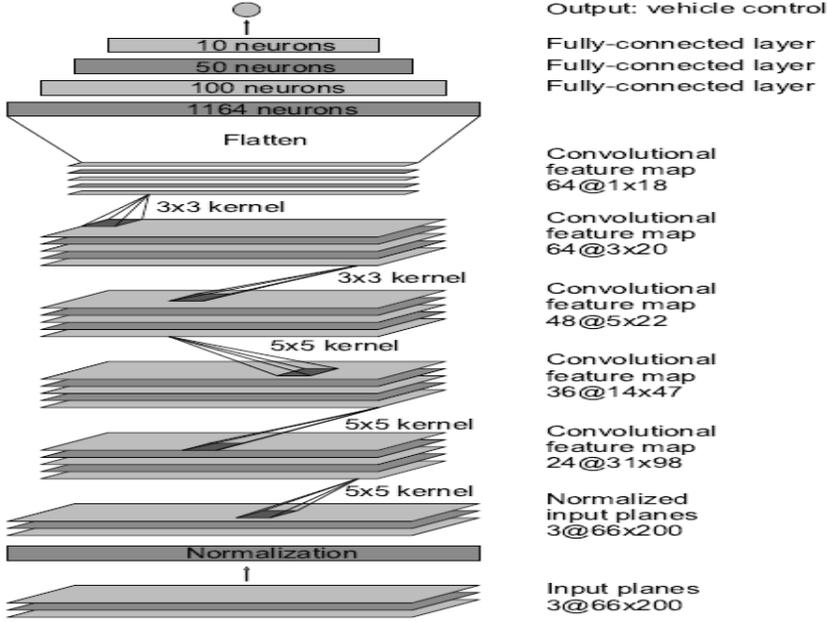


الشكل (2) خرج مرحلة المعالجة المسبقة للصورة.

#### 8- بناء نماذج الشبكات العصبونية

تم بناء 4 نماذج لشبكات عصبونية عميقة جديدة بالاعتماد على نماذج ResNet50 و VGG16 و VGG19 و Inception بالإضافة لاستخدام نموذج DAVE2 الخاصة بشركة NVIDIA من أجل مقارنة نماذج نقل التعلم مع أداء هذا النموذج. يوضح الشكل (3) نموذج شبكة DAVE2 [15] والذي يتكون من 5 طبقات التفاضلية وفي كل طبقة يتم تطبيق عدد من المرشحات الالتفافية وهي بدءاً من الطبقة الأولى 24 و 36 و 48 و 64 و 64 مرشح في آخر طبقة. يستخدم النموذج مرشحات بحجم 5\*5 في أول ثلاث طبقات و 3\*3 في آخر طبقتين. يعد هذا الجزء من الشبكة المسؤول عن تحليل مكونات الصورة واستخلاص السمات على شكل مجموعة من المصفوفات يتم تحويلها لشعاع سمات واحد يضم كامل المعلومات ويمثل خرج طبقة التسطيح (Flatten) والذي يعتبر بدوره دخل للطبقات الكاملة الاتصالية المسؤولة عن التنبؤ بزاوية التوجيه. تتكون كل طبقة من الطبقات الكاملة

الاتصالية من مجموعة من العصبونات وهي بالترتيب بدءاً من الطبقة الأولى و 100 و 50 و 10 و 1 على طبقة الخرج.



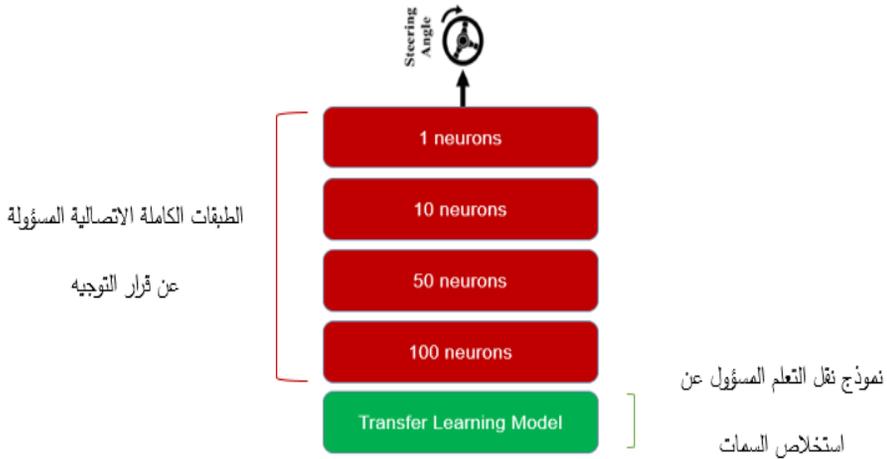
الشكل (3) نموذج شبكة DAVE2 [15] .

بشكل عام يمكن النظر لبنية الشبكات العصبونية التفاضلية بأنها تتكون من جزئين أساسيين، الجزء الأول من الشبكة المسؤول عن استخلاص السمات والذي ينبغي أن يشمل عدداً من الطبقات التفاضلية يختلف حسب بنية الشبكة والدخل الأساسي لهذا الجزء هو صورة، أما الجزء الثاني فيعقب طبقة التسطيح (flatten) ويتمثل بالطبقات الكاملة الاتصالية المسؤولة عن الخرج النهائي (القرار) وتختلف هذه الطبقات من بنية إلى أخرى والدخل الأساسي لها هو شعاع السمات الذي يتم استخلاصه من الجزء الأول. تم اتباع النهج التالي في بناء أربعة نماذج جديدة بحيث تشارك هذه النماذج في بنيتها بالطبقات الأخيرة المتمثلة بالطبقات الكاملة الاتصالية والمماثلة لنموذج DAVE2 وهي طبقات جديدة يتم إضافتها وتركيبها كخرج لنماذج نقل التعلم

بعد حذف الطبقات الكاملة الاتصالية من كل نموذج نقل تعلم واستخدام الطبقات الجديدة، تعد هذه الطبقات الجزء المسؤول عن حساب زاوية التوجيه وتختلف النماذج الأربعة عن بعضها بنموذج الطبقات الأولى المسؤولة عن استخلاص السمات (طبقات نماذج نقل التعلم). تم تهيئة النماذج الأربعة بالأوزان الناتجة عن بيانات ImageNet. ونظراً لأن بيانات ImageNet بعيدة الصلة عن طبيعة المسألة المدروسة فتم حذف الطبقات الكاملة الاتصالية للنماذج الأربعة وإضافة الطبقات الجديدة كما تم توضيح ذلك مسبقاً. يمكن تلخيص فكرة النهج المقترح بنقطتين رئيسيتين:

- 1- الاستفادة من الطبقات الأولى من نماذج نقل التعلم باستخلاص السمات.
- 2- الاستفادة من الطبقات الكاملة الاتصالية الجديدة باتخاذ قرار التوجيه.

يوضح الشكل (4) نموذج الربط النهائي المقترح عن طريق توظيف نموذج نقل التعلم كمستخلص سمات وإضافة الطبقات الكاملة الاتصالية من أجل التنبؤ بزاوية التوجيه بشكل مماثل لطبقات شبكة DAVE2.



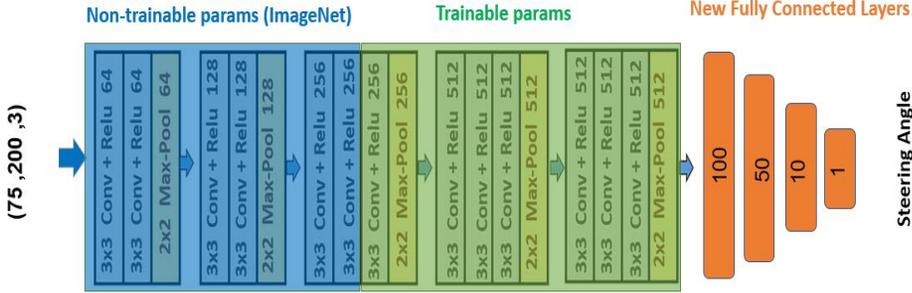
الشكل (4) نموذج الربط النهائي المقترح.

تمت الاستفادة بشكل أساسي من المعرفة المخزنة (الأوزان) ضمن الطبقات الأولى المسؤولة عن استخلاص السمات من نماذج نقل التعلم، ومن أجل توجيه هذه المعارف باتجاه المسألة المدروسة تم منح إمكانية تعديل أوزان الطبقات العشر الأخيرة الخاصة باستخلاص السمات من كل نموذج فيما تم تثبيت أوزان باقي الطبقات. منح إمكانية تعديل الطبقات العشرة الأخيرة يساعد على تركيز النموذج الكلي على السمات الخاصة بالمسألة الجديدة أي تحديد زاوية التوجيه بالاعتماد على صور الطريق. جميع النماذج المقترحة متماثلة في طبقة الدخل والمماثلة بدورها لحجم الصور الموحد (3، 200، 75) فيما تختلف هذه النماذج عن بعضها في بنية الطبقات الأولى بالتالي عدد البارامترات. يوضح الجدول (1) عدد البارامترات والطبقات في النماذج المقترحة.

الجدول (1) عدد الطبقات والبارامترات في النماذج المستخدمة

Model	Layers	Trainable params	Non-trainable params
<b>NVIDIA</b>	10	367,419	-
<b>VGG16</b>	24	13,599,271	1,735,488
<b>VGG19</b>	27	17,138,727	3,505,728
<b>ResNet50</b>	27	7,723,047	20,171,136
<b>Inception</b>	316	825,063	21,802,592

على سبيل المثال يوضح الشكل (5) بنية الشبكة العصبونية المقترحة من أجل التنبؤ بزوايا التوجيه للسيارات ذاتية القيادة باستخدام نموذج نقل التعلم VGG16، والتي حققت أفضل أداء كما هو موضح في عرض النتائج.



الشكل (5) بنية الشبكة العصبونية المقترحة.

## 9- تدريب نماذج الشبكات العصبونية

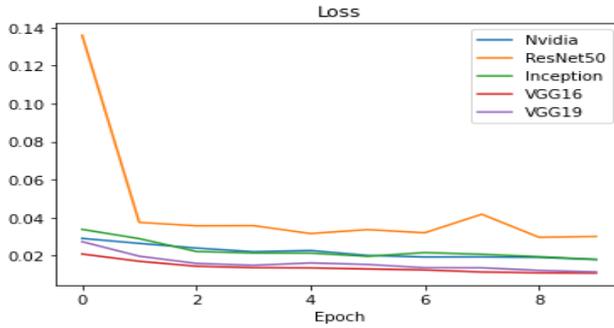
قمنا بتدريب النماذج جميعا من أجل 10 دورات تدريبية مع استخدام Mean Square Error في حساب تابع الكلفة Loss، يحسب MSE عن طريق العلاقة [24]:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2)$$

طريقة التعلم المستخدمة في تعديل الأوزان هي Adam بمعدل تعلم Learning Rate=0.00001 وتتم عملية التدريب باستخدام Batch Size=100 لكل من بيانات التدريب والتقييم بمعدل 300 خطوة في كل تكرار لبيانات التدريب و 200 خطوة في كل تكرار لبيانات الاختبار على أن تخضع الصور الخاصة بالتدريب لعملية تعزيز عشوائية بينما يتم تمرير بيانات التقييم دون أي تعزيز.

## 10- النتائج ومناقشتها

بعد تدريب النماذج الأربعة بالإضافة لنموذج DAVE2 تبين أن نموذج الشبكة العصبونية التفاضلية المعتمد على نموذج VGG16 هو الأفضل من ناحية قيمة MSE حيث حقق أدنى قيمة بالإضافة لدرجة تطابق مقبولة ما بين خرج هذا النموذج والخرج الفعلي لزوايا التوجيه. يوضح الشكل (6) قيم MSE بالنسبة لبيانات التقييم خلال مرحلة التدريب.



الشكل (6) قيم MSE الخاصة ببيانات التقييم لنماذج الشبكات العصبونية خلال مرحلة التدريب. لوحظ أن نماذج VGG16 و VGG19 متقاربة بشكل كبير جداً ومتفوقة على باقي النماذج من ناحية قيمة الخطأ الأصغر MSE. يوضح الجدول (2) قيمة MSE لكل النماذج على بيانات التقييم والتدريب.

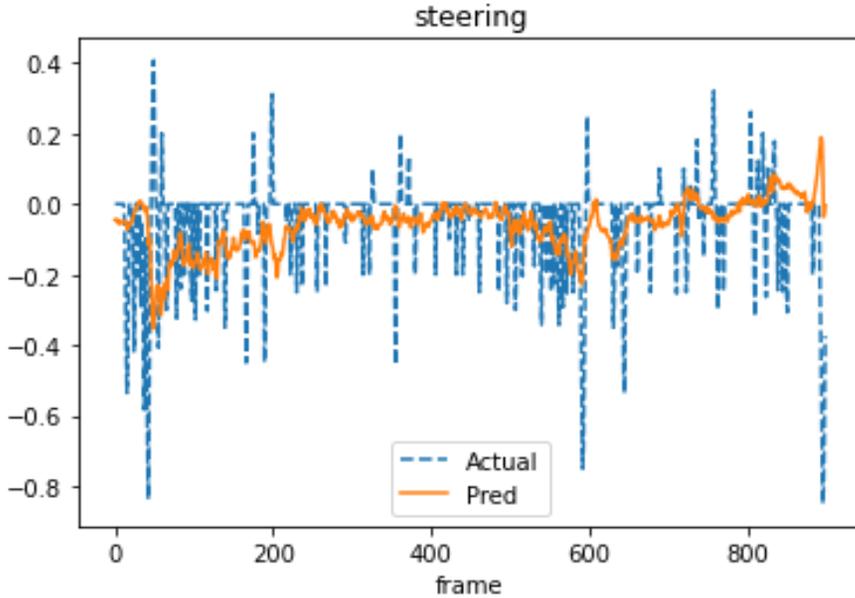
الجدول (2) قيم MSE بالنسبة لكل من بيانات التقييم والتدريب لكافة النماذج

Model	Train Loss	Validation Loss
DAVE2	0.0237	0.0179
ResNet50	0.0392	0.0300
Inception	0.0241	0.0180
<b>VGG16</b>	<b>0.0138</b>	<b>0.0108</b>
VGG19	0.0153	0.0114

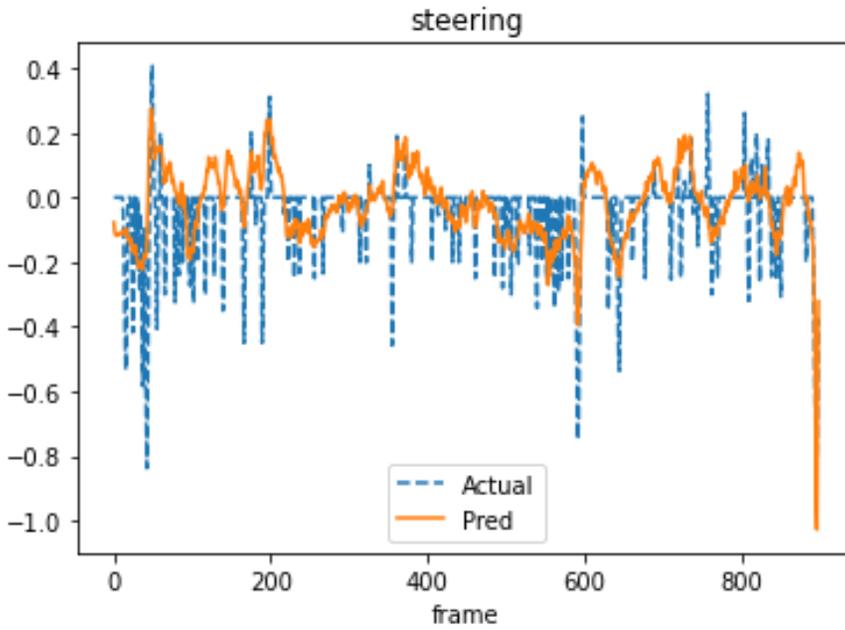
تم رسم خرج النماذج السابقة المتمثلة بزوايا التوجيه ومقارنته مع الخرج الفعلي لمقارنة مدى انطباقه مع القيم الصحيحة. توضح الأشكال (7) و (8) و (9) و (10)

و(11) مقارنة الخرج الفعلي مع خرج النماذج DAVE2 و ResNet50 و Inception و VGG16 و VGG19، على الترتيب، حيث يمثل المحور الأفقي تسلسل إطارات الصور المأخوذة خلال عملية القيادة (900 إطار) والمحور العمودي قيمة زاوية التوجيه المتوقعة عند كل إطار، علماً أن قيم زوايا التوجيه مقيسة ضمن المجال  $[-1,+1]$ .

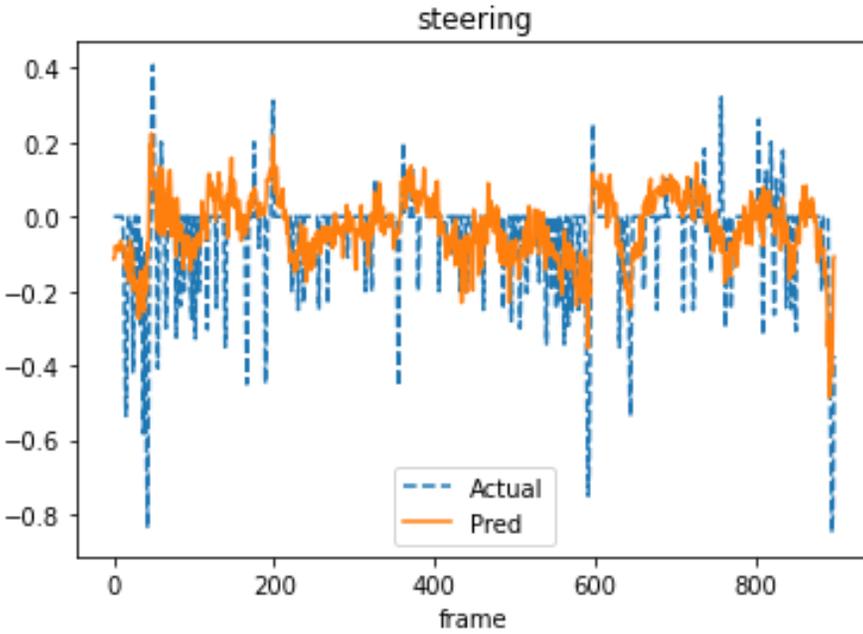
يُلاحظ تفوق نماذج نقل التعلم كافة على نموذج DAVE2 الخاص بشركة NVIDIA الذي لم يعطي درجة تطابق مقبولة ما بين خرجه والخرج الفعلي. تم تدريب نموذج DAVE2 بمقدار عشر دورات تدريبية ولم يتمكن النموذج من الوصول إلى المعرفة اللازمة للتنبؤ بزاوية التوجيه، على عكس نماذج نقل التعلم المستخدمة في البحث فقد استفادت من المعارف المخزنة مسبقاً ضمن طبقاتها الأولى للتنبؤ بزاوية التوجيه بنفس عدد دورات التدريب.



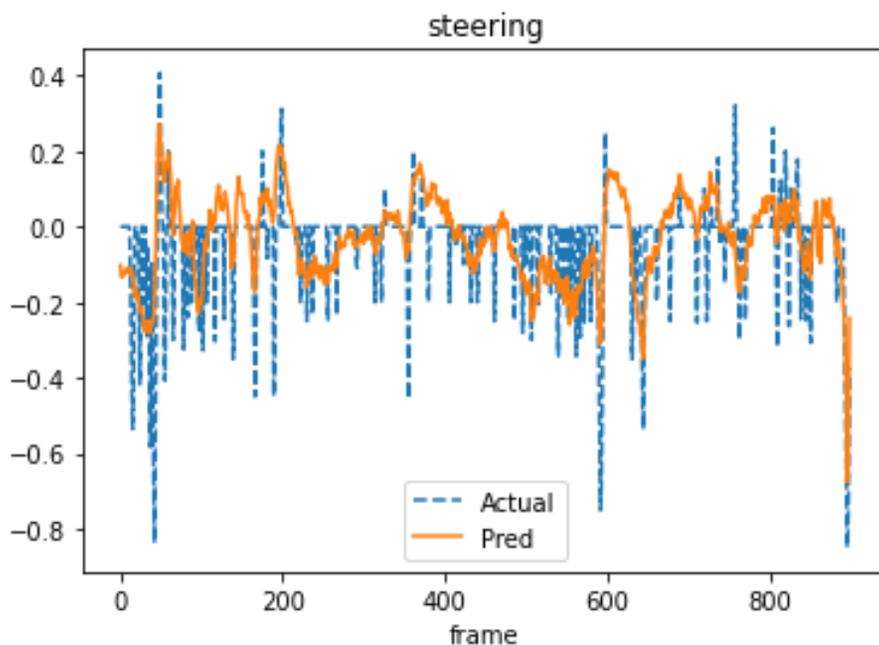
الشكل (7) مقارنة خرج DAVE2 مع الخرج الفعلي.



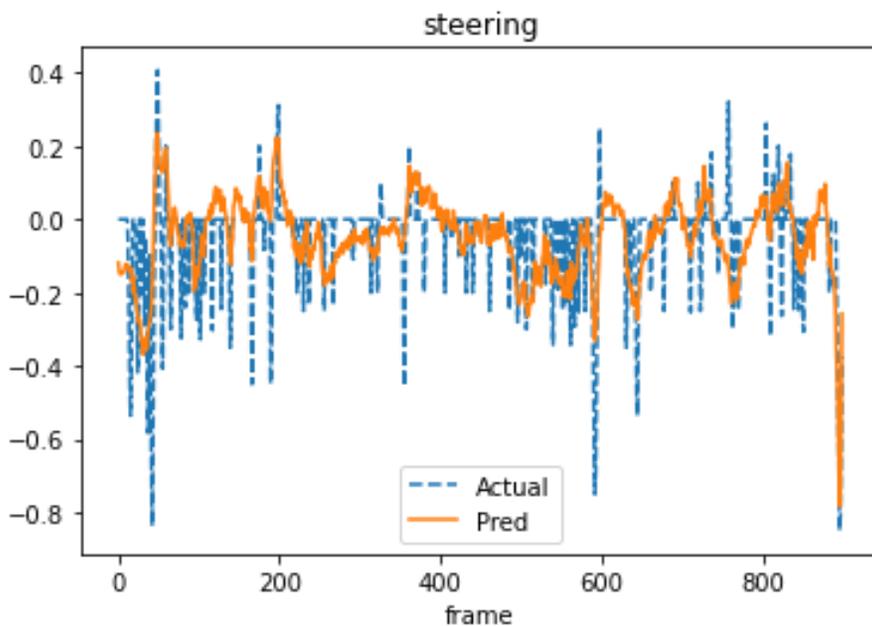
الشكل (8) مقارنة خرج ResNet50 مع الخرج الفعلي.



الشكل (9) مقارنة خرج Inception مع الخرج الفعلي.



الشكل (10) مقارنة خرج VGG16 مع الخرج الفعلي.



الشكل (11) مقارنة خرج VGG19 مع الخرج الفعلي.

## 11- الاستنتاجات والتوصيات

درسنا استخدام نماذج نقل التعلم من أجل التنبؤ بزوايا التوجيه للسيارات ذاتية القيادة حيث قمنا ببناء أربع نماذج جديدة تعتمد على شبكات ResNet50 و Inception و VGG16 و VGG19 وقمنا بمقارنتها مع نموذج شركة NVIDIA المسمى DAVE2 وتم التأكد من تفوق نماذج نقل التعلم جميعاً على نموذج DAVE2 من خلال مقارنة خرج النماذج مع الخرج الفعلي. أعطت نماذج VGG16 و VGG19 نتائج أفضل من ناحية قيمة الخطأ MSE واقترب انطباق خرج هذه النماذج مع الخرج الفعلي يليها نموذج Inception. على الرغم من تطابق خرج نموذج ResNet50 مع الخرج الفعلي بصورة كبيرة فقد أعطى أكبر قيمة MSE (الأسوأ) وذلك لاحتوائه على عدد أكبر من البارامترات المدربة مقارنة بالنماذج السابقة وهذا يتطلب عدد دورات تدريبية أكبر. أثبتنا في النهج المتبع أن استخدام نماذج نقل التعلم يسرع من الوصول إلى النتائج المرغوبة بعدد دورات تدريب أقل نظراً للمعرفة المخزنة ضمن هذه النماذج. يمكن مستقبلاً تحسين أداء هذه النماذج باستخدام بنية الذاكرة الطويلة-القصيرة الأمد LSTM لأخذ التسلسل الزمني لعملية القيادة واعتمادية إطارات الصور بالحسبان بالإضافة لتوسيع عملية التدريب من خلال زيادة عدد الصور لتغطي ظروف وحالات مختلفة بحيث يمكن تعميم أداء هذه النماذج قدر الإمكان كما يمكن استخدام نهج التعلم المعزز لأتمتة التغييرات الحاصلة على زاوية التوجيه.

## References

- [1] R. Singh Dharra, S. Daniel, S. Solankar and S. Raj. N2, 2019 Using Deep Convolutional Neural Network to Avoid Vehicle Collision. Volume: 06 Issue: 06, e-ISSN: 2395-0056.
- [2] Seiya, S., Carballo, A., Takeuchi, E., & Takeda, K. (2020, October). Point Grid Map-Based Mid-To-Mid Driving without Object Detection. In 2020 IEEE Intelligent Vehicles Symposium (IV) (pp. 2044-2051). IEEE.
- [3] Chopra, R., & Roy, S. S. (2020). End-to-end reinforcement learning for self-driving car. In *Advanced computing and intelligent engineering* (pp. 53-61). Springer, Singapore.
- [4] LEE, Myoung-jae; HA, Young-guk. Autonomous driving control using end-to-end deep learning. In: 2020 IEEE International Conference on Big Data and Smart Computing (BigComp). IEEE, 2020. p. 470-473.
- [5] CHEN, Zhilu; HUANG, Xinming. End-to-end learning for lane keeping of self-driving cars. In: 2017 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2017. p. 1856-1860.
- [6] Glasmachers, T. (2017, November). Limits of end-to-end learning. In *Asian conference on machine learning* (pp. 17-32). PMLR.
- [7] Bojarski, M., Yeres, P., Choromanska, A., Choromanski, K., Firner, B., Jackel, L., & Muller, U. (2017). Explaining how a deep neural network

trained with end-to-end learning steers a car. *arXiv preprint arXiv:1704.07911*.

[8] Bansal, M., Krizhevsky, A., & Ogale, A. (2018). Chauffeurnet: Learning to drive by imitating the best and synthesizing the worst. *arXiv preprint arXiv:1812.03079*.

[9] Torabi, F., Warnell, G., & Stone, P. (2018). Behavioral cloning from observation. *arXiv preprint arXiv:1805.01954*.

[10] Sammut, C., & Webb, G. I. (Eds.). (2011). *Encyclopedia of machine learning*. Springer Science & Business Media.

[11] Michie, D. (1993). Knowledge, learning and machine intelligence. In *Intelligent systems* (pp. 1-19). Springer, Boston, MA.

[12] KULIC, Ranka; VUKIC, Zoran. Autonomous vehicle obstacle avoiding and goal position reaching by behavioral cloning. In: *IECON 2006-32nd Annual Conference on IEEE Industrial Electronics*. IEEE, 2006. p. 3939-3944.

[13] Michie, D., & Camacho, R. (1994). Building symbolic representations of intuitive real-time skills from performance data. *Machine Intelligence* 13.

[14] D. Pomerleau, (1989) "Advances in neural information processing systems," pp. pp.305-313.

[15] Bojarski, M., Del Testa, D., Dworakowski, D., Firner, B., Flepp, B., Goyal, P. & Zieba, K. (2016). End to end learning for self-driving cars. *arXiv preprint arXiv:1604.07316*.

- [16] Karpathy, A., Toderici, G., Shetty, S., Leung, T., Sukthankar, R., & Fei-Fei, L. (2014). Large-scale video classification with convolutional neural networks. In Proceedings of the IEEE conference on Computer Vision and Pattern Recognition (pp. 1725-1732).
- [17] Farabet, C., Couprie, C., Najman, L., & LeCun, Y. (2012). Learning hierarchical features for scene labeling. IEEE transactions on pattern analysis and machine intelligence, 35(8), 1915-1929.
- [18] Szegedy, C., Toshev, A., & Erhan, D. (2013). Deep neural networks for object detection. Advances in neural information processing systems, 26.
- [19] Oinar, C., & Kim, E. (2022). Self-Driving Car Steering Angle Prediction: Let Transformer Be a Car Again. arXiv preprint arXiv:2204.12748.
- [20] Sallab, A. E., Abdou, M., Perot, E., & Yogamani, S. (2017). Deep reinforcement learning framework for autonomous driving. Electronic Imaging, 2017(19), 70-76.
- [21] Shalev-Shwartz, S., Shammah, S., & Shashua, A. (2016). Safe, multi-agent, reinforcement learning for autonomous driving. arXiv preprint arXiv:1610.03295.
- [22] Dosovitskiy, A., Ros, G., Codevilla, F., Lopez, A., & Koltun, V. (2017, October). CARLA: An open urban driving simulator. In Conference on robot learning (pp. 1-16). PMLR.

- [23] Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., & Liu, C. (2018, October). A survey on deep transfer learning. In International conference on artificial neural networks (pp. 270-279). Springer, Cham.
- [24] Ren, J., Zhang, M., Yu, C., & Liu, Z. (2022). Balanced MSE for Imbalanced Visual Regression. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 7926-7935).
- [25] "The Udacity open source self-driving car project," [Online]. Available: <https://github.com/udacity/self-driving-car>. [Last access: 1/10/2022].
- [26] "road-image," [Online]. Available: <https://github.com/rslim087a/track>. [Last access: 4/3/2022].

## دراسة فعالية كل من خوارزميتي الجار الأقرب والانحدار اللوجستي في تصنيف الأورام الحميدة والخبيثة لمرضى سرطان الثدي باختلاف السمات المدروسة

د. غادة سعد + م. لارا أمون  
كلية الهمك - جامعة تشرين

### الملخص

يعتبر مرض السرطان بشكل عام وسرطان الثدي بشكل خاص من أكثر الأمراض خطورة وتعقيداً، حيث يعتبر سرطان الثدي من أكثر الأمراض المسببة للوفيات عالمياً وتحديداً للسيدات، وقد أكدت الأبحاث الطبية ضرورة الكشف المبكر عن المرض لما له أهمية في تقليص عدد الوفيات وزيادة فرص العلاج، ومع التطور التقني الذي نشهده في أيامنا هذه كان لابد من الاستفادة من تقنيات هذا التطور، حيث تلعب أنظمة الكشف عن المرض بمساعدة الحاسوب، دوراً هاماً في الكشف المبكر عن الأمراض و تزيد من إمكانية الوصول إلى دقة عالية في تشخيص الأورام الحميدة والخبيثة وبالتالي زيادة فرص العلاج والبقاء على قيد الحياة. وتعد تقنيات الذكاء الصناعي والتعلم الآلي من التقنيات الهامة في العصر الحديث التي تستخدم للتنبؤ والتصنيف والتحليل واتخاذ القرارات. في هذه الورقة البحثية تم دراسة فعالية خوارزميتين من خوارزميات التعلم الآلي الخاضعة للإشراف والتي تعتمد على التدريب من البيانات السابقة للتنبؤ بالبيانات الجديدة وهذه الخوارزميات هي الجار الأقرب والانحدار اللوجستي وذلك بهدف تشخيص الأورام السرطانية لمرضى سرطان الثدي، حيث تم دراسة مجموعة من السمات وفق ثلاث حالات للوصول إلى دقة عالية في تشخيص المرض وفقاً للخوارزميات المذكورة، أخيراً تمت مقارنة نتائج الدراسة مع نتائج دراسات مرجعية سابقة.

**الكلمات المفتاحية:** سرطان الثدي، الذكاء الصناعي، التعلم الآلي، خوارزمية الجار الأقرب، خوارزمية الانحدار اللوجستي.

## **Studying the effectiveness of k-Nearest Neighbor and logistic regression algorithms in classifying benign and malignant tumors for breast cancer patients with different studied features**

**Dr. Ghada Saad\***

**Eng. Lara Ammoun\*\***

### **□ ABSTRACT □**

Cancer in general, and breast cancer in particular, is considered one of the most dangerous and complex diseases, as breast cancer is one of the most fatal diseases in the world, specifically for women. Medical research has confirmed the necessity of early detection of the disease because of its importance in reducing the number of deaths and increasing the chances of treatment. And with the technical development that we are keeping pace with today, it was necessary to take advantage of technologies of this development. As computer-aided disease detection systems play an important role in early detection of diseases and increase the possibility of reaching high accuracy in diagnosing benign and malignant tumors and thus increasing Chances of treatment and survival. Artificial intelligence and machine learning are the most important technologies in the modern era, which are used for prediction, classification, analysis and decision-making. In this paper, the effectiveness of two supervised machine learning algorithms that rely on training from previous data to predict new data was studied, these algorithms are the nearest neighbor and logistic regression, with the aim of diagnosing cancerous tumors for breast cancer patients. A group of features were studied according to three cases to reach a high accuracy in diagnosing the disease according to the mentioned algorithms. Finally, the results of the study were compared with the results of previous reference studies.

**Keywords:** breast cancer, artificial intelligence, machine learning, nearest neighbor algorithm, logistic regression algorithm.

## 1. المقدمة:

يعد مرض السرطان من أخطر الأمراض وأكثرها تعقيداً كونه نمو غير طبيعي للخلايا ويمكن أن ينتشر بسرعة إلى أي عضو من أعضاء الجسم دون القدرة على التحكم به علاوة على ذلك لم يتم اكتشاف سبب حقيقي للمرض حتى الآن وإنما فقط بعض العوامل التي قد تكون سبب في وجوده مثل التعرض للأشعة الكيماوية أو العوامل الوراثية أو الدهون الغذائية أو التعرض للمبيدات الحشرية بالإضافة إلى الضغط النفسي. توجد أنواع عديدة للسرطان وأخطرها سرطان الرئة والجلد والثدي حيث أن عدد الوفيات يصل إلى 9.2 مليون لمرضى سرطان الرئة و1.7 مليون لمرضى سرطان الجلد و627000 لمرضى سرطان الثدي وفقاً لإحصاءات منظمة الصحة العالمية [1] التي تم ذكرها ضمن [2]. عادة ما يتم اتخاذ مجموعة من الإجراءات للكشف عن سرطان الثدي، مثل التصوير الشعاعي للثدي، التصوير الحراري، الموجات فوق الصوتية، أخذ خزعة من الثدي وغيرها من الإجراءات الأخرى، حيث تعتبر بعض هذه الإجراءات مكلفة وبعضها يأخذ وقتاً طويلاً بالإضافة إلى انخفاض معدل دقة الكشف [3]. إلا أنه وفي أيامنا هذه، يشهد المجال التقني تطوراً ملحوظاً من حيث التجهيزات الحاسوبية والأنظمة المستخدمة، لذلك أصبح لا بد من الانتقال إلى عصر المعلومات والاستفادة من التقنيات المختلفة لتقليل الأخطاء واختصار الزمن، وتعد تقنيات الذكاء الصناعي والتعلم الآلي من أهم التقنيات المستخدمة في العصر الحديث، حيث يتم استخدامها للتنبؤ والتصنيف والتحليل واتخاذ القرارات، وتقديم رأي ثاني للأطباء بحيث يتم التغلب على العديد من عيوب الطرق التقليدية والمساعدة في الكشف المبكر عن المرض بهدف تقليل معدل الوفيات وزيادة فرص العلاج [4].

عام 2023 قام الباحث حكيم المصري بإجراء دراسة بحثية [5] هدفت إلى الكشف عن سرطان الثدي من خلال استخلاص القواعد من خوارزمية شجرة القرار وتطبيقها على

النموذج الانطولوجي (الوجودي) ontological model عبر لغة قواعد الويب الدلالية (SWRL) وقد استخدمت قاعدة البيانات مفتوحة المصدر وهي قاعدة ويسكنسون لتشخيص سرطان الثدي (WBCD) حيث استخدمت 9 سمات للمرضى مع الهدف لتدريب النموذج واستخدمت أداة Weka لبرمجة النموذج وكان من أبرز نتائجها أنه تم الوصول إلى دقة عالية في تشخيص سرطان الثدي باستخدام النموذج المقترح بنسبة 97.10%.

عام 2022 قام الباحث Dumpala Shanthi بنشر ورقة بحثية [6] هدفت إلى الحصول على دقة عالية في الكشف المبكر عن مرض سرطان الثدي باستخدام نهج تجميعي لخوارزمية الغابة العشوائية وقد استخدم قاعدتي بيانات (WBCDD و WBCPD) واستخدم البرنامج R لبرمجة النموذج وكان من أبرز نتائج الورقة البحثية الوصول إلى نسبة 96% من الدقة في تشخيص مرض سرطان الثدي.

وفي نفس العام 2022 تم نشر ورقة بحثية [7] هدفت إلى دراسة للتصنيف الثنائي والمتعدد لآفات سرطان الثدي باستخدام عدة شبكات عصبية عميقة ونقل التعلم إلى BreakHis حيث استخدمت قاعدة البيانات الصورية (BreakHis) ولغة Python لبرمجة النموذج وكان من أبرز نتائجها أنه تم الوصول إلى دقة بنسبة 99.7% و 97.66% و 96.94% لكل من ResNet و InceptionV3Net و ShuffleNet ، على التوالي عند التصنيف الثنائي لآفات سرطان الثدي، ودقة بنسبة 97.81% ، 96.07% ، 95.79% لكل من ResNet و Inception-V3Net و ShuffleNet على التوالي عند التصنيف المتعدد لآفات سرطان الثدي.

