

## التنبؤ بقيم معامل الجودة في نظام WDM-FSO باستخدام تقنيات تعلم الآلة

رنيم يونس \*

(تاريخ الإيداع ٢٠٢٤/١/١٤ . قبل للنشر في ٢٠٢٤/٥/٢٠)

### □ ملخص □

يتطلب الاتصال البصري في الفضاء الحر (FSO: Free Space Optical) خط نظر مباشر بين جهاز الإرسال وجهاز الاستقبال حيث يتم إرسال الإشارات بواسطة ليزر ينتشر في الفضاء الحر. تتمتع هذه التقنية بالكثير من الميزات منها عرض النطاق الترددي العالي، الأمن العالي، استهلاك أقل للطاقة أقل، وتشويه أقل للإشارة. إلا أن قناة FSO تتأثر بشكل كبير بالظروف الجوية مثل الضباب والأمطار والثلوج. تم في هذا البحث دراسة تأثيرات التخامد الناتج عن الضباب والأمطار على معامل الجودة (Q-Factor) لنظام FSO مع تقنية تعديل (WDM: Wavelength Division Multiplexing) باستخدام برنامج Optisystem ، إضافة لإدخال خوارزميات التعلم الآلي للتنبؤ بمعامل الجودة للنظام المقترح اعتماداً على حالة الطقس.

أظهرت النتائج أن خوارزمية الغابة العشوائية أعطت دقة أفضل من خوارزميتي شجرة القرار وانحدار المتجه الداعم.

**الكلمات المفتاحية:** WDM –FSO – معامل الجودة – خوارزميات تعلم الآلة.

---

\* مهندسة في قسم هندسة تكنولوجيا الاتصالات- كلية هندسة تكنولوجيا المعلومات والاتصالات-جامعة طرطوس-سوريا.

## Predicting quality factor values in WDM-FSO system using machine learning techniques

**Eng. Ranim Younes\***

(Received 14/1/2024 . Accepted 20/5/2024)

### □ ABSTRACT □

Free-space optical communication (FSO) requires a direct line of sight between the transmitter and receiver as signals are transmitted by a laser propagating in free space. This technology has many advantages including high bandwidth, high security, lower power consumption, and less signal distortion. However, the FSO channel is greatly affected by weather conditions such as fog, rain and snow. In this research, we studied the effects of attenuation caused by fog and rain on the Q-factor of the FSO system with WDM modification on Optisystem software. Then machine learning algorithms were introduced to predict the quality factor of the proposed system depending on the weather condition. The results showed that the random forest algorithm gave better accuracy than the remaining two algorithms Decision Tree and Support Vector Regression.

**Keywords:** FSO – WDM – Q-Factor- Machine Learning Algorithms.

---

\* Engineer in Communication Technology Engineering Department, Faculty of Information and communication Technology Engineering, Tartous University, Syria

## ١ - مقدمة (Introduction):

يعد الاتصال البصري في الفضاء الحر (FSO) تقنية تستخدم أشعة الليزر لنقل المعلومات إلى جهاز الاستقبال عبر الفضاء الحر. حيث تم تطويره لتحقيق معدلات نقل بيانات عالية في الاتصال اللاسلكي، والذي غالباً يستخدم كبديل جيد لاتصالات الألياف الضوئية عندما تكون عملية نشر وتركيب الألياف الضوئية صعبة [1,2]. من أهم الميزات التي تقدمها هذه التقنية أن استهلاك الطاقة فيها منخفض بشكل ملحوظ مقارنة باتصالات الألياف الضوئية، والنطاق الترددي الواسع والتكلفة المنخفضة لعملية تأسيس الاتصال والأمان العالي وأيضاً لا يحتاج إلى ترخيص طيف مقارنة مع الاتصالات الراديوية [3,4]. لكن نظراً لكون قناة الاتصال هي الفضاء الحر، فإن حالات الطقس الجوية تشكل تهديداً لنظام FSO إضافة إلى الاضطرابات الجوية والخفوت المتعدد المسارات والكثير من العوامل التي تحد من وصول الإشارة إلى جهة الاستقبال بشكل صحيح وتزيد من معدلات خطأ البت وبكثير من الأحيان حدوث قطع في الاتصال [5,6].

