

استخدام تقنيات الذكاء الصناعي في نظام اتصالات فضائي ضوئي للتنبؤ بقيم خطأ البت (BER)

م. رنيم يونس *

(تاريخ الإيداع ٢٠٢٣/٤/٣ . قُبل للنشر في ٢٠٢٣/٧/١٣)

□ ملخص □

اتصالات (FSO: Free Space Optics) هي عبارة عن تقنية اتصال لاسلكي تقوم بنقل المعلومات باستخدام الليزر عبر الهواء. يحتوي هذا النظام على العديد من الميزات مقارنة مع الأنظمة اللاسلكية الأخرى وأيضاً مقارنة مع أنظمة الألياف الضوئية. إلا أن هذا النظام له عيوب منها تباعد الحزمة (التشتت)، الخفوت، التداخل مع المصادر الضوئية الأخرى وأيضاً التأثير بالعوامل الجوية مثل المطر والضباب والغبار والتلج وغيرها والتي ستسبب ضعف الإشارة وفي كثير من الأحيان عدم وصولها إلى جهة الاستقبال. تم في هذا المقال استخدام تقنية التعديل لتحسين أداء النظام وزيادة دقة الإشارة المستقبلية. إن إدخال تقنيات الذكاء الصناعي في مجال الاتصالات الضوئية وخاصة اللاسلكية يهدف إلى تحسين جودة النظام عن طريق قدرته على التنبؤ الجيد ببارامترات الشبكة. تم في هذا البحث بناء نظام FSO باستخدام برنامج Optisystem حيث تم مناقشة حالات طقس مختلفة، ثم تم توظيف ثلاثة خوارزميات من تقنيات تعلم الآلة من أجل التنبؤ بقيم BER: Bit Error Rate. أظهرت النتائج أن خوارزمية الغابة العشوائية أعطت دقة تنبؤ أفضل من خوارزمية الانحدار الخطي وخوارزمية شجرة القرار.

الكلمات المفتاحية: نظام FSO – Optisystem – خوارزميات تعلم الآلة – BER

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

Using Artificial intelligence techniques for predicting BER value in Free-space optical systems

Eng. RanimYounes *

(Received 3/4/2023 . Accepted 13/7/2023)

□ ABSTRACT

FSO communication is a wireless communication technology that transmits information using laser via air. This system contains many features compared with other wireless systems and also compared with fiber optic systems. However, this system has some of the disadvantages, including beam divergence fading and interference with other light source, in addition to being affected by weather factors such as rain, fog, dust, snow, etc... which will cause the signal to weaken and often doesn't reach to the receiver. In this work, the modulation techniques were used to improve system performance and increase the accuracy of the received signal. The introduction of artificial intelligence technologies in the field of optical communications, especially wireless, aims to improve system quality through its ability to predict network parameters well. In this work, employed three of machine learning algorithms for predicting BER values after we obtained the data from Optisystem where different weather cases were discussed. The results showed that the random forest algorithm gave a better prediction of the linear regression algorithm and the decision tree algorithms.

Keywords: FSO System – Optisystem – MLAs- BER

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

١ - مقدمة:

نظام اتصالات FSO هو عبارة عن نظام اتصالات ضوئي، ينتقل فيها الليزر الحامل للمعلومات في الفضاء الحر بدلاً من كابلات الألياف الضوئية [1][2][3]. تصل الإشارة في أنظمة FSO إلى مسافة تصل إلى بضعة كيلومترات [4].

تتمتع هذه التقنية بالعديد من الميزات منها: معدل نقل بيانات عالي، مناعة من التداخل الكهرومغناطيسي بالإضافة إلى معدلات خطأ بت منخفضة BER، وإمكانية نشر هذه الأنظمة بسرعة وسهولة مقارنة مع الاتصالات الضوئية، إمكانية وصول المعلومات إلى مسافات بعيدة، بالإضافة إلى توفير أمن عالي وسرية للبيانات المنقولة مقارنة مع الاتصالات الأخرى، كما أنه يتمتع باستهلاك قليل للطاقة الكهربائية [5][6]. ومع ذلك تتعرض الإشارة أثناء انتقالها عبر قناة FSO لحالات الطقس الجوي (مثل الغبار والضباب والمطر وغيرها) والتي تؤدي إلى خفوت وامتصاص وتبعثر للإشارة بالإضافة إلى التشتت [8] [7].