سبق هذه الدراسات عام 2021، ورقة بحثية [8] هدفت إلى دراسة فاعلية العديد من خوارزميات التعلم الآلي في تشخيص سرطان الثدي وقد استخدمت قاعدة البيانات ويسكنسون لتشخيص سرطان الثدي (WBCD) في عملية الدراسة وبناء نموذج التصنيفي

باستخدام لغة Python وقد خلصت الورقة البحثية إلى أن خوارزمية SVM حققت دقة أعلى في تشخيص سرطان الثدي مقارنة بالخوارزميات الأخرى التي تمت دراستها في الورقة حيث حققت دقة وصلت إلى نسبة 97.2%

تم في هذا البحث تشخيص الأورام الخبيثة والحميدة لمرضى سرطان الثدي من خلال تدريب النموذج بالاعتماد على البيانات السابقة للتدريب بحيث يتمكن النموذج من التنبؤ ببيانات الإدخال الجديدة وذلك باستخدام كل من خوارزميتي التعلم الآلي الخاضعة للإشراف الجار الأقرب والانحدار اللوجستي، حيث تم المقارنة بين فاعلية كل من هذه الخوارزميتين في تصنيف مرضى سرطان الثدي، تلى ذلك مقارنة نتائج الخوارزميتين مع خوارزميات أخرى تم تطبيقها سابقاً على نفس قاعدة البيانات المستخدمة.

## 2. هدف البحث وأهميته:

دراسة فعالية خوارزميتي التعلم الآلي الخاضعة للإشراف الجار الأقرب والانحدار اللوجستي من خلال دراسة عدة حالات تستخدم العديد من سمات المرضى بحيث يتم الكشف المبكر عن سرطان الثدي والحصول على دقة عالية في اكتشاف الأورام الحميدة والخبيثة.

## 3. طرائق البحث ومواده:

تم استخدام قاعدة بيانات تشخيص سرطان الثدي ولاية ويسكونسن Wisconsin Breast Cancer Database (WBCD) [9] ضمن البحث مع 11 عمود تمثل السمات وهي ['ID', 'Clump', 'UnifSize', 'UnifShape', 'MargAdh', 'SingEpiSize', 'BareNuc', 'BlandChrom', 'NormNucl', 'Mit', 'Class'] وقد تم توضيحها ضمن الجدول (1):

دراسة فعالية كل من خوارزميتي الجار الأقرب والانحدار اللوجستي في تصنيف الأورام الحميدة والخبيثة لمرضى سرطان الثدي باختلاف السمات المدروسة

الجدول (1): السمات التي تتضمنها قاعدة البيانات WBCD

رقم السمة	اسم السمة	المجال	وصف السمات
1	رقم معرف المريض	----	رقم خاص لكل مريض
2	سمك الكتلة	1-10	غالباً ما تشكل الخلايا الحميدة طبقات أحادية، في حين أن الخلايا الخبيثة غالباً ما تشكل طبقات متعددة.
3	انتظام حجم الخلية	1-10	تختلف الخلايا السرطانية في الحجم.
4	انتظام شكل الخلية	1-10	تختلف الخلايا السرطانية في الشكل.
5	التصاق هامشي	1-10	فقدان الالتصاق مؤشر على الإصابة بالسرطان.
6	حجم الخلية الظهارية المنفردة	1-10	قد تكون الخلايا الظهارية الموسعة بشكل كبير خلايا سرطانية.
7	النوى العارية	1-10	شائعة في الأورام الحميدة.
8	الكروماتين اللطيف	1-10	في الخلايا الحميدة تمتلك النواة نسيجاً متجانساً
9	النوى الطبيعية	1-10	في الخلايا الطبيعية تكون النواة صغيرة جداً عامةً بينما تنمو بشكل أكثر وضوحاً في الخلايا السرطانية.
10	الانقسام الخيطي للخلية	1-10	
11	الصف 4،2	2 أو 4	الصف المتوقع (2 للحميد، 4 للورم الخبيث).

والتي تصف الكتلة المدروسة وخلاياها مع رقم التعريف الشخصي الخاص بالمريض، بالإضافة إلى 699 صف تمثل بيانات المرضى، وقد تم استخدام خوارزميتي الجار الأقرب والانحدار اللوجستي وبرمجتها ضمن بيئة عمل Spider بلغة البايثون.

### 1.3 خوارزمية الجار الأقرب (k-Nearest Neighbor (kNN):

تعد خوارزمية الجار الأقرب من خوارزميات التعلم الآلي الخاضعة للإشراف وهي إحدى الخوارزميات المهمة في التصنيف والتنبؤ، تعتمد على مفهوم التبعية المكانية [10]، أي يعتمد مبدأ عملها على مقارنة النقاط التي تنتمي إلى أصناف مختلفة مع النقطة المراد

النتيئة بتصنيفها وتقدير قيمة هذه النقطة بناء على معلومات النقاط القريبة منها (جيرانها) [11,12]. ومن الأساليب التي يتم استخدامها لتطوير فعالية خوارزمية الجار الأقرب هو زيادة عدد النقاط المجاورة للنقطة المراد تصنيفها. لذلك يفضل التنبؤ بالنقطة المطلوبة تبعاً لجميع النقاط في فضاء البحث وليس أقرب جار للنقطة المطلوبة فقط، وكذلك يتم استخدام خطط التحويل ومخططات الترجيح وخطط الرفض لتحسين الخوارزمية [13]

### 1.1.3 خطوات عمل خوارزمية الجار الأقرب [2,14,15] :

تم توضيح عمل الخوارزمية ضمن المخطط (1) حيث تمثلت بالخطوات التالية:

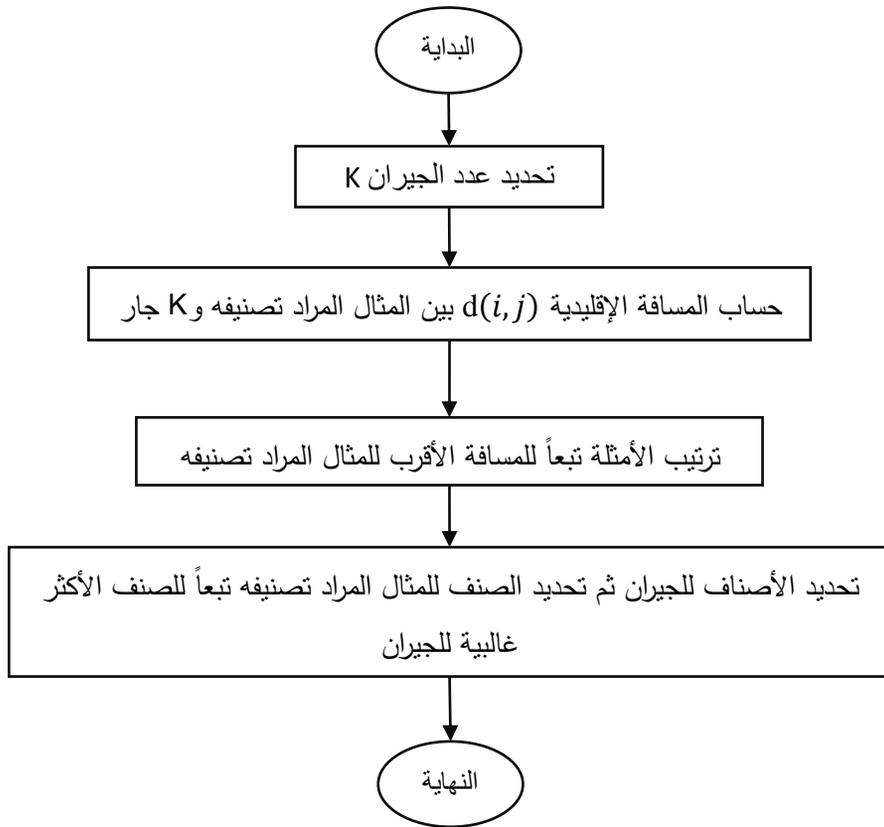
- تحديد قيمة عدد المجاورين والذي يتم تحديده من خلال المتغير  $K$ .
- حساب قيمة المسافة بين المثال المراد التنبؤ بتصنيفه والجيران الموجودة في فضاء البحث ويتم ذلك من خلال معادلة المسافة الإقليدية التالية:

$$d(i, j) = \sqrt{|x_i - x_j|^2} \quad (1)$$

حيث أن  $d$  هي المسافة الإقليدية بين نقطتين.

و  $x_i, x_j$  هي نقاط البيانات الموجودة في فضاء البحث.

- ترتيب الأمثلة بحيث يتم الحصول على المجاورين اعتماداً على المسافة الأقل التي تم حسابها في الخطوة السابقة علماً أنه تم اختيار  $K$  مجاور.
- تحديد الأصناف للجيران ثم يتم تحديد تصنيف المثال الجديد تبعاً للصنف الأكثر غالبية بالاستناد إلى مسافة حد أدنى  $K$ -th للأمتلة المجاورة.



المخطط (1): مخطط تدفقي يوضح خطوات عمل خوارزمية الجار الأقرب

### 2.3 خوارزمية الانحدار اللوجستي Logistic Regression:

تعتبر إحدى الخوارزميات المهمة في مجال الذكاء الصناعي حيث تعتبر من خوارزميات التعلم الآلي الخاضعة للإشراف لأنها تقوم بتصنيف البيانات الجديدة تبعاً لتدريبها على مجموعة من بيانات الإدخال والإخراج الموجودة في قاعدة البيانات، وهي عبارة عن طريقة إحصائية لتوقع نتيجة ثنائية (مثل نعم أو لا) بناءً على تحليل المعلومات السابقة

لمجموعة البيانات حيث يتنبأ نموذج الانحدار اللوجستي بمتغير بيانات تابع يكون تصنيفياً Categorical أو ترتيبياً Ordinal من خلال تحليل العلاقة بين واحد أو أكثر من المتغيرات المستقلة الموجودة وفق تقدير احتمال وقوع أو عدم وقوع حدث معين باستخدام منحى لوجستي [16,17].

### 1.2.3 الافتراضات الرئيسية للانحدار اللوجستي [18]:

- يجب أن تكون العلاقة بين المتغيرات والنتيجة مرتبطة خطياً.
- يجب أن تكون المتغيرات مستقلة وتمثل ظواهر غير مكررة.
- يتطلب الانحدار اللوجستي حجم كبير للعينات.
- يمكن تمثيل كل متغير باستخدام فئات ثنائية مثل مريض/معافى، ذكر/أنثى.

### 2.2.3 مجالات استخدام خوارزمية الانحدار اللوجستي:

يستخدم الانحدار اللوجستي للتنبؤ باحتمالات حدث ما يكون في وضع خطر، حيث أنه من الشائع استخدامه في المجالات الطبية والصحية بهدف التنبؤ بعوامل قابلية الإصابة بمرض ما وإمكانية الإصابة وتحديد عوامل الخطر [19]. كما يستخدم في الدراسات التي يكون الهدف منها التنبؤ بقيم متغيرات كيفية وشرحها حيث يمكن اعتباره من أكثر الأساليب الإحصائية الملائمة للاستخدام عندما يكون المتغير كيفياً أثناء بناء النموذج التنبؤي [20].

وكذلك يستخدم في الإعلان عبر الانترنت مما يتيح للمسوقين توقع احتمالية نقر المستخدم فوق إعلان معين على موقع معين، وبشاع توظيفه في العلوم الاجتماعية والطبية، ويستخدم في تطبيقات التنبؤ بالطقس، وفي الاستطلاعات السياسية، وفي مجال التأمين والخدمات المصرفية والعديد من المجالات الأخرى [18].

### 3.2.3 أنواع الانحدار اللوجستي:

يوجد ثلاثة أنواع للانحدار اللوجستي وفقاً لنتائج المتغير التابع [2,17,21]:

- الانحدار اللوجستي الثنائي: يعتبر من الانحدارات اللوجستية الأكثر شيوعاً حيث يستخدم في تحليل وتفسير أثر مجموعة متغيرات مستقلة على متغير تابع يكون ثنائي مثل (نعم/لا، مريض/معافى...) حيث تكون القيم الناتجة إما تأخذ القيمة 0 (غير موجودة)<sup>(2)</sup> أو تأخذ القيمة 1 (موجودة) وتعطى معادلة الانحدار اللوجستي الثنائي من العلاقة:

$$Y = b_0 + b_1X_1 + b_2X_2 + \dots + b_nX_n$$

حيث Y: المتغير الثنائي التابع.

b<sub>0</sub>: الحد الثابت.

b<sub>n</sub>X<sub>n</sub>: قيمة اللوجيت للمتغيرات المستقلة.

- الانحدار اللوجستي متعدد الحدود: يعد امتداداً للانحدار اللوجستي الثنائي ويستخدم عندما يكون المتغير التابع ينتمي إلى أكثر من تسميتين أو صنفين على سبيل المثال يمكن استخدامه في التنبؤ بما إذا كانت أسعار المنازل سترتفع بنسبة 25% أو 50% أو 75% أو 100% بالاعتماد على بيانات السكان.
- الانحدار اللوجستي الترتيبي: هو نوع خاص من الانحدار اللوجستي المتعدد يستخدم لتفسير أثر المتغيرات المستقلة على الاستجابات الترتيبية أي أن المتغير التابع يكون متغير ترتيبياً، مثلاً يمكن استخدامه لتصنيف خدمة معينة على أنها جيدة أو سيئة أو ممتازة بناءً على عدد العناصر التي يشتريها العملاء على مدار العام.

#### 4. المناقشة وتحليل النتائج:

تم في هذا القسم تطبيق مجموعة البيانات WDBC باستخدام كل من مصنف الجار الأقرب ومصنف الانحدار اللوجستي وفق ثلاث حالات وهي:

- استخدام جميع السمات المدروسة مع تضمين رقم التعريف الخاص بالمريض.
- استخدام جميع السمات المدروسة باستثناء تضمين رقم التعريف الخاص بالمريض.
- استخدام السمات ('Clump', 'BareNuc', 'BlandChrom', 'Mit').

تم عرض نتائج كل حالة على حدى لكل مصنف من المصنفين المذكورين، ومقارنة نتائجها ضمن جدول ومخططات خاصة بكل حالة.

**الحالة 1: استخدام جميع السمات المدروسة مع تضمين رقم التعريف الخاص بالمريض:**

#### 1- تطبيق مصنف الجار الأقرب:

يبين الجدول (2) نتائج تطبيق مصنف الجار الأقرب باستخدام السمات المدروسة مع تضمين رقم التعريف الخاص بالمريض وذلك وفق قاعدة البيانات المدروسة.

الجدول (2): النسب الناتجة عن تطبيق مصنف الجار الأقرب باستخدام جميع السمات المدروسة مع تضمين ID المريض

الدعم (support)	الدرجة (F1-score)	الاستدعاء (recall)	التوقع (precision)	
88	0.69	0.74	0.65	حالة حميدة
52	0.37	0.33	0.42	حالة خبيثة
140	0.59	-	-	الدقة (Accuracy)
140	0.53	0.53	0.54	متوسط الماكرو (Macro avg)
140	0.57	0.59	0.57	متوسط الوزن (W. avg)

## 2- تطبيق مصنف الانحدار اللوجستي:

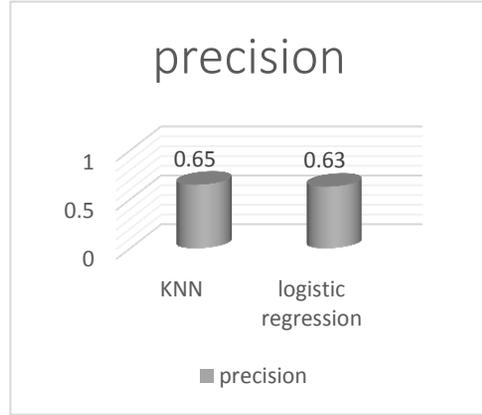
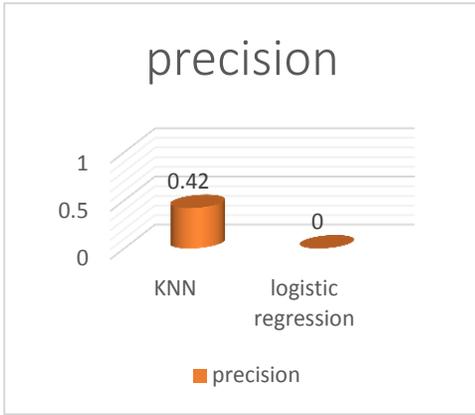
يبين الجدول (3) نتائج تطبيق مصنف الانحدار اللوجستي باستخدام جميع السمات المدروسة مع تضمين رقم التعريف الخاص بالمريض وذلك وفق قاعدة البيانات المدروسة.

الجدول (3): النسب الناتجة عن تطبيق مصنف الانحدار اللوجستي باستخدام السمات المدروسة مع تضمين ID المريض

الدعم (support)	الدرجة (F1-) (score)	الاستدعاء (recall)	التوقع (precision)	
88	0.77	1.00	0.63	حالة حميدة
52	0.00	0.00	0.00	حالة خبيثة
140	0.63	-	-	الدقة (Accuracy)
140	0.39	0.50	0.31	متوسط الماكرو (Macro avg)
140	0.49	0.63	0.40	متوسط الوزن (W. avg)

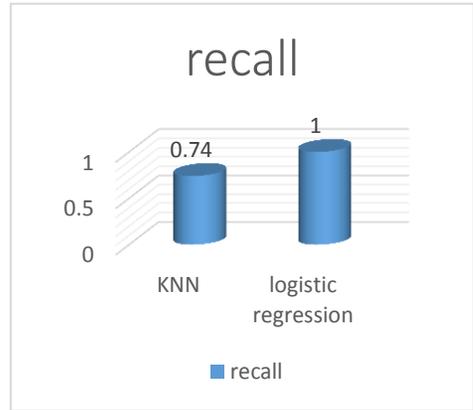
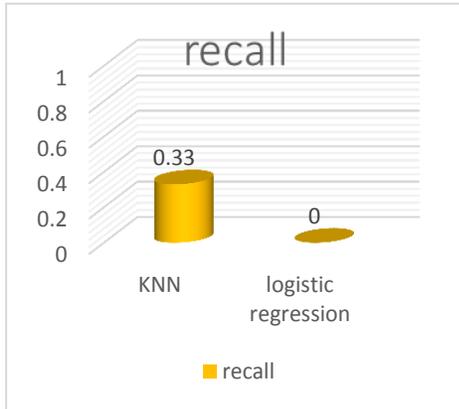
بمقارنة نتائج الخوارزميتين يتضح أنه عند استخدام جميع السمات مع سمة رقم تعريف المريض وفي حالة الصنف الحميد بأن مصنف الجار الأقرب يعمل بشكل أفضل بالنسبة لقيمة precision مساوية 65% بالمقارنة مع 63% لمصنف الانحدار اللوجستي، وفي حالة الصنف الخبيث يعمل مصنف الجار الأقرب بشكل أفضل بالنسبة لقيمة precision مساوية 42% بالمقارنة مع 0% لمصنف الانحدار اللوجستي كما يوضح الشكل (1) والشكل (2) على التوالي، أما بالنسبة لقيمة recall ففي الصنف الحميد تحقق قيمة أفضل مساوية 100% باستخدام مصنف الانحدار اللوجستي وفي حالة الصنف الخبيث تحقق قيمة أفضل مساوية 33% باستخدام مصنف الجار الأقرب كما يظهر كل من الشكلين (3) و(4) على التوالي. وبالنسبة لقيمة F1-score ففي الصنف

الحميد تحقق قيمة أفضل مساوية 77% باستخدام مصنف الانحدار اللوجستي وفي حالة الصنف الخبيث تحقق قيمة أفضل مساوية 37% باستخدام مصنف الجار الأقرب كما يظهر كل من الشكلين (5) و(6) على التوالي. وبالنسبة لقيمة Accuracy فتحقق قيمة أفضل مساوية 63% باستخدام مصنف الانحدار اللوجستي مقارنة مع قيمة 59% باستخدام مصنف الجار الأقرب كما يظهر الشكل (7).



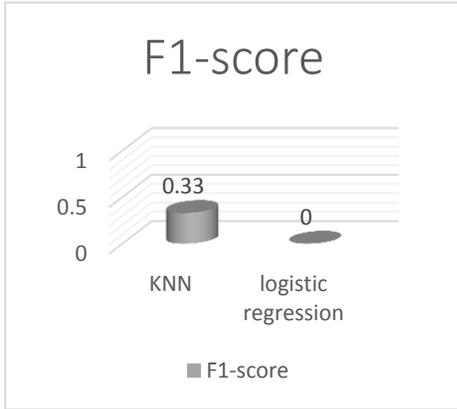
الشكل (2): precision للمصنف الخبيث مع الـ ID الخاص بالمريض

الشكل (1): precision للمصنف الحميد مع الـ ID الخاص بالمريض

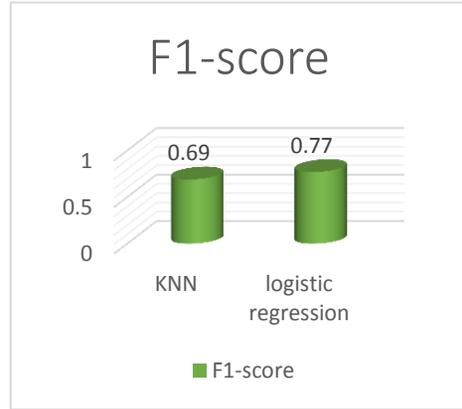


الشكل (4): recall للمصنف الخبيث مع الـ ID الخاص بالمريض

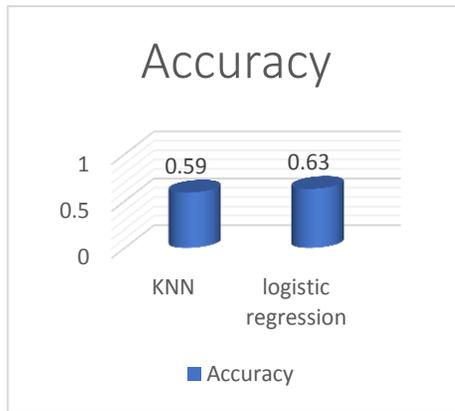
الشكل (3): recall للمصنف الحميد مع الـ ID الخاص بالمريض



الشكل (6): F1-score للصنف الخبيث مع ال-ID الخاص بالمرضى

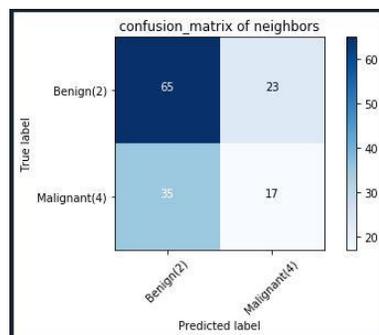
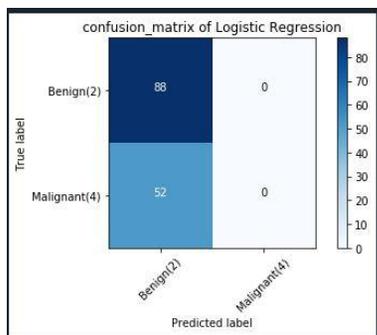


الشكل (5): F1-score للصنف الحميد مع ال-ID الخاص بالمرضى



الشكل (7): دقة خوارزميات التصنيف مع ال-ID الخاص بالمرضى

كما يوضح الشكلين (8) و(9) مصفوفة الانحياز "الالتباس" عند استخدام كل من مصنف الجار الأقرب ومصنف الانحدار اللوجستي عندما تكون جميع السمات مع رقم التعريف الخاص بالمرضى مضمنة:



الشكل (9): مصفوفة الانحياز لمصنف الانحدار اللوجستي

الشكل (8): مصفوفة الانحياز لمصنف الجار الأقرب بالمرضى

الحالة 2: استخدام جميع السمات المدروسة باستثناء رقم التعريف الخاص بالمرضى:

### 1- تطبيق مصنف الجار الأقرب:

يبين الجدول (4) نتائج تطبيق مصنف الجار الأقرب باستخدام جميع السمات المدروسة باستثناء رقم التعريف الخاص بالمرضى وذلك وفق قاعدة البيانات المدروسة.

الجدول (4): النسب الناتجة عن تطبيق مصنف الجار الأقرب باستخدام جميع السمات المدروسة باستثناء ID المريض

الدعم (support)	الهدف F1- (score)	الاستدعاء (recall)	التوقع (precision)	
88	0.98	0.99	0.97	حالة حميدة
52	0.96	0.94	0.98	حالة خبيثة
140	0.97			الدقة (Accuracy)
140	0.97	0.97	0.97	متوسط الماكرو (Macro avg)
140	0.97	0.97	0.97	متوسط الوزن (W. avg)

دراسة فعالية كل من خوارزميتي الجار الأقرب والانحدار اللوجستي في تصنيف الأورام الحميدة والخبيثة لمرضى سرطان الثدي باختلاف السمات المدروسة

الجدول (5): النسب الناتجة عن تطبيق مصنف الانحدار اللوجستي باستخدام جميع السمات المدروسة باستثناء ID المريض

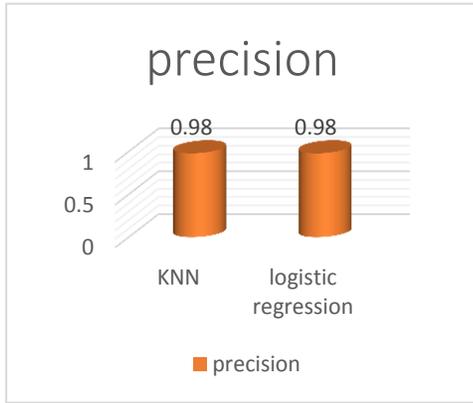
الدعم (support)	الهدف F1- (score)	الاستدعاء (recall)	التوقع (precision)	
88	0.97	0.99	0.96	حالة حميدة
52	0.95	0.92	0.98	حالة خبيثة
140	0.96			الدقة (Accuracy)
140	0.96	0.96	0.97	متوسط الماكرو (Macro avg)
140	0.96	0.96	0.96	متوسط الوزن (W. avg)

## 2- تطبيق مصنف الانحدار اللوجستي:

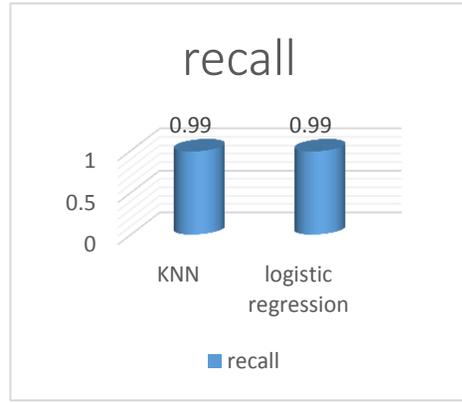
يبين الجدول (5) نتائج تطبيق مصنف الانحدار اللوجستي باستخدام جميع السمات المدروسة باستثناء رقم التعريف الخاص بالمريض وذلك وفق قاعدة البيانات المدروسة.

بمقارنة نتائج الخوارزميتين يتضح أنه عند استخدام جميع السمات باستثناء سمة رقم تعريف المريض وفي حالة الصنف الحميد بأن مصنف الجار الأقرب يعمل بشكل أفضل بالنسبة لقيمة precision مساوية 97% بالمقارنة مع 96% لمصنف الانحدار اللوجستي، وفي حالة الصنف الخبيث يحقق كل من المصنفين قيمة precision عالية مساوية 98% كما يوضح الشكل (10) والشكل (11) على التوالي، أما بالنسبة لقيمة recall ففي الصنف الحميد تحقق قيمة عالية مساوية 99% باستخدام كل من المصنفين وفي حالة الصنف الخبيث تحقق قيمة أفضل مساوية 94% باستخدام مصنف الجار

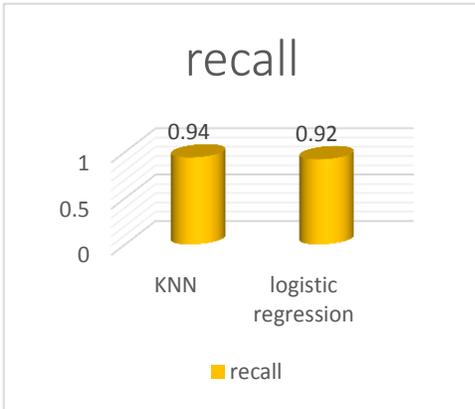
الأقرب كما يظهر كل من الشكلين (12) و(13) على التوالي. وبالنسبة لقيمة F1- score ففي الصنف الحميد تحقق قيمة أفضل مساوية 98% باستخدام مصنف الجار الأقرب وفي حالة الصنف الخبيث تحقق قيمة أفضل مساوية 96% باستخدام مصنف الجار الأقرب كما يظهر كل من الشكلين (14) و (15) على التوالي. وبالنسبة لقيمة Accuracy فتحقق قيمة أفضل مساوية 97% باستخدام مصنف الجار الأقرب مقارنة مع قيمة 96% باستخدام مصنف الانحدار اللوجستي كما يظهر الشكل (16).



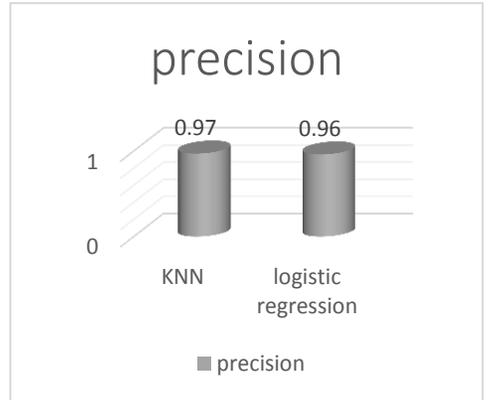
الشكل (11): precision للصنف الخبيث باستثناء الـ ID



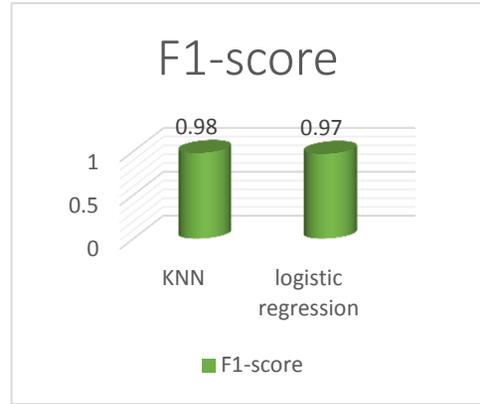
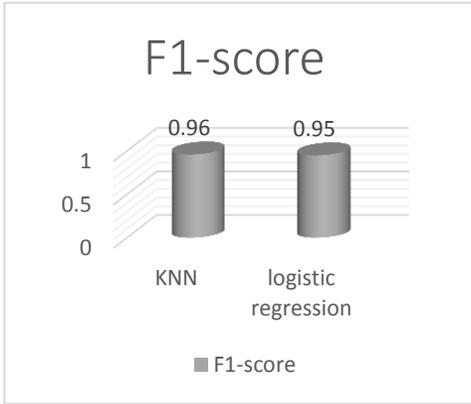
الشكل (10): precision للصنف الحميد باستثناء الـ ID



الشكل (13): recall للصنف الخبيث باستثناء الـ ID

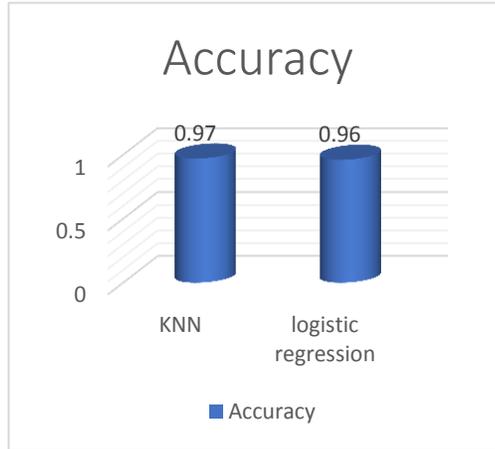


الشكل (12): recall للصنف الحميد باستثناء الـ ID



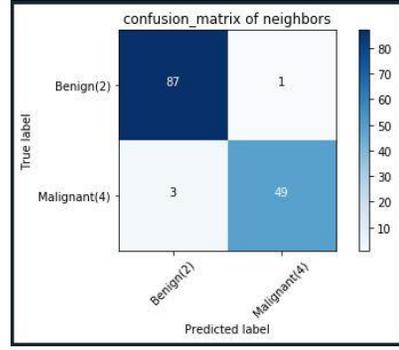
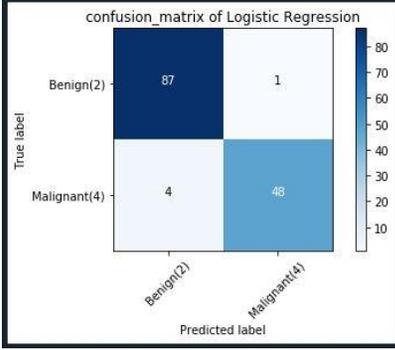
الشكل (15): F1-score للصنف الخبيث باستثناء الـ ID

الشكل (14): F1-score للصنف الحميد باستثناء الـ ID



الشكل (16): دقة خوارزميات التصنيف باستثناء الـ ID

كما يوضح الشكلين (17) و(18) مصفوفة الانحياز "الالتباس" عند استخدام كل من مصنف الجار الأقرب ومصنف الانحدار اللوجستي عندما تكون جميع السمات باستثناء رقم التعريف الخاص بالمرضى مضمنة:



الشكل (18): مصفوفة الانحياز لمصنف الانحدار اللوجستي

الشكل (17): مصفوفة الانحياز لمصنف الجار الأقرب

الحالة 3: استخدام السمات ('Clump', 'BareNuc', 'BlandChrom', 'Mit')

### 1- تطبيق مصنف الجار الأقرب:

يبين الجدول (6) نتائج تطبيق مصنف الجار الأقرب باستخدام السمات ('Clump', 'Mit', 'BareNuc', 'BlandChrom'), أرقامها (2,7,8,10) على التتالي ضمن الجدول (1)

الجدول (6): النسب الناتجة عن تطبيق مصنف الجار الأقرب باستخدام السمات رقم (2,7,8,10)

الدعم (support)	الهدف F1- (score)	الاستدعاء (recall)	التوقع (precision)	
88	0.98	0.98	0.98	حالة حميدة
52	0.96	0.96	0.96	حالة خبيثة
140	0.97			الدقة (Accuracy)
140	0.97	0.97	0.97	متوسط الماكرو (Macro avg)
140	0.97	0.97	0.97	متوسط الوزن (W avg)

## 2- تطبيق مصنف الانحدار اللوجستي:

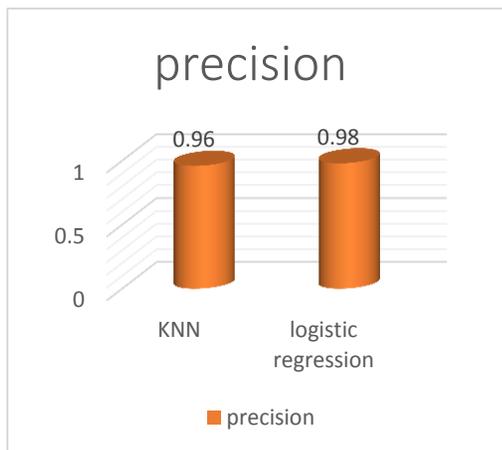
يبين الجدول (7) نتائج تطبيق مصنف الانحدار اللوجستي باستخدام السمات ('Clump', 'BareNuc', 'BlandChrom','Mit')

الجدول (7): النسب الناتجة عن تطبيق مصنف الانحدار اللوجستي باستخدام السمات رقم (2,7,8,10)

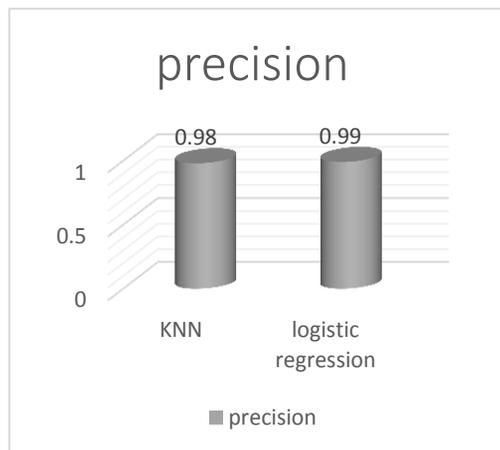
الدعم (support)	الهدف F1- (score)	الاستدعاء (recall)	التوقع (precision)	
88	0.99	0.99	0.99	حالة حميدة
52	0.98	0.98	0.98	حالة خبيثة
140	0.99			الدقة (Accuracy)
140	0.98	0.98	0.98	متوسط الماكرو (Macro avg)
140	0.99	0.99	0.99	متوسط الوزن (W. avg)

بمقارنة نتائج الخوارزميتين يتضح عند استخدام السمات ('Clump', 'BareNuc', 'BlandChrom', 'Mit') وفي حالتي الصنف الحميد والصنف الخبيث بأن مصنف الانحدار اللوجستي يعمل بشكل أفضل بالنسبة لقيمة precision مساوية 99% بالمقارنة مع 98% لمصنف الجار الأقرب كما يوضح الشكل (19) والشكل (20) على التوالي، وبالنسبة لقيمة recall يحقق مصنف الانحدار اللوجستي قيمة أفضل مساوية 99% للصنف الحميد و 98% للصنف الخبيث كما يظهر كل من الشكلين (21) و(22) على التوالي. وبالنسبة لقيمة F1-score يحقق مصنف الانحدار اللوجستي قيمة أفضل مساوية 99% للصنف الحميد و 98% للصنف الخبيث كما يظهر كل من الشكلين (23) و(24) على التوالي. وبالنسبة لقيمة Accuracy فيتم تحقيق قيمة أفضل مساوية 99%

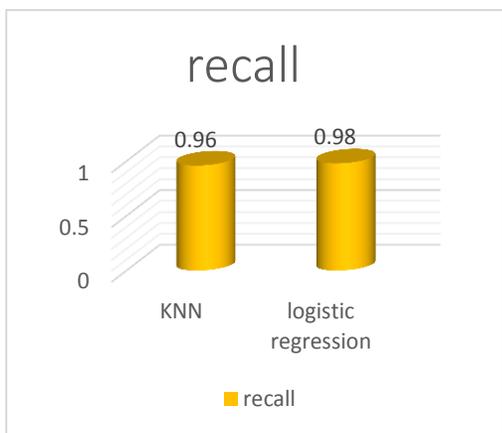
باستخدام مصنف الانحدار اللوجستي مقارنة مع قيمة 97% باستخدام مصنف الجار الأقرب كما يظهر الشكل (25).