في السنوات الأخيرة أدى إدخال تقنيات التعلم الآلي إلى أنظمة الاتصالات إلى إضافة الكثير من الذكاء. خاصة في قطاع الاتصالات الضوئية. حيث تم في دراسات سابقة التنبؤ بالعديد من البارامترات منها من عمل على التنبؤ بقيم BER في نظام اتصالات فضائي يستخدم تقنية تعديل OFDM حيث أظهرت النتائج أن خوارزمية الغابة العشوائية أعطت دقة أفضل في التنبؤ [7]، وفي دراسات أخرى تم استخدام طريقة معرفية تعتمد على خوارزميات تعلم الآلة لتقدير عدد المستخدمين المتصلين في نفس الوقت، أظهرت النتائج أنه تم الحصول على دقة تصل إلى ٩٢% في تقدير عدد المستخدمين حتى في حالة وجود اضطرابات جوية [8].

تم العمل في هذا البحث على مرحلتين، المرحلة الأولى تم فيها باستخدام برنامج Optisystem لبناء نظام FSO مع تقنية تعديل WDM مكونة من ٣٢ قناة حيث ترسل كل قناة بمعدل بيانات يبلغ 2.5 Gbps، وفي المرحلة الثانية، تم استخدام خوارزميات التعلم الآلي للتنبؤ بقيم معامل الجودة وذلك بالاعتماد على قاعدة البيانات التي تم جمعها من المرحلة الأولى والتي تتكون من قيم التخامد الناتجة عن الظروف الجوية (صحو-مطر-ضباب). إضافة إلى قيم المسافة بين جهاز الإرسال وجهاز الاستقبال كمميزات إدخال لكل نموذج من نماذج التعلم الآلي. تمت مقارنة أداء كل خوارزمية تعلم الآلة (Random Forest – Support Vector Regression – Decision Tree) من خلال حساب الدقة لكل منها باستخدام متوسط مربع الخطأ (MSE: Mean Square Error) ومعامل التصميم  $R^2$ .

## ٢ - أهمية وهدف البحث (Importance and Purpose of the research):


هدف البحث هو دراسة أداء نظام اتصال ضوئي في الفضاء الحر مع توظيف تقنية WDM والذي يستخدم لنقل ٣٢ قناة بصرية وذلك في حالات طقس جوية مختلفة ومن ثم تم توظيف خوارزميات تعلم الآلة للتنبؤ بقيم معامل الجودة المتعلق بالنظام.

### ٣- مواد وطرق البحث (Materials and Methods of research):

تم في هذا البحث الاعتماد على برنامج Optisystem لتنفيذ نظام WDM-FSO في المرحلة الأولى، واستخدام لغة البايثون من أجل تنفيذ تقنيات تعلم الآلة للتنبؤ بـقيم عامل الجودة بالاعتماد على قاعدة البيانات التي تم جمعها من المرحلة الأولى.

#### ٣-١ تقنية التجميع بتقسيم طول الموجة (WDM) Wavelength-Division Multiplexing:

تكمّن الميزة الأساسية لتعدد الإرسال بتقسيم الطول الموجي في توسيع الاتصالات الضوئية. عملت هذه التقنية على مضاعفة تدفق البيانات عبر حوامل ضوئية ذات أطوال موجية مختلفة تسمى القنوات وتنقل هذه البيانات كإشارة واحدة في نفس الوقت وعبر نفس الوسيط. وبالتالي زيادة معدل نقل البيانات للنظام الذي يستخدم تقنية WDM. بمعنى آخر أنه في WDM، ينقسم مجال الطيف البصري إلى عدة قنوات أصغر، يمكن استخدام كل قناة لإرسال واستقبال البيانات في نفس وقت [9]. يمكن الحفاظ على كل طول موجي كقناة منفصلة ويتم نقل بيانات مختلفة. يبين الشكل (١) شبكة WDM الضوئية.