هناك العديد من تقنيات التخفيف التي يتم توظيفها في أنظمة FSO من أجل زيادة وثوقية النظام FSO وتحسين جودة الإشارة ووصولها إلى مسافات أبعد في حالات الطقس المختلفة. تم في هذا المقال توظيف إحدى تقنيات التخفيف وهي تقنية تعديل OFDM [9].

أصبحت في الآونة الأخيرة تقنيات الذكاء الصناعي بمختلف أنواعه موضوع مهم جداً في مجال الاتصالات وخاصة الضوئية حيث تعد هذه التقنيات منهجية واعدة لإدخال الذكاء إلى شبكات الاتصالات.

في أنظمة FSO هناك تطبيقات عديدة لتقنيات تعلم الآلة والتي تعد فرع من فروع الذكاء الصناعي مثل عندما يكون لدينا عدد من المستخدمين يتواصلون مع مستقبل واحد وينشرون عرض نطاق ترددي واحد، يكون دور تقنيات تعلم آلة عندها في التنبؤ بعدد المستخدمين [10]، أو مثلاً للتنبؤ ببارامترات مختلفة في الشبكة مثل SNR والكثير من البارامترات الأخرى [11].

في عملنا هذا قمنا بتوظيف خوارزميات تعلم الآلة التالية:

• الغابة العشوائية: Random Forest

• شجرة القرار: Decision Tree

• الانحدار الخطي: Linear Regression

ومن ثم حساب دقة كل خوارزمية في تقدير قيمة BER.

٢ - أهمية وهدف البحث:

تأتي أهمية هذا البحث من توظيف تقنيات تعلم الآلة للتنبؤ بقيم BER تبعاً لحالة الطقس الموجودة بالإضافة إلى المسافة بين المرسل والمستقبل في نظام OFDM-FSO، حيث بعد التنبؤ بقيم BER نستطيع إدخال طرق للتخفيف من تأثير حالات الطقس وبالتالي زيادة المسافة التي من الممكن أن تصل إليها الإشارة أي بمعنى تخفيض قيم BER وبالتالي زيادة أداء النظام.

٣- مواد وطرق البحث:

استخدمنا في المرحلة الأولى برنامج Optisystem v.15 كأداة محاكاة لإجراء التجارب التجريبية، وهو برنامج ذو دقة عالية في إعطاء النتائج في أنظمة الاتصالات الضوئية السلكية واللاسلكية. أما في المرحلة الثانية استخدمنا لغة Python من أجل تطبيق تقنيات تعلم الآلة. وقد تم ذلك من خلال الاعتماد على العديد من المراجع والدراسات الحديثة [17] [13] [12] [11].

١-٣ خوارزميات تعلم الآلة:

تم تطبيق خوارزميات تعلم الآلة في هذا العمل من أجل التنبؤ بقيم BER لنظام OFDM-FSO.

A- LR: Linear Regression

يُعتبر من أبسط خوارزميات تعلم الآلة الخاضعة للإشراف (Supervised Learning) الذي يقوم بنمذجة مفهوم الانحدار. وهو نوع من النمذجة الإحصائية التي تسمح بالتحقيق فيما إذا كان متغير من المتغيرات يعتمد على الآخر يحتوي على متغيرات مستقلة متعددة. يستخدم الانحدار اللوجستي للتنبؤ باحتمالية وقوع حدث ما بمعرفة إضافية لقيم متغيرات يمكن أن تكون مفسرة أو مرتبطة بهذا الحدث [14].

B- DT: Decision Tree

هي من خوارزميات تعلم الآلة التي تقوم بتحليل وتقسيم البيانات على شكل شجرة أي إلى فروع وعقد. يمكن استخدام هذه الخوارزمية في مسائل الانحدار Regression والتصنيف Classification. تتميز هذه الخوارزمية بسهولة تطبيقها مقارنة مع الخوارزميات الأخرى. العقد الداخلية تعبر عن الميزات Features أما العقد النهائية تعبر عن النتيجة [15].