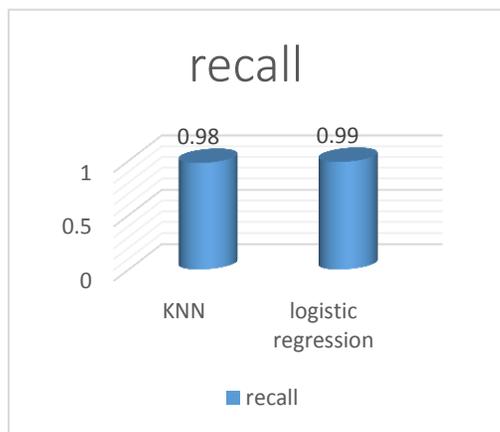
الشكل (20): precision للمصنف الخبيث مع تضمين السمات رقم (2,7,8,10)



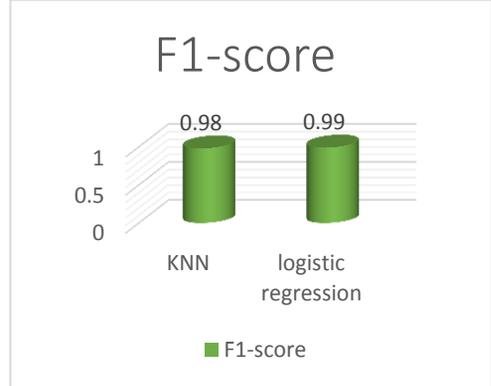
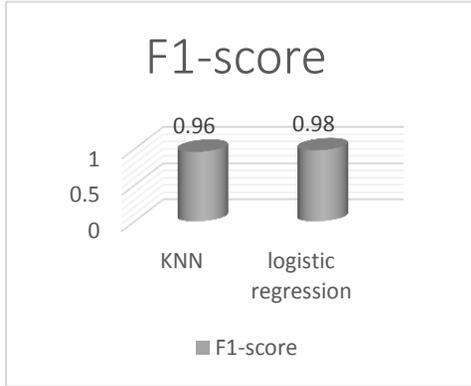
الشكل (19): precision للمصنف الحميد مع تضمين السمات رقم (2,7,8,10)



الشكل (22): recall للمصنف الخبيث مع تضمين السمات رقم (2,7,8,10)

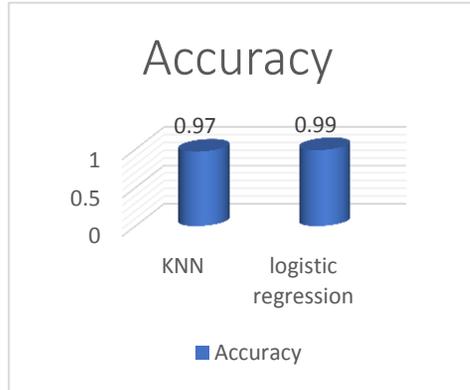


الشكل (21): recall للمصنف الحميد مع تضمين السمات رقم (2,7,8,10)



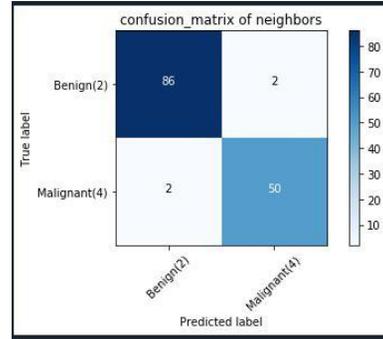
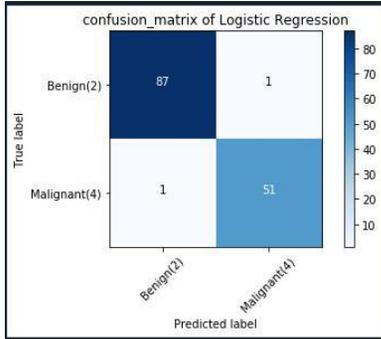
الشكل (24): F1-score للصف الخبيث مع تضمين السمات رقم (2,7,8,10)

الشكل (23): F1-score للصف الحميد مع تضمين السمات رقم (2,7,8,10)



الشكل (25): دقة خوارزميات التصنيف مع تضمين السمات رقم (2,7,8,10)

كما يوضح الشكلين (26) و (27) مصفوفة الانحياز "الالتباس" عند استخدام مصنف الجار الأقرب ومصنف الانحدار اللوجستي عندما تكون السمات التالية ('Clump', 'BareNuc', 'BlandChrom', 'Mit') مضمنة:



الشكل (27): مصفوفة الانحياز لمصنف الانحدار اللوجستي

الشكل (26): مصفوفة الانحياز لمصنف الجار الأقرب

## 5. التقييم ومقارنة النتائج:

سيتم في هذا القسم المقارنة بين خوارزميات الجار الأقرب KNN والانحدار اللوجستي Logistic Regression التي تمت دراستها في هذا البحث مع خوارزميات آلة المتجهات الدعمة ذات دالة الأساس الشعاعي RBF SVM وآلة المتجهات الدعمة الخطية Linear SVM و بايز الساذج Naïve Bayes وشجرة القرار Decision Tree المذكورة في المرجع [22,23]، حيث تم في هذه الدراسات استخدام نفس قاعدة البيانات WBCD والسّمات المدروسة ومناقشة النتائج، ويوضح الجدول (8) ما تم الوصول إليه من دقة لكل خوارزمية وفق عدة حالات:

دراسة فعالية كل من خوارزميتي الجار الأقرب والانحدار اللوجستي في تصنيف الأورام الحميدة والخبيثة لمرضى سرطان الثدي باختلاف السمات المدروسة

الجدول (8): جدول يوضح الدقة التي تم الوصول إليها في التصنيف من قبل كل خوارزمية وفق ثلاث حالات للسمات المستخدمة

Logistic Regression	KNN	Decision Tree	Naïve Bayes	Linear SVM	RBF SVM	
0.63	0.59	0.95	0.80	0.69	0.66	دقة النموذج عند استخدام جميع السمات مع ID
0.96	0.97	0.95	0.95	0.96	0.96	دقة النموذج عند استخدام جميع السمات باستثناء الـ ID
0.99	0.97	0.94	0.97	0.98	0.98	دقة النموذج عند استخدام السمات ذات الرقم ('2', '7', '8', '10')

نلاحظ من خلال المقارنة بين دقة جميع الخوارزميات المذكورة سابقاً أنه عند تضمين جميع السمات لتدريب المصنف على تصنيف الفئة لكل مريض (حميدة أو خبيثة)، بما في ذلك سمة رقم معرف المريض (سمة المعرف لا تحتوي على ارتباط بالمرض) أثر ذلك على تدريب المصنف وحصلنا على دقة أقل بالنسبة لأغلب الخوارزميات، حيث حصلنا على دقة 0.66 لخوارزمية RBF SVM و 0.69 لخوارزمية SVM الخطية و 0.80 لخوارزمية بايز الساذج و 0.59 لخوارزمية الجار الأقرب و 0.63 لخوارزمية الانحدار اللوجستي، أما بالنسبة لخوارزمية شجرة القرار فقد استطاعت أن تختار أفضل الميزات لتدريب المصنف باستخدام برنامج Python مع الأخذ بالاعتبار عمق الشجرة التي نحددها [هنا نحدد أقصى عمق للشجرة هو 3] لذلك نلاحظ أن الدقة عالية وهي 0.95، كما نلاحظ أنه عند استخدام كل السمات باستثناء سمة معرف المريض ستصبح

الدقة عالية لجميع الخوارزميات المستخدمة وهي 0.96 لخوارزمية SVM RBF و 0.96 لخوارزمية SVM الخطية و 0.95 لخوارزمية بايز الساذج و 0.95 لخوارزمية شجرة القرار و 0.97 لخوارزمية الجار الأقرب و 0.96 لخوارزمية الانحدار اللوجستي، وعند تدريب المصنف على سمات محددة "وفقاً للتجربة" وهي ('Clump', 'BareNuc', 'Mit', 'BlandChrom') تم الحصول على نتائج عالية الدقة، وهي 0.98 لخوارزمية SVM RBF و 0.98 لخوارزمية SVM الخطية و 0.97 لخوارزمية بايز الساذج و 0.94 لخوارزمية شجرة القرار و 0.97 لخوارزمية الجار الأقرب و 0.99 لخوارزمية الانحدار اللوجستي.

## 6. الاستنتاجات والتوصيات:

- بملاحظة نتائج الخوارزميتين في الحالتين الأولى والثانية نلاحظ أنه عند إدخال سمة رقم تعريف المريض (وهي السمة ليس لها علاقة بالمرض) في تدريب المصنفين تعجز كل من الخوارزميتين عن تحييد هذه السمة عن النتائج وبالتالي عدم تحقيق دقة عالية في تشخيص مرضى سرطان الثدي، فقد حققت خوارزمية الجار الأقرب دقة 59% وخوارزمية الانحدار اللوجستي دقة 63% عند استخدام هذه السمة مع بقية السمات، أما عند استخدام جميع السمات ماعدا رقم التعريف الخاص بالمريض في تدريب الخوارزميتين ترتفع الدقة وتصبح 97% لخوارزمية الجار الأقرب و 96% لخوارزمية الانحدار اللوجستي، أي ان الخوارزميتين عجزتا عن تحييد سمة غير مرتبطة بالمرض مما أثر بنسبة كبيرة على دقة نتاجهما مما يعني أن عملية تحديد السمات المستخدمة يجب أن يكون دقيقاً بحيث تكون هذه السمات مرتبطة بالمرض وأن أي سمة يتم استخدامها

دون معرفة مدى علاقتها بالمرض ستؤثر على عمل الخوارزمية لعجز الخوارزمية عن عزلها.

- بالإضافة إلى أنه عند التجربة نلاحظ أنه عند تقليل عدد السمات واستخدام السمات التالية ('Clump', 'BareNuc', 'BlandChrom', 'Mit') كانت الدقة عالية حيث وصلت إلى 97% لخوارزمية الجار الأقرب و 99% لخوارزمية الانحدار اللوجستي.
- كما تشير النتائج إلى فاعلية الخوارزميتين في التنبؤ بالأورام الحميدة والخبيثة لسرطان الثدي عند استخدام السمات المتعلقة بالمرض، حيث أنه عند المقارنة بين الخوارزميات التالية RBF SVM و Linear SVM و Naïve Bayes و Decision Tree و KNN و Logistic Regression تم ملاحظة تفوق خوارزمية KNN بدقة 97% عند استخدام جميع السمات ماعدا رقم معرف المريض، وتفوق خوارزمية Logistic Regression بدقة 99% عند استخدام السمات ('Clump', 'BareNuc', 'BlandChrom', 'Mit')
- سيتم في العمل المستقبلي تجربة سمات مختلفة في التدريب ودراسة تأثيرها على فاعلية الخوارزميتين كما سيتم العمل على قاعدة بيانات مختلفة ومقارنة النتائج.

## References:

- [1] <https://www.who.int/data/gho/publications>
- [2] BOTLAGUNTA, M., BOTLAGUNTA, M.D., MYNENI, M.B., LAKSHMI, D., NAYYAR, A., GULLAPALLI, J.S. and SHAH, M.A. 2023- Classification and diagnostic prediction of breast cancer metastasis on clinical data using machine learning algorithms. Scientific Reports, 13(1), p.485.
- [3] KADHIM, RANIA R., and MOHAMMED Y. KAMILL. 2023- "Comparison of machine learning models for breast cancer diagnosis." IAES International Journal of Artificial Intelligence 12, no. 1: 415.
- [4] GUPTA, N. and KAUSHIK, B.N 2023- Prognosis and prediction of breast cancer using machine learning and ensemble-based training model. The Computer Journal, 66(1). pp.70-85.
- [5] EI MASSARI, H., GHERABI, N., MHAMMEDI, S., SABOURI, Z., GHANDI, H., & QANOUNI, F. (2023). Effectiveness of applying Machine Learning techniques and Ontologies in Breast Cancer detection. Procedia Computer Science, 218, 2392-2400.
- [6] SHANTHI, D. (2022). Early-stage breast cancer detection using ensemble approach of random forest classifier algorithm. Oncology and Radiotherapy, 16 (4).
- [7] ALJUAID, H., ALTURKI, N., ALSUBAIE, N., CAVALLARO, L. and LIOTTA, A., 2022. Computer-aided diagnosis for breast cancer classification using deep neural networks and transfer learning. Computer Methods and Programs in Biomedicine, 223, p.106951.

[8] NAJI, M.A., EI FILALI, S., AARIKA, K., BENLAHMAR, E.H., ABDELOUHAHID, R.A. and DEBAUCHE, O., 2021. Machine learning algorithms for breast cancer prediction and diagnosis. Procedia Computer Science, 191, pp.487-492.

[9] <https://www.kaggle.com/datasets/uciml/breast-cancer-wisconsin-data>

[10] OYANA T. J 2020- Spatial Analysis with R: Statistics, Visualization, and Computational Methods. CRC press, (2020).

[11] الطائي ، فاضل عباس ، هرمز ، ساندي يوسف ، 2011، التنبؤ بالسلسلة الزمنية باستخدام طريقة الجار الأقرب المصنوب مع التطبيق، المجلة العراقية للعلوم الإحصائية، 11(19) ، 181-196.

[11] AL-TAEH, F, A. HURMOZ, Y, H. 2011, Prediction for time series by using fuzzy nearest neighbor method with application, Iraqi Journal of Statistical Sciences, 11(19), 181-196

[12] IMANDOUST, S.B. and BOLANDRAFTER, M, 2013, Application of k-nearest neighbor (knn) approach for predicting economic events: Theoretical background. International journal of engineering research and applications. 3(5), pp.605-610.

[13] PETERSON, L.E, 2009- K-nearest neighbor. Scholarpedia, 4(2), p.1883.

[14] DAWOD, A, S. MOHAMMED K, A. 2012- Development of important patterns in student database using statistical classifier, Anbar University Journal of Economic and Administrative Sciences, 4(9), 425-452.

[15] الفخري، نعمه عبد الله، الفارس، جاسم ، 2018- استخدام خوارزمية الجار الأقرب (kNN) في تحديد العوامل المؤثرة على خط الفقر الوطني، مجلة جامعة كركوك للعلوم الإدارية والاقتصادية، (2)8 ، 573-589.

[15] AL-FAKHRY A. N., Al-FARIS, J. Using K-nearest neighbor (Knn) to determine influencing factors on the national poverty line, Kirkuk University Journal of Administrative and Economic Sciences, 2018, 8(2), 573-589.

[16] PARK, H.A., 2013- An introduction to logistic regression: from basic concepts to interpretation with particular attention to nursing domain. Journal of Korean Academy of Nursing, 43(2), pp.154-164.

[17] MAROOF, D.A. Statistical methods in neuropsychology: Common procedures made comprehensible. New York, 107.

[18] دعيش، محمد أمين ، ساري، محمد ، 2017- نموذج الانحدار اللوجستي: مفهومه، خصائصه، تطبيقاته "مع مثال تطبيقي للانحدار اللوجستي ثنائي الحدين على برنامج spss" ، مجلة السراج في التربية وقضايا المجتمع، (1)، 124-133.

[18] DAESH A, M, SARI, M,. Logistic Regression Model: Concept, characteristics, applications "With an example of a binary logistic regression in SPSS", Al-Sarraj Journal of Education and Community Issues, 2017, (1), 124-133.

[19] RAKOTOMALALA, R. Pratique 2015 de la Régression Logistique Régression Logistique Binaire et Polytomique, Université Lumière Lyon, 2, P3.

[20] CLEOPHAS, T.J., ZWINDERMAN, A.H. 2013- Logistic regression for health profiling. Machine Learning in Medicine, pp.17-24.

[21] BAYAGA, A 2010- Multinomial Logistic Regression: Usage and Application in Risk Analysis. Journal of applied quantitative methods., Jun 30;5(2).

[22] JENA, L., AMMOUN, L. and PATRA, B., 2022. Machine Learning Model for Breast Cancer Tumor Risk Prediction. In Intelligent and Cloud Computing: Proceedings of ICICC 2021 (pp. 517-531). Singapore: Springer Nature Singapore.

[23] JENA, L., AMMOUN, L. and CHITHALURU, P., 2022. Supervised intelligent clinical approach for breast cancer tumor categorization. In Augmented Intelligence in Healthcare: A Pragmatic and Integrated Analysis (pp. 15-40). Singapore: Springer Nature Singapore.

# دراسة ومحاكاة تقنيات تخمين القناة في نظام Massive MIMO وتحسينها باستخدام التخمين شبه الأعمى القائم على الفضاء الجزئي في أنظمة (5G)

الباحثة: م. ليليان صليبي

كلية الهمةك - جامعة البعث

## الملخص

يقدم البحث طريقة لدراسة ومحاكاة تقنيات تخمين القناة في نظام Massive MIMO، باستخدام برنامج MATLAB حيث دُرست تغيرات الخطأ المتوسط التريعي MSE مقابل تغير نسبة الإشارة إلى الضجيج مع تشكيلات مختلفة للهوائيات ووجدنا أن MSE ينخفض مع ازدياد عدد الهوائيات في محطة القاعدة.

ثم تم دراسة تأثير الترابط المكاني وتلوث الرموز الدليلية على تخمين القناة ولوحظ أنه إذا كانت أجهزة المستخدم لها نفس الزاوية، تكون التخمينات متطابقة ويحدث التداخل. وأن تلوث الرموز الدليلية له تأثير بسيط على جودة التخمين عندما يكون لتجهيزات المستخدمين مسافات ارتباط متعامدة تقريباً.

وقدم البحث مقارنة للأداء بين مخططات تخمين القناة المختلفة من ناحية الأداء والتعقيد الحسابي وقد ظهر مخطط EW-MMSE بأنه يجمع بين الأداء الجيد والتعقيد الحسابي المنخفض. ومن أجل المزيد من تحسين الأداء وتقليل التعقيد الحسابي تمت دراسة ومحاكاة تقنيات تخمين القناة من النوع شبه الأعمى، وتم إيجاد أيضاً أن المخمن شبه الأعمى المستند إلى الفضاء الجزئي يقدم أداءً يتفوق بشكل كبير على تقنيات التخمين التقليدية المستندة إلى الرموز الدليلية من حيث تقليل MSE.

**كلمات مفتاحية:** الرموز الدليلية، الهوائيات المتعددة الكثيفة، التخمين شبه الأعمى،

الفضاء الجزئي، الجيل الخامس، MATLAB

## Studying and Simulating Channel Estimation Techniques in Massive MIMO System and Improving it Using Semi-blind Subspace-based Estimation in (5G) Systems

### Summary

The research presents a method to study and analyze, the channel estimation techniques were studied and simulated in the Massive MIMO system using MATLAB program, where the MSE changes were studied against the signal-to-noise ratio changes with different antenna configurations, and we found that the MSE decreases with the increase in the number of antennas in the base station. We then investigated the effect of spatial correlation and pilot contamination on channel estimation and found that if user devices have the same angle, the estimations are identical and interference occurs. and that the pilot contamination has little effect on the quality of the estimation when the users' equipment has nearly orthogonal link distances.

A study was conducted to compare the performance between different channel estimation schemes in terms of performance and computational complexity, and the EW-MMSE scheme appeared as a scheme that combines good performance with low computational complexity. In order to further improve the performance and reduce the computational complexity, Semi-blind channel estimation techniques were studied and simulated. We also found that the semi-blind subspace-based estimator significantly outperforms the traditional estimation techniques based on leading symbols in terms of MSE reduction.

**Keywords:** Pilots, Massive MIMO, Semi-blind estimation, Subspace, 5G, MATLAB.

## 1- مقدمة

تتطلب الخدمات المترابطة بشبكات الاتصالات اللاسلكية الحديثة مثل الفيديو والإنترنت أن يتم نقل المعطيات بسرعة عالية ومن ثمّ هناك حاجة إلى إيجاد تقنيات تلبي المطلوب، ومن أبرز هذه التقنيات أن يدعم كل من المرسل والمستقبل بالعديد من الهوائيات. ونظراً إلى المزايا التي تحملها هذه الهوائيات كالتخلص من تأثيرات خفوت تعدد المسارات وإنجاز معدلات نقل عالية موثوق بها عبر قناة لاسلكية عريضة الحزمة، تم اعتماد نظام Massive MIMO كواجهة اتصال جذابة للعديد من أنظمة اتصالات اللاسلكية في الجيل الخامس 5G من أنظمة الاتصالات الخلوية والشبكات اللاسلكية المحلية [11].

تؤثر خصائص القناة في الإشارة المستقبلية ولإستعادة البتات المرسلة، يجب تخمين تأثير القناة وتعويضها عند المستقبل. يمكن اعتبار كل حامل فرعي قناة مستقلة طالما لم يحدث أي تدخل ما بين الحوامل (Inter-Carrier Interference (ICI)، ومن ثم الحفاظ على التعامد بين الحوامل الفرعية. يسمح التعامد في التعبير عن كل حامل فرعي للإشارة المستقبلية بحاصل ضرب الإشارة المرسلة مع الاستجابة الترددية للقناة عند الحامل الفرعي. ومن ثم يمكن استعادة الإشارة المرسلة بتخمين استجابة القناة في كل موجة حاملة فرعية فقط [8].

يمكن تخمين القناة عموماً باستخدام التمهيدي preamble أو الرموز الدليلية pilot (التجريبية) المعروفة لكل من المرسل والمستقبل، والتي تستخدم تقنيات الاستيفاء interpolation المختلفة لتخمين استجابة القناة للحاملات الفرعية بين السلاسل الدليلية. بشكل عام يمكن استخدام إشارة البيانات وكذلك إشارة التجريب، أو كليهما، لتخمين القناة. تعدّ الطريقتان نصف العمياء (Semi-blind) والعمياء (Blind) بديلين لتخمين القناة القائم على الرموز الدليلية والتي تقوم بتخمين القناة بسلاسل إشارات تجريبية قصيرة

بالنسبة للطريقة شبه العمياء ومن دون سلاسل إشارة تجريبية بالنسبة للطريقة العمياء مما يحسن من أداء النظام.

لاختيار أسلوب تخمين القناة للنظام، يجب أن تؤخذ في الاعتبار العديد من الجوانب المختلفة للتطبيقات، بما في ذلك الأداء المطلوب والتعقيد الحسابي والتغيير الزمني في القناة [10].

## 2-هدف البحث

يهدف البحث إلى عدد من النقاط الهامة وهي:

1. دراسة أداء تقنيات تخمين القناة (LS,MMSE) المستخدمة مع نظام التجميع بالتقسيم الترددي المتعامد OFDM المعتمدة على الرموز الدليلية.
2. دراسة ومحاكاة أداء تقنيات تخمين القناة (LS,MMSE,EW-MMSE) والعوامل المؤثرة على جودة التخمين في أنظمة Massive MIMO المستخدمة في أنظمة الجيل الخامس (5G).
3. دراسة ومحاكاة تقنية التخمين شبه الأعمى (subspace-based semi-blind) واقتراح خوارزمية لتحسين التخمين في أنظمة Massive MIMO باستخدام هذه التقنية.

وقد تمت المحاكاة باستخدام برنامج MATLAB.

## 3-آلية إجراء البحث

في البداية تمت دراسة مقدمة نظرية عن تخمين القناة المعتمد على الرمز التجريبية باستخدام سلاسل الرموز الدليلية والدراسة الرياضية لتقنيتي تخمين الأقل تريغ LS

وطريقة الحد الأدنى لمتوسط مربع الخطأ MMSE وذلك من أجل عدد  $K$  من الحوامل الفرعية في نظام تجميع بالتقسيم الترددي المتعامد OFDM.

تم بعد ذلك دراسة ومحاكاة تقنيات تخمين القناة في نظام Massive MIMO باستخدام برنامج MATLAB وذلك على أساس إرسال الرموز الدليلية على الوصلة الصاعدة واعتماد تقنية تخمين MMSE لدراسة تأثير الترابط المكاني وتلوث الرموز الدليلية على تخمين القناة وتم اعتماد بارامترات محددة بالجدول بالاعتماد على نموذج الانتثار المحلي حيث تمت محاكاة تغيرات MSE (متوسط مربع الخطأ) من أجل قناة مترابطة مكانياً وتغيرات MSE من أجل تجهيزات متداخلة تستخدم نفس الرمز الدليلي.

بعدها تمت مقارنة الأداء بين تقنيات تخمين قناة مختلفة في هذه الأنظمة من حيث تحليل MSE والتعقيد الحسابي وذلك من خلال الدراسة النظرية والمحاكاة.

ثم تم دراسة ومحاكاة تقنية تخمين القناة من النوع شبه الأعمى القائم على الفضاء الجزئي مع العرض النظري للمشكلة الأساسية لأنظمة Massive MIMO مع التقنيات السابقة باستخدام الرموز الدليلية حيث تم دراسة مخمن قناة شبه أعمى قائم على الفضاء الجزئي مع اقتراح نموذج للدراسة والمحاكاة وفق خوارزمية تعتمد على هذا المخمن ومناسب لأنظمة Massive MIMO وتحليل ومحاكاة أداء MSE لهذا المخمن مقارنة مع المخمنات المعتمدة على سلاسل الرموز الدليلية وذلك من أجل تغيرات أعداد الهوائيات في المحطة القاعدة وعدد رموز البيانات المستخدمة في التخمين وذلك وفق بارامترات تم جدولتها ورسم المنحنيات المطلوبة.

#### 4- تخمين القناة المعتمد على الرموز التجريبية

يمكن استخدام الرموز التجريبية لتخمين القناة، وعادةً ما تقدم أداءً جيداً. لكن في المقابل فإن فاعلية الإرسال تقل بسبب الحمولة الزائدة المطلوبة للرموز التجريبية مثل المقدمة preamble، والسلاسل الدليلية التي يتم إرسالها بالإضافة لرموز البيانات.

تستخدم تقنيات الأقل تربيع (LS) least-square، minimum-mean-square-error (MMSE) على نطاق واسع لتخمين القناة عندما تكون الرموز التجريبية متاحة [1].

نفرض أن جميع الحوامل الفرعية متعامدة (لا يوجد ICI)، يمكن تمثيل الرموز التجريبية الخاصة بالحوامل الفرعية  $N$  بالمصفوفة القطرية الآتية:

$$\mathbf{X} = \begin{bmatrix} X[0] & 0 & \dots & 0 \\ 0 & X[1] & & \vdots \\ \vdots & & \ddots & 0 \\ 0 & \dots & 0 & X[N-1] \end{bmatrix} \quad (1)$$

إذ يشير  $X[k]$  إلى النغمة الدليلية عند الحامل الفرعي  $k$ .  $E\{X[k]\} = 0$ ,  $\text{Var}\{X[k]\} = \sigma_x^2$ .  $K=0,1, 2, \dots, N-1$ . يلاحظ أنه يتم إعطاء  $X$  بواسطة مصفوفة قطرية لأنه تم افتراض أن كل الحوامل الفرعية متعامدة. بفرض أن ربح القناة  $H[k]$  لكل حامل فرعي  $k$ ، يمكن تمثيل إشارة التجريب المستقبلية كما يأتي:

$$\mathbf{Y} \triangleq \begin{bmatrix} Y[0] \\ Y[1] \\ \vdots \\ Y[N-1] \end{bmatrix} = \begin{bmatrix} X[0] & 0 & \dots & 0 \\ 0 & X[1] & & \vdots \\ \vdots & & \ddots & 0 \\ 0 & \dots & 0 & X[N-1] \end{bmatrix} \begin{bmatrix} H[0] \\ H[1] \\ \vdots \\ H[N-1] \end{bmatrix} + \begin{bmatrix} Z[0] \\ Z[1] \\ \vdots \\ Z[N-1] \end{bmatrix} \\ = \mathbf{X}\mathbf{H} + \mathbf{Z} \quad (2)$$

حيث  $\mathbf{H} = [H[0], H[1], \dots, H[N-1]]^T$  شعاع القناة الذي يعطى كما يأتي:  $\mathbf{Z} = [Z[0], Z[1], \dots, Z[N-1]]^T$  شعاع الضجيج الذي يعطى كما يأتي:

تخمين القناة  $H$ .  
 $\text{Var}\{Z[k]\} = \sigma_x^2, k=0,1,2,\dots,N-1$ . في المناقشة الآتية سنفرض أن  $\hat{H}$  تشير إلى تخمين القناة  $H$ .

#### 4-1 تخمين القناة بطريقة الأقل تربيع LS

تكتشف طريقة تخمين القناة الأقل تربيع (LS) least-square تخمين القناة  $\hat{H}$  من خلال تقليل مقدار التابع الآتي [4].

$$\begin{aligned} J(\hat{H}) &= \|Y - X\hat{H}\|^2 \\ &= (Y - X\hat{H})^H (Y - X\hat{H}) \\ &= Y^H Y - Y^H X\hat{H} - \hat{H}^H X^H Y + \hat{H}^H X^H X\hat{H} \end{aligned} \quad (3)$$

حيث  $H$ : تشير إلى منقول المرافق العقدي.

يتم إيجاد الحد الأدنى من خلال اشتقاق التابع بالنسبة لـ  $\hat{H}$  ومساواته بالصفر.

$$\frac{\partial J(\hat{H})}{\partial \hat{H}} = -2(X^H Y)^* + 2(X^H X\hat{H})^* = 0 \quad (4)$$

$$X^H X\hat{H} = X^H Y$$

العلاقة الأخيرة تعطي الحل لتخمين قناة LS كما يأتي:

$$\hat{H}_{LS} = (X^H X)^{-1} X^H Y = X^{-1} Y \quad (5)$$

لنشير إلى كل عنصر لتخمين القناة LS  $(\hat{H}_{LS})$  بـ  $\hat{H}_{LS}[K]$  إذ  $K=0,1,2,\dots,N-1$ . باعتبار لتخمين  $X$  تم افتراضه ليكون قطرياً تبعاً للشرط عدم وجود ICI، يمكن عندئذ كتابة تخمين القناة LS  $(\hat{H}_{LS})$  لكل حامل فرعي على الشكل الآتي:

$$\hat{H}_{LS}[k] = \frac{Y[k]}{X[k]}, \quad k = 0, 1, 2, \dots, N-1 \quad (6)$$

يعطى متوسط تربيع الخطأ (MSE) mean-square error لتخمين قناة LS كما يأتي:

$$\begin{aligned}
 MSE_{LS} &= E\{(\mathbf{H}-\hat{\mathbf{H}}_{LS})^H(\mathbf{H}-\hat{\mathbf{H}}_{LS})\} \\
 &= E\{(\mathbf{H}-\mathbf{X}^{-1}\mathbf{Y})^H(\mathbf{H}-\mathbf{X}^{-1}\mathbf{Y})\} \\
 &= E\{(\mathbf{X}^{-1}\mathbf{Z})^H(\mathbf{X}^{-1}\mathbf{Z})\} \\
 &= E\{\mathbf{Z}^H(\mathbf{X}\mathbf{X}^H)^{-1}\mathbf{Z}\} \\
 &= \frac{\sigma_z^2}{\sigma_x^2}
 \end{aligned} \tag{7}$$

حيث E: التوقع الرياضي.

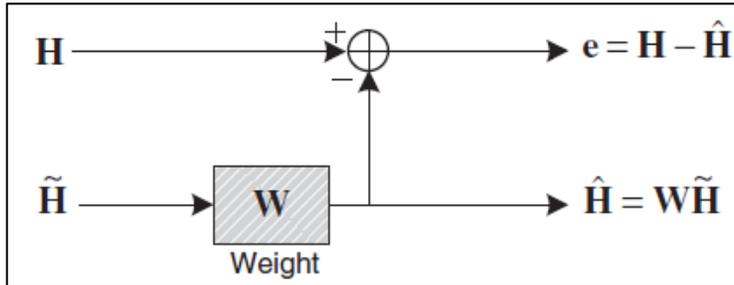
يلاحظ أن MSE في العلاقة (7) تتناسب عكسياً مع نسبة  $\frac{\sigma_x^2}{\sigma_z^2}$  SNR. مما يعني أنه قد يكون تابعاً لزيادة الضجيج. لكن بسبب بساطة طريقة LS فإنها تستخدم على نطاقٍ واسع لتخمين القناة.

4-2 تخمين القناة بطريقة الحد الأدنى لمتوسط مربع الخطأ MMSE  
لنعتبر أن حل LS في المعادلة (6) هو [4]:

$$\hat{\mathbf{H}}_{LS} = \mathbf{X}^{-1}\mathbf{Y} \triangleq \tilde{\mathbf{H}} \tag{8}$$

باستخدام مصفوفة وزن W لنعرف  $\hat{\mathbf{H}} \equiv W\tilde{\mathbf{H}}$  والتي توافق تخمين MMSE. تبعاً للشكل (1) فإن MSE لتخمين القناة  $\hat{\mathbf{H}}$  يعطى كما يأتي:

$$J(\hat{\mathbf{H}}) = E\{\|\mathbf{e}\|^2\} = E\{\|\mathbf{H}-\hat{\mathbf{H}}\|^2\} \tag{9}$$



الشكل (1): تخمين القناة بطريقة الحد الأدنى لمتوسط مربع الخطأ MMSE.

تكتشف طريقة تخمين القناة MMSE تخميناً أفضل (خطياً) إذ  $W$  تقلل من MSE في المعادلة (9) إلى الحد الأدنى. ينص مبدأ التعامد على أن متجه خطأ التخمين  $e = H - \hat{H}$  متعامد مع  $\tilde{H}$ ، إذ:

$$\begin{aligned} E\{e\tilde{H}^H\} &= E\{(H - \hat{H})\tilde{H}^H\} \\ &= E\{(H - W\tilde{H})\tilde{H}^H\} \\ &= E\{H\tilde{H}^H\} - WE\{\tilde{H}\tilde{H}^H\} \\ &= R_{H\tilde{H}} - WR_{\tilde{H}\tilde{H}} = 0 \end{aligned} \quad (10)$$

إذ  $R_{AB}$ : مصفوفة تابع الارتباط المتبادل لمصفوفات  $N \times N$  لكل من  $A$  و  $B$  ( $R_{AB} = E[AB^H]$ ).  
 $\tilde{H}$ : تخمين القناة LS الذي يعطى كما يأتي:

$$\tilde{H} = X^{-1}Y = H + X^{-1}Z \quad (11)$$

حل المعادلة (10) للنتائج  $W$ :

$$W = R_{H\tilde{H}}R_{\tilde{H}\tilde{H}}^{-1} \quad (12)$$

إذ  $R_{\tilde{H}\tilde{H}}$  مصفوفة تابع الارتباط الذاتي للمصفوفة  $\tilde{H}$  والذي يعطى كما يأتي:

$$\begin{aligned} R_{\tilde{H}\tilde{H}} &= E\{\tilde{H}\tilde{H}^H\} \\ &= E\{X^{-1}Y(X^{-1}Y)^H\} \\ &= E\{(H + X^{-1}Z)(H + X^{-1}Z)^H\} \\ &= E\{HH^H + X^{-1}ZH^H + HZ^H(X^{-1})^H + X^{-1}ZZ^H(X^{-1})^H\} \\ &= E\{HH^H\} + E\{X^{-1}ZZ^H(X^{-1})^H\} \end{aligned} \quad (13)$$

إذ  $R_{H\tilde{H}}$  مصفوفة تابع الارتباط المتبادل بين متجه القناة الحقيقية ومتجه القناة المؤقتة في المجال الترددي.

باستخدام المعادلة (13)، يتبع تخمين قناة MMSE ما يأتي:

$$E\{h_{k,l}\tilde{h}_{k',l'}^*\} = E\{h_{k,l}h_{k',l'}^*\} = r_f[k-k']r_t[l-l'] \quad (14)$$

دراسة ومحاكاة تقنيات تخمين القناة في نظام **Massive MIMO** وتحسينها باستخدام التخمين شبه الأعمى القائم على الفضاء الجزئي في أنظمة (5G)

إذ يشير  $k$  و  $l$  إلى دليل الموجة الحاملة الفرعية (التردد) ودليل رمز OFDM (الزمن)، على التوالي. في قناة PDP (Power Delay Profile) متعددة المسارات المتناقصة أسياً، يعطى الارتباط في المجال الترددي كما يأتي:

$$r_f[k] = \frac{1}{1 + j2\pi\tau_{rms}k\Delta f} \quad (15)$$

$f = 1/T_{sym}\Delta$ : الفرق الترددي ما بين الحوامل الفرعية.

لقناة خفوت مع الحد الأقصى لتردد دوبلر  $f_{max}$  وطيف Jake، يعطى الارتباط في المجال الزمني كما يأتي:

$$r_t[l] = J_0(2\pi f_{max}lT_{sym}) \quad (16)$$

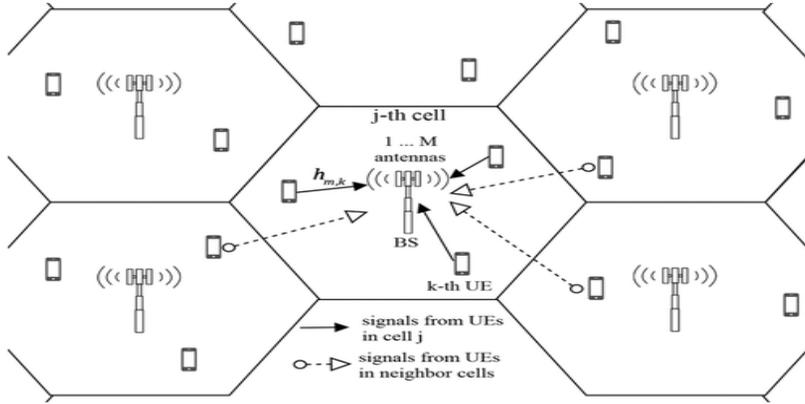
بعد أداء تخمين MMSE أفضل من تخمين LS، خصوصاً عند القيم المنخفضة للنسبة  $E_b/N_0$ . يمكن ل MMSE أن يقدم ربحاً 10-15 dB أكثر من أداء LS. ومع ذلك، وبسبب انقلابات المصفوفة المطلوبة، يكون الحساب معقداً للغاية عندما يزداد عدد الحوامل الفرعية للنظام. لذلك، يمكن أن يكون العيب المهم لتخمين MMSE هو التعقيد الحسابي العالي.