يتم في هذه التقنية إرسال كل طول موجي بشكل منفصل بواسطة كل جهاز إرسال إلى أجهزة استقبال مختلفة. تتميز تقنية WDM بقدرتها على إرسال ترددات متعددة ومختلفة دون حدوث أي تدخل في البث. يوجد نوعان من أنظمة WDM: تعدد الإرسال بتقسيم الطول الموجي الكثيف (DWDM: Dense Wavelength Division Multiplexing) بالإضافة إلى تعدد الإرسال بتقسيم الطول الموجي الخشن (CWDM: Coarse Wavelength Division Multiplexing). في تقنية WDM، يتم دمج الأطوال الموجية المختلفة باستخدام معدد الإرسال WDM multiplexer، وفي جهاز الاستقبال تحدث العملية بشكل معاكس، حيث يتم فصل الأطوال الموجية كقنوات فردية في مزيل تعدد الإرسال WDM De-multiplexer. كل طول موجي بصري مختلف ونموذجي؛ التباعد بين القنوات سيحدد الفجوة بين تلك الأطوال الموجية، بهدف تجنب حدوث تداخل بين الموجات الضوئية. [10][11]

### ٢-٣ الدراسة التحليلية لحالات الطقس المختلفة ( Analytical study of different weather )

:(conditions)

تعد حالات الطقس الجوية من أبرز العوائق والمؤثرات التي يتعرض لها الليزر أثناء مروره في قناة الإرسال باتجاه جهاز الاستقبال، والتي تؤدي إلى انخفاض جودة الإشارة وضياع معلومات وأحياناً عدم وصولها إلى جهة الاستقبال، تم في هذه الفقرة مناقشة ثلاث حالات طقسية وهي الضباب والمطر والصحو من خلال قيم التخماد الناتجة عن كل حالة جوية وهي كما يلي:

#### ١-٢-٣ التخماد الناتج عن حالة الطقس الماطر ( Attenuation resulting from rainy )

:(weather)

يؤثر المطر بشكل خفيف على الإشارة الضوئية مقارنة بالضباب وذلك لأن حجم قطرات المطر أكبر بكثير من طول الموجة المستخدم في عملية الإرسال، إلا أن حبات المطر المتساقطة تعمل على تبعثر طول الموجة ومع زيادة كمية هطول الأمطار يزداد الضياع تدريجياً. تصف المعادلة (1) التخماد الناتج عن المطر [12].

$$\alpha_{rain} = 1.076 R^{0.67} \quad (1)$$

حيث  $R$  تعبر عن معدل هطول الأمطار وتقاس ب mm/h

#### ٢-٢-٣ التخماد الناتج عن حالة الطقس الضباب ( Attenuation resulting from foggy )

:(weather)

يعد الضباب من أسوأ حالات الطقس التي تعيق مرور الليزر وذلك بحسب كثافته وحجم جسيماته التي يمكن أن تتم مقارنتها مع طول الموجة المستخدم في عملية الإرسال، في الحالات التي يكون فيها كثافة الضباب كبيرة تكون عملية تأسيس الاتصال صعبة وعندها يتم استخدام الليزر ذو الطاقة العالية من أجل تحسين عملية الاتصال. بشكل عام تعد الليزر ذات الطول الموجي 1550 nm هي الخيار الأفضل خلال التخماد القوي وذلك بسبب طاقتها العالية للإرسال

ينص قانون بير لامبرت على أن التخماد الناتج عن الضباب المؤثر على إشارة الليزر المرسل يُعطى بالمعادلة [13,14]. (2)

$$A_{fog} = \frac{3.912}{V} \left( \frac{\lambda}{\lambda_0} \right)^{-q} \quad (2)$$

حيث:  $V$  هي مجال الرؤية وتقاس ب Km

$\lambda$  تعبر عن طول الموجة للإشارة المرسله وتقاس ب nm

$q$  معامل توزع حجم التبعثر ويمكن تحديد قيمته باستخدام النماذج الرياضية Kim أو Kurse.