C- RF: Random Forest

تعد هذه الخوارزمية نوعاً من خوارزميات تعلم الآلة الخاضعة للإشراف والتي تقوم بتدريب العديد من أشجار القرار على مجموعات فرعية عشوائية من البيانات ثم تقوم بحساب المتوسط الحسابي لجميع تنبؤات أشجار القرار لتعطي التنبؤ النهائي.

من ميزات هذه الخوارزمية أنها تأخذ وقت أقل أثناء التدريب بالإضافة إلى دقة عالية في إعطاء النتائج حتى عندما تكون مجموعة العينات كبيرة. [15]

٣-٣ مقاييس تقييم الأداء:

تم استخدام مقياس متوسط مربع الخطأ ومعامل التصميم لتقييم دقة النموذج، وهما من المعايير المعتمدة في تقييم دقة خوارزميات تعلم الآلة وذلك باستخدام لغة Python.

• متوسط مربع الخطأ MSE نعبر عنه بالمساواة التالية من [16]:

$$MSE = \frac{1}{n} \sum_{j=1}^n e_j^2$$

حيث أن: A_j : القيمة الحقيقية للمتغير الذي نريد أن نتنبأ به.

P_j : القيمة المتوقعة للمتغير من قبل خوارزميات تعلم الآلة.

• معامل التصميم R^2 يقوم بقياس مدى قرب القيمة الحقيقية من القيمة المتوقعة أي أنه كلما كانت

قيمة R^2 أكبر كلما كانت دقة الخوارزمية في إعطاء النتائج أفضل. يعطى بالمساواة التالية [17]:

$$R^2 = 1 - \frac{\sum_{i=1}^n (A_j - P_j)}{\sum_{i=1}^n (A_j - \bar{A})} \quad (7)$$