## 5- دراسة ومحاكاة تقنيات تخمين القناة في نظام Massive MIMO

ندرس في هذا القسم مخططات تخمين القناة من قبل محطات القاعدة المستخدمة في الجيل الخامس والمزودة بأنظمة الهوائيات المتعددة الكثيفة (Massive MIMO) على أساس إرسال الرموز الدليلية على الوصلة الصاعدة (Uplink).

### 5-1 إرسال الرموز الدليلية على الوصلة الصاعدة

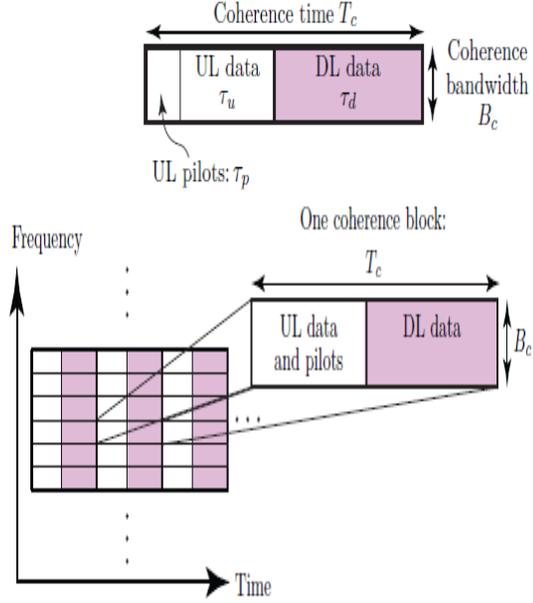
لتحقيق الاستخدام الفعال للعدد الهائل من الهوائيات، تحتاج كل محطة قاعدة إلى تخمين استجابات القناة من أجهزة المستخدمين النشطة في البلوك المتناسك الحالي، كما هو موضح في الشكل (2). [7]



الشكل (2) نموذج نظام يوضح الإشارات من الأجهزة المرغوبة والإشارات من الأجهزة المتداخلة

ويمكن أن تكون تخمينات القنوات من أجهزة المستخدمين المُسببة للتداخل في الخلايا الأخرى مفيدة أيضاً في قمع التداخل أثناء إرسال البيانات.

تخصص في كل بلوك متماسك  $\tau_p$  عينة لتشوير الرموز الدليلية على الوصلة الصاعدة، ويقوم كل UE (user equipment) بإرسال سلسلة رموز دليلية (pilot sequence) طولها  $\tau_p$ . نرمز للسلسلة من UE رقم  $k$  إلى محطة القاعدة رقم  $j$  بالرمز  $\phi_{jk}$  ونعتبر أن استطاعة الرموز الدليلية ثابتة وموحدة. ويتم تضخيم كل عنصر من عناصر  $\phi_{jk}$  بالمقدار  $\sqrt{P_{jk}}$  ثم يتم إرساله عبر  $\tau_p$  عينة، كما هو موضح في الشكل (3). [5].



الشكل (3) تخصيص الرموز الدليلية في البلوك المتماسك على الوصلة الصاعدة

ومن ثم فإن الإشارة المستقبلية عند BS (base station) رقم  $z$  تعطى العلاقة:

$$\mathbf{Y}_j^p = \underbrace{\sum_{k=1}^{K_j} \sqrt{p_{jk}} \mathbf{h}_{jk}^j \phi_{jk}^T}_{\text{Desired pilots}} + \underbrace{\sum_{l=1, l \neq j}^L \sum_{i=1}^{K_l} \sqrt{p_{li}} \mathbf{h}_{li}^j \phi_{li}^T}_{\text{Inter-cell pilots}} + \underbrace{\mathbf{N}_j^p}_{\text{Noise}} \quad (17)$$

ونلاحظ أن هذه العلاقة تتضمن ثلاثة حدود يمثل الأول منها الإشارة المرغوبة القادمة من أجهزة المستخدم ضمن الخلية  $z$ ، بينما يمثل القسم الثاني إشارات التداخل القادم من أجهزة المستخدمين في الخلايا المجاورة، ويمثل القسم الثالث الضجيج [2].

ولذلك فإنه يتم استخدام  $\mathbf{Y}_j^p$  من المحطة القاعدية رقم  $z$  لتخمين استجابة القناة. ولتخمين قناة تجهيزات معينة، تحتاج المحطة القاعدية إلى معرفة سلسلة الرموز الدليلية التي أرسلها هذا المستخدم. وهذا هو السبب في أن الرموز الدليلية تكون على شكل سلاسل

حتمية ويتم تخصيص الرموز الدليلية عادةً عندما تتصل تجهيزات المستخدم بمحطة القاعدة، باستخدام إجراء وصول عشوائي.

## 5-2 تخمين القناة من نوع MMSE

إن تخمين MMSE للقناة  $h_{li}^j$  والتي تشير إلى القناة بين محطة القاعدة  $j$  و UE رقم  $i$  من الخلية  $l$ ، وباستخدام مجموعة من سلاسل الرموز الدليلية المتعامدة فيما بينها استناداً إلى  $Y_j^p$  في (17) تعطى بالعلاقة:

$$\hat{h}_{li}^j = \sqrt{p_{li}} \mathbf{R}_{li}^j \Psi_{li}^j \mathbf{y}_{jli}^p \quad (18)$$

إذ:

$$\Psi_{li}^j = \left( \sum_{(l',i') \in \mathcal{P}_{li}} p_{l'i'} \tau_p \mathbf{R}_{l'i'}^j + \sigma_{UL}^2 \mathbf{I}_{M_j} \right)^{-1} \quad (19)$$

ويكون لخطأ التخمين  $\tilde{h}_{li}^j = h_{li}^j - \hat{h}_{li}^j$  مصفوفة الترابط  $C_{li}^j = E \{ \tilde{h}_{li}^j (\tilde{h}_{li}^j)^H \}$  ويتم التعبير عن جودة تخمين القناة من خلال الخطأ التربيعي المتوسط MSE. والذي يعبر عنه ب  $E \{ \|h_{li}^j - \hat{h}_{li}^j\|^2 \} = tr(C_{li}^j)$  من النوع MMSE. وكلما كان MSE أصغر كان التخمين أفضل [2].

يؤدي استخدام عدة أجهزة مستخدمين UE لنفس سلسلة الرموز الدليلية إلى التداخل بين تخمينات القناة وتدعى هذه الظاهرة بتلوث الرموز الدليلية (pilot contamination). ويقلل هذا التداخل من جودة التخمين (أي يزيد من MSE).

ولهذا التلوث تأثير مهم يتجاوز تخمين القناة، إذ إن هذا التداخل يجعل من الصعب بشكلٍ خاص على BS التخفيف من التداخل بين UEs التي تستخدم نفس الرمز

الدليلي. وغالباً ما يوصف تلوث الرموز الدليلية بأنه السمة الرئيسية والعامل المحدد ل Massive MIMO إذ إن العدد الكبير من أجهزة المستخدمين يتطلب إعادة استخدام لسلاسل الرموز الدليلية [12].

### 5-3 دراسة تأثير الترابط المكاني وتلوث الرموز الدليلية على تخمين القناة

لدراسة الخصائص الأساسية لمخمن MMSE، قدم البحث توضيح كيفية تأثير الترابط المكاني للقناة (spatial channel correlation) وتلوث الرموز الدليلية (pilot contamination) على أدائه.

#### 5-3-1 دراسة تأثير الترابط المكاني على تخمين القناة

أفضل وصف للخصائص الأساسية لتخمين القناة هو أننا عندما ننظر في تخمين استجابة القناة لجهاز المستخدم الذي له سلسلة رموز دليلية فريدة. عندئذٍ يتأثر تخمين القناة فقط بالضجيج وليس بالتداخل.

لنفترض لدينا قناة عشوائية  $h \sim N_c(0_M, R)$ ، ولنعتبر أن  $R = U\Lambda U^H$  يشير إلى تحليل القيمة الذاتية (eigenvalue decomposition) لمصفوفة الترابط (correlation matrix). إذ تضمن المصفوفة الواحدية  $U$  الأشعة الذاتية (eigenvectors)، أما المصفوفة القطرية  $\Lambda$  فتتضمن القيم الذاتية. ومن ثم فإن مصفوفة الترابط لخطأ التخمين تعطى بالعلاقة (20) [2]:

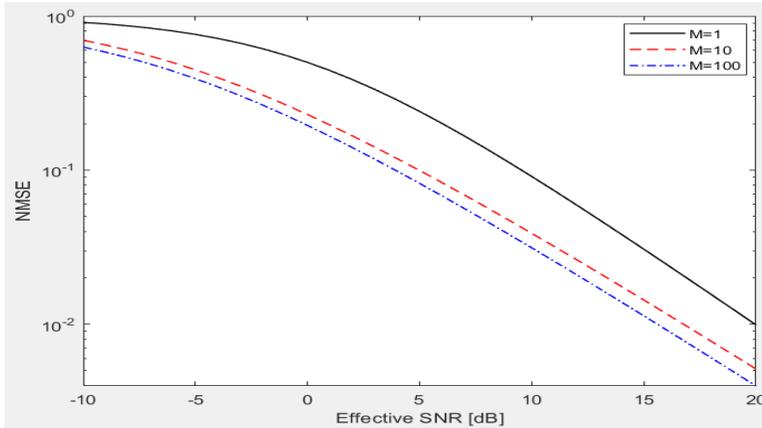
$$\begin{aligned} C &= \mathbf{R} - p\tau_p \mathbf{R} \left( p\tau_p \mathbf{R} + \sigma_{UL}^2 \mathbf{I}_M \right)^{-1} \mathbf{R} \\ &= \mathbf{U} \left( \Lambda - p\tau_p \Lambda \left( p\tau_p \Lambda + \sigma_{UL}^2 \mathbf{I}_M \right)^{-1} \Lambda \right) \mathbf{U}^H \\ &= \mathbf{U} \text{diag} \left( \lambda_1 - \frac{p\tau_p \lambda_1^2}{p\tau_p \lambda_1 + \sigma_{UL}^2}, \dots, \lambda_M - \frac{p\tau_p \lambda_M^2}{p\tau_p \lambda_M + \sigma_{UL}^2} \right) \mathbf{U}^H \end{aligned} \quad (20)$$

مصفوفة ارتباط خطأ التخمين  $C$  لها الأشعة الذاتية نفسها مثل مصفوفة الارتباط المكاني  $R$ ، لكن القيم الذاتية مختلفة وأصغر عموماً. مع زيادة نسبة الإشارة إلى الضجيج (SNR)، فإن كل تباينات الأخطاء هذه تقل وتقترب من الصفر وهذا ما سوف يتم إيضاحه عددياً بالمحاكاة الآتية إذ يوضح الجدول (1) بارامترات المحاكاة.

الجدول (1) بارامترات المحاكاة

[1 10 100]	عدد الهوائيات في محطة القاعدة
10	الانحراف المعياري الزاوي ASD
$(-\pi, +\pi)$	مجال زوايا الوصول
نصف طول الموجة	المسافة بين الهوائيات
-10:1:20	مجال تغير نسبة الإشارة إلى الضجيج [dB]
10	عدد مرات التكرار

ويوضح الشكل (4) نتائج المحاكاة لمصفوفات الارتباط المكاني الناتجة عن نموذج الانتثار المحلي (local scattering)، المحدد في [2]، مع التوزيع الغاوسي للزوايا.



الشكل (4): دراسة تغيرات MSE في تخمين القناة MMSE من أجل القناة المترابطة مكانياً

يظهر الشكل (4) تغيرات الخطأ المتوسط التربيعي MSE مقابل تغير نسبة الإشارة إلى الضجيج مع تشكيلات مختلفة للهوائيات إذ اقترح ثلاثة تشكيلات هي هوائي وحيد، عشر هوائيات، مئة هوائي. ونجد أن قيمة MSE تنخفض مع ارتفاع SNR. وكذلك نجد أن MSE ينخفض مع ازدياد عدد الهوائيات في محطة القاعدة.

ترجع هذه الميزة إلى الارتباط المكاني للقناة (spatial channel correlation)، كما يتضح من حقيقة أن القناة غير المرتبطة مكانياً أي  $R = \beta I$  تعطي  $NMSE = 1 / (SNR^p + 1)$  (Normalized) وهو مستقل عن عدد الهوائيات في محطة القاعدة  $M$ . ومن ثم، من الأسهل تخمين القنوات المرتبطة مكانياً.

### 2-3-5 دراسة تأثير تلوث الرموز الدليلية على تخمين القناة

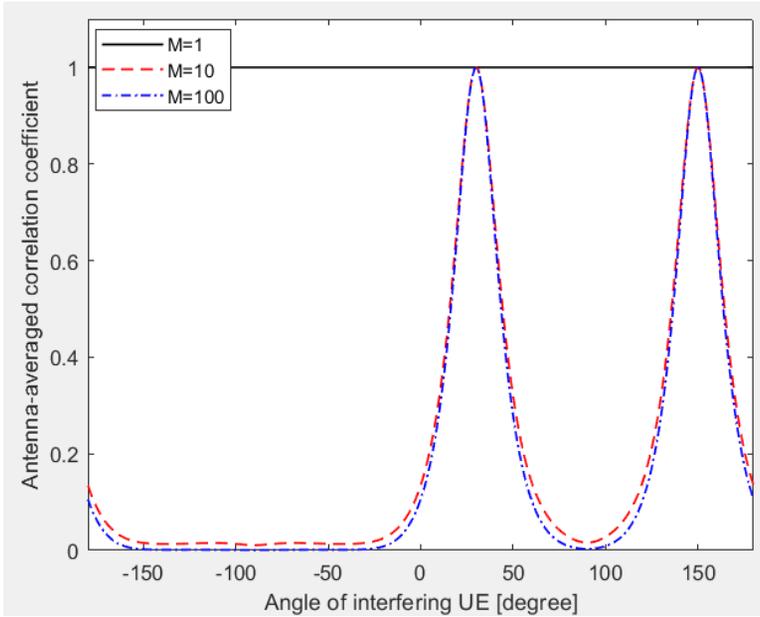
نقوم الآن بدراسة تأثير تلوث الرموز الدليلية من خلال النظر في نموذج يستخدم فيه اثنان من أجهزة المستخدم سلسلة الرموز الدليلية نفسها. إذ تخمن  $j$  قناة BS في UE  $k$  في خليتها الخاصة، بينما يرسل UE  $i$  في الخلية  $l$  الرمز الدليلي نفسه. ومن ثم فإن التداخل المتبادل الذي تسببه أجهزة المستخدمين أثناء إرسال الرموز الدليلية يؤدي إلى نتيجتين رئيسيتين:

- تصبح تخمينات القناة مترابطة.
- تنخفض جودة تخمين القناة.

نقوم الآن بإجراء دراسة لبيان أثر التداخل بين الرموز الدليلية إذ يتم اختيار جهازي مستخدم يقع الأول منهما عند زاوية 30 درجة بالنسبة لهوائيات المحطة القاعدية و يبلغ SNR له 10 dB في حين يملك الجهاز المتداخل الذي له سلسلة الرموز الدليلية نفسها SNR أقل بمقدار 10 dB.

نجد من الشكل (5) أن زوايا أجهزة المستخدمين تلعب دوراً رئيسياً عندما تكون المحطة القاعدية مجهزة بهوائيات متعدّدة. فإذا كانت أجهزة المستخدم لها نفس الزاوية، يكون معامل الارتباط يساوي الواحد، مما يعني أن التخمينات متطابقة ويحدث التداخل. في حين إذا كانت زوايا أجهزة المستخدم مفصولة جيداً، يكون معامل الارتباط صفرًا تقريباً ولا يتأثر تخمين المحطة القاعدية بهذا التداخل.

وهذا يختلف عن حالة الهوائي الأحادي (والحالة متعدّدة الهوائيات ذات الخفوت غير المترابط)، إذ يكون معامل الارتباط مساوياً للواحد، بغض النظر عن زوايا تجهيزات المستخدمين.

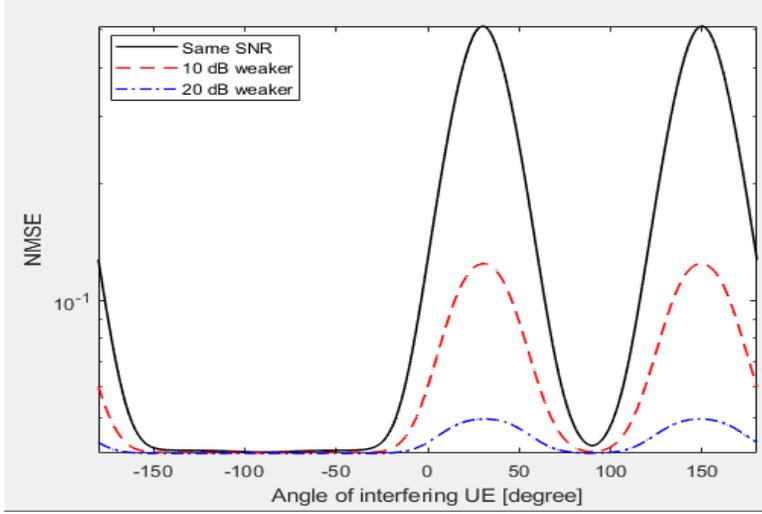


الشكل (5): دراسة تغيرات متوسط معامل ارتباط الهوائيات في تخمين القناة MMSE من

أجل UE المرغوب و UE المتداخل الذي يستخدم نفس الرمز الدليلي

النتيجة الرئيسية الثانية لتلوث الرموز الدليلية هي انخفاض جودة التخمين وتم دراسة هذا التأثير في النموذج نفسه على النحو المذكور آنفاً.

ندرس الآن الخطأ المتوسط التربيعي MSE لتخمين القناة المرغوبة مع عدد هوائيات قدره  $M = 100$  في محطة القاعدة. ويتم اختبار نسبة الإشارة إلى الضجيج (SNR) الفعالة من تجهيزات المستخدم المرغوبة 10 dB وأما إشارة التداخل فيتم اختيارها إما قوية بنفس القدر أو أضعف بمقدار 10 dB أو أضعف بمقدار 20 dB. ونحصل على النتيجة الموضحة في الشكل (6).



الشكل (6): دراسة تغيرات MSE في تخمين القناة MMSE عندما يكون هناك تجهيزات متداخلة تستخدم نفس الرمز الدليلي.

من الشكل (6) في الحالة المرتبطة مكانياً، عندما تكون زوايا تجهيزات المستخدم مفصولة جيداً، يكون NMSE حوالي 0.04 بغض النظر عن مدى قوة إشارة الرموز الدليلية المسببة للتداخل.

وهذا يعني أن تلوث الرموز الدليلية له تأثير ضئيل على جودة التخمين عندما يكون لتجهيزات المستخدمين مسافات ارتباط متعامدة تقريباً.

في حين يزداد NMSE عندما تكون لتجهيزات المستخدمين زوايا متشابهة، لا سيما الحالة التي يكون لتجهيزات المستخدمين المسببة للتداخل قناة قوية إلى المحطة القاعدة.

ومن ثم، فمن الممكن السماح للمستخدمين التشارك في سلاسل الرموز الدليلية، دون التسبب في تلوث الرموز الدليلية، إذا كانت مصفوفات الارتباط المكاني الخاصة بهما

$$R_{jk}^j R_{lk}^j = 0_{M_j \times M_j}.$$

#### 5-4 مقارنة الأداء بين مخططات تخمين القناة المختلفة

إذا لم تكن محطة القاعدة قادرة على إدارة التعقيد الحسابي لتخمين قناة MMSE، فإن هناك مخططات تخمين بديلة للقناة مثل مخمن (Element Wise) الذي يقوم بتخمين كل عنصر من عناصر  $h_{ii}^j$  بشكل منفصل ومن ثم تجاهل الارتباط بين العناصر. أي أن مخمن EW-MMSE لا يستخدم مصفوفات الارتباط المكاني الكاملة، ولكنه يستخدم العناصر الموجودة على الأقطار الرئيسية فقط [9]. يمكن أن تحسب محطة القاعدة  $j$  BS تخمين MMSE للعنصر رقم  $m$   $[h_{ii}^j]_m$  للقناة من  $i$  UE في الخلية  $l$  كما يأتي [2]:

$$[\hat{h}_{li}^j]_m = \frac{\sqrt{p_{li}} [\mathbf{R}_{li}^j]_{mm}}{\sum_{(l', i') \in \mathcal{P}_{li}} p_{l' i'} \tau_p [\mathbf{R}_{l' i'}^j]_{mm} + \sigma_{UL}^2} [y_{jli}^p]_m. \quad (21)$$

ويحسب تباين خطأ التخمين لهذا العنصر وفق المعادلة:

$$[\mathbf{R}_{li}^j]_{mm} - \frac{p_{li} \tau_p \left( [\mathbf{R}_{li}^j]_{mm} \right)^2}{\sum_{(l', i') \in \mathcal{P}_{li}} p_{l' i'} \tau_p [\mathbf{R}_{l' i'}^j]_{mm} + \sigma_{UL}^2}. \quad (22)$$

ويعطى MSE الذي يحققه مخمن EW-MMSE بالمعادلة:

$$\text{MSE} = \text{tr}(\mathbf{R}_{li}^j) - \sum_{m=1}^M \frac{p_{li} \tau_p \left( [\mathbf{R}_{li}^j]_{mm} \right)^2}{\sum_{(l', i') \in \mathcal{P}_{li}} p_{l' i'} \tau_p [\mathbf{R}_{l' i'}^j]_{mm} + \sigma_{UL}^2}. \quad (23)$$

دراسة ومحاكاة تقنيات تخمين القناة في نظام **Massive MIMO** وتحسينها باستخدام التخمين شبه الأعمى القائم على الفضاء الجزئي في أنظمة (5G)

وفي حالة عدم معرفة إحصائيات القناة بدقة أو عدم موثوقيتها (على سبيل المثال، بسبب التغيرات السريعة في جدولة تجهيزات المستخدمين في الخلايا الأخرى)، فقد يكون من الضروري مراعاة المخمنات التي لا تتطلب معلومات إحصائية مسبقة يستخدم مخمن الأقل تربيع (LS) لهذا الغرض.

ويعطى تخمين القناة وفق تقنية LS بالعلاقة:

$$\hat{\mathbf{h}}_{li}^j = \frac{1}{\sqrt{p_{li}\tau_p}} \mathbf{y}_{jli}^p. \quad (24)$$

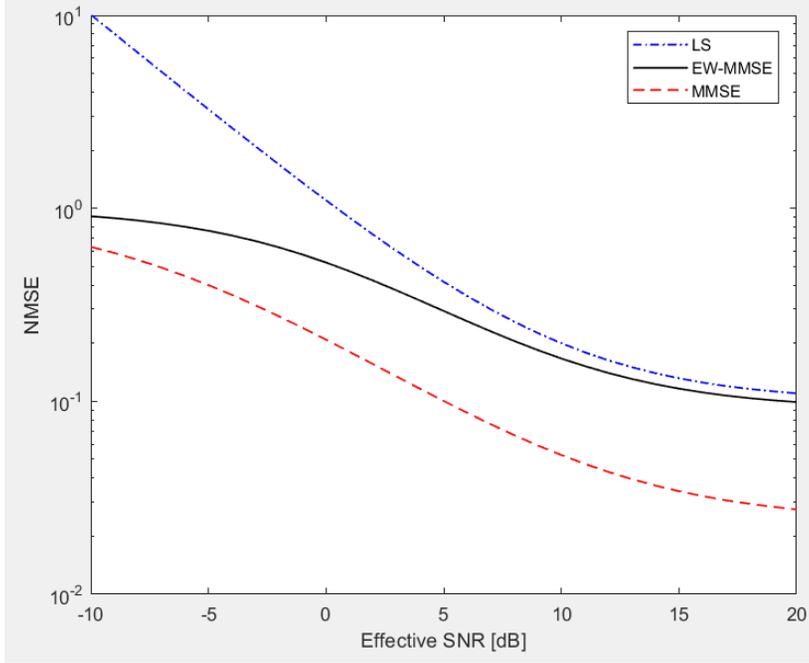
ويتناسب التعقيد الحسابي لكل بلوك متماسك مع  $M_j$ . ويعطى MSE لهذا المخمن بالعلاقة:

$$\text{MSE} = \text{tr} \left( \sum_{(l',i') \in \mathcal{P}_{li} \setminus (l,i)} \frac{p_{l'i'}}{p_{li}} \mathbf{R}_{l'i'}^j + \frac{\sigma_{\text{UL}}^2}{p_{li}\tau_p} \mathbf{I}_{M_j} \right) \quad (25)$$

تتم مقارنة جودة تخمين القناة لمخمنات MMSE و EW-MMSE و LS في الشكل (5) من حيث NMSE.

نفترض نموذج تخمن فيه  $j$  BS قناة  $k$  UE الخاصة بها، في حين ترسل UE في خلية أخرى سلسلة الرموز الدليلية نفسها.

وتتغير نسبة الإشارة إلى الضجيج (SNR) لتجهيزات المستخدم المطلوبة من -10 dB إلى 20 dB، بينما يفترض أن إشارة التداخل تكون أضعف بمقدار 10 dB من الإشارة المرغوبة. يوضح الشكل (7) أن المخمنات الثلاثة توفر NMSEs مختلفة نوعاً ما.

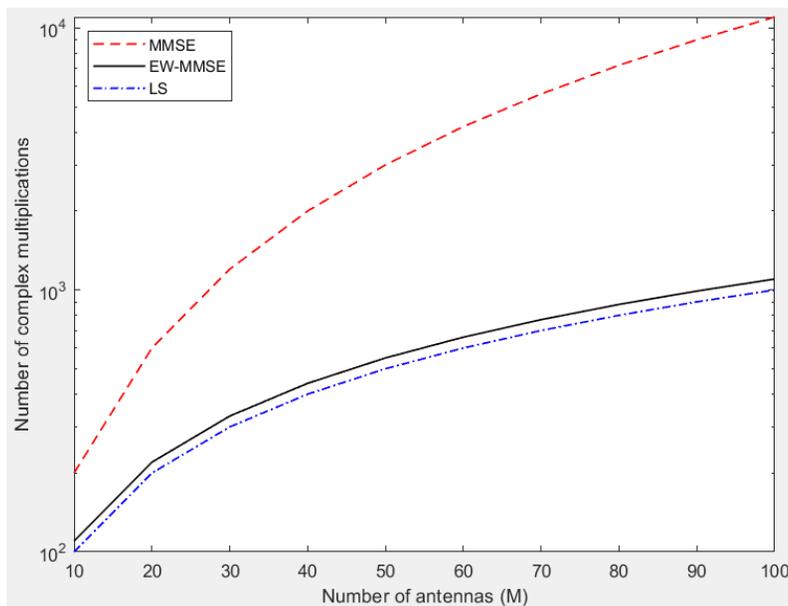


الشكل (7): حساب NMSE لمخططات تخمين مختلفة

إن ارتباط القناة المكانية يستغل كاملاً، لذلك فإن مخمن MMSE هو المخمن الأفضل. في حين يوفر مخمن EW-MMSE أداء تخمين جيد (مكافئ لتخمين MMSE لقناة غير مرتبطة)، ولكن هناك فجوة كبيرة من مخمن EW – MMSE حتى عند نسبة الإشارة إلى الضجيج (SNR) العالية. يعمل مخمن LS بشكل سيء للغاية عند انخفاض معدل الإشارة إلى الضجيج (SNR) إذ يكون NMSE أعلى من 1. ولقيم أعلى ل SNR، يكون أداء LS مشابهاً لمخمن EW-MMSE.

نتنقل الآن إلى المقارنة بين المخططات المختلفة من ناحية التعقيد الحسابي من خلال المحاكاة، إذ يوضح الشكل (8) عدد عمليات الضرب العقدية في كل بلوك متماسك كتابع لعدد هوائيات محطة القاعدة  $M$  في نموذج مع UEs عددها  $K = \tau_p = 10$

في كل خلية. لقد أهملنا تعقيد الحساب المسبق للمصفوفات التي تعتمد على إحصائيات القناة فقط، لأنها عادةً ما تكون ثابتة لعدد كبير من البلوكات المتماصة.



الشكل (8): عدد عمليات الضرب العقدية لكل بلوك متماصك مع 10 أجهزة مستخدمين عند استخدام مخططات تخمين مختلفة

نجد من الشكل (8) أن MMSE تتميز بأعلى درجة من التعقيد، تليها EW-MMSE، إذ ينخفض التعقيد بنسبة 45% - 90% نظراً لعدم استغلال الارتباط بين الهوائيات في تخمين القناة. يعدّ تقليل التعقيد في استخدام LS بدلاً من EW-MMSE هامشياً: بالنسبة إلى  $M = 100$  فإننا نوفر فقط 1% إضافية فقط باستخدام LS.

## 6- دراسة ومحاكاة تقنيات تخمين القناة من النوع نصف الأعمى

إن المشكلة الأساسية التي تعاني منها أنظمة Massive MIMO هي انخفاض أداء هذه الأنظمة عندما تكون معلومات حالة القناة غير كاملة والحاجة إلى إعادة استخدام للرموز الدليلية المتعامدة مما يسبب تلوث الرموز الدليلية وتدهور أداء تخمين القناة [6].

ولذلك فقد انتقل في هذا القسم من الدراسة إلى تقييم أداء تقنية تخمين القناة شبه الأعمى القائم على الفضاء الجزئي (subspace-based semi-blind).

يستخدم هذا التخمين تحليل القيمة المفردة (SVD) على الإشارات المستقبلية لتحديد مصفوفة القناة استناداً إلى مصفوفة الغموض واستناداً إلى التعامد التقريبي لأشعة القناة لأنظمة Massive MIMO، وبالتالي تجنب الحاجة إلى قلب المصفوفة في حل مصفوفة الغموض، وهو أمر كان يعدّ ضرورياً للمخمنات التقليدية القائمة على الفضاء الجزئي والتي تفقد معلومات حالة القناة CSI جزئياً [3].

تحقق مخمنات القنوات شبه العمياء القائمة على الفضاء الجزئي أداءً جيداً. لكن يجب استخدام المساحة المتبقية من مصفوفة القناة من دون خصائص أنظمة Massive MIMO، ومن ثم فإن هذه المخمنات إما أنها تؤدي أداءً ضعيفاً أو أنها تكون معقدة عند تعديلها لأنظمة Massive MIMO [5].

ولذلك فقد اقترح مخمن قناة شبه أعمى قائم على الفضاء الجزئي لأنظمة Massive MIMO، وقدم تحليل خصائص المخمن. يستخدم المخمن تحليل القيمة المفردة (SVD) على الإشارات المستقبلية.

وبسبب التعامد التقريبي لأشعة القناة لأنظمة Massive MIMO، فإن الأشعة المفردة اليسرى ذات العدد  $K$  التي تتوافق مع  $K$  أكبر قيم مفردة تكون تقريباً في الفضاء الجزئي الممتد بواسطة أشعة القناة، إذ  $K$  هو عدد أجهزة المستخدمين النشطة في وقت واحد لكل خلية .

بعد ذلك يتم التعبير عن المصفوفة التي تتكون من الأشعة المفردة اليسرى هذه تقريباً على أنها ناتج جداء مصفوفة القناة المقيسة (normalized channel matrix)

ومصفوفة الغموض (ambiguity matrix). تكون مصفوفة الغموض واحدة تقريباً ويمكن تخمينها باستخدام الرموز الدليلية [5].

### 6-1 نموذج النظام

نفترض أن النظام المقترح يتضمن  $l$  خلية سداسية تشترك في نطاق الترددات نفسه. كل خلية تجاور  $l - 1$  خلية أخرى. ويعمل النظام في نمط الإرسال المزوج بتقسيم الزمن (TDD)، وتضمن محطات القاعدة قنوات الوصلة الصاعدة بواسطة الإشارات المستقبلية، وتحصل على تخمين قنوات الوصلة الأمامية من خلال الاستفادة من المعاملة بالمثل (reciprocity of the channels) للمحطة القاعدة في كل خلية مجهزة ب  $M$  عنصر هوائي، وتخدم  $K$  جهاز مستخدم كل منها مزود بهوائي وحيد في نفس الوقت. ونفترض أن  $M \gg K$  في هذه الدراسة.

تعطى القنوات من الأجهزة في الخلية  $l$  إلى المحطة القاعدة في الخلية  $z$  بالعلاقة [5]:

$$\mathbf{G}_{jl} = \mathbf{H}_{jl} \mathbf{D}_{jl} \in \mathbb{C}^{M \times K} \quad (26)$$

إذ تشير  $H_{jl}$  إلى معاملات الخفوت صغير النطاق، بينما تشير  $D_{jl}$  إلى مصفوفة مربعة للجذور التربيعية لمعاملات الخفوت واسع النطاق. وبشكل أكثر تحديداً، فإن القناة الممتدة من المحطة  $k$  في الخلية  $l$  إلى هوائي المحطة  $m$  للخلية  $z$  تعطى بالعلاقة:

$$g_{jlmk} \triangleq [\mathbf{G}_{jl}]_{m,k} = h_{jlmk} \beta_{jlk}^{1/2}, \quad (27)$$

وتشير  $\beta$  إلى معامل الخفوت الواسع النطاق المكون من فقد المسار وخفوت الظلال. ونفترض هنا أن معامل الخفوت واسع النطاق ثابت ومستقل عن هوائي الاستقبال

ومعروف مسبقاً. لأن فقد المسار يتناقص بشكلٍ أسي مع المسافة. وتعطى مصفوفة الإشارة المستقبلية عند محطة القاعدة  $z$  بالعلاقة:

$$Y_j = \sum_{l=1}^L G_{jl} S_l^T + N_j. \quad (28)$$

إذ تشير  $S_l$  إلى مصفوفة الرموز المرسله من الخلية  $l$ . بينما تشير  $N_j$  إلى مصفوفة الضجيج.

من المفترض أن تكون استجابة القناة ثابتة في إرسال الرموز (رموز البيانات  $N_d +$  الرموز الدليلية  $N_p$ ) والهدف هو تخمين مصفوفة القناة  $H_{jj}$  مع مصفوفة الإشارة المستقبلية  $Y_j$ . ولإيضاح أكبر، يمكن التعبير عن جزأي  $Y_j$  كالاتي [4]:

$$Y_j^p = \sqrt{p_u N_p} \sum_{l=1}^L G_{jl} \Phi_l^T + N_j^p \quad (29)$$

$$Y_j^d = \sqrt{p_u} \sum_{l=1}^L G_{jl} A_l^T + N_j^d. \quad (30)$$

## 6-2 تخمين القناة شبه الأعمى القائم على الفضاء الجزئي

لم يتم حل الغموض تماماً باستخدام المخمن شبه الأعمى التقليدي. في حين حلت مخمنات القناة شبه العمياء القائمة على الفضاء الجزئي في [4] مصفوفة الغموض، وهي تستخدم المساحة اليسرى الخالية من مصفوفة القناة، والتي تكون إما ضعيفة أو معقدة عند تعديلها لأنظمة Massive MIMO ومن ثم هناك حاجة إلى مخمن قناة شبه أعمى قائم على الفضاء الجزئي مناسب لأنظمة Massive MIMO. والذي يعتمد الخوارزمية الآتية [5]:

أولاً- حساب مصفوفة التباين المتوسط ( $\hat{R}_{y_j^d}$  average covariance matrix) كما يأتي:

$$\hat{R}_{Y_j^d} = \frac{1}{N_d} \sum_{n=1}^{N_d} [Y_j^d]_n \left( [Y_j^d]_n \right)^H \quad (31)$$

ثانياً- تطبيق تحليل SVD ل  $\hat{R}_{y_j^d}$  كما يأتي:

$$R_{Y_j^d} = U_j \Sigma_j U_j^H \quad (32)$$

إذ  $U_j$  تشير إلى مصفوفة من  $M$  أشعة مفردة يسرى، و  $\Sigma_j$  مصفوفة قطرية تتكون من  $m$  من القيم المفردة اليسرى.

ثالثاً- إيجاد الأشعة المفردة اليسرى (left-singular vectors) بعدد  $K$  والتي تتوافق مع ال  $K$  قيمة ذاتية الأكبر ل  $\hat{R}_{y_j^d}$  والتي تستخدم أيضاً في تشكيل أعمدة  $U_j^S$ .

رابعاً- حساب تخمين القناة المستند إلى الرموز الدليلية ( pilot-based channel estimate  $\hat{H}_{jj}^P$  كما يأتي:

$$\hat{H}_{jj}^P = \frac{1}{\sqrt{p_u N_p}} Y_j^P \Phi^* D_{jj}^{-1} \quad (33)$$

خامساً- حساب تخمين القناة  $\hat{H}_{jj}^S$  كما يأتي:

$$\begin{aligned} \hat{H}_{jj}^S &= \sqrt{M} U_j^S \hat{E}_j^H \\ &= U_j^S (U_j^S)^H \hat{H}_{jj}^P \end{aligned} \quad (34)$$

إذ  $\hat{E}_j^H$  تشير الى مصفوفة الغموض.