### ٣-٣ خوارزميات تعلم الآلة المستخدمة (Machine Learning Algorithms used):

#### • خوارزمية شجرة القرار (Decision Tree Algorithm):

تعد خوارزمية شجرة القرار من الخوارزميات البسيطة ذات التنفيذ السهل. تعمل هذه الخوارزمية على تقسيم مجموعة العينات إلى عدة مجموعات وتعطي التنبؤات بناءً على متوسط ملاحظات التدريب. تبدأ العملية من عقدة الجذر، ثم تبدأ عملية إنشاء شجرة القرار بناءً على تكرار التقسيمات. تنقسم كل عقدة إلى عقدتين. واعتمادًا على معامل المراقبة، يتم الحصول على أكبر قدر من المعلومات، وتستمر عملية التقسيم هذه حتى تنتمي جميع العينات في كل عقدة إلى نفس الفئة. عيوب هذه الخوارزمية هي أنه في حالة حدوث تغيير بسيط في البيانات، فسينتج عدم الاستقرار بسبب تغيير كبير في بنية شجرة القرار. إضافة إلى أن العمليات الحسابية في هذه الخوارزمية أكثر تعقيداً مقارنة بالخوارزميات الأخرى. كما يستغرق تدريب النموذج وقتاً أطول [15].

#### • خوارزمية الغابة العشوائية (Random Forest Algorithm):

تتكون خوارزمية الغابة العشوائية من العديد من أشجار القرار أثناء مرحلة التدريب، حيث لا يحدث أي تفاعل أو تواصل بين هذه الأشجار أثناء عملية البناء. وتكون نتيجة التنبؤ هي المتوسط الحسابي لمخرجات جميع الأشجار. تتميز خوارزمية الغابة العشوائية بالدقة العالية جداً للنتائج التي تعطيها، بالإضافة إلى كفاءتها الكبيرة، خاصة عندما تكون مجموعات البيانات كبيرة. ومع ذلك، فإن لها بعض العيوب، بما في ذلك مشكلة الإفراط (Overfitting). علاوة على ذلك، يجب اختيار عدد الأشجار التي سيتم تضمينها في النموذج [15].


#### • خوارزمية انحدار المتجه الداعم (Support Vector Regression Algorithm):

تعد خوارزمية انحدار المتجه الداعم واختصاراً لها SVM: Support Vector (Machine)، حيث SVM هو أحد أنواع الخوارزميات الخاضعة للإشراف والتي يمكن استخدامها لحل مشاكل التصنيف والانحدار.

تعمل هذه الخوارزمية على إيجاد أقرب تطابق بين نقاط البيانات والدالة الفعلية التي تمثلها. وتحتوي على خط انحدار يعبر عن المستوى الفائق الذي يزيد الهامش بين المتغير الهدف والأخطاء المتبقية. والمقصود بالهامش هو المسافة بين المستوى الفائق ومتجهات الدعم التي تعبر عن نقاط البيانات. تهدف خوارزمية انحدار المتجه الداعم، إلى ملائمة خط الانحدار الذي يعمل على فصل البيانات إلى فئتين، الفئة الأولى هي المتغير المستهدف، أما الفئة الثانية هي الأخطاء المتبقية.

### ٣-٤ مقاييس تقييم الأداء (Performance evaluation metrics):

بعد أن تم جمع البيانات في المرحلة الأولى من برنامج OPTISYSTEM، تم تنظيمها في جدول ضمن ملف EXCEL يتم عرض جزء منها في الشكل (٢) حيث بلغ طول قاعدة البيانات ٣٠٠ سطر، بعد ذلك بدأت المرحلة الثانية وهي مرحلة التعلم الآلي، حيث تم تقسيم البيانات إلى مجموعتين، المجموعة الأولى تشكل نسبة ٨٠% من البيانات كلها وهي لتدريب النموذج والمجموعة الثانية تشكل ٢٠% وهي لاختبار النموذج. الهدف الأساسي من تدريب النموذج واختباره من أجل معرفة أداء هذا النموذج في حال إدخال بيانات جديدة. ومن أجل تقييم أداء النموذج تم استخدام مقاييس أداء محددة. تم في هذا العمل الاعتماد على مقياس متوسط مربع الخطأ ومعامل التصميم وذلك لأنهما الأكثر شيوعاً في علم البيانات.