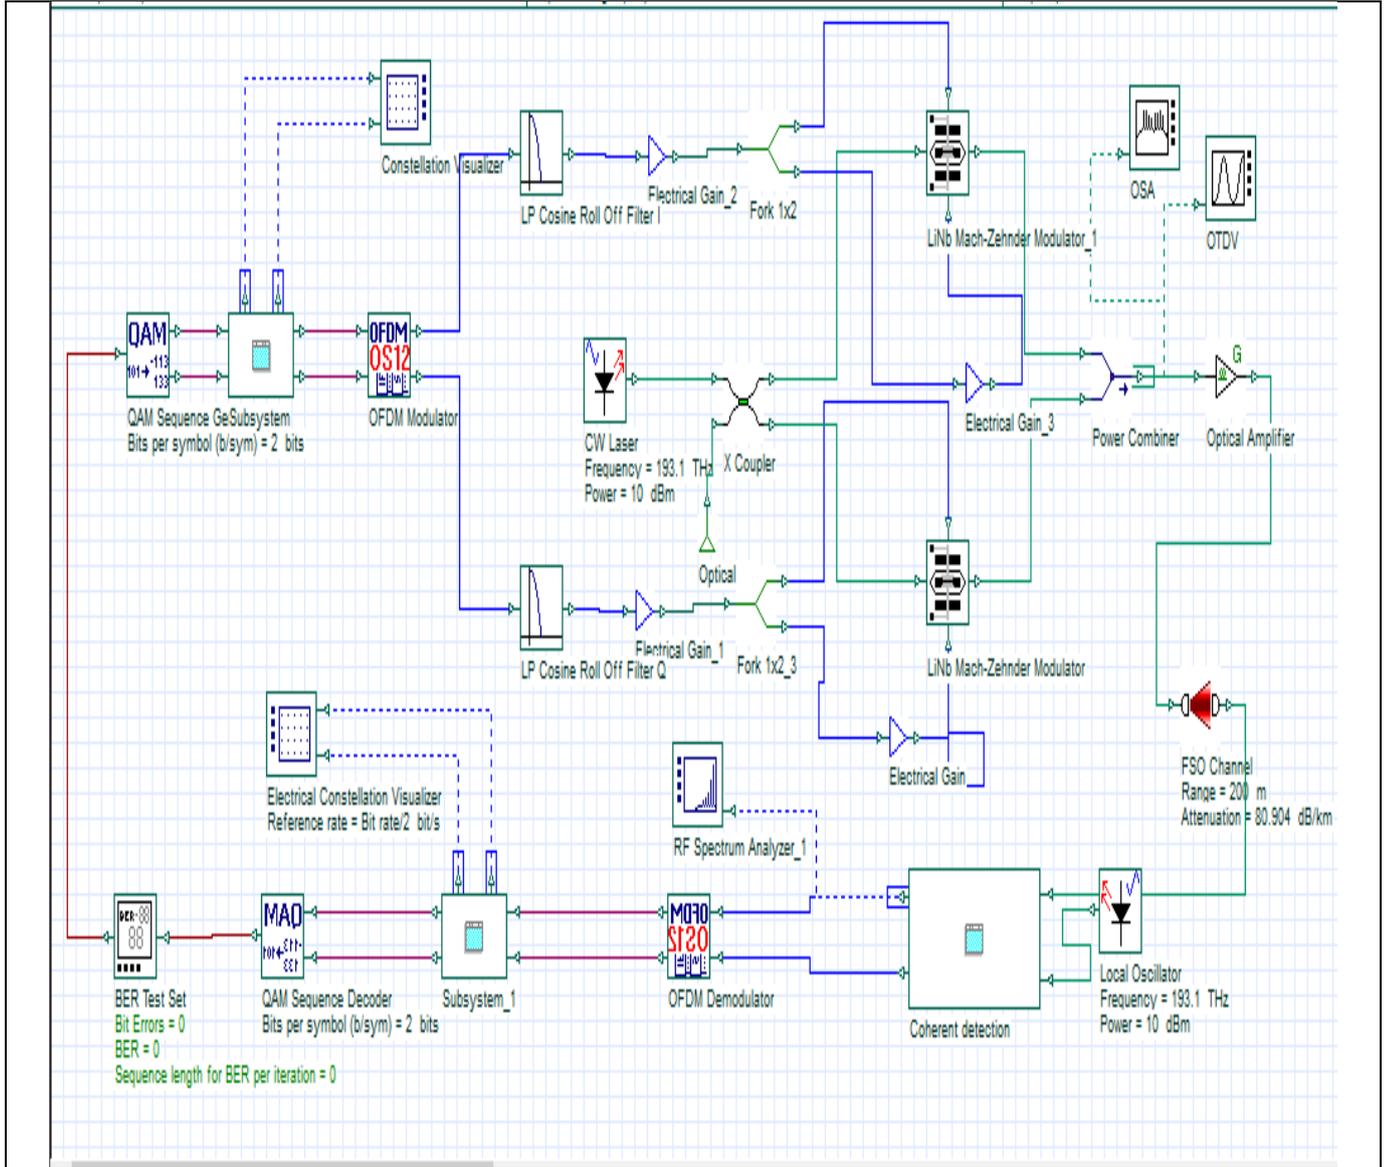
حيث n : هو عدد العينات

\bar{A} : هو متوسط مجموع العينات ويعطى بالمعادلة التالية:

$$\bar{A} = \frac{1}{n} \sum_{i=1}^n A_j \quad (8)$$

٤ - النموذج المقترح:

في هذه البحث تم استخدام برنامج الـ Optisystem v.15 من أجل تنفيذ نظام OFDM-FSO ومناقشة حالات الطقس المختلفة من خلال قيم التخامد ثم حساب قيم BER تبعاً لكل حالة طقس، وبعد ذلك تم تشكيل قاعدة البيانات المكونة من هذه القيم (التخامد-المسافات-قيم الخطأ) وذلك من أجل تطبيق خوارزميات تعلم الآلة للتنبؤ بقيمة BER. مع العلم أن هناك عوامل أخرى تؤثر على الإشارة أثناء انتشارها في نظام FSO مثل التشتت والتداخل وغيرها ولكن ضمن هذه المقالة تم أخذ بعين الاعتبار تأثير التخامد الناتج عن حالات الطقس فقط. يوضح الشكل (1) صورة النظام بشكل كامل الذي تم تنفيذه في برنامج Optisystem v.15.