## 3-6 خصائص تخمين القناة شبه الأعمى القائم على الفضاء الجزئي

يعدّ MSE مقياساً معقولاً لخطأ تخمين القناة، يتم تحليل MSE للمخمن المقترح إذ تعطى مصفوفة خطأ التخمين للمخمن المقترح بالعلاقة [5]:

$$\begin{aligned}\tilde{\mathbf{H}}_{jj}^s &= \hat{\mathbf{H}}_{jj}^s - \mathbf{H}_{jj} \\ &= \frac{1}{M} \tilde{\mathbf{H}}_{jj}^H \tilde{\mathbf{H}}_{jj}^H \Delta_j + \tilde{\mathbf{F}}_j.\end{aligned}\quad (35)$$

ونقدم الآن المعادلة (36) التي تعبر عن مجموع ICI والضجيج

$$\Delta_j = \sum_{l \neq j} \left( \mathbf{H}_{jl} \mathbf{D}_{jl} + \frac{1}{\sqrt{p_u N_p}} \mathbf{N}_j^p \Phi^* \right) \mathbf{D}_{jj}^{-1} \in \mathbb{C}^{M \times K} \quad (36)$$

بتعويض (36) في المعادلة (35) نحصل على:

$$\begin{aligned}\mathbb{E} \left\{ \left| \left[ \tilde{\mathbf{H}}_{jj}^s \right]_{m,n} \right|^2 \right\} &= \left[ \mathbf{R}_{\tilde{\mathbf{F}}_j} \right]_{m,n} + \frac{\left\| \left[ \tilde{\mathbf{H}}_{jj}^T \right]_m \right\|^2}{M} \\ &\times \left( p_u^{-1} \beta_{jjn}^{-1} N_p^{-1} + \beta_{jjn}^{-1} \mu_\beta \sum_{l=1}^L \left\| \left[ \Psi_{jl} \right]_n \right\|^2 \right)\end{aligned}\quad (37)$$

إذ يمكن أن نعبر عن  $R_{\tilde{\mathbf{F}}_j}$ :

$$\mathbf{R}_{\tilde{\mathbf{F}}_j} = \mathbb{E} \left\{ \tilde{\mathbf{F}}_j \odot \tilde{\mathbf{F}}_j^* + 2 \operatorname{Re} \left( \left( (1/M) \tilde{\mathbf{H}}_{jj} \tilde{\mathbf{H}}_{jj}^H \Delta_j \right) \odot \tilde{\mathbf{F}}_j^* \right) \right\} \quad (38)$$

يتوافق ICI في رموز البيانات المستلمة مع  $R_{\tilde{\mathbf{F}}_j}$ ، ويتوافق ICI في الرموز الدليلية المستقبلية مع  $\Psi_{jj}$ . يمكن ملاحظة أن MSE يتناقص مع زيادة عدد الهوائيات في محطة القاعدة  $M$ ، في حين لا يكون الأمر كذلك في المخمن الذي يعتمد على الرموز الدليلية. ومن ثم، عندما تكون مدخلات  $R_{\tilde{\mathbf{F}}_j}$  صغيرة بما يكفي، فإن ICI المتبقي في التخمين أقل من ذلك في المخمن المعتمد على الرموز الدليلية في نظام Massive-MIMO.

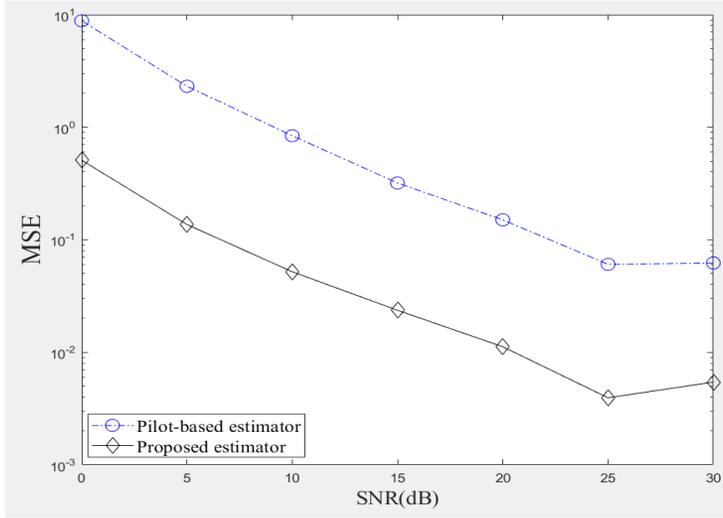
#### 6-4 المحاكاة والنتائج العددية: يوضح الجدول (2) بارامترات المحاكاة

الجدول (2) بارامترات المحاكاة

3	عدد الخلايا السداسية
800 متر	نصف قطر الخلية
3.8	قيمة التلاشي الأسي
3	عدد المستخدمين المخدمين بوقت واحد في الخلية
3	عدد الرموز الدليلية لكل مستخدم
BPSK	نظام التعديل المستخدم
أكبر من 100 متر و أصغر من 800 متر	المسافة من أي محطة إلى محطة الخدمة

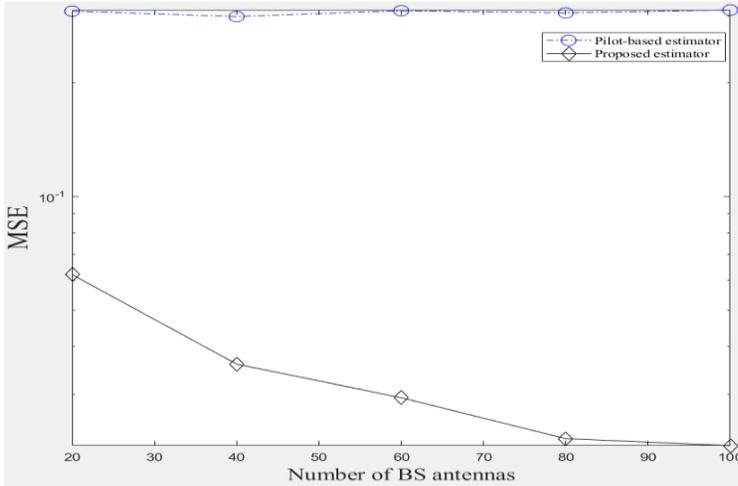
نفترض أنه يتم حساب MSE لكل مخمن على اعتبار أنه متوسط أخطاء التخمين لجميع مداخل مصفوفات القناة  $H_{jz}$  إذ  $j=1,2,\dots,L$ .

في البداية يتم دراسة MSE لقيم مختلفة لنسبة الإشارة إلى الضجيج (SNR)  $\gamma = p_u \beta M$  المستقبلية عند محطة القاعدة لمخمن القناة المستند إلى الرموز الدليلية، ومخمن القناة شبه الأعمى المستند إلى الفضاء الجزئي المقترح. وتظهر نتيجة عملية المحاكاة في الشكل (9) حيث نجد أن المخمن شبه الأعمى المستند إلى الفضاء الجزئي يقدم أداءً يتفوق بشكل كبير على تقنيات التخمين التقليدية المستندة إلى الرموز الدليلية من حيث تقليل MSE وزيادة دقة التخمين لهذا النوع من المخمنات أيضاً.



الشكل (9): MSE مقابل SNR من أجل  $M = 100$  و  $K = 3$  و  $N_d = 100$

بالانتقال إلى دراسة MSE مقابل أعداد مختلفة للهوائيات في محطة القاعدة  $M$  لمخمن القناة المستند إلى الرموز الدليلية، ومخمن القناة نصف الأعمى المستند إلى الفضاء الجزئي المقترح. هنا يتم تعريف  $\gamma = p_u \beta M_{max}$ ، إذ إن  $M_{max} = 100$  هي القيمة العظمى لـ  $M$  في المحاكاة. وتظهر نتيجة عملية المحاكاة هذه في الشكل (10).

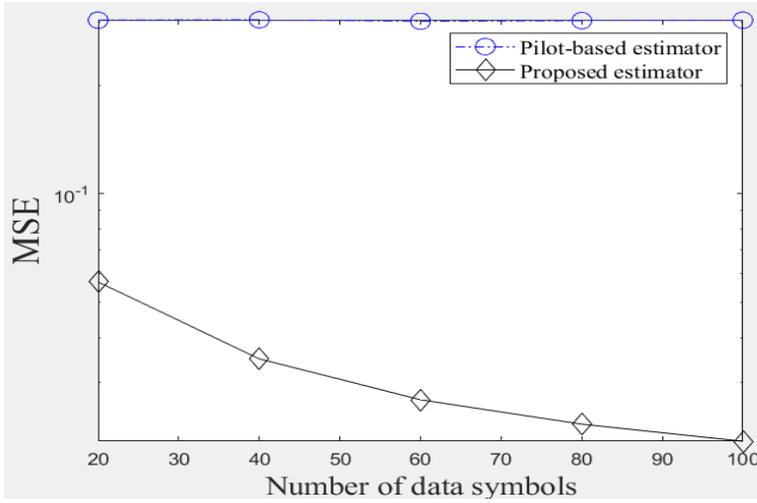


الشكل (10): MSE مقابل عدد الهوائيات في محطة القاعدة من أجل  $SNR = 15$  و

$$N_d = 100 \text{ و } K = 3$$

في هذا الشكل، تتناقص MSE للمخمن نصف الأعمى المستند إلى الفضاء الجزئي المقترح عندما يزيد عدد هوائيات محطة القاعدة  $M$ ، مما يؤكد تحليل MSE للمخمن المقترح في الفقرة السابقة.

ننتقل الآن إلى دراسة MSE مقابل عدد رموز المعطيات  $N_d$  مخمن القناة المستند إلى الرموز الدليلية، ومخمن القناة نصف الأعمى المستند إلى الفضاء الجزئي المقترح. وتوضح نتيجة المحاكاة في الشكل (11).



الشكل (11): MSE مقابل عدد رموز المعطيات  $N_d$  ل  $SNR=15$  و  $K=3$  و

$$M = 100$$

نجد من الشكل (11) أن MSE للمخمن شبه الأعمى المقترح تتناقص مع زيادة عدد رموز البيانات  $N_d$ . ونجد أن هذه النتيجة تتوافق مع التحليل الرياضي السابق إذ أنه مع ازدياد عدد رموز البيانات  $N_d$  تتقارب مصفوفة التباين للرموز المتوسطة  $\hat{R}_{y^d}$  المخمنة مع مصفوفة التباين الحقيقية  $R_{y^d}$  ويتحسن أداء هذا المخمن.

## 7- الخلاصة والنتائج:

أوضح البحث أن MSE ينخفض مع ازدياد عدد الهوائيات في محطة القاعدة. ومن ثم، من الأسهل تخمين القنوات المرتبطة مكانياً وكلما كانت زوايا أجهزة المستخدم مفصولة جيداً، يكون معامل الارتباط صفر تقريباً ولا يتأثر تخمين المحطة القاعدية بالتداخل بين المستخدمين بنفس سلسلة الرموز الدليلية ومن الممكن السماح للمستخدمين التشارك في سلاسل الرموز الدليلية، دون التسبب في تلوث الرموز الدليلية، إذا كانت مصفوفات الارتباط المكاني الخاصة بهما تفي بشرط التعامد وبالمقارنة للأداء بين مخططات تخمين القناة المختلفة من ناحية الأداء والتعقيد الحسابي أظهر مخطط EW-MMSE بأنه يجمع بين الأداء الجيد والتعقيد الحسابي المنخفض، وكما بينت النتائج أن المخمن شبه الأعمى المستند إلى الفضاء الجزئي المقترح ليناسب أنظمة Massive MIMO يقدم أداءً يتفوق بشكل كبير على تقنيات التخمين التقليدية المستندة إلى الرموز الدليلية من حيث تقليل MSE مع زيادة عدد الهوائيات وزيادة عدد رموز المعطيات المستخدمة في التخمين.

المراجع العلمية:

- [1]- L. Pu, J. Liu, Y. Fang, W. Li and Z. Wang, "Channel Estimation in Mobile Wireless Communication," 2010 International Conference on Communications and Mobile Computing, 2010, pp. 77-80, doi: 10.1109/CMC.2010.201.
- [2]- Emil Björnson; Jakob Hoydis; Luca Sanguinetti, Massive MIMO Networks: Spectral, Energy, and Hardware Efficiency, now, 2017.
- [3]- Subspace-based semi-blind channel estimation for Massive MIMO systems. WANG Qianzhu, QIU Congcong. School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China. **Published:**2018-05-02
- [4]- H. Kaur, M. Khosla and R. K. Sarin, "Channel Estimation in MIMO-OFDM System: A Review," 2018 Second International Conference on Electronics, Communication and Aerospace Technology (ICECA), 2018, pp. 974-980, doi: 10.1109/ICECA.2018.8474747
- [5]- Semi-blind MIMO-OFDM channel estimation using expectation maximisation like techniques ISSN 1751-8628 Received on 3rd June 2019 Revised 27th August 2019 Accepted on 12th September 2019 E-First on 14th November 2019 doi: 10.1049/iet-com.2019.0583
- [6]- Jeya, R, Amutha, B. Optimized semiblind sparse channel estimation algorithm for MU-MIMO OFDM system. *Comput Commun* 2019;146:103. <https://doi.org/10.1016/j.comcom.2019.07.018>.

[7]- Comparative study of channel estimators for massive MIMO 5G NR systems. Diego Fernando Carrera, Cesar Vargas-Rosales, Leyre Azpilicueta, Jose Alejandro Galaviz-Aguilar. First published: 01 April 2020.

[8]- Comparative Analysis of Higher Constellation in Intercarrier Interference Self-cancellation Orthogonal Frequency Division Multiplexing. Akintoye N. O.<sup>1</sup>, Adesina A. A.<sup>2</sup>, Salami S. A.<sup>2</sup>, Alabi T. I.<sup>2</sup>, Ojo S. I.<sup>2</sup>. Copyright © 2020 The Author(s).

[9]- Channel Estimation in Massive MIMO Systems for Spatially Correlated Channels with Pilot Contamination. Mohamed Boulouird, Jamal Amadid, Abdelhamid Riadi & Moha M'Rabet Hassani. Conference paper. First Online: 02 October 2021

[10]- A systematic literature review on channel estimation in MIMO-OFDM system: performance analysis and future direction. B.M.R. Manasa and Venugopal P. EMAIL logo from the journal Journal of Optical Communications  
<https://doi.org/10.1515/joc-2022-0033>

[11]- Kansal, L, Berra, S, Mounir, M, Miglani, R, Dinis, R, Rabie, K. Performance analysis of massive MIMO-OFDM system incorporated with various Transforms for image communication in 5Gsystems. *Electronics* 2022;11:621. <https://doi.org/10.3390/electronics11040621>

[12]- Pilot Contamination Mitigation in Massive MIMO Cloud Radio Access Networks. Hussein Taleb, Kinda Khawam, Samer Lahoud, Melhem El Helou, Steven Martin. *IEEE Access*, 2022, 10, pp.58212-58224.



# تحسين أداء نظم كشف الاختراق باستخدام المنطق العصبوني الضبابي والخوارزمية الجينية

## مقارنة مع SNORT

الباحث: د. محمد العصور\*\*

الباحث: م. محمد حمدان\*

### المخلص

تم في هذا البحث، الاعتماد على مفهوم تعلم الآلة باستخدام بنية هجينة من الشبكات العصبونية والمنطق الضبابي Fuzzy logic، لتحسين أداء نظام كشف الاختراق ضد الهجمات غير المعروفة مسبقاً، عبر الاستفادة من نظام الاستنتاج العصبوني الضبابي (ANFIS) Adaptive Neural Fuzzy Inference System، وذلك عبر استخدام إحدى أهم الخوارزميات التجريبية وهي الخوارزمية الجينية Genetic Algorithm، لإنشاء مجموعة السمات Features التي ستستخدم كمدخل لهذا النظام، ومقارنة أدائه مع أداء نظام SNORT المفتوح المصدر عبر مجموعة معطيات معيارية تستخدم عادةً لاختبار هذا النوع من الأنظمة.

تهدف عملية الدمج والمكاملة بين الشبكات العصبونية والمنطق الترجيحي والشبكات الهجينة إلى الاستفادة من ميزات كل منها، عبر إنشاء نظام قابل للتعلم واكتشاف هجمات غير موجودة مسبقاً، والابتعاد عن القرارات الحدية باعتبار حزمة معطيات ما هجوماً أو حركةً طبيعيةً على الشبكة، بالاستفادة من ميزات المنطق الترجيحي، والاختيار الأمثل للسمات التي تلعب دوراً مهماً في تدريب النظام المقترح عبر استخدام الخوارزمية الجينية. بعد ذلك، سيتم اختبار أداء هذا النظام مع نظام كشف

تحسين أداء نظم كشف الاختراق باستخدام المنطق العصبي الضبابي والخوارزمية الجينية مقارنة مع SNORT

الاختراق المفتوح المصدر SNORT، عبر استخدام مجموعة معطيات معيارية هي KDDCup99 و NSL-KDD و UNSW-NB15 و CSE-CIC-IDS2018. أظهرت نتائج هذا النظام إمكانية كبيرة للتعلم، واكتشاف الهجمات الجديدة، وبالتالي رفع دقة الكشف Accuracy وتقليل معدل التنبيهات الموجبة الخاطئة False Positive Rate (FPR).

**الكلمات المفتاحية:** أمن الشبكات الحاسوبية، نظم كشف الاختراق، الشبكات العصبونية، المنطق الضبابي، الخوارزمية الجينية.

---

\* حاصل على درجة الماجستير في هندسة الاتصالات من قسم الاتصالات في المعهد العالي للعلوم التطبيقية والتكنولوجيا، دمشق، سوريا.

\*\* باحث رئيسي في المعهد العالي للعلوم التطبيقية والتكنولوجيا، دمشق، سوريا.

# Enhancing IDS Performance using ANFIS and Genetic algorithm: Comparison with SNORT

\*Mohammad Hamdan \*\* Mohammad Alassoura

## Abstract

In this research, a new Machine learning scheme using hybrid neural network and fuzzy logic is proposed. The research aims to enhance network intrusion detection systems (IDS) performance against unknown attacks. Our scheme uses adaptive neural fuzzy inference system (ANFIS), and the genetic algorithm to prepare feature sets to be used as system inputs. We compare the suggested system performance with open-source intrusion detection system SNORT on multiple datasets, which are usually used on these kinds of systems. The scheme benefits from the advantages of fusion between neural networks, fuzzy logic, and genetic algorithms to create a system with the ability to learn and discover attacks that are not discovered before. In addition, the fuzzy logic sense avoids the scheme to be critical in making decisions either attack or normal traffic. Furthermore, applying the genetic algorithm maintains the best selection of input features. The suggested scheme is compared to SNORT by using the following datasets: KDDCup 99, NSL-KDD, UNSW-NB15 and CIC-IDS2017. The comparison results show enhancing in IDS functions by increasing of detection rate and decreasing of false positive rate (FPR). In addition, the scheme maintains a good ability to learn and discover new attacks.

**Key Words:** Network security, IDS, neural networks, Fuzzy logic, Genetic algorithm

\* Master's degree, From Communication Department in Higher institute for Applied Sciences and Technology, Damascus, Syria.

\*\* Lecturer in Higher institute for Applied Sciences and Technology, Damascus, Syria.

## 1- مقدمة:

يزداد حجم ومستوى التهديدات الأمنية للشبكات الحاسوبية يوماً بعد يوم نتيجةً للتوسع الكبير في بنية هذه الشبكات، وتتطور مدى قدرتها على إلحاق الأذى بالتجهيزات الحاسوبية، مما يستدعي البحث عن مفهوم آخر أكثر تطوراً لأجهزة حماية هذه الشبكات والتي تعتبر أجهزة كشف الاختراق من أهمها، وكان من الواجب تحسين قدرتها على كشف الهجمات غير المعروفة مسبقاً عبر تحليل سلوك وتسلسل العمليات الخاصة بكل هجمة.

إن مفهوم تعلم الآلة Machine Learning والذي هو أحد مفاهيم الذكاء الصناعي كان حجر الأساس لمواجهة هذه الهجمات، حيث يتم الاعتماد على تقنية أو دمج تقنيات تعلم الآلة للوصول إلى الهدف المطلوب وهو زيادة قدرة نظم كشف الاختراق على التصدي لهذه الهجمات.

تركز هذه المقالة على استعراض بعض تقنيات تعلم الآلة المستخدمة في هذا المجال، ومن ثم شرح مفهوم نظام الاستنتاج العصبي الضبابي Adaptive Neural Fuzzy Inference System (ANFIS) وكيفية استخدام الخوارزمية الجينية لتحديد السمات المستخدمة في عملية التدريب والاختبار، ومن ثم استعراض النتائج العملية للنظام المقترح على مجموعة بيانات معيارية ومقارنته بأداء نظام SNORT وتحليل هذه النتائج.

## 2- أهمية البحث وأهدافه:

تعد مفاهيم الذكاء الصناعي وتعلم الآلة من الطرق الحديثة لتحسين أداء أنظمة كشف الاختراق، عبر الاعتماد على بناء نظم قادرة على التكيف مع التغيرات الحاصلة في نوع وبنية الهجمات في الشبكات الحاسوبية، وإن بناء نظام يستفيد من المنطق الترجيحي في دقة اختيار القرار فيما إذا كانت الحزمة التي تمر في الشبكة هجوماً أم لا، ومن الشبكات العصبونية لما لها من قدرة على التعلم، ومن الخوارزمية الجينية للاستخلاص الأمثل للسمات التي تعتبر العنصر الأساسي في عملية تدريب النظام هو

الهدف الذي قمنا بالعمل عليه للوصول لنظام كشف الاختراق قابل للتعلم لمواجهة التغيرات السريعة في الهجمات الحاسوبية كماً ونوعاً، ومقارنته بأداء أنظمة كشف الاختراق المستخدمة حالياً مثل SNORT.

### 3- طرائق البحث ومواده:

قمنا في هذا البحث ببناء نظام يعتمد على ANFIS والخوارزمية الجينية لتحسين معدل الكشف وتقليل التنبهات الخاطئة الموجبة ومقارنة أداء هذا النظام مع نظام SNORT المفتوح المصدر. توجد عدة برامج لمحاكاة عمل النظام المقترح لكن أفضلها هو بيئة MATLAB بما تحتويه من مكتبات تؤمن الواجهات التفاعلية في التعامل مع المنطق الترجيحي والشبكات العصبونية والخوارزمية الجينية، كما تم اعتماد توزيعه Ubuntu لتتصيب نظام SNORT واختبار أدائه.

- نظام ANFIS: يوضح الشكل (1) بنية ANFIS [1]. يحوي النظام دخلين هما  $x$  و  $y$  وخرج وحيد هو  $Z$ ، ويعتمد هذا النظام على نموذج Sugeno الترجيحي باستخدام قاعدتين فقط حيث يمكن تعميم الشكل على مجموعة كبيرة من أشعة الدخل.

إن القاعدتين المستخدمتين في هذا النمط هما كالتالي:

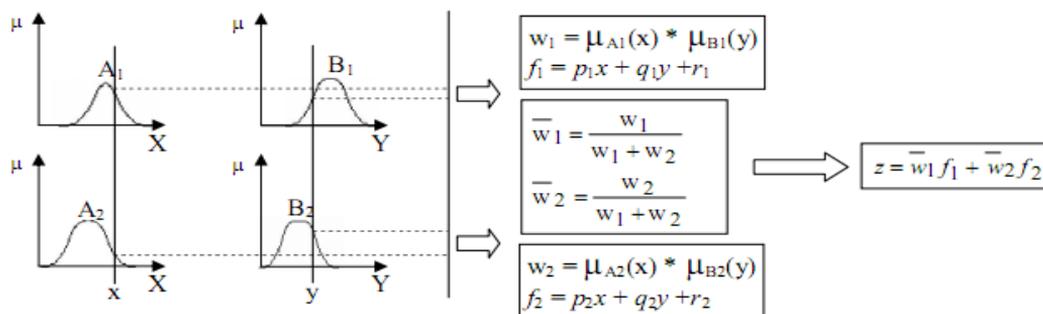
$$\text{Rule 1: if } x \text{ is } A_1 \text{ and } y \text{ is } B_1, \text{ then } f_1 = p_1x + q_1y + r_1$$

$$\text{Rule 2: if } x \text{ is } A_2 \text{ and } y \text{ is } B_2, \text{ then } f_2 = p_2x + q_2y + r_2 \quad \square$$

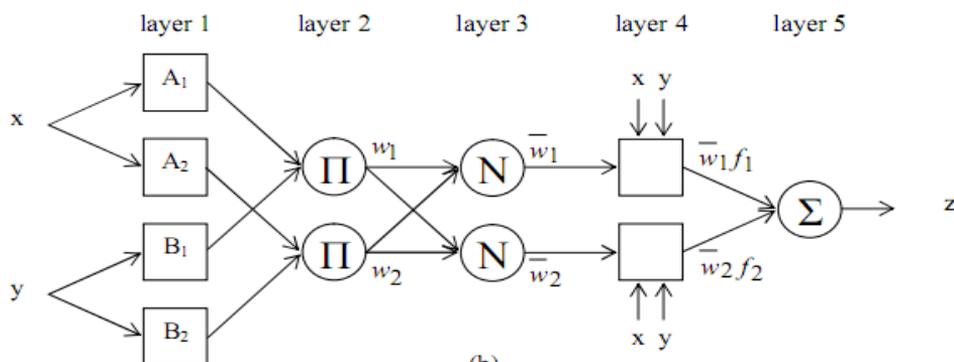
يحوي هذا النظام خمس طبقات هي :

- الطبقة الأولى: طبقة توابع العضوية. يحدد خرج أي عقدة في هذه الطبقة درجة العضوية لمداخل الشبكة. سنستخدم في بحثنا هذا التابع الغوصي لما يتمتع به من مزايا وخاصة تلك المتعلقة بقابلية الاشتقاق.
- الطبقة الثانية: طبقة الضرب. تقوم كل عقدة بحساب جداء درجة توابع العضوية لكل عنصر دخل ويكون الناتج هو درجة تابع العضوية الخاص بهذه العقدة.

- الطبقة الثالثة: طبقة التقييس. يتم تقييس درجة العضوية لهذه العقدة بالنسبة لمجموع درجات العضوية لكل عناصر الدخل.
- الطبقة الرابعة: طبقة الخرج الموزنة. يتم توزيع القواعد الخاصة بنموذج Sugeno بالأوزان المقيسة المحسوبة في الطبقة 3.
- الطبقة الخامسة: طبقة الخرج النهائي. الخرج الكلي للنظام هو مجموع الخرج الناتج في الطبقة 4، ويلاحظ أن هناك عقدة وحيدة أي أن النظام يمتلك خرجاً وحيداً.



(a)



(b)

الشكل (1). نظام ANFIS

a. نموذج Sugeno الترجيحي

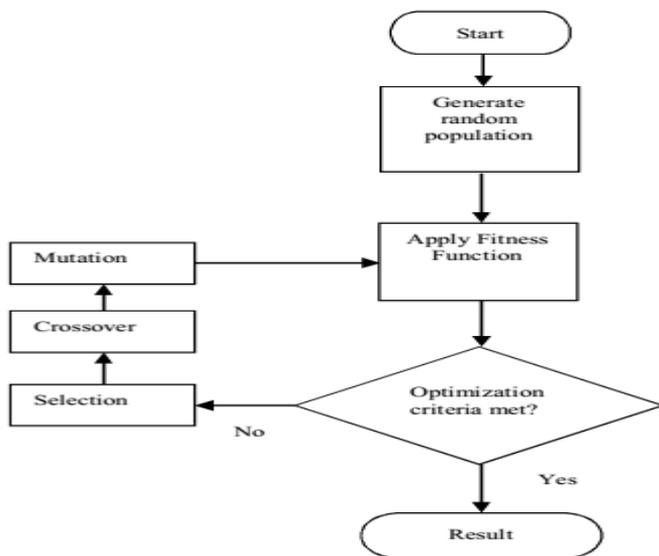
b. بنية ANFIS المقابلة

يتم تنفيذ خوارزمية التعلم في ANFIS عبر إحدى الطريقتين: الخوارزمية الهجينة Hybrid، وخوارزمية الانتشار الخلفي backpropagation. في كلا الخوارزميتين، يتم تطبيق شعاع دخل والحصول على قيمة الخرج، ويتم استخدام الخطأ الناتج عن الفرق بين الخرج المتوقع والخرج الحقيقي لتصحيح ضبط معاملات النظام، ويختلف ذلك بحسب الخوارزمية المتبعة. كما يتم ضبط المتحولات في الخوارزمية الهجينة عبر مرورين:

- المرور الأمامي forward pass: حيث تعطي كل عقدة خرجاً ينتقل إلى الطبقة التالية حتى الوصول للطبقة 4، من ثم يتم ضبط متحولات تابع الخرج الخاص بنموذج Sugeno باستخدام طريقة مربع الخطأ الأصغري (Least Square error (LSE).
- المرور العكسي backward pass: يتم الاعتماد على إشارة الخرج بمفهوم عكسي لتحديث المتحولات الخاصة بتوابع العضوية بالاعتماد على طريقة المشتق التدريجي gradient descent.

تعتبر الخوارزمية الجينية هي الخوارزمية الأكثر شيوعاً في هذا النمط [2] وتعتمد على مبدأ الانتقاء الطبيعي، حيث تقوم هذه الخوارزمية بانتقاء الآباء في كل مرحلة، بحسب معيار محدد للكفاءة، للحصول على الأبناء في المرحلة التالية. تمتاز الخوارزمية الجينية بالقدرة على التعامل مع المعطيات الاسمية والرقمية والمجموعات التي تحوي سمات كثيرة. تعتمد هذه الخوارزمية على ثلاث مراحل أساسية لإنتاج الأبناء كما يبين الشكل (2):

- 1- الاختيار Selection: حيث يتم اختيار الآباء.
- 2- التقاطع أو التزاوج Cross Over : وتعني ضم زوجين من الآباء للحصول على الجيل التالي.
- 3- الطفرة Mutation : حيث يتم تطبيق مجموعة من القواعد للتغيير في مواصفات الأبناء.



الشكل (2). المخطط الصندوقي للخوارزمية الجينية [2]

### 3- المفاهيم ذات الصلة:

يقوم نظام كشف الاختراق بمراقبة وتحليل حركة الحزم ضمن الشبكة لاكتشاف أي تهديد، ويصنف بناءً على نمط عمله كمبني على الحواسيب Host-Based عندما يعمل على الحواسيب، ومبني على الشبكة Network-Based عندما يراقب حزم بيانات الشبكة [3]. كما يصنف حسب نمط كشفه إلى الكشف المعتمد على التوقيع Signature-Based عندما يراقب العينات المشابهة لعينات الهجوم المعرفة لديه، والكشف المعتمد على الأنماط المشبوهة Anomaly-based عندما يكشف العينات غير المطابقة للحركة الطبيعية في الشبكة. هناك عدة معايير لقياس أداء نظم كشف الاختراق منها: الخطأ السلبي (False negative (FN): يعني عدم قيام نظام كشف الاختراق بإصدار تنبيه لحدوث اختراق بالرغم من وجود محاولة لذلك، ويمكن توصيف هذا الخطأ بعدم قدرة النظام على كشف الاختراق. الخطأ الإيجابي (False Positive (FP): يعني إصدار نظام كشف الاختراق لتنبيه بوجود هجوم بالرغم من عدم وجوده. الصواب الإيجابي (True Positive (TP): عند وجود هجوم يصدر نظام كشف الاختراق تنبيهاً

بوجود هجوم. الصواب السلبي (True Negative(TN): عندما لا يكون هناك هجوم ولا يصدر نظام كشف الاختراق أي تنبيه.

إن المعيارين اللذان سنهتم بهما في هذه الدراسة هما معدل الكشف DR ومعدل

الخطأ الإيجابي FP حسب المعادلتين التاليتين: [4]

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

$$FPR = \frac{FP}{FP + TN} \quad (2)$$

• **مجموعة البيانات المعيارية KDDCup 99:** مبنية على مجموعة DARPA 1998 [5]، والتي تحوي حوالي 4 غيغابايت من ملفات TCP dump، مؤلفة من 41 سمة بنوعها المستمر (33 سمة) والمتقطع (8 سمات)، كما أنها تعرف 22 نوعاً من أنواع الهجمات. تقسم الهجمات في KDD Cup 99 إلى أربعة أنواع:

- حجب الخدمة DoS: يؤدي الهجوم من هذا النمط إلى إشغال موارد الشبكة الحاسوبية بحيث تصبح عاجزة عن تخدم مستخدمين مصرح لهم باستعمال الشبكة.
- Root to Local(R2L): نفاذ غير مصرح به لجهاز ما عن بعد بغية استكشاف نقاط ضعف الشبكة.
- User to Root(U2R): الحصول على صلاحيات مستخدم محلي لاستخدام موارد النظام واستنزافها، والحصول لاحقاً على صلاحيات الجذر.
- PROBE: يقوم المهاجم بفحص بوابات الشبكة بغية جمع المعلومات عنها ومعرفة نقاط ضعفها.

تحسين أداء نظم كشف الاختراق باستخدام المنطق العصبي الضبابي والخوارزمية الجينية مقارنة مع SNORT

حيث يبين الجدول التالي توزيع الهجمات والحزم الطبيعية ضمن 10% من مجموعة البيانات هذه:

الجدول 1. توزيع العينات في 10% من KDD Cup99

النسبة المئوية للعينات	عدد العينات	الصف
19.69	97277	Normal
79.24	391458	DoS
0.01	52	U2R
0.23	1126	R2L
0.83	4107	Probe
100	492021	المجموع

- مجموعة البيانات المعيارية **NSL-KDD**: وهي مجموعة محسنة عن مجموعة KDD Cup 99، حيث أنها تتشابه معها بعدد السمات وأنواع الهجمات لكنها أفضل من ناحية حذف السجلات المكررة والتي تؤدي إلى خلل في عملية التدريب. [6]
- مجموعة البيانات المعيارية **UNSW-NB15**: مبنية على مجموعة بيانات Cyber Range Lab of Australian Centre for Cyber Security (ACCS)، تتألف من تسعة أنواع من الهجمات هي: [7] Analysis, Backdoors, DoS, Exploits, Fuzzers, Generic, Reconnaissance, Shellcode و Worms إضافةً إلى الحزم الطبيعية موزعة على مجموعتي تدريب واختبار حسب الجدول التالي:

الجدول 2. توزيع العينات في UNSW-NB15

Class Type	Training Samples	Training Samples Percentage	Testing Samples	Testing Samples Percentage
Normal	56000	31.94	37000	44.94
Analysis	2000	1.14	677	0.82
Backdoors	1746	1.00	583	0.71
DoS	12264	6.99	4089	4.97
Exploits	33393	19.05	11132	13.52
Fuzzers	18184	10.37	6062	7.36
Generic	40000	22.81	18871	22.92
Reconnaissance	10491	5.98	3496	4.25
Shellcode	1133	0.65	378	0.46
Worms	130	0.07	44	0.05
<b>Total</b>	<b>175341</b>	<b>100</b>	<b>82332</b>	<b>100</b>

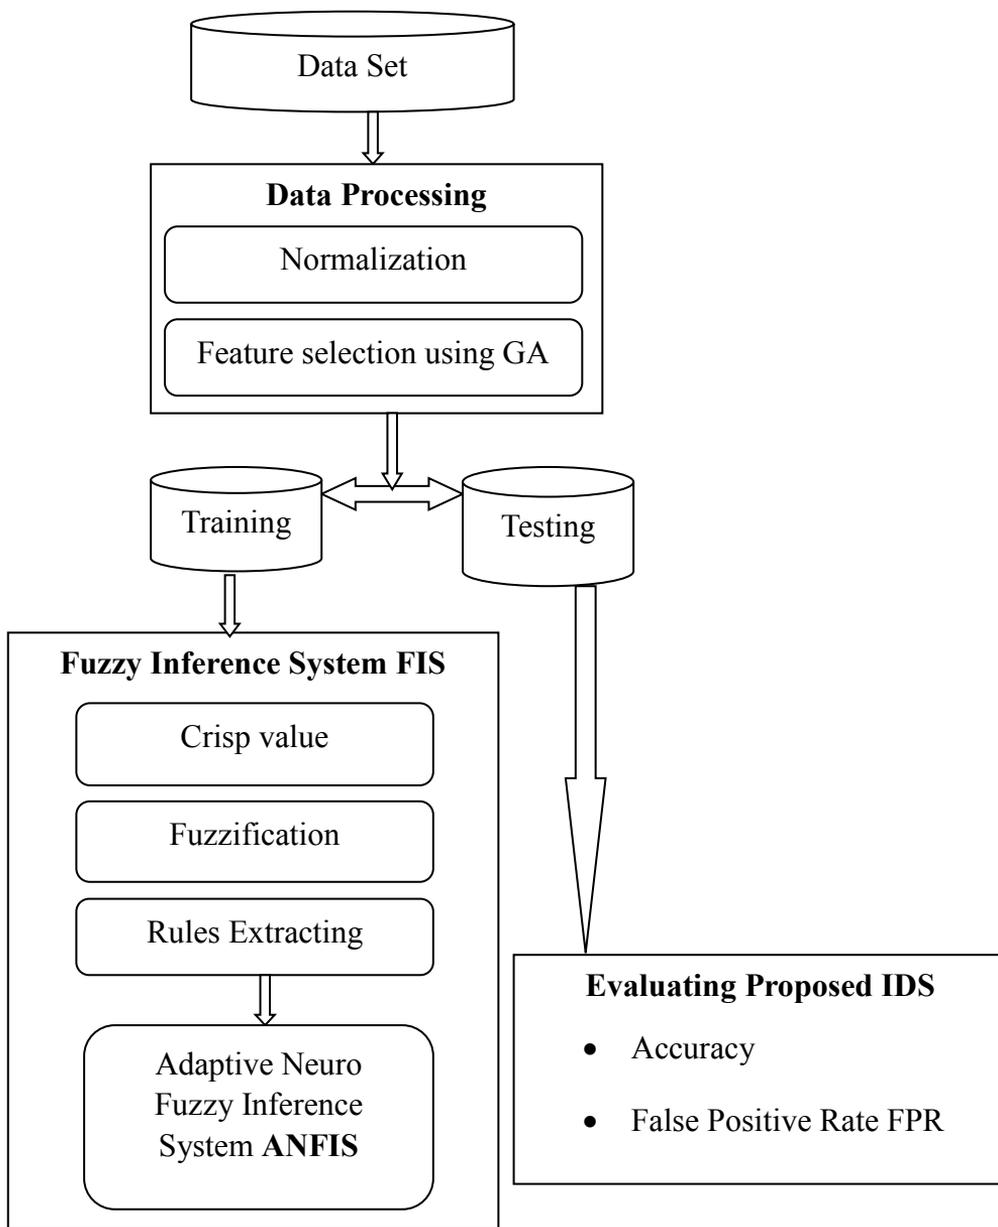
- مجموعة البيانات المعيارية **CSE-CIC-IDS2018** [8] تحتوي على 14 نوعاً من الهجمات مصنفة كالتالي: DoS Golden Eye, Heartbleed, DoS hulk, DoS Slow http, DoS Slowloris, DDoS, SSH-Patator, FP, Patator, Brute force, XSS, Botnet, infiltration, .PortScann, SQL injection

#### 4- الدراسة المرجعية:

اقترح الباحثون [9] نظاماً يعتمد على استخدام الشبكات العصبونية الأمامية التغذية مع مصنفات K nearest neighbor(KNN) لكن واجه هذا النظام مشكلةً تتمثل في عدد السمات الكبير والذي يصعب عمليةً توزيع المصنف حيث تم التغلب على هذه المشكلة باستخدام إحدى خوارزميات اختيار السمات وهي الخوارزمية الجينية، تم اختبار النظام على مجموعة البيانات المعيارية KDD Cup99 و قد لوحظ ازدياد في معدل الكشف لكن مع ارتفاع بمعدل الأخطاء الإيجابية. كما قدم Patil et al [10] إطاراً لكشف الهجمات بالاعتماد على خوارزمية Binary Bat لاستخراج السمات واختبارها على مجموعة البيانات UNSW-NB15. كما قام مجموعة من الباحثين [11] ببناء مصنفات اعتماداً على طرق تعلم الآلة التالية ANN، RF، KNN، SVM، ADA، BOOST واختبارها على مجموعة البيانات المعيارية CSE-CIC-2018.