|   | A           | B     | C          | D        | E | F | G | H | I |
|---|-------------|-------|------------|----------|---|---|---|---|---|
| 1 | Attenuation | Range | WaveLength | Q-Factor |   |   |   |   |   |
| 2 | 80.904      | 250   | 1550       | 14.1705  |   |   |   |   |   |
| 3 | 80.904      | 270   | 1550       | 11.7908  |   |   |   |   |   |
| 4 | 80.904      | 290   | 1550       | 9.8864   |   |   |   |   |   |
| 5 | 80.904      | 310   | 1550       | 7.906    |   |   |   |   |   |

الشكل (٢): جزء من قاعدة البيانات التي تم جمعها من برنامج Optisystem

- يعبر متوسط مربع الخطأ (MSE) عن مقدار التباين بين القيم الحقيقية والقيم المتوقعة وبالتالي كلما كانت قيمته أصغر كان أداء النموذج أفضل. يعطى هذا المقياس بالمعادلة التالية من [16]:

$$MSE = \frac{1}{n} \sum_{i=1}^N (x_i - \hat{x}_i)^2 \quad (3)$$

حيث أن:  $x_i$ : القيمة الحقيقية للمتغير  $i$ .


$\hat{x}_i$ : القيمة المتوقعة للمتغير  $i$ .

- معامل التصميم  $R^2$  يعبر مدى اقتراب القيمة الحقيقية من القيمة المتوقعة وبالتالي كلما كانت قيمته أعلى كانت أداء النموذج أفضل. يعطى بالمعادلة التالية [16]:

$$R^2 = 1 - \frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{\sum_{i=1}^N (x_i - \bar{x}_i)^2} \quad (4)$$

#### ٤- تصميم النظام المقترح (Proposed system design):

يبين الشكل (3) تصميم النظام المقترح WDM-FSO على برنامج Optisystem. حيث تمت دراسة أداء النظام تحت ظروف جوية مختلفة (ضباب - مطر - صحو) بهدف قياس قيم المعامل (Q) بعد ذلك تم تطبيق خوارزميات التعلم الآلي للتنبؤ بـقيم عامل الجودة لهذا النظام. يتكون نظام FSO المقترح مع تقنية تعديل WDM من ٣٢ قناة. معدل سرعة نقل كل قناة يبلغ 2.5 Gbps.



الشكل (3): نظام WDM-FSO المقترح

يتم أولاً توليد بتات ثنائية باستخدام تسلسل البتات العشوائية الزائفة (PRBS: Pseudo Random Binary Sequence) بعد ذلك ترسل هذه البتات إلى مولد نبض غير العودية إلى الصفر (NRZ) من أجل تحويلها إلى إشارة كهربائية. يتم تعديل الإشارة الكهربائية من NRZ باستخدام Mach-Zehnder (MZM) بواسطة ليزر موجة مستمرة بطول موجة يبلغ ١٥٥٠ نانومتر. ثم يتم إرسال الإشارة الضوئية في الفضاء الحر، وأثناء مرورها في الفضاء تتعرض الإشارة للعوامل الجوية التي تؤثر عليها. وعندما تصل الإشارة بعد ذلك إلى قسم الاستقبال تعبر إلى الكاشف الضوئي

(APD: Avalanche Photodiodes optical Detectors) ليتم تحويلها من الشكل الضوئي إلى الكهربائي. تم استخدام مرشح الترددات المنخفضة (LPF) لإزالة أي ضوضاء عالية التردد موجودة في الإشارة المستقبلية. وأخيراً تم توجيه الإشارة إلى محلل BER من أجل تحليل جودة الإشارة المستقبلية .