الشكل(1): تصميم مخطط نظام OFDM-FSO

حيث أولاً يتم توليد بتات ثنائية عشوائية بمعدل 10 Gbps، بعدها يتم نقل هذه البتات إلى مولد التسلسل QAM-Sequence Generator تكمن وظيفته في تحويل هذه البتات إلى إشارات متوازية، ثم يتم تحويل الإشارة الكهربائية إلى إشارة ضوئية في قسم (RTO: Radio To Optical) وبعدها يتم إطلاق الإشارة في قناة FSO. قسم RTO يحوي على عدة عناصر: ليزر مستمر (CW laser) ومعدلين ماخ زيندر (Linb Mach Zehnder) حيث يعمل على تعديل إشارة خرج معدل OFDM وتوليد إشارات ضوئية باستخدام CW Laser بتردد 193.1 THz [18].

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 [2].

حيث يتم أولاً استقبالها من قبل الكاشف المتماسك (Coherent Detection) كمستقبل ضوئي [19] ويتم التغلب على ضعف الإشارة الذي تعرضت له في قناة FSO من خلال المزود المحلي. تحتوي جهة الاستقبال على فاك تعديل OFDM و QAM Sequence Detector للحصول على إشارة الخرج [18].

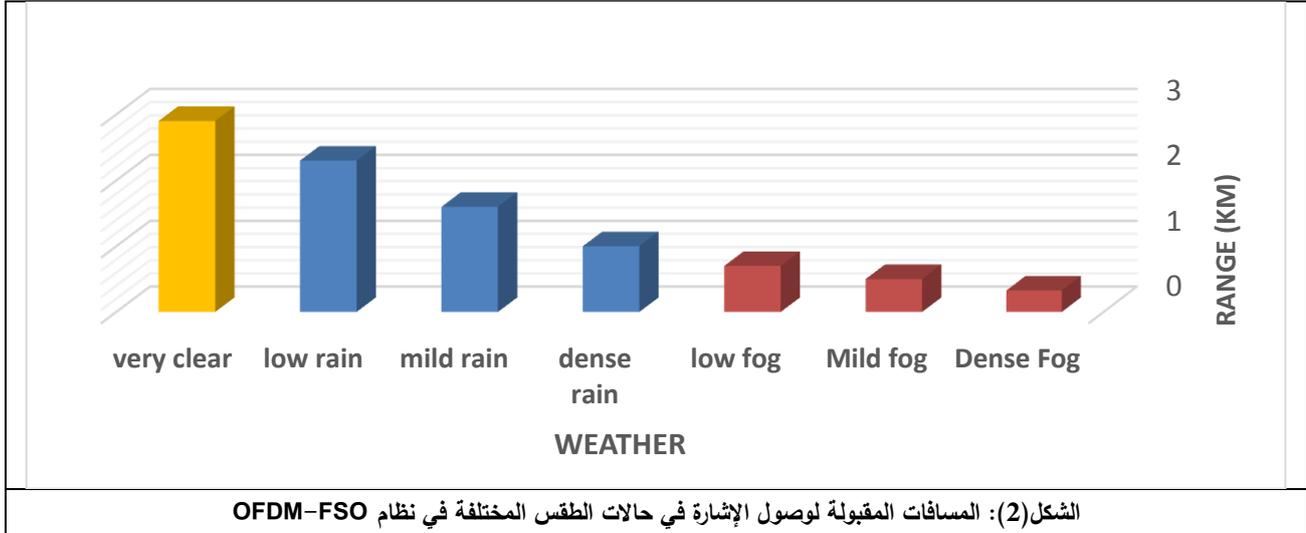
البارامترات المستخدمة في المحاكاة		البارامترات
القيمة (dB/km)		
80.904	ضباب كثيف	قيم التخامد لحالات الطقس المختلفة
33.961	ضباب بكثافة متوسطة	
15.55	ضباب خفيف	
10.115	مطر كثيف	
4.285	مطر متوسط	
1.537	مطر خفيف	
0.155	صحو	
١٢٥٠ و 1550 nm و 850 nm		طول الموجة