#### 5- النموذج المقترح:

يعتمد النموذج الذي صممناه على خطوات هامة أولها عملية تحويل السمات النصية الموجودة في مجموعة البيانات المستخدمة إلى سمات عددية ومن ثم القيام بعملية التقييس اعتماداً على القيم الصغرى والكبرى لكل سمة، ومن ثم توليد السمات الأفضل بالاعتماد على الخوارزمية الجينية والتخلص من السمات غير المرغوب بها والتي تسبب انحرافاً في عملية تدريب النموذج. بعد ذلك قمنا ببناء نظام ANFIS بالاعتماد على مجموعة توابع العضوية والقواعد الهامة لعملية التدريب ومن ثم اختبار النموذج المقترح على مجموعة بيانات الاختبار الخاصة بكل مجموعة. يوضح الشكل (3) النموذج المقترح لتحسين أداء أنظمة كشف الاختراق.



الشكل (3). بنية النموذج المقترح

- يبين الشكل (4) مجموعة البيانات قبل إجراء أية معالجة:

```
0, tcp, http, SF, 181, 5450, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 8, 8, 0.00, 0.00,
0.00, 0.00, 1.00, 0.00, 0.00, 0.00, 9, 9, 1.00, 0.00, 0.11, 0.00, 0.00, 0.00, 0.00, 0.00,
normal.
0, tcp, http, SF, 239, 486, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 8, 8, 0.00, 0.00, 0
.00, 0.00, 1.00, 0.00, 0.00, 0.00, 19, 19, 1.00, 0.00, 0.05, 0.00, 0.00, 0.00, 0.00, 0.00,
normal.
0, tcp, http, SF, 235, 1337, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 8, 8, 0.00, 0.00, 0.00
, 0.00, 1.00, 0.00, 0.00, 0.00, 29, 29, 1.00, 0.00, 0.03, 0.00, 0.00, 0.00, 0.00, 0.00, normal
.
0, tcp, http, SF, 219, 1337, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 6, 6, 0.00, 0.00, 0.00
, 0.00, 1.00, 0.00, 0.00, 0.00, 39, 39, 1.00, 0.00, 0.03, 0.00, 0.00, 0.00, 0.00, 0.00, normal
.
0, tcp, http, SF, 217, 2032, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 6, 6, 0.00, 0.00, 0.00
, 0.00, 1.00, 0.00, 0.00, 0.00, 49, 49, 1.00, 0.00, 0.02, 0.00, 0.00, 0.00, 0.00, 0.00, normal
.
```

الشكل(4). جزء من معطيات التدريب والاختبار قبل عملية التقييس

- المعالجة الأولية للسّمات:

- تحويل السّمات النصية إلى عددية: هناك عدة طرق لتحويل المتحولات النصية إلى قيم عددية ، لكن سنختار الطريقة الأكثر شيوعاً [12]:

$$\text{Protocol type} = \begin{cases} 4 \text{ if } ICMP \\ 10 \text{ if } TCP \\ 17 \text{ if } UDP \end{cases}$$

$$\text{service} = \begin{cases} 2 \text{ if } ecr\_i \\ 5 \text{ if } http \\ 7 \text{ if } private \\ 9 \text{ if } domain\_u \\ 12 \text{ if } hostnames \\ 15 \text{ if } vmnet \\ 17 \text{ if } other \end{cases}$$

$$\text{flag} = \begin{cases} 3 \text{ if } REJ \\ 7 \text{ if } SF \end{cases}$$

تتم أهمية هذه الطريقة في ضمان عدم تكرار القيم المختلفة السمة بنفس القيمة في مجموعة بيانات الاختبار والتدريب.

- **تقييس السمات العددية:** نحصل بعد إجراء عملية التحويل على متحولات ذات قيم عددية متباعدة فيما بينها، لذلك نلجأ لعملية التقييس حيث توجد عدة أنماط للقيام بذلك، وسنعمد طريقة (UR) Unit range نظراً لبساطتها، حيث تعطى بالعلاقة:

$$UR = \frac{X - X_{min}}{X_{max} - X_{min}}$$

حيث تعبر  $X$  عن قيمة السمة، في حين  $X_{max}$  و  $X_{min}$  هي القيم الكبرى والصغرى للسمة على الترتيب. بعد القيام بعملية التقييس نحصل على مجموعة القيم موضحة بالشكل التالي:

```
0, 0.4615, 0.2, 1, 0.1422, 1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0.00, 0.0
0, 0.00, 0.00, 1.00, 0.00, 0.00, 0.01375, 0.01375, 1.00, 0.00, 1, 0.00, 0.00, 0.0
0, 0.00, 0.00, normal.

0, 0.4615, 0.2, 1, 0.1877, 0.0892, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0.0
0, 0.00, 0.00, 0.00, 1.00, 0.00, 0.00, 0.03339, 0.03339, 1.00, 0.00, 0.33, 0.00,
0.00, 0.00, 0.00, 0.00, normal.

0, 0.4615, 0.2, 1, 0.1846, 0.2453, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 1, 0.0
0, 0.00, 0.00, 0.00, 1.00, 0.00, 0.00, 0.05304, 0.05304, 1.00, 0.00, 0.11, 0.00,
0.00, 0.00, 0.00, 0.00, normal.

0, 0.4615, 0.2, 1, 0.1720, 0.2453, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0.75, 0.
75, 0.00, 0.00, 0.00, 0.00, 1.00, 0.00, 0.00, 0.07269, 0.07269, 1.00, 0.00, 0.0.
11, 0.00, 0.00, 0.00, 0.00, 0.00, 0.00, normal.

0, 0.4615, 0.2, 1, 0.1704, 0.3729, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0.75, 0.
75, 0.00, 0.00, 0.00, 0.00, 1.00, 0.00, 0.00, 0.092337, 0.092337, 1.00, 0.00, 0.
0.00, 0.00, 0.00, 0.00, 0.00, 0.00, normal.
```

الشكل (5). جزء من معطيات التدريب والاختبار بعد عملية التقييس

**ملاحظة:** في الشكل أعلاه (5)، تعبر كلمة normal أو attack على نمط الحزمة ولا تعتبر دخلاً للنظام المقترح بل هي خرج تدريب هذا النظام.

### • اختيار السمات Features Selection:

توجد سمات من المعروف أنها تؤثر على أداء المصنف وتساعد في رفع

قدرته على الكشف منها الزمن ونوع الخدمة. [13]

يعتمد مبدأ عمل الخوارزمية الجينية على اختيار عناصر، هي السمات في حالتنا، ومن ثم تمثيلها ك كروموسوم (صبغيات)، يتم إجراء عمليات التزاوج وتحديد الطفرات واختيار العناصر المناسبة من كل تزاوج واستخدامه كدخل للمرحلة التالية وهكذا حتى الوصول إلى الحل الأفضل. حيث يتم اختيار العناصر المناسبة وفقاً لنتائج قيمة تابع الملاءمة Fitness Function ، ويتم تكرار العملية حتى الوصول إلى شرط مناسب إما تحسن في أفضل شرط أو الوصول لعدد معين من الأجيال. اعتمدنا الشرط الثاني في موضوع بحثنا بسبب محدودية الإمكانيات المادية الخاصة بعملية تدريب نظام ANFIS. نحدد قيمة تابع الملائمة الذي سنستخدمه لتحديد السمات في الجيل التالي، حيث استخدمنا تابع الملائمة التالي، في بيئة 2014 MATLAB:

$$\text{Fitness function} = \text{No. of attacks in dataset} / \text{No. of normal traffic}$$

إن تابع الملاءمة المستخدم يؤمن المعالجة السريعة للمعطيات، وبالتالي من الممكن تطبيقه لتحديد السمات في الشبكات عالية السرعة [13]. لإعداد مرحلة التقاطع، نختار النمط المنتظم لتبديل البتات بين كل زوج من السمات لأنه يضمن عدم وجود قيم شاذة عند إنتاج جيل جديد كما هو موضح في المثال التالي:

ليكن الآباء هما Parent1 = 1010001110 و Parent2 =  
00111010010 عند إجراء النمط المنتظم يصبح لدينا offspring1 =  
0011001010 و offspring2 = 1010010110

كما نحدد احتمالية تابع التقاطع بـ 60% كون هذا الاحتمال يعطي أداءً فعالاً. [14]

لإعداد المرحلة الثالثة وهي مرحلة الطفرات، نقوم باستخدام التابع الغوسي بمتوسط معدوم وانحراف معياري ثابت كي نعطي كل عناصر الأجيال نفس الأوزان ومن دون انحياز لأي منها، مع احتمالية 1% [13].

نحصل بنهاية هذه المرحلة على مجموعة السمات ذات التأثير الأقوى والتي ستستخدم كمدخل لنظام ANFIS، وهي السمات التالية:

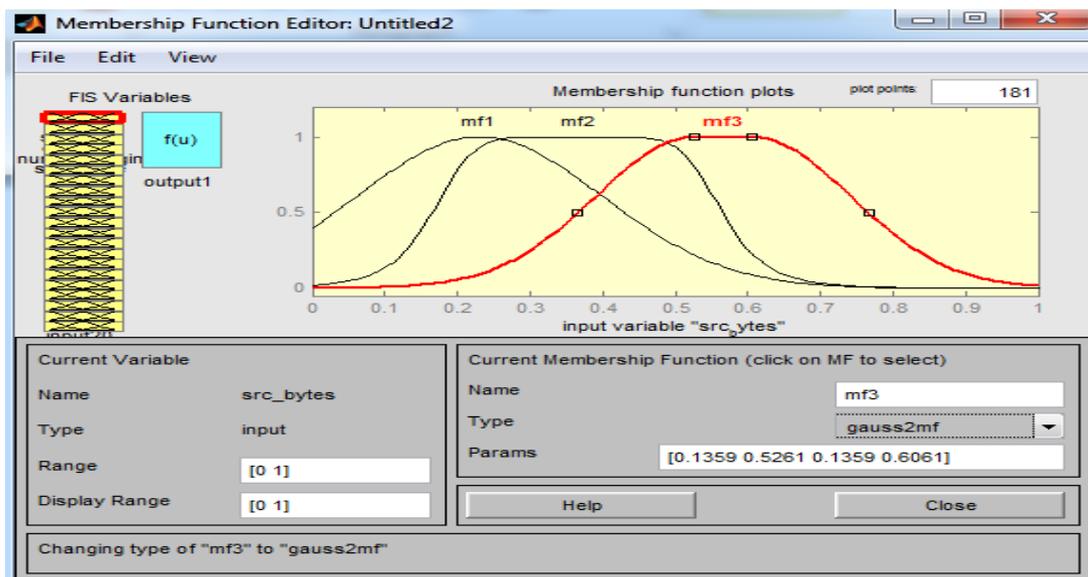
اسم السمة	رقم السمة في مجموعة البيانات	اسم السمة	رقم السمة في مجموعة البيانات	اسم السمة	رقم السمة في مجموعة البيانات
Serror_rate	30	Num_failed_login	13	Srv_error_rate	1
Dst_host_srv_count	34	Is_guest_login	16	Dst_host_same_src_port_rate	2
Dst_host_diff_srv_rate	35	Num_file_cre	18	Service	3
Dst_host_serror_rate	36	Count	21	Flag	4
Dst_host_rerror_rate	37	Srv_count	22	Src_bytes	5
Dst_host_same_srv_rate	40	Num_compromised	24	Protocol type	7
Dst_host_srv_count	41	Srv_diff_host_rate	29	Hot	12

إن مدخلات ANFIS عبارة عن 21 مدخلاً تعبر عن مجموعة السمات التي حصلنا عليها من مرحلة اختيار السمات، ونقوم بعدها بتحديد عدد توابع العضوية الخاصة بكل مدخل بالإضافة إلى نوع هذه التوابع، وتم الاستفادة من بيئة MATLAB عبر استخدام المكتبة الخاصة بالمنطق الترجيحي Fuzzy logic toolbox كما يبين الشكل (6)، حيث تم اعتماد مرحلة الدخل كالتالي:

تحسين أداء نظم كشف الاختراق باستخدام المنطق العصبي الضبابي والخوارزمية الجينية مقارنة مع SNORT

الجدول (3). إعداد نظام ANFIS

21	عدد المداخل
5	عدد توابع العضوية لكل مدخل
ثابت	نوع الخرج
200	عدد التكرارات
الخوارزمية الهجينة	خوارزمية التعلم



الشكل (6). ضبط المتحولات الخاصة بمداخل FIS

إن اختيارنا لعدد توابع العضوية لكل مدخل هو نتيجة لاعتمادنا خمس درجات انتماء لكل مدخل إلى كل مجموعة ترجيحية، وهذه الدرجات هي: large, medium, small, low, very small. حيث تم تقسيم المجال الخاص بكل سمة إلى خمس أقسام رئيسية، بحيث يكون كل قسم موافقاً لتابع عضوية عبر حساب المتوسط الحسابي والانحراف المعياري لكل سمة، ومن ثم تقسيم الناتج إلى خمسة أقسام رئيسية.

تستخدم الخوارزمية الهجينة لتدريب هذه الشبكة على طريقتين هما مربع الخطأ التدريجي LSM والمشتق التنازلي GD . تقوم خوارزمية LMS بضبط المتحولات الخاصة بالطبقة الرابعة من شبكتنا حيث تكون المتحولات الخاصة بتتابع العضوية مثبتة، أما خوارزمية GD فتقوم بنمذجة النظام الترجيحي عبر استخدام معطيات التدريب.

عندما يتم الحصول على القيم المثلى للمتحولات الخاصة بالطبقة 4 يبدأ التعلم عبر المرور الخلفي Backward Pass حيث يتم تحديث قيم المتحولات الخاصة بتتابع العضوية باستخدام معطيات التدريب.

#### 6- نتائج المحاكاة والمناقشة:

لمقارنة أداء نظامنا المقترح، اعتمدنا على تنصيب أحد أنظمة كشف الاختراق الشائعة SNORT. حيث يبين الجدول (4) الأدوات المستخدمة لبناء إطار العمل المقترح ومقارنة أدائه:

الجدول (4). ملخص عام للأنظمة والأدوات المستخدمة في العمل المقترح

Operating System	Platform	Tools
Windows 10 under 3.2GHz core i7 CPU with 16 GBytes of RAM	Matlab 2014	FIS + ANFIS
Virtual Machine	Linux Ubuntu	Snort IDS

تحسين أداء نظم كشف الاختراق باستخدام المنطق العصبي الضبابي والخوارزمية الجينية مقارنة مع SNORT

تم اختبار أداء النظام المقترح على مجموعات البيانات المعيارية KDDCup 99، NSL-KDD، UNSW-NB15 و CSE-CIC-2018 ومقارنة النتائج مع نظام SNORT وكانت النتائج حسب الجدول التالي:

	SNORT		GA-ANFIS	
	FPR (%)	Accuracy (%)	FPR (%)	Accuracy (%)
KDDCup 99	12	92	0.28	99.72
NSL_KDD	12.54	91.7	0.31	98.83
UNSW_NB15	10.73	95.62	0.195	99.91
CSE_CIC_2018	10.12	96.23	0.18	99.93

إن أداء نظام GA-ANFIS المقترح كان أفضل من ناحية معدل الكشف ومعدل الخطأ الإيجابي من أداء SNORT ، وذلك لكون النظام المقترح قد استفاد من ميزات الشبكات العصبونية وتجنب مشاكل الحدية في التصنيف اعتماداً على المنطق العائم، إضافةً لمساهمة الخوارزمية الجينية في اختيار السمات الأمثل كدخلٍ للنظام اعتماداً على درجة تأثيرها في القرار.

كما نلاحظ أن أداء النظام المقترح مع مجموعة البيانات KDDCUP\_99 كان أفضل من أدائه على مجموعة البيانات NSL\_KDD وذلك لأن البيانات NSL\_KDD تحوي تكراراً Redundant في مجموعة السجلات الخاصة بها مما ينتج عنه أخطاء في عملية تدريب النظام، كما أن مجموعة البيانات CSE\_CIC\_2018 أظهرت أفضل أداء للتعامل مع النظام المقترح.

## 7- الخلاصة:

قدم هذا البحث منهجية قابلة للتعميم عبر توظيف أدوات تعلم الآلة والتقيب في المعطيات من أجل تحسين عملية التعلم، وشملت هذه المنهجية صياغة المسألة المستهدفة وتحديد مقاربتها ووضع مجموعة القواعد الناظمة لعملها. كما يمكن تطوير هذا البحث عبر تصميم نظام أكثر فاعلية من خلال تطوير عملية استخراج القواعد واستخدام طرق مختلفة لتشكيل نظام هجين قابل للتعلم. كما يمكن تطوير هذا البحث من خلال إنشاء نظام قابل للتعلم وكشف الأنواع المتعددة للهجمات وليس تحديد الهجمات أو النشاط الطبيعي فقط. يمكن كذلك استخدام طرق مختلفة لاستخراج مجموعة القواعد الترجيحية إما عبر استخدام قواعد الارتباط الترجيحية fuzzy association rules أو استخدام خوارزميات أخرى.

## 8- المراجع References:

- [1] Mostaque, Md., Morshedur, H., 2013, Network Intrusion Detection System Using Genetic Algorithm and Fuzzy Logic, IJIRC.
- [2] Ganapathy, S., Kulothungan, K., Yogesh, P., Kannan, A., 2012, A novel weighted fuzzy C-means clustering based on immune genetic algorithm for intrusion detection, *Procedia Engineering* 38:1750-1757. International Conference on Modeling Optimization and Computing.
- [3] Hussain, A., Madni, U., Memoona, J., Arshad, M.J., 2014, An Overview of Intrusion Detection System (IDS) along with its Commonly Used Techniques and Classifications , IJCST [Volume 5, Issue 2].
- [4] Sokolova, M., Japkowicz, N., Szpakowicz, S., 2006, Beyond accuracy, F-score and ROC: a family of discriminant measures for performance evaluation, *Lecture Notes in Computer Science*, Springer, vol. 4304, pp. 1015–1021, Berlin, Germany.
- [5] KDD cup 1999 data at:  
<http://kdd.ics.uci.edu/databases/kddcup99/kddcup99.html>
- [6] <https://www.unb.ca/cic/datasets/nsl.html>.

[7] Moustafa, N., Slay, N., 2016, evaluation of network anomaly detection systems: statistical analysis of the unsw-nb15 dataset and the comparison with the kdd99 data set, *Information Security Journal: A Global Perspective*, vol. 25, no. 1-33, pp.18–31.

[8] Martins, N., Cruz, J.M., Abreu, P.H., 2020, Adversarial Machine Learning Applied to Intrusion and Malware Scenarios: A Systematic Review, *IEEE Access*, 8, 35403-35419.

[9] Rao, BB., swathi, K., 2017, Fast KNN classifiers for Network IDS , Indian journal of science and technology.

[10] Patil, R., Dudeja, H., Modi, C., 2019, Designing an efficient security framework for detecting intrusions in virtual network of cloud computing, Science Direct, Computer and Security, Volume 85, Pages 402,422.

[11] Kathryn, A., Khan, J., Alqahtani, F., 2021, Intrusion Detection using Machine Learning Techniques: An Experimental Comparison, International Congress of Advanced Technology and Engineering (ICOTEN).

[12] Brian, E., 2010, Implementation of Genetic algorithms into a Network Intrusion Detection System (netGA) and Integration into nProbe, M.Sc. Dissertation California State University Sacramento.

[13] Cheng, K., Li, J., Wang, S., 2018, Feature selection: A data perspective, ACM Computing Surveys, January.

[14] Botha, M., Solms, R., 2004, Utilizing Neural Networks for effective Intrusion detection.

## إعداد الحسابات اللازمة لتشكيل سبيكة خاصة

### بالتطبيقات الشاقّة بصهر الفولاذ والكروم

### والموليبيدينوم في فرن تحريضي

م. نسيم احمد الضاهر<sup>1</sup> د.م. علي هتره<sup>2</sup> د.م. أحمد سلامة<sup>3</sup>

#### الملخص

تم العمل على إضافة معدني الكروم والموليبيدينوم إلى الفولاذ الخاص المصنوعة منه مطارق الكسارات وأسنان الحفارات بهدف اختبار السبيكة الناتجة في التطبيقات الشاقّة، وتم إجراء الحسابات اللازمة لهذه الإضافات لضبط النسب الناتجة وفق ما هو مخطط له وبيان أهم التفاعلات الكيميائية التي تحدث أثناء الصهر وكميات الحرارة المنطلقة من هذه التفاعلات.

بيّنت النتائج وجود أكاسيد معدنية متعددة ضمن الخبث واحتراق كمية من المكونات بفعل الصهر كما نمت معرفة نسب الغازات في المصهور خاصة الأوكسجين والنتروجين حيث نتج عن الحسابات أن حد ذوبان النتروجين منخفض جداً في المصهور والتفاعلات تلقائية بنسبة قليلة جداً من الأوكسجين. ونتيجة الحسابات ميّزنا التفاعلات التلقائية وغير التلقائية وطرق تحفيزها والتحكم بها لتنتج السبيكة المطلوبة.

**الكلمات المفتاحية:** احتراق، أكاسيد، نتروجين، منغيز، موليبيدينوم، كروم.

<sup>1</sup> طالب دكتوراه في قسم هندسة التصميم والإنتاج، جامعة تشرين،

<sup>2</sup> أستاذ مساعد في قسم هندسة التصميم والإنتاج، جامعة تشرين،

<sup>3</sup> أستاذ مساعد في قسم هندسة التصميم والإنتاج، جامعة تشرين.

# Preparation of calculations required to form an alloy for heavy-duty applications by melting steel, chromium and molybdenum in an induction furnace

Nassim Aldaher<sup>1</sup>    Ali Hatra<sup>2</sup>    Ahmad Salamah<sup>3</sup>

## Abstract

Work was done to add chromium and molybdenum to the special steel from which crushers' hammers and excavators' teeth are made in order to test the resulting alloy in heavy-duty applications. Interactions.

The results showed the presence of multiple metal oxides within the slag and the combustion of a quantity of components as a result of smelting. The knowledge of the proportions of gases in the melt, especially oxygen and nitrogen, grew, as the calculations resulted in a very low solubility limit of nitrogen in the melt, and the reactions were spontaneous with a very small percentage of oxygen. As a result of the calculations, we distinguished the spontaneous and non-spontaneous reactions and the methods of catalyzing and controlling them to produce the required alloy.

**Key words:** Combustion, oxides, nitrogen, manganese, molybdenum, chromium

---

<sup>1</sup> Ph.D. Candidate, Dep. Design and Production Engineering, Tishreen University.

<sup>2</sup> Assistant Prof., Dep. Design and Production Engineering, Tishreen University.

<sup>3</sup> Assistant Prof., Dep. Design and Production Engineering, Tishreen University.

## 1- مقدمة

تعتبر أسنان الحفارات من أهم أجزاء أدوات الحفر المستخدمة في الحفر والجرف ونقل الأتربة والصخور، وتستخدم في المناجم والمقالع للحفر كما تستخدم مطارق الكسارات في إعادة تدوير هياكل السيارات وطحن الحجارة وتحويلها إلى حصى ورمال، بالإضافة لمختلف التطبيقات الشاقة المدنية والعسكرية.

يعتبر الفولاذ الخاص الأوستيني من أهم السبائك المستعملة في هذا المجال لكثته يدي تشوهات أثناء العمل وخاصية التصلد الانفعالي مما يسيء للخواص الميكانيكية.

بالنسبة لمعدن الكروم فهو موجود في جداول تصنيف الفولاذ الأوستيني بنسبة بين 2.5-1.5% بعدم وجود الموليبيدينوم ويعتبر الكروم مسؤول عن تشكيل كربيدات بحجم كبير على حدود الحبيبات مما ينقص طاقة الصدم عند إضافته بنسب أكبر من 0.09% ولذلك عندها لابد من إزالة تلك الكربيدات ومحاولة تشكيلها ضمن الأرضية الأوستينية وليس على حدود الحبيبات في طور الانتقال من الحالة السائلة إلى الصلبة عند التصلب (التجمد).

بالنسبة لمعدن الموليبيدينوم فهو أيضاً غير موجود عند وجود الكروم في جداول ASTM لسبيكة الفولاذ الأوستيني ويتواجد الموليبيدينوم بنسب (2.1-0.9%) ويتميز بخواص فريدة من نوعها خاصة للتطبيقات الشاقة إذ يحسن المتانة ومقاومة التشققات ويشكل كربيد عقدي بدلاً من وجوده على حدود الحبيبات.

## 2- هدف البحث

إنّ هدف البحث هو إضافة الكروم والموليبيدينوم معاً للفولاذ الأوستيني وفق حسابات وكميات دقيقة تتعلق بالتفاعلات الحاصلة وكميات الحرارة المنطلقة لمعرفة التفاعلات التلقائية وغير التلقائية في الفرن إذ أن وضع هذين المعدنين معاً (كروم وموليبيدينوم) يشكل تحدياً صعباً في الصناعة كما سنرى، وخياراً غير موجوداً في جداول ASTM

إعداد الحسابات اللازمة لتشكيل سبيكة خاصة بالتطبيقات الشاقّة بصهر الفولاذ والكروم والموليبدنوم في فرن تحريضي

A128. خاصة أنّ الكروم يخفض المتانة بزيادة نسبته فوق 0.09% والموليبدنوم يزيدھا.

### 3- طرائق البحث ومواده

- فرن صهر سعته العظمى 1.2 طن والاستطاعة العظمى 500 KW.
- قوالب رملية حيث الرمل مخلوط بالماء والمادة الرابطة (البنتنونايت).
- آلة القص لقص الزوائد المعدنية.
- جهاز التحليل الطيفي Foundry-Master 01M0026 Optik 01M0026

### 4-مراحل العمل :

1-صهر العينات ضمن فرن سعته عظمى 1.2 ton واستطاعته العظمى 500 KW حيث أن الفرن بشكل اسطواني تقريباً، وأهم التفاعلات التي تحدث عند صهر الفولاذ الأوستينيبي بحيث ( للخبث، { للغازات، والتي تحتها خط تنحل في المعدن المصهور.

$\underline{2Mn} + (SiO_2) \rightarrow 2(MnO) + \underline{Si} \quad (1)$	$\underline{Mn} + (FeO) \rightarrow (MnO) + Fe \quad (2)$
$\underline{C} + (FeO) \rightarrow \{CO\} + Fe \quad (3)$	$2C + (SiO_2) \rightarrow \underline{Si} + 2\{CO\} \quad (4)$
$Mn + (CO) \rightarrow \underline{C} + (MnO) \quad (5)$	$\underline{Si} + 2(FeO) \rightarrow (SiO_2) + 2Fe \quad (6)$
$\{N_2\} \rightarrow \underline{2N} \quad (7)$	$\{H_2O\} \rightarrow \underline{2H} + \underline{O} \quad (8)$

وبحسب دراستنا سنضيف الكروم والموليبدنوم وبالتالي:

$(Cr_2O_3) + 3C \rightarrow 2Cr + 3\{CO\}$ (9)	$MoO_2 + 2C \rightarrow Mo + \{2CO\}$ (10)
$2Cr + 3FeO \rightarrow 3Fe + (Cr_2O_3)$ (11)	$Mo + 2(FeO) \rightarrow (MoO_2) + 2Fe$ (12)

الصهرة الأولى: تم وضع أربع قطع من الفولاذ الأوستنيتي ASTM A128 D يحوي نيكل ذات الأبعاد  $300 \times 83 \times 44 \text{ mm}^3$  كتلتها 8.6 Kg بشكل متوازي مستطيلات تحوي ثقب بقطر 20 mm كما الشكل (1) وكمية X Kg من الكروم و Y Kg من الموليبيدينوم حيث أن النسب المراد الحصول عليها هي % (0.8-1) Cr, % (1-1.9) Mo

$$m = \frac{M(Cr_0 - Cr)}{0.85 Cr1} \text{ Kg}$$

m الكمية المطلوبة من عينات الكروم، M كمية المعدن المصهور،  $Cr_0$  نسبة الكروم المطلوبة، Cr كمية الكروم بالتحليل قبل إضافة عينات الكروم، Cr1 محتوى الكروم في عينات الكروم. و 0.85 هو المردود بسبب الأكاسيد المزالة مع الخبث من على سطح المصهور. [11]

$$X = m(Cr) = \frac{34.4(1.5 - 0.55)}{0.85 * 70} = 0.55 \text{ Kg}$$

وينفس الطريقة بالنسبة للموليبيدينوم:

$$Y = m(Mo) = \frac{34.4(0.9 - 0.041)}{0.85 * 69.08} = 0.503 \text{ Kg}$$

الصهرة الثانية: تم وضع أربع قطع من فولاذ هادفيلد D ذات الأبعاد  $300 \times 83 \times 44 \text{ mm}^3$  كتلتها 8.6 Kg بشكل متوازي مستطيلات تحوي ثقب بقطر 20 mm كما الشكل (1) وكمية X Kg من الكروم و Y Kg من الموليبيدينوم حيث أن النسب المراد الحصول عليها هي % (2-2.2) Mo, % (2-3) Cr .

إعداد الحسابات اللازمة لتشكيل سبيكة خاصة بالتطبيقات الشاقّة بصهر الفولاذ والكروم والموليبدنوم في فرن تحريضي

$$X = m (Cr) = \frac{34.4(2.5 - 0.55)}{0.85 * 70} = 1.13 \text{ Kg}$$

وبنفس الطريقة بالنسبة للموليبديوم:

$$Y = m (Mo) = \frac{34.4(2.1 - 0.041)}{0.85 * 69.08} = 0.105 \text{ Kg}$$

Identification		Chemistry						
Spec.	Grade	C	Mn	Si	Ni	Cr	Mo	P
ASTM A128	A	1.05-1.35	11.0 min	1.00 max				0.07 max
	B1	0.90-1.05	11.5-14.0	1.00 max				0.07 max
	B2	1.05-1.20	11.5-14.0	1.00 max				0.07 max
	B3	1.12-1.28	11.5-14.0	1.00 max				0.07 max
	B4	1.20-1.35	11.5-14.0	1.00 max				0.07 max
	C	1.05-1.35	11.5-14.0	1.00 max		1.5-2.5		0.07 max
	D	0.70-1.30	11.5-14.0	1.00 max	3.0-4.0			0.07 max
	E1	0.70-1.30	11.5-14.0	1.00 max			0.9-1.2	0.07 max
	E2	1.05-1.45	11.5-14.0	1.00 max			1.8-2.1	0.07 max
	F	1.05-1.35	6.0-8.0	1.00 max			0.9-1.2	0.07 max



Foundry-Master 01M0026 Qoptik 01M0026  
Sample :  
Alloy : FE-100 Mode : PA\_7/25/2019 5:02:28 PM

	Fe	C	Si	Mn	P	S	Cr
1	82.200	1.150	0.301	12.150	0.001	0.001	0.500
2	82.668	1.175	0.265	12.001	0.002	0.001	0.600
Average	82.434	1.083	0.283	12.075	0.015	0.001	0.550

	Mo	Ni	Al	Co	Cu	Nb	Ti
1	0.052	2.855	0.101	0.020	0.010	0.005	0.001
2	0.031	3.334	0.556	0.090	0.021	0.001	0.003
Average	0.041	3.094	0.328	0.055	0.015	0.003	0.002

	V	W	Pb	Sn	B	Ca	Zr
1	0.003	0.001	0.002	0.010	0.001	0.002	0.003
2	0.007	0.001	0.001	0.009	0.001	0.001	0.003
Average	0.005	0.001	0.001	0.009	0.001	0.001	0.003

	As	Bi
1	0.000	0.000
2	0.000	0.000
Average	0.000	0.000

الشكل (1) شكل عينة من فولاذ هادفيلد صنف D وتصنيف ASTM A128 والتحليل الطيفي لفولاذ هادفيلد صنف D

وتم الصهر وتجهيز القوالب الرملية ضمن الريازك بحيث الرمل متوسط الرطوبة ويخلط جيد مع المادة الرابطة (البنتونايت). تم تجفيف القوالب بوساطة حراقات الغاز المنزلي العادي.

يبين الشكل (2)، (3) عينات من الكروم وعينات من الموليبيدينوم والتحليل الطيفي لكل منهما:

إعداد الحسابات اللازمة لتشكيل سبيكة خاصة بالتطبيقات الشاقّة بصهر الفولاذ والكروم والموليبدنوم  
في فرن تحريضي



Foundry-Master 01M0026 Optik 01M0026

Sample :

Alloy : CR-100 Mode : PA 1/2/2023 8:09:03 PM

	Fe	C	Si	Mn	P	S	Cr
1	25.310	0.200	0.330	0.500	0.002	0.001	70.000
2	25.308	0.240	0.370	0.520	0.001	0.002	71.000
Average	25.309	0.220	0.350	0.510	0.001	0.001	70.000

	Mo	Ni	Al	Co	Cu	Nb	Ti
1	0.002	0.100	3.501	0.008	0.007	0.000	0.000
2	0.003	0.100	3.499	0.009	0.008	0.000	0.000
Average	0.002	0.100	3.500	0.007	0.007	0.000	0.000

	V	W	Pb	Sn	B	Ca	Zr
1	0.000	0.000	0.000	0.000	0.000	0.000	0.000
2	0.000	0.000	0.000	0.000	0.000	0.000	0.000
Average	0.000	0.000	0.000	0.000	0.000	0.000	0.000

	As	Bi
1	0.000	0.000
2	0.000	0.000
Average	0.000	0.000

الشكل (2) عينات من الكروم والتحليل الطيفي لها



Foundry-Master 01M0026 Optik 01M0026

Sample :

Alloy : CR-100 Mode : PA 5/2/2023 6:59:07 PM

	Fe	C	Si	Mn	P	S	Cr
1	25.822	0.300	0.290	0.533	0.001	0.002	0.005
2	25.805	0.280	0.330	0.530	0.001	0.002	0.004
Average	25.813	0.240	0.310	0.531	0.001	0.002	0.004

	Mo	Ni	Al	Co	Cu	Nb	Ti
1	69.059	0.001	4.000	0.001	0.003	0.000	0.001
2	69.110	0.003	4.002	0.002	0.005	0.000	0.002
Average	69.084	0.002	4.001	0.001	0.004	0.000	0.001

	V	W	Pb	Sn	B	Ca	Zr
1	0.000	0.000	0.000	0.000	0.000	0.000	0.000
2	0.000	0.000	0.000	0.000	0.000	0.000	0.000
Average	0.000	0.000	0.000	0.000	0.000	0.000	0.000

	As	Bi
1	0.000	0.000
2	0.000	0.000
Average	0.000	0.000

الشكل (3) عينات من الموليبيدينوم والتحليل الطيفي لها

إعداد الحسابات اللازمة لتشكيل سبيكة خاصة بالتطبيقات الشاقّة بصهر الفولاذ والكروم والموليبدنوم  
في فرن تحريضي

---

في المحلول الصلب للفولاذ الأوستنيتي مع الكروم والموليبدنوم يتواجد أكسيد المنغنيز،  
أكسيد الحديد، أكسيد السيليسيوم، أكسيد الكروم وأكسيد الموليبدنوم وهي أكاسيد منحلة  
في الخبث. وأيضاً كل من  $\{N_2\}$ ،  $\{H_2O\}$ ،  $\{CO\}$  كغازات.