خلال عملية الانتشار عبر قناة FSO تم ضبط قيمة التخامد في القناة على اختلاف الطقس المستخدم والموضحة في الجدول (1) وبعد أن تنتشر عبر القناة FSO سوف تصل إلى جهة الاستقبال.

| الجدول(1): البارامترات المستخدمة في المحاكاة |                    |                                              |
|----------------------------------------------|--------------------|----------------------------------------------|
| القيمة                                       |                    | البارامتر                                    |
| 2.5 Gbps                                     |                    | معدل البتات                                  |
| 80.904                                       | ضباب كثيف          | قيم التخامد لحالات الطقس المختلفة<br>(dB/km) |
| 33.961                                       | ضباب بكثافة متوسطة |                                              |
| 15.55                                        | ضباب خفيف          |                                              |
| 10.115                                       | مطر كثيف           |                                              |
| 4.285                                        | مطر متوسط          |                                              |
| 1.537                                        | مطر خفيف           |                                              |
| 0.155                                        | صحو                |                                              |
| 1550                                         |                    | طول الموجة (nm)                              |

## ٥- النتائج والمناقشة (Results and Discussing):

تم في هذا القسم عرض النتائج التي تم التوصل إليها بعد تطبيق خوارزميات تعلم الآلة (SVR – RF – DT) على مجموعة البيانات التي تم استخراجها من برنامج Optisystem من خلال حساب مقياس MSE و  $R^2$ ، حيث كما ذكرنا يعبر  $R^2$  عن مدى قرب القيم الحقيقية من القيم المتوقعة، بينما يعبر ال MSE عن الفرق بين القيمة الحقيقية والقيمة المتوقعة، وبالتالي فإن الخوارزمية التي تعطي أعلى قيمة  $R^2$  وأقل قيمة MSE هي الأفضل مقارنة إلى بقية الخوارزميات.

يوضح الشكل (4) دقة التنبؤ ب MLAs اعتماداً على قيم  $R^2$  ويوضح الشكل (5) دقة التنبؤ ب MLAs اعتماداً على قيم MSE تعطي خوارزمية الغابة العشوائية  $R^2=0.895= 89.5\%$  و  $MSE=0.031= 3\%$ ، وتعطي خوارزمية شجرة القرار  $R^2=0.65= 65\%$  و  $MSE=0.063= 6.3\%$ ، بينما تعطي خوارزمية (SVR)  $R^2=0.49= 49\%$  و  $MSE=0.084= 8.4\%$



يوضح الجدول (٢) ملخص نتائج المقارنة بين الخوارزميات:

| الجدول(٢): مقارنة بين الخوارزميات |      |       |       |
|-----------------------------------|------|-------|-------|
| SVR                               | DT   | RF    |       |
| 49%                               | 65%  | 89.5% | $R^2$ |
| 8.4%                              | 6.3% | 3.1%  | MSE   |

ومن النتائج التي تم الحصول عليها يلاحظ أن خوارزمية RF أعطت أعلى قيمة  $R^2$  وأصغر قيمة MSE مقارنة ببقية الخوارزميات المستخدمة في هذا العمل. وبالتالي يمكننا القول أنها هي الخوارزمية الأفضل في التنبؤ بمعامل الجودة في نظام WDM-FSO مقارنة مع SVR و DT.

## ٦- الاستنتاجات والتوصيات (Conclusions and Recommendations):

تم في هذا العمل توظيف تقنية تعديل WDM في نظام اتصالات FSO. واختبار أداء هذا النظام في حالات جوية مختلفة وتم استخدام خوارزميات تعلم الآلة للتنبؤ بقيمة عامل الجودة (Q-Factor). وبعد مناقشة النتائج تبين أن خوارزمية الغابة العشوائية تعطي دقة تنبؤ أفضل من SVR و DT.