٥- النتائج والمناقشة:

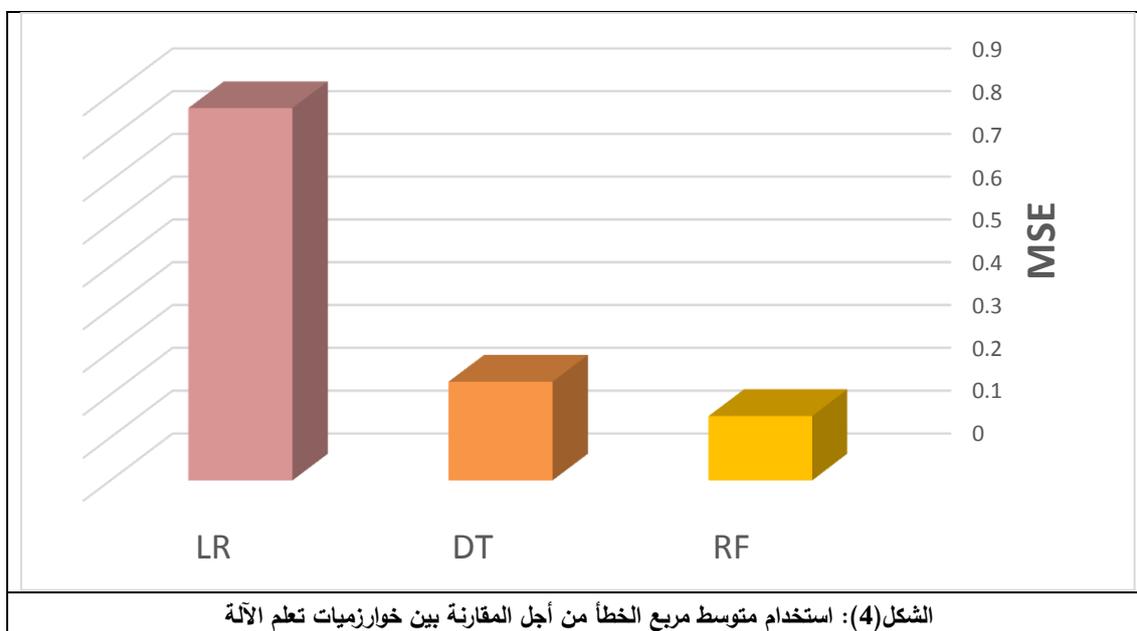
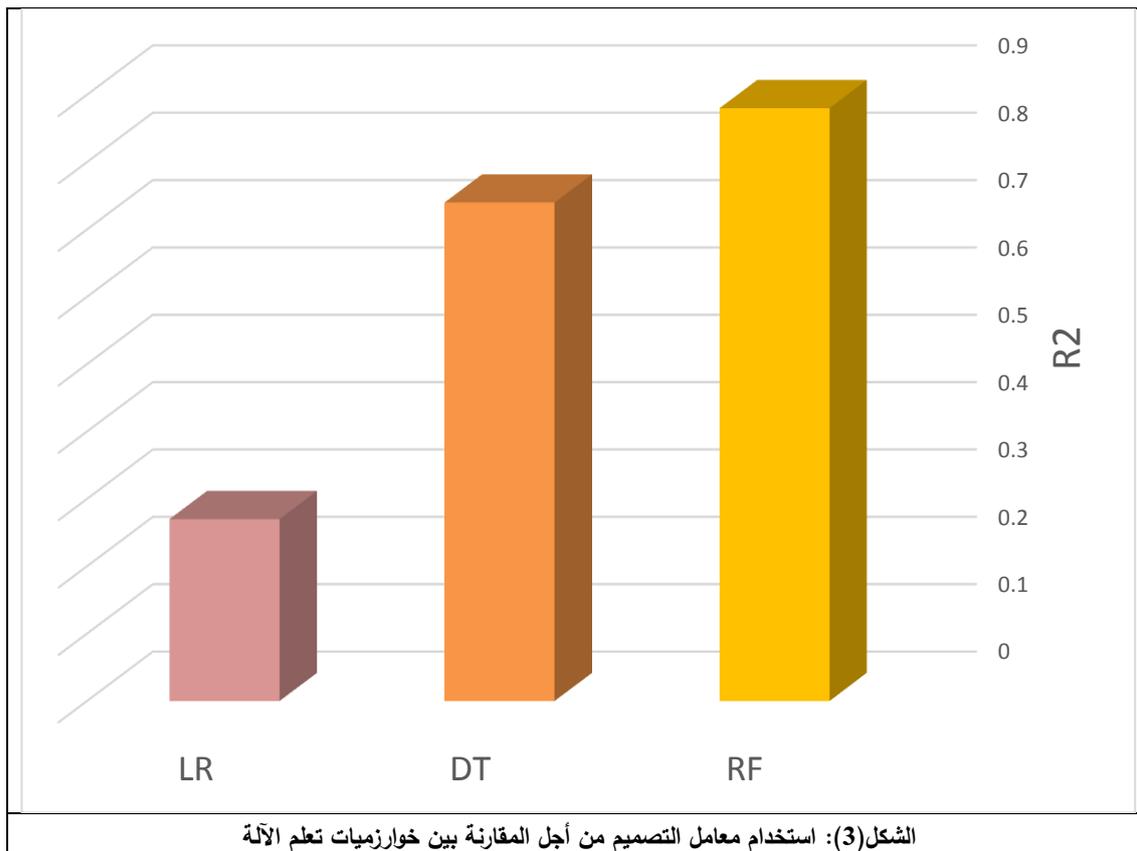
تم في هذا القسم تقديم النتائج على مرحلتين حيث تم الحصول في المرحلة الأولى على البيانات التي تم استخدامها في المرحلة الثانية وذلك عن طريق برنامج Optisystem v.15، حيث قمنا بحساب قيم BER تبعاً لكل حالة طقس المذكورة في الجدول أعلاه مع حساب المسافات التي يمكن أن تصل إليها الإشارة وذلك في نظام OFDM-FSO. وبعدها تم تشكيل قاعدة البيانات المكونة من ٢٥٠ سطر من أجل المرحلة الثانية لتطبيق خوارزميات تعلم الآلة (LR, DT, RF) عليها من أجل التنبؤ بقيم BER.