2-تمّت عملية الصب من الفرن إلى بوتقة مسخنة ذات ذراعين عند الدرجة 1700  
مئوية تقريباً. بمساعدة الرافعة الجسرية في المعمل وتوجيه عاملين كل عامل على ذراع،  
تمّ صب المصهور المعدني في القوالب الرملية ثم تبريد العينات بالماء العادي بعد التجمّد  
في كل من الصهرتين. ويبين الشكل (4) أفران وقوالب الصب المستعملة:



الشكل (4) أفران الصهر والصب في احد القوالب الرملية المجهزة بالإضافة للوحة التحكم ببارامترات الصهر

إعداد الحسابات اللازمة لتشكيل سبيكة خاصة بالتطبيقات الشاقّة بصهر الفولاذ والكروم والمولبيديوم في فرن تحريضي

3- باستخدام آلة القص تم إزالة الزوائد المعدنية من العينات الناتجة. يبين الشكل (5) آلة القص:



الشكل (5) آلة القص

4- تم أخذ عينات وتجهيزها للتحليل الطيفي.

يبين الجدول (1) و(2) نتائج التحليل الطيفي للصهرتين بواسطة جهاز التحليل الطيفي، الجدول (1) التحليل الطيفي للعينات المصنعة من فولاذ هادفيلد صنف D والمضاف لها معدني الكروم 1.5% والمولبييوم 0.9%

Foundry-Master 01M0026 Optik 01M0026  
Sample :  
Alloy : FE-100 Mode : PA 20/1/2023 10:02:28 AM

	Fe	C	Si	Mn	P	S	Cr
1	80.522	1.170	0.251	12.130	0.001	0.001	1.375
2	82.516	1.165	0.275	12.151	0.002	0.001	1.635
Average	80.519	1.167	0.263	12.140	0.015	0.001	1.505

	Mo	Ni	Al	Co	Cu	Nb	Ti
1	0.912	2.845	0.111	0.010	0.012	0.004	0.001
2	0.868	3.324	0.546	0.090	0.020	0.002	0.003
Average	0.890	3.084	0.328	0.05	0.016	0.003	0.002

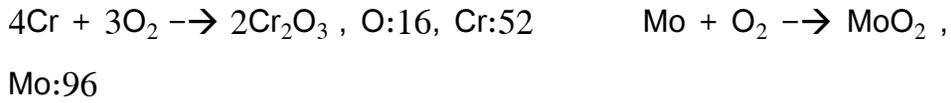
	V	W	Pb	Sn	B	Ca	Zr
1	0.002	0.001	0.002	0.010	0.001	0.001	0.003
2	0.008	0.001	0.001	0.009	0.001	0.002	0.003
Average	0.005	0.001	0.001	0.009	0.001	0.001	0.003

	As	Bi
1	0.000	0.000
2	0.000	0.000
Average	0.000	0.000



إعداد الحسابات اللازمة لتشكيل سبيكة خاصة بالتطبيقات الشاقّة بصهر الفولاذ والكروم والمولبيديوم  
في فرن تحريضي

وكتلة أكسيد الكروم وأكسيد المولبيديوم هي:



208	304	96	128
$82.5 \times 10^{-7}$	Oxide	$45 \times 10^{-7}$	Oxide

$$\text{Oxide} = 1.2 \times 10^{-5} \text{ gr} \rightarrow 3.95 \times 10^{-6} \% \quad \dots \quad \text{Oxide} = 6 \times 10^{-5} \text{ gr} \rightarrow 46 \times 10^{-6} \%$$

بالنسبة لباقي الأكاسيد سنحسب كل منها:

Si in  $\text{SiO}_2$ : (0.35 in Cr specimen+0.283 hadfield D)-0.263 hadfield with Cr, Mo =0.37%

Mn in  $\text{MnO}$ : (0.510 in Cr specimen+12.075 hadfield D)-12.140 hadfield with Cr, Mo =0.445%



28	60	55	71
0.37	Oxide	0.445	Oxide

$$\text{Oxide}=0.793 \text{ gr} \rightarrow 1.321\% \quad \text{Oxide}=0.574 \text{ gr} \rightarrow 0.808\%$$

تحت ضغط ثابت 1 atom ودرجة حرارة حوالي 1700 مئوية (1973.15 كلفن) تكون

طاقة جيبس الحرة القياسية المعروفة بأنها أكبر كمية من الطاقة يمكن إطلاقها عند

حدوث عملية تحت ضغط ودرجة حرارة ثابتين لكل تفاعل هي:

$$\Delta G^0 = \Delta H^0 + \Delta S.T$$

$\Delta G_1^0 = 2900 - 11.18 T = -19159.817$	$\Delta G_2^0 = -40650 + 11.4 T = -18156.09$
$\Delta G_3^0 = 23550 + 21.99 T = 6693.56$	$\Delta G_4^0 = 131300 - 73.96 T = -14634.17$
$\Delta G_5^0 = -64200 + 31.39 T = 2262.82$	$\Delta G_6^0 = 84200 - 29.98 T = 25400.13$
$\Delta G_7^0 = 1721 + 11.4 T = 24214.91$	$\Delta G_8^0 = 15280 + 15.37 T = 45607.31$
$\Delta G_9^0 = 140013 - 100.23T = -37709.8$	$\Delta G_{10}^0 = +11295 - 85.95T = -141107.2$
$\Delta G_{11}^0 = +10165 - 72.23T = -117909.6$	$\Delta G_{12}^0 = +192130 - 86.15 = 39373.12$

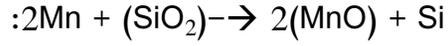
حيث درجة الحرارة بالكلفن. وطاقة جيبس Cal/mol، و S هو الانتروبي مقياس لدرجة عدم الانتظام بين الجزيئات أو الشوارد المكونة لنظام ترموديناميكي وهي أكبر ما يمكن في الغازات وأصغر ما يمكن في المعادن وبقيم متوسطة في السوائل وبالنسبة للتفاعلات فهو مجموع انتروبي نواتج التفاعل مطروحاً منه مجموع انتروبي مدخلات التفاعل.

H هي الطاقة اللازمة لتكون مول واحد من ذرات العنصر عند ضغط 1 atom ودرجة حرارة 25 مئوية.

$$\Delta G = \Delta G^0 + 2T \text{ Log } \frac{\text{activities oxides, metals and P gases}}{\text{activities oxides, metals and P gases}}$$

إعداد الحسابات اللازمة لتشكيل سبيكة خاصة بالتطبيقات الشاقّة بصهر الفولاذ والكروم والموليبدنوم  
في فرن تحريضي

- عند الدرجة 1700 مئوية يكون نشاط عناصر المعادلة



$$A_{\text{Si}}=1.148, A_{\text{Mn}}=0.121, A_{\text{MnO}}=1, A_{\text{SiO}_2}=1$$

حيث يتم حساب نشاط كل عنصر أو أكسيد بالعلاقة:

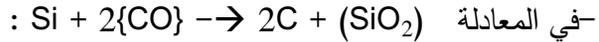
$$A_i = f_i \cdot (w\%)$$

$$\text{Log } f_i = \sum e_j^i (j\%)$$

$W$  هي النسبة الوزنية للعنصر أو الأكسيد،  $f_i$  هو معامل يتم حسابه،  $e$  هو معامل بين كل عنصرين ويعطى بجدول خاصة عند الصهر. وبالتالي المتغير في العلاقة هو فقط النسب الوزنية.

$$\Delta G_1 = -19159.817 + 2T \text{Log} \frac{(1.148)(1)^2}{(1)(0.121)^2} = -11684.043 \text{ Cal/mol}$$

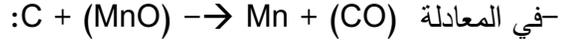
علماً أن الحالة القياسية لأكسيد المنغنيز هي الحالة الصلبة عند التوازن وبما أن الطاقة الناتجة سالبة فالنفاعل يحدث تلقائياً ومن الممكن تفاعل المعدن المصهور مع الرمل الذي يحوي سيليكاً حتى حدود الدرجة 1500 مئوية. مما يعني أن سطح المسبوكات قد يحوي سيليكون أعلى ومنغنيز أقل من مركز المسبوكات عند استعمال رمال السيليكا. ولتجنب ذلك يمكن استعمال الكلس عند الصهر.



$$A_{\text{Si}}=1.148, A_{\text{C}}=1.374, P_{\text{CO}}=1, A_{\text{SiO}_2}=1$$

$$\Delta G_4 = -14634.17 + 2T \text{Log} \frac{(1.148)(1)^2}{(1)(1.374)^2} = -15486.7 \text{ Cal/mol}$$

ويحدث التفاعلات تلقائياً طالما الطاقة أصغر تماماً من الصفر ويتعلق ذلك بدرجة الحرارة. ويمكن تقليل أكسيد المنغنيز بوساطة الكربون أو الغرافيت الذي ينصهر في الفولاذ.



$$A_{\text{Mn}}=1.121, A_{\text{C}}=1.374, P_{\text{CO}}=1, A_{\text{MnO}}=0.68$$

$$\Delta G_5 = 2262.82 + 2T \text{ Log} \frac{(1)(1.121)}{(0.68)(1.374)} = 2575.011 \text{ Cal/mol}$$

أي لا يحدث التفاعل طالما درجة الحرارة عالية ويانخفض درجة الحرارة حتى حوالي 1500 مئوية يكون  $A_{\text{MnO}}=0.55$  وبالتالي:

$$\Delta G_5 = -8540.82 + 2T \text{ Log} \frac{(1)(1.121)}{(0.55)(1.374)} = -7933.5 \text{ Cal/mol}$$

أي يحدث التفاعل تلقائياً عندما تنخفض درجة الحرارة إلى 1500 مئوية. لكن الاستعادة الأفضل للمنغنيز عند درجة الحرارة العالية حوالي 1700 مئوية. ويمكن هنا تفسير المسامات في المسبوكات نتيجة تفاعل أكسيد المنغنيز المحتجز في المعدن والكربون المنصهر.



$$A_{\text{Cr}}=1.52, A_{\text{C}}=1.374, P_{\text{CO}}=1, A_{\text{Cr}_2\text{O}_3}=0.9$$

$$\Delta G_9 = -37709.8 + 2T \text{ Log} \frac{(1.52 * 1.52)(1)}{(0.9)(1.374)^3} = -37725.813 \text{ Cal/mol}$$



$$A_{\text{Mo}}=1.48, A_{\text{C}}=1.374, P_{\text{CO}}=1, A_{\text{MoO}_2}=0.85$$

$$\Delta G_9 = -141107.2 + 2T \text{ Log} \frac{(1.48)(1)}{(0.85)(1.374)^2} = -141231.8 \text{ Cal/mol}$$

إعداد الحسابات اللازمة لتشكيل سبيكة خاصة بالتطبيقات الشاقّة بصهر الفولاذ والكروم والموليبدنوم في فرن تحريضي

بسبب ارتفاع نسبة المنغنيز في الفولاذ الأوستنيتي، تكون نسبة الأوكسجين المذاب في مصهور الفولاذ منخفضة جداً.

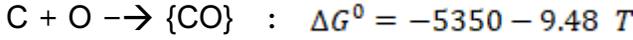


$$A_{\text{MnO}}=0.55, A_{\text{Mn}}=0.121, A_{\text{O}}=[\%0]$$

$$\Delta G = -58400 + 16.78 T + \text{Log} \frac{0.55}{0001\% \times 0.121} = -28642 \text{ Cal/mol}$$

وبذلك يكون التفاعل تلقائي بوجود نسبة قليلة جداً من الأوكسجين.

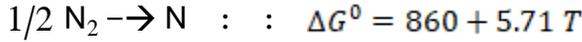
وينفس الأسلوب في التفاعل:



$$P_{\text{CO}}=1, A_{\text{C}}=1.37, A_{\text{O}}=\%0$$

$$\Delta G = -5350 - 9.48 T + \text{Log} \frac{1}{0001\% \times 1.37} = -22156.6 \text{ Cal/mol}$$

ونحسب انحلالية النتروجين في مصهور هادفيلد:



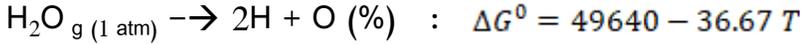
$$\Delta G = -R T \ln \frac{h_{\text{N}}}{\sqrt{P_{\text{N}_2}}}$$

$h_{\text{N}}$  هو نشاط النتروجين في الفولاذ ويحسب كنسبة من N% بحيث :  $h_{\text{N}}=0.832$  (%N)

$$\Delta G^0 = -2T \log \frac{0.832(\%N)}{\sqrt{0.79}} ; P_{\text{N}_2} = 0.79 \text{ atm at air}$$

يوضح هذا الحساب أن حد ذوبان النتروجين في فولاذ هادفيلد منخفض جداً وعند إضافة النتروجين بشكل متعمد سوف تنتج ثقب في المسبوكات عند التصلب كون النتروجين مثبت قوي للطور الأوستنيتي.

بالنسبة للهيدروجين فإنه يتسرب للفرن بسبب رطوبة الجو أو تسربات نظام التبريد ومغارف إزالة الخبث.



انحلالية الهيدروجين في مصهور الفولاذ الأوستنيتي حوالي 19 ppm (parts per million)، وبسبب انخفاض محتوى الأوكسجين وانصهار الكربون السريع فإن هناك خطر لالتقاط الهيدروجين من الشحنة الرطبة أو الإضافات السبائكية أو حتى عند الصب في القالب الرملي.

ويمكن في النهاية استعمال الغرافيت كعامل مرجع لتقليل حجم الخبث المزال وتفعيل استعادة المعادن من الأكاسيد كما توضح المعادلات (3)، (4)، (5) لكن C بشكل غرافيت. كما يمكن إضافة الألمنيوم أثناء الصهر عند شدة غليان المصهور وحدوث فورانه أو عند الصب كونه يهدئ المصهور.

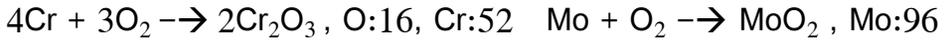
#### الصهرة الثانية:

كتلة الكروم X وكتلة الموليبيدينوم Y التي نقصت بالإحتراق والخبث المزال من سطح المصهور:

100	2.5	100	2.1
1.13	X	0.105	Y
X=2.5(1.13)/100=0.03 Kg		Y=0.9(0.105)/100=0.0022 Kg	

إعداد الحسابات اللازمة لتشكيل سبيكة خاصة بالتطبيقات الشاقّة بصهر الفولاذ والكروم والمولبيديوم في فرن تحريضي

وكتلة أكسيد الكروم وأكسيد المولبيديوم هي:



208                      304    96                      128

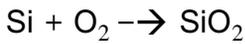
$3 \times 10^{-5}$                       Oxide     $22 \times 10^{-7}$                       Oxide

Oxide =  $4.40 \times 10^{-5}$  gr    Oxide =  $2.93 \times 10^{-6}$  gr

بالنسبة لباقي الأكاسيد سنحسب كل منها:

Si in  $\text{SiO}_2$ : (0.35 in Cr specimen + 0.283 hadfield D) - 0.257 hadfield with Cr, Mo = 0.376%

Mn in MnO: (0.510 in Cr specimen + 12.075 hadfield D) - 12.170 hadfield with Cr, Mo = 0.415%



28                      60    55                      71

0.376                      Oxide    0.415                      Oxide

Oxide = 0.805 gr  $\rightarrow$  2.201%    Oxide = 0.535 gr  $\rightarrow$  0.754%

في المعادلة  $(\text{Cr}_2\text{O}_3) + 3\text{C} \rightarrow 2\text{Cr} + 3\{\text{CO}\}$  :

$A_{\text{Cr}}=1.57, A_{\text{C}}=1.374, P_{\text{CO}}=1, A_{\text{Cr}_2\text{O}_3}=1.2$

$$\Delta G_9 = -37709.8 + 2T \text{Log} \frac{(1.57 * 1.57)(1)}{(1.2)(1.374)^3} = -37575.35 \text{ Cal/mol}$$

في المعادلة  $\text{MoO}_2 + 2\text{C} \rightarrow \text{Mo} + \{2\text{CO}\}$  :

$$A_{Mo}=1.6, A_C=1.374, P_{CO}=1, A_{MoO_2}=1.31$$

$$\Delta G_9 = -141107.2 + 2T \text{ Log} \frac{(1.6)(1)}{(1.31)(1.374)^2} = -141777.9 \text{ Cal/mol}$$

## 5- الاستنتاجات

- 1- تعطي هذه الحسابات فكرة عن أهم التفاعلات التي تجري عند الصهر تلقائياً والتفاعلات الغير تلقائية والتي تحتاج لتغيير في درجة الحرارة أو إضافة مكونات للمواد المصهورة لتحفيز هذه التفاعلات.
- 2- من خلال الحسابات الدقيقة تمت معرفة كمية المواد المراد صهرها للحصول على نسب معينة.
- 3- يحدث تفاعل المنغنيز مع أكسيد السيليكون تلقائياً وتكون الطاقة الحرة  $(-11684.043 \text{ Cal/mol})$ .
- 4- يحدث تفاعل السيليكون مع غاز أول أكسيد الكربون تلقائياً وتكون الطاقة الحرة  $(-15486.7 \text{ Cal/mol})$ .
- 5- لا يحدث تفاعل الكربون مع أكسيد المنغنيز تلقائياً طالما درجة الحرارة عالية وبتناقص درجة الحرارة حتى حوالي 1500 مئوية يحدث تلقائياً وتكون الطاقة الحرة  $(-7933.5 \text{ Cal/mol})$ .
- 6- يكون تفاعل تشكل أكسيد المنغنيز تلقائياً بوجود نسبة قليلة جداً من الأوكسجين.
- 7- حد ذوبان النتروجين في فولاذ هادفيلد منخفض جداً وعند إضافة النتروجين بشكل متعمد سوف تنتج ثقب في المسبوكات عند التصلب كون النتروجين مثبت قوي للطور الأوستيني.

إعداد الحسابات اللازمة لتشكيل سبيكة خاصة بالتطبيقات الشاقّة بصهر الفولاذ والكروم والموليبدنوم في فرن تحريضي

8- انحلالية الهيدروجين في مصهور الفولاذ الأوستنيتي حوالي 19 ppm (parts per million)، وبسبب انخفاض محتوى الأوكسجين وانصهار الكربون السريع فإن هناك خطر لالتقاط الهيدروجين من الشحنة الرطبة أو الإضافات السبائكية أو حتى عند الصب في القالب الرملي.

9- زادت الطاقة الحرة لتفاعل أكسيد الكروم مع الكربون والذي ينتج الكروم في الصهرة الثانية مقارنة بقيمة الطاقة الحرة لنفس التفاعل في الصهرة الأولى بسبب زيادة فعالية الكروم المتعلقة بنسبته الوزنية.

10- نقصت الطاقة الحرة لتفاعل أكسيد الموليبدنوم مع الكربون والذي ينتج الكربون في الصهرة الثانية مقارنة بالصهرة الأولى بالرغم من زيادة فعالية الموليبدنوم بسبب  $H$  التي تكون في تفاعل الموليبدنوم أكبر بحوالي 3.7 مرة من قيمتها في تفاعل الكروم.

#### 6- التوصيات:

1- يوصى بأخذ الحسابات الدقيقة بعين الاعتبار عند صهر المواد ومعرفة أهم التفاعلات الحاصلة والتي تؤثر على الخواص الميكانيكية للمنتج فيما بعد.

2- إضافة معادن أخرى غير موجودة في جداول ASTM A128 وإجراء الحسابات اللازمة لها.

3- اختبار الخواص الميكانيكية للسبيكة الناتجة وبنيتها المجهرية ومقارنتها بالسبائك التجارية المستعملة في الأعمال الشاقّة خاصة أصناف السبيكة ASTM A128.

4- تطبيق المعالجات الحرارية على السبيكة الناتجة وملاحظة تغيرات البنية المجهرية والخواص الميكانيكية.

7- قائمة المراجع

1. Li Shifeng ,2011. **A New production technique for wear resistance ring hammers.**
2. Olawale J. O.\*, Ibitoye S. A., Shittu M. D, 2013. **Workhardening Behaviour and Microstructural Analysis of Failed Austenitic Manganese Steel Crusher Jaws.**
3. Agunsoye, J.O. , Talabi, S.I., Bello, O ,2015. **Wear characteristics of heat- treated Hadfield austenitic manganese steel for engineering application.**
4. Guanqiao Su, 2016. **Influence of mn on the corrosion behavior of manganese steel.**
5. School of engineering ,2017. **On deoxidation practice and grain size of austenitic manganese steel.**
6. Arbash, 2017. **Impact toughness and wear resistance of low alloy steel, Al-Baath University.**
7. Chen Chen, 2018. **Strain hardening and nanocrystallization behaviors in Hadfield steel subjected to surface severe plastic deformation.**
8. Robert A, 2019. Vacuum sand casting hammer casting alloys,
9. Rawad Y Jabr, 2019. **Abaad Kasoha, Studing the influence of solidification speed on the resulting microstructure of Hadfield steel casting, Al-Baath University.**
10. Hatra, Salamah, Aldaher, 2021. **Improving mechanical properties (impact strength and wear resistance) of drilling teeth steel and breakers hammers, Tishreen University.**

11. Hatra Ali, Aktaa Samir, Jadeed Ali, 2004. **Manufacturing flexible cast iron in Syria with modern scientific methods and techniques, Tishreen University.**
- [12] Chang, line, 2019. **Hadfield manganese steel melting practices.**
- [13] Jinchen X ,2018. **Ecodesign for wear resistant ductile cast iron with medium manganese content.Mater Des;24:63 – 68.**
- [14] Chenje TW ,2017. **Results of survey on the Zimbabwean mining industry.Zimbabwe: SIRDC.**
- [15] Repas PE ,2015. **Microstructures and mechanical properties of API 2Y plate steels.Processing, microstructure and properties of HSIA steels.Pittsburgh: TMS.**
- [16] Chenje TW ,2011. **A study of relationships between microstructure, hardness, impact toughness and performance of mill balls in operation, M.Phil. Thesis, University of Zimbabwe.**
- [17] Evans JG ,2014. **A critical review of grinding media.Proceedings of the Cement Group Technical Conference.**

## تشكيل مادة مركبة مقاومة لرصاص البندقية

### الآلية كلاشينكوف عيار 7.62mm

\* م. ياسر يوسف قره فلاح

\*\* د. رامي حنا منصور

\*\*\* د. هادي عبد الكريم معلا

#### الملخص

يهدف هذا البحث إلى تشكيل مادة مركبة صفائحية متعددة الطبقات تقاوم الصدم عالي السرعة (مقاومة الطلقات الرصاصية) بهدف استخدامها كدروع حماية الأفراد والعربات والمراكز الهامة من اختراق الرصاص، وذلك باستخدام الريزين بولي استر غير المشبع UPR المملد بالمطاط الطبيعي ومواد تدعيم مختلفة (أنسجة طبيعية، أنسجة صناعية). دلت التجارب على إمكانية تشكيل مادة مركبة صفائحية مفردة ومادة مركبة هجينة بأساس ألياف صناعية وأخرى طبيعية، تقاوم رصاص البندقية الآلية عيار 7.62mm بنواة رصاصية.

**كلمات مفتاحية:** مادة مركبة صفائحية، ريزين البولي استر غير المشبع، مطاط طبيعي NR ، ألياف صناعية ، ألياف طبيعية، الصدم عالي السرعة، طلقات البندقية الآلية عيار 7.62mm ذات نواة رصاصية، ستاندر NIJ، مستويات الحماية، مقاومة الصدم، تشقق، انهيار، انفصال الطبقات.

- طالب دكتوراه في قسم هندسة التصميم والإنتاج - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين اللاذقية - سوريا
- \*\* أستاذ في قسم هندسة التصميم والإنتاج - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين اللاذقية - سوريا
- \*\*\* مدرس في قسم هندسة التصميم والإنتاج - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين اللاذقية - سوريا

## Forming a composite materials resistant to 7.62 mm caliber Kalashnikov automatic rifle bullets

\* Eng. Yasser Youssef kara fallah

\*\* Dr. Rami Hanna Mansour

\*\*\* Dr. Hadi Abed AL Kareem Moualla

### Abstract

This research aims to form a multi-layered composite material that resists high speed impact with using it as shields to protect individuals, vehicles and important centers from bullet penetration, using the unsaturated polyester resin (UPR), plasticized by natural rubber with different reinforcement materials (natural, synthetic fibers).

Experiments have shown the possibility of forming a single and hybrid laminated composite material based on natural or synthetic fibers that resists 7.62 mm caliber Kalashnikov bullet.

**Keywords:** Laminated Composite Material, Unsaturated polyester resin UPR, Synthetic fibers, Natural fibers, Nature Rubber, High Velocity Impact, 7.62 mm caliber Kalashnikov automatic rifle bullets with lead core, Layer separation, NIJ Standard, protection levels, Impact Strength, cracking, Failure , Delamination.

---

\* Doctorate student in Mechanical and Electrical Faculty - Design and Production Engineering Department – Tishreen University – Lattakia – Syria

\*\* Professor in Design and Production Engineering Department – Mechanical and Electrical Faculty – Tishreen University – Lattakia – Syria

\*\*\* Lecture in Design and Production Department – Mechanical and Electrical Faculty – Tishreen University – Lattakia – Syria

## 1- مقدمة

تستخدم المواد المركبة الصفائحية ( LCM Laminated Composite Materials ) بشكل كبير في مجال الحماية الشخصية، حيث أنها بشكل عام أخف وزناً وأكثر صلابة مقارنةً بالمعادن. وتتألف المادة المركبة الصفائحية من عدة طبقات من مزيج مركب يحوي على مادة رابطة (Matrix) وألياف (Fibers)، ويمكن أن تمتلك كل من هذه الطبقات خواصاً مادية متشابهة أو مختلفة عن بعضها وكذلك اتجاهات مختلفة للألياف وترتيب مختلف لتراس الطبقات فوق بعضها. [1]

إن النجاح الحالي الذي تلقاه المواد المركبة المدعمة بالألياف في تصنيع الدروع المقاومة للرصاص ذات الوزن الخفيف لم يحدث بين ليلة وضحاها، فقد بدأ محدوداً جداً ببضع أنواع من الألياف ونوع محدد من النسيج، ثم بعد ذلك ازداد مستوى الحماية عند استخدام الراتنج المتصلب حرارياً تحت تأثير الضغط والحرارة. [2]

إن هدف البحث هو تشكيل مادة مركبة مقاومة للرصاص بهدف استخدامها كدروع حماية الأفراد والعربات والمراكز الهامة من اختراق الرصاص، وذلك باستخدام الراتنج بولي استر غير المشبع Unsaturated Polyester Resin-UPR ومواد تدعيم مختلفة ( أنسجة طبيعية، أنسجة صناعية).

وبما أن إضافة اللدائن المطاطية إلى الراتنج UPR يؤدي إلى تحسين المتانة ومقاومة الصدمات للمزيج الناتج، لذلك سنستخدم هذا المزيج كمادة رابطة للأنسجة المستخدمة. [3]

## 2- الدراسة المرجعية Literature Review

هناك دراسات كثيرة عن خواص المواد المركبة الصفائحية وسلوكها عند التعرض للصدمة منخفض وعالي السرعة، فمثلاً أجرى الباحث Nadzri وزملائه في العام 2020 بمراجعة للخواص الميكانيكية للمواد المركبة الهجينة بأساس ألياف زجاجية/ألياف كتان

وسلوكتها تحت تأثير الصدم منخفض السرعة، وبينت النتائج بأن المادة المركبة بأساس هجين (ألياف زجاجية/كتان ) ومادة رابطة راتنج UPR ويمحتوى ألياف 40% تتمتع بقوة شد عالية 85MPa وتتحسن أكثر إذا ماتم معالجة ألياف الكتان، وهي تتحمل طاقة صدم منخفض السرعة تصل إلى 12 Joule، وهنا تم استكمال سلوك هذه المادة المركبة الهجينة بالصدم عالي السرعة (كطبقة أخيرة) ولكن بعد استخدام راتنج UPR المملدن بالمطاط. [4]

كما قام الباحث Luz وزملاءه في العام 2020 بدراسة مقارنة بين استخدام الألياف الطبيعية ( أوراق الأناناس) في الدرع المركب القاسي مع السيراميك ومقارنة أدائه مع الدرع الصلب من مادة البولي إيثيلين عالي الوزن الجزيئي، حيث تم استخدام درع مركب بإدخال 30% ألياف الأناناس مع الإيبوكسي كطبقة خلف صفيحة الدرع السيراميكي وأعطت نتائج أفضل من ناحية الأثر الخلفي عند اختبارها بطلقة البارودة عيار 7.62mm، حيث خفضت الأثر الخلفي إلى 26.6mm في حين كان لدرع البولي إيثيلين 41.4mm، مما يعكس ذلك تحسين سماكة الدرع. [5]

تم تسليط الضوء في هذه الدراسة على إمكانية استخدام الألياف الطبيعية في نظام الدرع الصلب وإمكانية تحسين سماكته وأدائه في مقاومة الطلقات الرصاصية الحي عن طريق استخدام الدرع متعدد الطبقات.

في دراسة حديثة بعنوان استجابة الصفائح المركبة الهجينة للصدمة البالستية للباحثة Moli وزميلها في عام 2019 بينت آلية الضرر لمادة مركبة بأساس هجين ( ألياف كيفلر مع ألياف الكيناف الطبيعية ) والتي تتمثل بكسر الألياف ونزوعها من مكانها وتهشم الراتنج، وتبين بأن مزج الألياف الطبيعية مع الصناعية أدى إلى نتيجة إيجابية على طاقة الاختراق عند الصدم البالستي وخاصة على الحد البالستي وامتصاص الطاقة. [6]

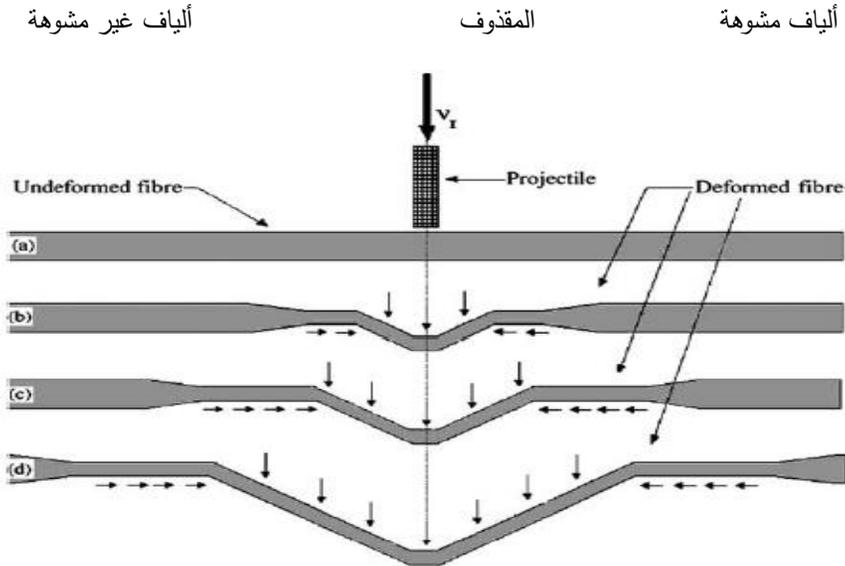
وفي دراسة للباحث Oliveira وزملاءه في العام 2019 تم فيها تقييم فقدان الطاقة لمقذوف عند عبوره في مادة مركبة بأساس ألياف الخيزران وراتنج البولي استر، حيث تم تشكيل مادة مركبة بنسب مختلفة من الألياف المذكورة (10,20,30%) حجماً مع UPR واختبارها بطلقة البندقية الآلية عيار 7.62 mm، وأشارت فقدان الطاقة المحسوبة للقذيفة إلى تبيد طاقة كبيرة نسبياً في المادة المركبة، كما تبين أن أفضل النسب هي 30% في التطبيقات متعددة الطلقات حيث بددت طاقة حوالي 100 Joule من طاقة القذيفة، وبالتالي يمكن أن تحل مكانها كطبقة ثانية في انظمة الدروع متعددة الطبقات نظراً لرخص ثمنها وصديقة للبيئة. [7]

في دراسة للباحث Braga وزملاءه في العام 2017 بعنوان أداء المادة المركبة بأساس ألياف الأناناس الطبيعية مع راتنج البولي استر تحت تأثير طلقة كلاشينكوف عيار 7.62mm كدرع باليستي مفرد، حيث تم تشكيل مادة مركبة بنسب مختلفة من الألياف المذكورة (10,20,30%) حجماً وبالنتيجة تبين أن أفضل النسب هي 30% في التطبيقات متعددة الطبقات مقارنة مع المادة المركبة بأساس ألياف الكيفلر، ويمكن أن تحل مكانها كطبقة ثانية في انظمة الدروع متعددة الطبقات. [8]

وفي دراسة حول سلوك المواد المركبة بأساس ألياف زجاجية مع راتنج البولي استر تحت تأثير الصدم عال السرعة للباحث Barcikowski في العام 2008 ، تم استخدام أنواع مختلفة من الألياف الزجاجية منها ماهو منسوج بغراماج (200,400,960 g/m<sup>2</sup>) ومنها ماهو غير منسوج (non woven mat) بغراماج (350,450 g/m<sup>2</sup>) ، وينسب تحميل من (20%,60%) وإجراء اختبار صدم عالي السرعة بكرات فولاذية وزنها 3 g وبسرعتين (60,70m/sec) ( تعطي طاقة حركية (5.4,7.35 j) وذلك باستخدام بندقية غاز بحيث نحافظ على عدم ثقب العينات للحفاظ على طاقة التأثير وإيجاد عدة بارامترات ( مثل مساحة منطقة تأثير المقذوف ومساحة

وحجم منطقة الأثر الخلفي للتشوه الحاصل ) وبنهاية البحث تم تصوير مجهري لمناطق التأثير وتبيان حجم التلف الحاصل في الألياف. [9]

كما قدم Shrirao وزميله في العام 2004 دراسة حول سلوك الصدم الباليستي للمواد المركبة المدعمة بألياف المنسوجة، ثم مقارنة سلوك الصدم بين المواد المركبة المؤلفة من الألياف الزجاجية المشربة براتنج الإيبوكسي، والمواد المركبة المؤلفة من الألياف الكربونية المشربة براتنج الإيبوكسي، وتم تحديد عدة ميكانيزمات للضرر وامتصاص الطاقة وهي: تشكل مخروط (بروز مخروطي) على الوجه الخلفي للهدف الشكل(1)، انهيار على الشد للطبقات الأولية للألياف، تشوه في الطبقات الثانوية للألياف، انزياح في الطبقات (فصل طبقي) ، تشقق المادة الرابطة، انسداد بالقص (shear plugging)، واحتكاك خلال الاختراق. كما وضعت صيغة تحليلية لكل ميكانيزم من ميكانيزمات امتصاص الطاقة وتم تحديد كل من الطاقة الممتصة خلال كل فترة زمنية، والتناقص في سرعة القذيفة. [10]



الشكل (1) يوضح شكل طبقات الألياف قبل وبعد الصدم. (a) قبل الصدم. (b,c,d) بعد الصدم. [10]

كما تم التوصل الى أنه في ظروف الصدم الباليستي المثالية فإن الحد الباليستي لـ E-glass/epoxy أعلى منه لـ T300 carbon/epoxy . وأن الطاقة الممتصة من قبل طبقة الألياف الثانية، والانهياب على الشد لطبقة الألياف الأولى هي التي تشكل الميكانيزمات الرئيسية لامتصاص الطاقة في الـ E-glass/epoxy، أما بالنسبة لـ T300 carbon/epoxy فإن ميكانيزمات امتصاص الطاقة الرئيسية تحدث في الطبقة الثانية وفق مايسمى بظاهرة الانسداد بالقص [10]. Shear Plugging.

استناداً للدراسات المرجعية السابقة فإن هدف البحث هو :

تشكيل مادة مركبة بأساس ألياف - مع راتنج البولي استر غير المشبع المعدل بالمطاط الطبيعي Natural Rubber -مقاومة لخصائص البندقية الآلية كلاشينكوف عيار 7.62mm.

### 3- مواد وطرق البحث

#### 3-1-المواد الأولية :

\*- ريزين البولي استر غير المشبع UPR معدل بالمطاط الطبيعي بنسبة 2% (القيمة التي أعطت أعلى قيمة لمقاومة للصدم، وتم الحصول عليها نتيجة اختبارات في سياق البحث الرئيسي).

#### \*-الألياف الصناعية Synthetic fibers

هي تلك الألياف التي يعتمد إنتاجها إلى حد كبير على استخدام مواد مبتكرة جديدة وتقنيات صناعية متطورة، حيث تتميز بكفاءتها في تعزيز الخواص، لذلك تضاف إلى المنتجات النهائية لإكسابها الخواص المطلوبة التي تجعل هذه المنتجات تقاوم ظروف الاستخدام المختلفة.

تشكيل مادة مركبة مقاومة لرصاص البندقية الآلية كلاشينكوف عيار 7.62mm

إن أهم الألياف الصناعية التي تستخدم في تشكيل المواد المركبة هي: ألياف الكيفلر (Kevlar)، وألياف الزجاج (S,E-glass)، ألياف البازلت (Basalt)، والألياف الكربونية الشكل (2). [11]

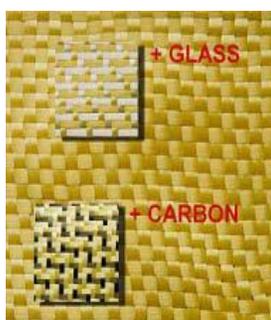
يبين الجدول (1) الأنسجة الصناعية المستخدمة مع مواصفاتها الأساسية.