يمكن وضع بعض التوصيات لقادم الأعمال من خلال:

- ✓ اختبار خوارزميات تعلم آلة مختلفة في عملية التنبؤ لأنها من الممكن أن تعطي نتائج أفضل.
  - ✓ استخدام خوارزميات تعلم آلة بغرض عمليات التصنيف وليس فقط التنبؤ في مجال الاتصالات الضوئية
  - ✓ التنبؤ ببارامترات أخرى مثل BER ، أو مثلاً نوع التعدي أو الترميز الأفضل تبعاً لحالة القناة
- تجدر الإشارة أيضاً إلى أنه من الممكن استخدام خوارزميات التعلم العميق وليس فقط تقنيات تعلم الآلة.

## ٧- المراجع (References):

- [1] J Kaufmann (2011) Free space optical communications: An overview of applications and technologies. Proceedings of the Boston IEEE Communications Society Meeting.
- [2] MNO Sadiku, SM Musa (2016) Free space optical communications: An overview. European Scientific Journal 12: 55-68.
- [3] K. Anbarasi, C. Hemanth, and R. G. Sangeetha, "A review on channel models in free space optical communication systems," Optics Laser Technology, vol. 97, pp. 161–171, 2017.
- [4] Kaushal, H.; Jain, V.K.; Kar, S. Free Space Optical Communication; Springer: Gurgaon, India, 2017; Volume 18.
- [5] A. Mansor, R. Mesleh, and M. Abaza "New challenges in wireless and free space optical communications," Optics and Laser in Engineering, vol. 89, pp. 95-108, 2017.
- [6] H. Kaushal and G. Kaddourn, "Optical communication in space: Challenges and mitigation techniques," IEEE Communication Survey & Tutorials, vol. 19, no. 1. 2017.
- [7] R. Younes, F. Ghosna, M. Nassr, M. Anbar, H. Alasadi, "Predicting BER value in OFDM-FSO systems using Machine Learning techniques", Opt. Pura Api., vol. 55, no. 4, 51114, 2022.
- [8] S F.Aveta, H.H.Refai, P.G.Lopresti, "Cognitive Multi-Point Free Space Optical Communication: Real-Time Users Discovery Using Unsupervised Machine Learning," Digital Object Identifier 10.1109/ACCESS. 2020
- [9] K. Alatawi, et al., "Performance Study of 1 Tbits/s WDM Coherent Optical OFDM System," Optics and Photonics Journal, vol. 3, pp. 330-335, 2013.
- [10] H. A. Mohammed and A. H. Ali, "Effect of some security mechanisms of the Qos VoIP application using OPNET," Int. J. Curr. Eng. Technol., vol. 3, pp. 1626-1630, 2013.
- [11] A. A. Abdulrazzaq, et al., "QoS Performances Evaluation for Mobile WIMAX Networks based on OPNET," Int. J. Appl. Eng. Res., vol. 13, pp. 6545-6550, 2018.
- [12] T. H. Carbonneau and D. R. Wisley, "Opportunities and challenges for optical wireless: The competitive advantage of free space telecommunications links in today crowded market place," SPIE Conference on Optical Wireless Communications, Massachusetts, pp. 119–128, 1998.
- [13] I. I. Kim, B. McArthur, and E. Korevaar, "Comparison of laser beam propagation at 785 nm and 1550 nm in fog and haze for optical wireless communications," Proc. SPIE, 4214, Boston, MA, USA, 2001.
- [14] غصنه، ف; نصر، م; يونس، ر. 2022 ، " دراسة تأثير حالات الطقس المختلفة على نظام اتصالات OFDM-FSO " مجلة جامعة طرطوس

[15] W. S. Saif, M. A. Esmail, A.M. Ragheb, T.A.Alshawi, S.A.Alshebeili," Machine Learning Techniques for Optical Performance Monitoring and Modulation Format Identification: ASurvey,"IEEE COMMUNICATIONS SURVEYS & TUTORIALS, VOL.22.4,FOURTH QUARTER (2020)

[16] A.otchkarev, "Performance Metrics (Error Measures) in Machine Learning Regression, Forecasting and prognostics: Properties and Typology," 1809.03006 (2018).