يبين الشكل (2) المسافة المقبولة لوصول الإشارة مقاسة ب Km تبعاً لكل حالة طقس وذلك من خلال قيم التخامد التي تم عرضها في الجدول السابق.

من الواضح أنه خلال الطقس الضبابي الكثيف تصل الإشارة إلى مسافة تقريباً 325m وذلك لأن جزيئات الضباب بسبب حجمها الذي من الممكن أن تتم مقارنته مع الأطوال الموجية التي تم توظيفها تسبب ضعف الإشارة وفي كثير من الأحيان تمنع مرورها ووصولها إلى جهة الاستقبال. ومع انخفاض قيم التخامد تدريجياً نلاحظ أن الإشارة تصل إلى مسافة أبعد حيث في حالة المطر الكثيف تصل الإشارة إلى مسافة 1 Km تقريباً أما في حالة الطقس الصحو فإن الإشارة تصل لمسافة تقريباً 3Km مع قيمة BER مقبولة. ننوه أن بعد هذه القيم للمسافة فإن قيم الخطأ تزداد بشكل كبير وذلك بسبب العوامل التي تتعرض لها أثناء عبورها في قناة FSO وعند ازدياد المسافة بشكل كبير من الممكن ألا تصل الإشارة أبداً إلى المستقبل.