الجدول (1) بعض مواصفات الأنسجة الصناعية المستخدمة

السماكة (mm)	الغراماج (وزن المتر المربع) (gr/m <sup>2</sup> )	نوع النسيج
0.50±0.05	300 ±5	نسيج زجاجي E EW300(Plain)
0.40±0.05	250 ±10	نسيج بازلتي BAS250 (Plain)
0.60±0.05	880 ±10	نسيج بازلتي BAS880 (Plain)
0.35±0.05	210 ±10	نسيج كيفلر Kevlar 29 (Plain)
0.55±0.05	500 ±10	نسيج كيفلر Kevlar 29 (Plain)
0.55±0.05	550 ±10	نسيج سيليك (Plain)
0.45±0.05	200 ±10	نسيج كربوني 200 (Plain)



ألياف بازلتية



ألياف كيفلر - زجاج-كربون



ألياف زجاجية

الشكل (2) بعض الألياف الصناعية المستعملة

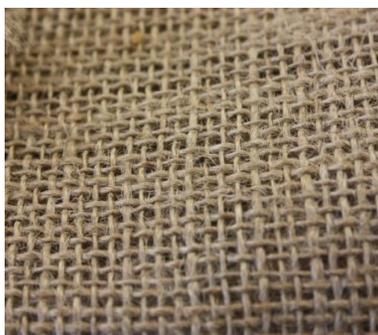
#### \*-الألياف الطبيعية Natural fibers

تم استخدام نوعين منها وهما ألياف الجوت أو الخيش Jute fibers، والصوف الحيواني

#### Animal Wool

تم استخدام ألياف الجوت Jute fibers التي تتميز بالقوة والمتانة والوزن الخفيف، كما تمتاز أيضا بخاصية الحماية من الأشعة فوق البنفسجية وعزل الصوت والحرارة إضافة إلى العازلية الحرارية الجيدة والخصائص المضادة للكهرباء الساكنة الشكل (3).

[12]



الشكل (3) نسيج القنب Jute fiber

### 3-2- تحضير عينات المواد المركبة

تم تحضير عينات المواد المركبة بأساس ألياف صناعية بعدد طبقات متغير من صفحة لأخرى ( كيفلر، زجاجية، بازلتية )، وذلك وفق الخطوات التالية :

1- تحضير خليط المادة الرابطة وهو عبارة عن ريزين البولي استر غير المشبع UPR المضاف له المطاط الطبيعي بنسب وزنية (2%W) .

2- قص طبقات النسيج وفق الأبعاد المناسبة ( مع ملاحظة معالجة النسيج الطبيعي بمحلول هيدروكسيد الصوديوم بتركيز 11% لتنظيفه من الأوساخ المختلفة وتهيبته لزيادة ارتباطه بالمادة الرابطة).

3- دهن القالب بمادة مانعة للالتصاق.

4- تشريب جميع طبقات الألياف بالمادة الرابطة باستخدام فرشاة.

5- تنضيد طبقات النسيج المشربة فوق بعضها البعض ضمن القالب ثم التشكيل بالمكبس الحراري وفق البارامترات التالية:

ضغط 15-20 Ton - حرارة قالب  $120^{\circ}\text{C}$  - زمن 30 min.

5- إزالة الضغط وفتح القالب.

6- نزع القطعة المشكلة.

7- بغرض تحقيق التصلب الكامل تم وضع العينات بعد تصلبها داخل فرن كهربائي في درجة حرارة  $60^{\circ}\text{C}$  مدة 2-3 hr. تسمى هذه العملية بالمعالجة الحرارية السريعة (Post Curing)، وبعد إتمام هذه العملية تصبح العينات جاهزة للفحص والاستخدام.

### 3-3- طريقة اختبار مقاومة المادة المركبة للصدم عالي السرعة

تم اختبار الدروع الصلبة ( صفائح المواد المركبة ) بما يتناسب مع معيار معهد العدالة الأمريكي NIJ 0101.06 الخاص باختبارات الدروع المقاومة للرصاص وتحديد كافة الشروط والأدوات اللازمة وباستخدام أسلحة وطلقات محددة، وذلك نظراً لانتشار هذا المعيار بشكل كبير واعتماده من قبل العديد من دول العالم. سيتم تنفيذ الاختبار وفق الإمكانيات المتاحة والأسلحة المتاحة، مع التقيد ببعض الشروط الممكن تحقيقها من المعيار المذكور. [13]

تم تحضير العينات واختبارها في كلية جامعة تشرين-كلية الهندسة الميكانيكية والكهربائية-قسم هندسة التصميم والإنتاج-مخبر البلاستيك.

### 4- النتائج والمناقشة

تتعرض المواد المركبة الصفائحية ( مادة أساس بوليميرية، ألياف تسليح )، إلى أنواع مختلفة من الإجهادات عند تعرضها للصدم بسرعات عالية، بواسطة طلقات البندقية الآلية، ونتيجة لذلك يتعرض الهدف إلى أضرار متنوعة وخاصة عند حدوث اختراق، حيث تتعرض مادة الأساس البوليميرية للتفتت والتشطي، بينما تتعرض ألياف التسليح إلى التمزق وفصل في الطبقات نتيجة لتشكيل إجهادات قص، بالإضافة إلى أضرار أخرى متنوعة يمكن ملاحظتها بالعين المجردة.

واستناداً للدراسات المرجعية المستعرضة في بحثنا، ولنتائج الاختبارات الميكانيكية التي أنجزت في سياق بحثنا توصلنا إلى فناعة بأنه لا بد من ضرورة تلدين الراتنج UPR لتحسين خواص الصدم وزيادة استطالته لمنع حدوث تشطيه من ناحية، بالإضافة إلى عمله كجملة واحدة مع الألياف أو المادة المقوية، وأيضاً اعتماد استخدام أنواع أخرى من الألياف ( كيفلر، بازلت ....الخ) لتصنيع عدد كبير من العينات المفردة والهجينة بهدف الحصول على عينات مقاومة لاختراق الرصاص ( المسدس، البندقية الآلية).

#### 4-1- العينات الأولية التي تم اختراقها من قبل رصاص البندقية الآلية الروسية

#### كلاشينكوف 7.62mm

تم تشكيل عينات أولية على شكل صفائح مفردة من المواد المركبة بأساس ألياف صناعية لوحدها أو تهجين مع ألياف طبيعية، وتم اختبار تلك العينات إما بشكلها المفرد أو بالشكل الهجين المكون من عدة صفائح متوضعة فوق بعضها البعض وذلك بهدف توجيه البوصلة بشكل صحيح للتوصل إلى درع مفرد أو هجين يقاوم الصدمات عالية السرعة الناجمة عن رصاص البندقية الآلية الروسية كلاشينكوف 7.62mm.

أظهرت نتائج بحث ماجستير لعام 2016 في كلية الهندسة الميكانيكية والكهربائية - قسم هندسة التصميم والإنتاج - مخبر البلاستيك ، أن الاختبارات التي أجريت على عدد كبير من عينات الاختبار بأن التسليح حتى ولو كان بعدد كبير من طبقات الألياف الزجاجية المنسوجة أو غير المنسوجة (عشوائية على شكل صوف) مع الراتنج UPR (حتى 17 طبقة)، غير كافٍ لمنع اختراق الصفائح لطلقة البندقية الآلية 7.62mm.

[14]

لذلك عمدنا إلى تشكيل عينات أولية باستخدام أنواع أخرى من الألياف، وبيين الجدول (2) نتائج الاختبار الوظيفي للعينات الأولية المشكلة، والتي تم اختراقها بشكل كامل من قبل رصاص البندقية الآلية كلاشينكوف AK47 عيار 7.62mm بنواة رصاصية.

الجدول (2) نتائج اختبار مقاومة رصاص البندقية الآلية كلاشينكوف AK47 عيار 7.62mm بنواة رصاصية- لصفائح مركبة بأساس ألياف مشربة بالراتنج UPR المدن بـ 2% من المطاط الطبيعي

نتيجة الاختبار الوظيفي	سماكة العينة mm	رمز العينة	ماهية العينة	رقم العينة
اختراق طلقة كلاشينكوف AK47 بنواة رصاصية	15.2	50BaF(880)- UPR2%NR	صفائح مركبة صلبة عدد 2 بأساس نسيج بازلتني غراماج $880g/m^2$ ( BaF ) عدد طبقات 50	01
	15.1	50KF(500) - UPR2%NR	صفائح مركبة صلبة عدد 2 بأساس نسيج كيفلر غراماج $500g/m^2$ ( BaF ) عدد طبقات 50	02
	34	(50Ba(880)+ 21Wjute)- UPR2%NR	صفائح مركبة هجينة بأساس ألياف صناعية ( بازلتية عدد 2 50 طبقة $880g/m^2$ )- مع ثلاث أقراص من مادة مركبة بأساس ألياف طبيعية ( قنب سماكة 7.2mm	03

### الخلاصة

1- لا تكفي استخدام 50 طبقة من الألياف البازلتية ذات الغراماج  $880g/m^2$  في المادة المركبة في صد طلقة البندقية الآلية كلاشينكوف AK47 بنواة رصاصية ( العينة 01).

2- لا تكفي استخدام 50 طبقة من ألياف الكيفلر ذات الغراماج  $500g/m^2$  في المادة المركبة في صد طلقة كلاشينكوف AK47 بنواة رصاصية ( العينة 02).

3- لم تقدم صفائح المواد المركبة بأساس ألياف الجوت بعدد طبقات 21 طبقة أي مقاومة لطلقات البندقية الآلية كلاشينكوف AK47 عيار 7.62mm بنواة رصاصية عند استخدامها مع 50 طبقة من ألياف بازلتية  $880g/m^2$  ( العينة 03).

4-2- تصميم عينات من صفائح مركبة مقاومة لاختراق رصاص البندقية الآلية الروسية كلاشينكوف 7.62mm بنواة رصاصية

وجهت نتائج العينات الأولية بتشكيل عدة عينات مكونة من عدة صفائح مركبة مفردة متوضعة فوق بعضها البعض باستخدام المادة الرابطة (الراتنج UPR المدن بالمطاط الطبيعي NR بنسبة 2%) كما وارد في الجدول (3)، وتم ربط هذه الصفائح بشريط لاصق خارجي مع بقاءها منفصلة عن بعضها البعض دون وضع أي مادة لاصقة بينها.

الجدول (3) العينات المركبة الهجينة بأساس ألياف صناعية مع بعضها أو مع الألياف الطبيعية

ت	وصف العينة	رمز العينة	سماكة العينة mm
1	صفائح مركبة هجينة بأساس ألياف صناعية	[25BaF(880) +150GF(300)+10BaF880)]- UPR2%NR	67.42
2	صفائح مركبة هجينة بأساس ألياف صناعية	[75GF(300)+25BaF(880) +25KF(500)] - UPR2%NR	51.05
3	صفائح مركبة هجينة بأساس ألياف صناعية	[50KF(210)+50BaF(250)+13SiF(550)]- UPR2%NR	48.5
4	صفائح مركبة هجينة بأساس ألياف صناعية	[25BaF(880)+25KF(500)+ 9SiF(550)+8CF(200)] -UPR2%NR	40.01
5	صفائح مركبة هجينة بأساس ألياف صناعية وطبيعية	[25BaF(250) +25KF(210)+50BaF(880)+aniwool] - UPR2%NR	45.83
6	صفائح مركبة هجينة بأساس ألياف صناعية وطبيعية	[50Ba(880)+ 50GF(300)+ 28Wjute]- UPR2%NR	77.06

تم اختبار العينات وظيفياً باستخدام رصاص البندقية الآلية كلاسينكوف AK47 عيار 7.62mm بنواة رصاصية، وذلك بهدف التوصل إلى تصميم لدع أمثلي يقاوم الصدمات عالية السرعة، ويبين الجدول (4) نتائج الاختبارات الوظيفية المنفذة.

الجدول (4) نتائج اختبار مقاومة رصاص بندقية كلاسينكوف AK47 بنواة رصاصية للعينات غير المختزقة بشكل كامل

ت	مكونات العينة	نتيجة الاختبار الوظيفي
1	<p>صفیحة مركبة /عدد 1/ مسلحة بألیاف بازلتیة            880g/m<sup>2</sup> بعدد طبقات 25 وسماكة 16.780 mm، وهي تمثل الوجه الأمامي لعينة الاختبار Front Face + صفائح مركبة /عدد 6/ مسلحة بألیاف زجاجیة            300g/m<sup>2</sup> كل صفیحة عبارة عن 25 طبقة            وسماكة 7.25mm، أي بعدد طبقات إجمالي 150 طبقة            وسماكة 43.5 mm صفیحة مركبة مسلحة بألیاف بازلتیة            880g/m<sup>2</sup> بعدد طبقات 10 وسماكة 7.135mm،            وهي تمثل الوجه الخلفي للعينة أثناء الاختبار Back Face.            [25BaF(880)+150GF(300)+10BaF(880)]-            UPR2%NR</p>	<p>نتیجة الاختبار الوظيفي            حدوث اختراق القذیفة للصفیحة المركبة الأولى            ولجميع الصفائح المسلحة بألیاف الزجاج وعددها 6 فقط، مع أثر خلفي بحدود 6mm .            حدوث انحراف بزوایة ورود الطلقة ضمن طبقات الصفائح المركبة، ويعود ذلك إلى انزياح الصفائح عن بعضها البعض بفعل الصدمة العالیة، والذي يعود سببه إلى طریقة ربط الصفائح مع بعضها البعض بواسطة شریط لاصق ورقی.</p>
2	<p>صفائح مركبة /عدد 3/ مسلحة بألیاف زجاجیة            300g/m<sup>2</sup> بعدد طبقات 75 وسماكة 21.96 mm، وهي تمثل الوجه الأمامي لعينة الاختبار Front Face + صفیحة مركبة مسلحة بألیاف بازلتیة            880g/m<sup>2</sup> - 25 طبقة وسماكة 15.65mm +            صفیحة مركبة مسلحة بألیاف كیفلر 500g/m<sup>2</sup> جراما            25 وسماكة 13.44mm، وهي تمثل الوجه الخلفي للعينة أثناء الاختبار Back Face .</p>	<p>نتیجة الاختبار الوظيفي            حدوث اختراق القذیفة للصفائح المركبة التي تمثل الوجه الأمامي للعينة بأساس ألیاف الزجاج، كما تم اختراق الصفیحة المركبة المسلحة بألیاف البازلت، في حين لم یحصل اختراق للصفیحة المركبة الخامسة والأخیرة التي تمثل الوجه الخلفي للعينة بأساس ألیاف الكیفلر مع أثر خلفي بحدود 5mm.</p>

تشكيل مادة مركبة مقاومة لרصاص البندقية الآلية كلاشينكوف عيار 7.62mm

	<p>- [75GF(300)+25BaF(880) +25KF(500)] UPR2%NR</p>	
<p>حدوث اختراق القذيفة لكامل طبقات الصفائح المسلحة بالكيفلر والبازلت، في حين لم يحصل اختراق للصفحة الأخيرة المسلحة بألياف السيليكيا مع وجود أثر لرأس المقذوف على شكل تشوه سطحي على الوجه الأمامي لها بقطر حوالي 1.5mm، دون حدوث أي أثر خلفي وذلك بسبب انفصال هذه الصفحة عن العينة من جراء الصدمة.</p> <p>من ناحية أخرى حصل انحراف بزواوية ورود الطلقة إلى الصفائح الأخيرة بسبب انزياح الصفائح عن بعضها البعض بفعل الصدمة العالية، والذي يعود سببه إلى طريقة ربط الصفائح مع بعضها البعض بواسطة شريط لاصق ورقي من ناحية، بالإضافة إلى تشكل اجهادات قص نتيجة للصدم عالي السرعة.</p>	<p>صفائح مركبة / عدد 3 / مسلحة بألياف كيفلر غراماج 210g/m<sup>2</sup> بعدد طبقات إجمالي 50 طبقة وسماكة 17.86mm وذلك على النحو التالي (عدد طبقات الصفحة الأولى والثانية 17 طبقة أما الصفحة الثالثة 16 طبقة)، وهي تمثل الوجه الأمامي لعينة الاختبار Front Face،</p> <p>- صفيحتين مركبتين مسلحة بألياف بازلتية غراماج 250g/m<sup>2</sup> بعدد طبقات 50 وسماكة 15.6mm،</p> <p>- صفيحة مركبة مشكلة من ألياف السيليكيا غراماج 550g/m<sup>2</sup> (عدد طبقات 13) بسماكة 8.30mm، وهي تمثل الوجه الخلفي للعينة أثناء الاختبار Back Face</p> <p>- [50KF(210)+50BaF(250)+13SiF(550)]- UPR2%NR</p>	<p>3</p>
<p>حدوث اختراق القذيفة لكامل الطبقات المركبة بأساس البازلت والكيفلر، في حين لم يحصل اختراق للصفحة المركبة بأساس ألياف السيليكيا والكربون مع وجود أثر لرأس المقذوف على الوجه الأمامي لها بقطر حوالي 1.6mm، تمثل بتشوه سطحي بسيط على شكل علامة مع تغلغل المقذوف لسماكة قليلة ضمن الطبقات دون نفاذه من الوجه الخلفي.</p> <p>من ناحية أخرى حدث انحراف بزواوية ورود الطلقة إلى الصفحة الأخيرة بسبب انزياح الصفائح عن بعضها البعض بفعل الصدمة العالية، والذي يعود سببه إلى طريقة ربط الصفائح مع بعضها البعض بواسطة شريط لاصق ورقي، مما أدى ذلك إلى</p>	<p>صفائح مركبة صلبة / عدد 2 / مسلحة بألياف بازلتية غراماج 880g/m<sup>2</sup> بعدد طبقات 25 وسماكة 18.025 mm وذلك على النحو التالي : (عدد طبقات الصفحة الأولى 12 طبقة، وللصفحة الثانية 13 طبقة)، وهي تمثل الوجه الأمامي لعينة الاختبار Front Face.</p> <p>-صفائح مركبة صلبة / عدد 2 / مسلحة بألياف كيفلر غراماج 500g/m<sup>2</sup> بعدد طبقات إجمالي 25 طبقة وسماكة 14.025 mm وذلك على النحو التالي (عدد الطبقات للصفحة الثالثة 12 طبقة، وللصفحة الرابعة 13 طبقة).</p> <p>صفحة مركبة مسلحة بألياف السيليكيا غراماج 550g/m<sup>2</sup> (عدد طبقات 9) بالإضافة لألياف الكربون غراماج</p>	<p>4</p>

انحراف الصفيحة الأخيرة عن المركزية مع سابقتها من الصفائح.	200g/m <sup>2</sup> (عدد طبقات 8)، وسماكة الصفيحة 8.05mm، وهي تمثل الوجه الخلفي للعينة Back Face. [25BaF(880)+25KF(500)+9SiF(550)+8CF(200)] -UPR2%NR
حدث اختراق القذيفة للصفائح المركبة المسلحة بألياف البازلت وكذلك صفيحة ألياف الكيفلر 210g/m <sup>2</sup> ، كما حصل اختراق شبه تام للصفائح المركبة المسلحة بألياف البازلت 880g/m <sup>2</sup> ، في حين حصل تحطم وانهيار تام للصفحة الرابعة المسلحة بالصوف الحيواني دون حصول أثر خلفي يذكر.	صفيحة مركبة /عدد 1/ مسلحة بألياف بازلت 250g/m <sup>2</sup> بعدد طبقات 25 طبقة بسماكة 9.40 mm، وهي تمثل الوجه الأمامي لعينة الاختبار Front Face. صفيحة مركبة /عدد 1/ مسلحة بألياف كيفلر 210g/m <sup>2</sup> بعدد طبقات إجمالي 25 طبقة بسماكة 11.25 mm. صفائح مركبة /عدد 2/ مسلحة بألياف بازلتية 880g/m <sup>2</sup> بعدد طبقات 50 بسماكة 17.35mm، وهي متوضعة في الوسط. صفيحة مركبة عدد 1 بأساس صوف حيواني (aniwool) بسماكة 7.83 mm، وهي تمثل الوجه الخلفي للعينة Back Face [25BaF(250) - +25KF(210)+50BaF(880)+aniwool] - UPR2%NR
حدث اختراق القذيفة للصفائح المركبة المسلحة بألياف البازلت وألياف الزجاجية 300g/m <sup>2</sup> ، كما حصل اختراق شبه تام للصفائح المركبة المسلحة بألياف البازلت 880g/m <sup>2</sup> ، في حين حصل تحطم وانهيار تام للصفحة الرابعة المسلحة بالصوف الحيواني دون حصول أثر خلفي يذكر.	صفائح مركبة هجينة عدد 4 بأساس ألياف صناعية (الأولى والثانية مكونة من ألياف بازلتية 50 - 880g/m <sup>2</sup> طبقة، والثالثة والرابعة مكونة من 50 طبقة من ألياف الزجاجية 300 g/m <sup>2</sup> ) + صفائح مركبة بأساس ألياف الجوت الطبيعية [50Ba(880)+ 50GF(300)+ 28Wjute]- UPR2%NR

### خلاصة نتائج اختبار العينات التي صمدت لطلقات البندقية الآلية

1- تصلح الصفائح المركبة بأساس ألياف الزجاج بغراماج  $300\text{g/m}^2$  ( بعدد طبقات 150 طبقة) لاستخدامها في الدروع المقاومة لطلقات كلاشينكوف AK47 بنواة رصاصية، فقط عند تهجينها مع طبقات مركبة من الألياف البازلتية ( $880\text{g/m}^2$ ) عدد 35 طبقة تتوضع بين صفيحتين أمامية مؤلفة من 25 طبقة وخلفية مؤلفة من 10 طبقات (العينه 1)، أو ( بعدد طبقات 75 طبقة) مع كلاً من مادة مركبة بأساس ألياف بازلتية ( $880\text{g/m}^2$ ) وألياف كيفلر ( $500\text{g/m}^2$ ) بعدد طبقات 25 لكل منهما (العينه 2)، وهنا يمكن القول بأن الألياف الزجاجية لم تقدم أي قيمة مضافة في مقاومة اختراق طلقات الكلاشينكوف AK47 بنواة رصاصية وبالتالي لايمكن اعتمادها كوصفة للإنتاج.

2- لم تصمد الصفائح المركبة بأساس 50 طبقة ألياف الكيفلر ( $210\text{g/m}^2$ ) مع 50 طبقات ألياف بازلت ( $250\text{g/m}^2$ ) ، حيث تم اختراقهما وتوقفت الطلقة بالطبقة الثالثة من الصفيحة ( $13\text{SiF}(550)$  المتوضعة خلفهما مع انفصالها عن المجموعة دون حدوث انخماص خلفي (العينه 3)، وبالتالي يمكن الاستنتاج بأنه لا يصلح هذين النوعين من الألياف بالغراماج  $(210, 250)\text{g/m}^2$  لوحدهما كدروع مقاومة لطلقات الكلاشينكوف AK47 بنواة رصاصية، أو يمكن تشكيل درع مهجن مؤلف من 25 طبقة من كل ألياف بازلت ( $250\text{g/m}^2$ )، و ألياف الكيفلر ( $210\text{g/m}^2$ ) كطبقات أمامية، مع 50 طبقة من ألياف البازلت غراماج  $880\text{g/m}^2$  كطبقة خلفية بالإضافة لصفيحة مركبة بأساس الصوف الحيواني ( العينه 5).

3- لم تصمد الصفائح المركبة بأساس 25 طبقة ألياف بازلت ( $880\text{g/m}^2$ ) مع 25 طبقة ألياف كيفلر ( $500\text{g/m}^2$ )، حيث تم اختراقهما وتوقفت الطلقة ببداية الصفيحة المركبة المكونة من  $9\text{SiF}(550) + 8\text{CF}(200)$  مع انفصالها عن المجموعة دون حدوث انخماص خلفي ، وبالتالي يمكن الاستنتاج بأن لا يصلح استخدام 25 طبقة من كل من هذين النوعين من الألياف بالغراماج المذكور لوحدها كدروع مقاومة لطلقات

كلاسيكوف AK47 بنواة رصاصية مالم نضع ورائهما صفيحة مركبة من ألياف سيليكيا والكربون ( العينة 4).

4- حدود استخدام الصفائح المركبة بأساس ألياف الجوت كدروع مقاومة لطلقات كلاسيكوف AK47 بنواة رصاصية هي فقط عند استخدام 26 طبقة خلف صفائح مواد مركبة بأساس (ألياف بازلتية  $880\text{g/m}^2$  - 50 طبقة + الألياف الزجاجية  $300\text{g/m}^2$  - 50 طبقة) ( العينة 6)، وهنا يبرر استخدام هذا النوع من الألياف الطبيعية لتخفيف كلفة إنتاج الدروع بحدود جيدة.

الخلاصة : تمكنا من تصميم عدة نماذج من الدروع المقاومة لرصاص البندقية الآلية عيار 7.62mm ( العينات من 1 ولغاية 6).

#### 4-3 ميكانيزم الصدم عالي السرعة للعينات المختبرة High Impact

##### Mechanism

يتطلب تصميم الصفائح المقاومة للصدم عالي السرعة، فهماً كاملاً لاستجابة التأثير الباليستي وانتشار الموجة أثناء عملية التأثير الباليستي، حيث يقدم الضرر المتشكل في عينات الاختبار نتيجة الصدم عالي السرعة فكرة هامة عن طبيعة العينات المصنعة، وقدرتها على مقاومة الاختراق.

تتعلق قدرة تخميد الصفائح المركبة للصدمة عالية السرعة الناجمة عن طلقات البندقية الآلية بنواة رصاصية عيار 7.62mm وامتصاص طاقتها وبالتالي اختلاف شكل الانهيار الناتج، بعوامل عدة منها نوع تلك الصفائح ( مفردة أو هجينة ) وسماكتها المتعلقة بعدد الطبقات، نوع الألياف المستخدمة، ومكان التوضع ونوع المادة الرابطة.....الخ.

كما رأينا في دراسة نتائج العينات المختبرة فإن الطلقات قد اخترقت جزء من الصفائح المركبة -المشكلة للعينات- بشكل كامل وجزء آخر تم الاختراق بشكل جزئي وفي كلتا الحالتين تم تسجيل أنماط مختلفة من التشوهات للعينات المختبرة ( شكلاً

## تشكيل مادة مركبة مقاومة لرصاص البندقية الآلية كلاشينكوف عيار 7.62mm

وأبعاداً) حسب نوع المواد الداخلة في تصنيع العينات وطريقة توضع الصفائح المختلفة وعدد طبقات كل منها، بالإضافة لطريقة التصنيع ونوع السلاح والطلقة ونواتها، وأيضاً في بعض العينات طبيعة التهجين المطبق وغير ذلك، وقد كان ذلك واضحاً بالعين المجردة .

لم تبدي الألياف الزجاجية  $300 \text{ g/m}^2$  مقاومة لاختراق رصاص البندقية الآلية كلاشينكوف عيار 7.62mm، وكان شكل الانهيار عندما كانت تمثل صفائح أمامية (العينة 2) على شكل تفتت تمزق الألياف داخل وفي جوار منطقة الاختراق مع عدم انسداد بالطبقات الشكل (4)، أما عندما الصفائح المركبة بأساس الألياف الزجاجية في الوسط (العينة 1) فاقتصر انهيارها على انفصال الطبقات وإزاحتها عن بعضها بعض بفعل اجهادات القص الشكل (5).



الشكل (4) تمزق الألياف داخل منطقة الاختراق مع عدم انسداد بالطبقات للصفائح

المسلحة بالألياف الزجاجية  $300 \text{ g/m}^2$  (1,2,3) من العينة 2

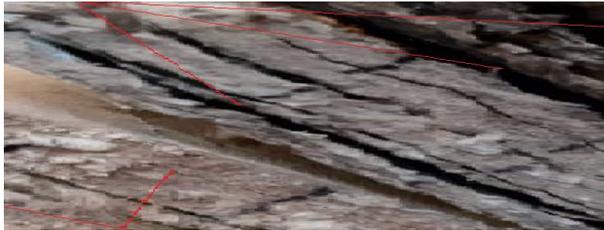


الشكل (5) انفصال طبقات الألياف الزجاجية  $300\text{g/m}^2$  - العينة 1

أما سلوك الألياف البازلتية  $880\text{g/m}^2$  فاختلف باختلاف موقع صفائحها المركبة، فمثلاً عندما كانت تمثل تلك الصفائح الطبقة الأمامية ( العينتين 1 و 4) تمثل الانهيار بالاختراق مع حصول تفتت وتمزق كبير بالألياف داخل وفي جوار منطقة الاختراق وانفصال غير تام للطبقات وانسدادها بالقص، وهذا يدل على قدرة هذه الألياف البازلتية على تشتيت طاقة الصدم وتفريغها في كامل طبقات ( الشكلين 6,7 ).



الشكل (6) مجرى الطلقة في الصفحة الأولى بأساس الألياف البازلتية  $880\text{g/m}^2$  للعينة 1



الشكل (7) فصل بين طبقات الصفائح المركبة بأساس ألياف بازلتية  $880\text{g/m}^2$  بشكل كامل -

العينة 4

في حين إذا توضع تلك الصفائح في الخلف ( العينة 5 ) فانحصر الانهيار بتفتت وتمزق بالألياف داخل وفي جوار منطقة الاختراق مع عدم حصول انسداد بالقص مع انفصال بسيط لطبقات ( الشكل 8).



الشكل (8) تمزق الألياف مع عدم حصول انسداد بالقص للصفحة المركبة بأساس ألياف

بازلت  $880\text{g/m}^2$  من العينة رقم 5

طبعاً حصل تحطم المادة الرابطة وتفتتها بشكل واضح وبالتالي يمكن القول بأن ألياف البازلت ( $880\text{g/m}^2$ ) تمكنت من امتصاص طاقة طلقة الكلاشينكوف وتبديد هذه الطاقة على شكل فصل بين طبقات الصفائح بشكل كامل على الرغم من حصول الاختراق التام.

بالنسبة لسلوك ألياف الكيفلر  $500\text{g/m}^2$  فأيضاً يتبع لموقع صفائحها المركبة فعندما تموضعت تلك الصفائح في الوسط ( العينة 4) خلف صفائح مركبة بأساس ألياف البازلت ( $880,250\text{g/m}^2$ ) فكان الاختراق تام للصفائح المركبة المسلحة مع تفتت وتمزق بالألياف وحصول الانفصال غير التام للطبقات مع بقاء تماسك بسيط وحصول انسداد جزئي للثقب الناجم عن تأثير الطلقة (الشكل 9,10).



الشكل (9) تفتت كبير بألياف الكيفلر  $500\text{g/m}^2$  المتوضعة خلف الألياف البازلتية دون

حصول الانفصال التام في العينة 4

في حين إذا توضع تلك الصفائح في الخلف ( العينة 2 ) خلف الطبقات 75GF(300)+25BaF(880) فانحصر الانهيار بحدوث تفتت أقل في مكان تأثر الطلقة مع عدم حدوث اختراق كامل وعدم حدوث انفصال لطبقات هذه الصفيحة، وهذا يدل على ضعف الطاقة الحركية وطاقة الصدم للقذيفة عند وصولها لهذه الصفيحة الشكل (84).



الشكل (10) تفتت قليل مع عدم حدوث انفصال لطبقات الصفيحة المركبة الخلفية

المسلحة بألياف الكيفلر  $500\text{g/m}^2$  - العينة 2

أما الصفائح المركبة بأساس ألياف كربونية و سيليكيا فلم تختبر إلا كطبقة خلفية التي لم يحصل الاختراق الكامل لهما ( العينتين 3,4 )، واقتصر الانهيار الجزئي على شكل تفتت وتمزق الألياف في موضع التأثير فقط دون حصول أي فصل للطبقات ( الشكل 11 ).



الشكل (11) عدم حصول الاختراق للصفيحة الأخيرة المسلحة بألياف السيليكيا والكربون

من العينة 4 مع وجود أثر لرأس المقذوف على الوجه الأمامي

نستخلص من ذلك أن تفوق استخدام الألياف البازلتية  $880\text{g/m}^2$  في امتصاص وتشتيت طاقة الصدم عالي السرعة ( طلاقات البندقية الآلية 7.62mm)، لكن رافق ذلك انفصال واضح بالطبقات، بينما تميز ألياف كيفلر في تماسك الطبقات وعدم انفصالها بشكل كامل، وكذلك عدم انسداد الثقب الناجم عن تأثير الطلقة. أما الألياف الزجاجية  $300\text{g/m}^2$  فأبدت تواضع في أداءها بشكل عام ورافق ذلك انفصال كبير بالطبقات وخاصة عند وجودها في وسط العينة أي خلف صفائح مركبة بأساس ألياف بازلتية أو كيفلر. لن نستطع إجراء مقارنة الألياف المذكورة مع ألياف الكربون والسيليكا كوننا لم نستخدم الأخيرة إلا كطبقة خلفية.

## 5- الاستنتاجات: Conclusions

1. إن استخدام ألياف صناعية بغراماج كبير نسبياً في الصفائح المركبة أو زيادة عدد الطبقات وبالتالي زيادة سماكة العينات، فإن ذلك يزيد من مقاومتها وقدرتها على امتصاص طاقة الصدم عالي السرعة، بغض النظر على نوع الألياف الصناعية المستخدمة.
2. بينت النتائج وجود أنماط مختلفة ومعقدة للضرر الحاصل في العينات، وتعتبر هذه الأنماط آليات فعالة لامتصاص طاقة الصدم، وتختلف باختلاف نوع الألياف الصناعية المستخدمة وعدد الطبقات وطريقة التوضع، حيث أظهرت الألياف السيليكا بغراماج  $550\text{g/m}^2$ ، والبازلتية بغراماج  $880\text{g/m}^2$  وألياف الكيفلر بغراماج  $500\text{g/m}^2$  أعلى قدرة على امتصاص طاقة الصدم عالي السرعة.

3. أظهرت التجارب أن الصفائح المركبة بأساس ألياف طبيعية غير كافية كبنية مستقلة لمقاومة قذائف عالية السرعة، وإنما يمكن أن تمثل جزء مهم لا يتجزأ من بنية الدرع المركب إذا ما استخدمت كصفائح خلفية.
4. لم ننجح بتشكيل مادة مركبة صفائحية مقاومة للصدمات عالية السرعة من مواد رخيصة الثمن، وإنما استطعنا في بعض العينات تخفيض كلفتها بإدخال الألياف الطبيعية كصفائح خلفية في الدروع المقاومة للرصاص.
5. تتعلق مسألة فصل الطبقات في الصفائح المركبة بعدة عوامل منها نوعية الألياف ودرجة ملائمتها مع المادة الرابطة (compatibility)، موقع الصفيحة المركبة في العينة، طريقة وجودة تصنيع الصفيحة المركبة، سرعة المقذوف وطاقته وزاوية التوجه نحو الهدف.....الخ، حيث أبدت كل من ألياف الكيفلر وألياف السيليكا التوافقية الأفضل من كل من الألياف الزجاجية وألياف البازلت مع المادة الرابطة ( العينتين 2,4 ).

## 6- المقترحات والتوصيات: Recommendations:

1. إجراء دراسة تجريبية على مستوى التلائم (compatibility) بين الألياف الصناعية والطبيعية المستخدمة كل منها، مع الراتنج بولي استر المعدل بالمطاط.
2. تكرارية التجارب على العينات الصامدة وزيادة عدد الطلقات على العينة الواحدة للتأكد من تحقيق الصمود ضد تعدد الطلقات كما هو وارد في المعيار NIJ.
3. يجب استخدام أنواع أخرى من الأسلحة والطلقات في الاختبارات من أجل التأكد من تحقيق مستويات الحماية III كما هو وارد في المعيار NIJ.

المراجع

- [1] SUNA B. A., 2015- **Design and Analysis of Laminated Composite Materials**. National Institute of technology, India.
- [2] WEETON J.W., PETERS D. M., THOMAS K. L., 1987- **Guide to Composite Materials**. American Society for Metals, Ohio.
- [3] BHUYANESWARY M. G., THACHIL, E. T., 2008- **Blends of Natural Rubber with Unsaturated Polyester Resin**. International Journal of Polymeric Materials and Polymeric Biomaterials, VOL57,N<sup>o</sup> 6,INDIA, 543-554.
- [4] ZUMAMIMI S. N., NADZRI A., SULTAN M. T. H., 2020- **A review on the Kenaf/Hybrid composites with limitations on mechanical and low velocity impact properties**. Polymers MDPI, Vol. 12, 1285.
- [5] FERNANDA S. D. L., COSTA F. D., FILHO G., OLIVEIRA M. S., **Composites with Natural fibers and conventional materials applied in a hard armor**. Vol. 12, Polymers MDPI, 2021, 1920.
- [6] LOGNATHAN T. M., SULTAN M.T.H., GOBALAKRISHNAN M. K., MUTHAIYAH G., 2019- **Ballistic impact response of laminated hybrid composite materials**. Mechanical and physical of Bio composites, Vol. 10, 1016.
- [7] OLIVEIRA, A., PEREIRA C., FOLUKE S. A., 2019- **Evaluation of the projectile's loss of energy in polyester**

composite reinforced with Figue fiber and fabric. Vol.22,

Mat. Res., 1516,1439.

[8] BRAGA F. D. O., BOLZAN L. T., MONTEIRO S. N.,  
2017-Performance of natural Curaua fiber-reinforced  
polyester composite under 7.62mm bullet impact as a  
stand-alone ballistic armor. Journal of materials research  
and technology, Vol. 6, 323-328.

[9] BARCIKOWSKI M., 2008-GLASS FIBRE /POLYESTER  
COMPOSITES UNDER BALLISTIC IMPACT. Vol. 8 - 1, 70-  
76.

[10] NAIK N.K . SHRIRAO P., 2004- *Composite Structures  
Under Ballistic Impact.* Vol. 66, Composite Structures, 579-590.

[11] WALLENBERGER F.T., 2001- Introduction to  
Reinforcing Fibers. ASM Handbook, Composites, ASM  
International, Vol 21.

[12] CHIFFOLO A. F., 2014 - World production of Jute  
Fibers, International Jute Study Group (IJSJ). 01-09.

[13] NIJ STANDARD -0101.06, 2008- Ballistic Resistance of  
Body Armor, National Institute of Justice, U.S. Department of  
Justice, Washington.

[14] Noura Suleiman , Master thesis 2016- **Improving the Mechanical Properties of Sheets prepared from Composite Materials used in the Lamination**, Tishreen University, Faculty of Mechanical and Electrical Engineering, Department of Design and production Engineering.