يبين الشكل (3) والشكل (4) تنفيذ خوارزميات تعلم الآلة على البيانات السابقة حيث تم تقسيم مجموعات البيانات إلى مجموعتين رئيسيتين: مجموعة بيانات التدريب (Training Dataset) تمثل 80% من البيانات، ومجموعة بيانات الاختبار (Testing Dataset) تمثل 20% من البيانات حيث تم اعتبار قيم التخماد والأطوال الموجية والمسافات كميزات (Features) وقيم الـ BER هي الهدف. في الشكل (3) تمت المقارنة بين الخوارزميات الثلاثة من خلال قيم R^2 أما في الشكل (4) تمت المقارنة بينهم من خلال قيم MSE. من الشكلين (3) و (4) نلاحظ خوارزمية الغابة العشوائية (RF) قدمت نتائج أفضل من حيث قيم $R^2 = 0.88$ وقيم $MSE=0.15$ أي أن نموذج RF يمكن تطبيقه في نظام OFDM-FSO للتنبؤ بقيم BER أما بالنسبة لخوارزمية شجرة القرار DT فإنها تأتي بعد نموذج RF من حيث الدقة حيث أعطت قيمة $R^2 = 0.74$ مع قيمة $MSE=0.23$ أما بالنسبة لخوارزمية LR والذي أظهر أكبر قيمة $MSE= 0.87$ و أقل قيمة $R^2 = 0.27$ مقارنة مع باقي النموذجين وبالتالي لا يصلح لاستخدامه في نظامنا.



٦ - الخاتمة والتوصيات:

في هذا العمل تم العمل على تنفيذ نظام FSO باستخدام برنامج Optisystem مع استخدام تقنية تخفيف من تأثير حالات الطقس وهي تقنية تعديل OFDM. وبعدها أخذ النتائج وتشكيل قاعدة بيانات من اجل المرحلة التالية وهي تطبيق خوارزميات تعلم الآلة التي تحدثنا عنها وتدريب واختبار البيانات من خلالها وذلك للتنبؤ بقيمة BER في نظام OFDM-FSO ، اعتماداً على النتائج وجدنا أن خوارزمية RF يمكن استخدامها في نظام OFDM-FSO حيث أعطت أفضل قيمة من حيث معامل التصميم مقارنة مع الخوارزميتين شجرة القرار والانحدار الخطي. ولاحظنا أن LR لا يمكن استخدامها لأنها أعطت قيم تنبؤ سيئة.

يمكن دراسة أداء النظام من خلال:

- إمكانية استخدام تقنيات تخفيف أخرى على نظام FSO سواء على الطبقة الفيزيائية أو طبقات الشبكة والنقل.
- توظيف خوارزميات تعلم آلة أو خوارزميات التعلم العميق لإدخال الذكاء إلى نظام FSO تعمل على التنبؤ ببارامترات أخرى للنظام مثل معامل الجودة أو SNR أو غيرها من بارامترات أخرى.
- استخدام تقنيات الذكاء الصناعي من أجل مراقبة حالة قناة FSO
- مناقشة حالات قناة FSO مثل Log-normal و K-distribution وغيرها، مع توظيف تقنيات تعديل، ثم استخدام تقنيات تعلم الآلة لاختيار أفضل تقنية تعديل تساهم في التخفيف من التأثير السلبي على الإشارة المرسل.

[14] W. S. Saif, M. A. Esmail, A. M. Ragheb, T. A. Alshawi, and S. A. Alshebeili, "Machine learning techniques for optical performance monitoring and modulation format identification: A survey", IEEE Communications Surveys & Tutorials, vol. 22.4, 2020.

[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: A Survey,"IEEE COMMUNICATIONS SURVEYS & TUTORIALS, VOL.22.4,FOURTH QUARTER 2020.

[16] A.Botchkarev," Performance Metrics (Error Measures) in Machine Learning Regrission, Forecasting and prognostics: Properties and Typology," arXiv preprint arXiv: 1809.03006, 2018-arxiv.org.

[17] M.A.Esmail, W.S.Saif, A.M.Ragheb, S.A.Alshebeili,"Free space optic channel monitoring using machine learning," Vol.29,No.7/29 March 2021/Optics Express 10967

[18] F. Hario, E. Maulana, Sholeh H. Pramono, Sapriesty N. Sari, Anas M. Al Junaedi, " Design of OFDM-FSO Communication System on High Data Rate for Tropical Climate Region", (2019) International Conference on advanced Technologies for Communications(ATC

أسعد، ر. ٢٠١٨ "استخدام تقنيات معالجة الإشارة الرقمية لتحسين أداء نظم الاتصالات ; نصر، م[19] الضوئية المتناسكة عالية السرعة". مجلة جامعة طرطوس