

## تقييم أداء شبكات WBAN باستخدام تقنيات الذكاء الاصطناعي

\* د.م. ناجي ابراهيم محمد

\* ا.د.م. غسان محمد

\* م. علاء ابراهيم الشيخ

(تاريخ الإيداع ٢٠٢٥/٣/٣ . قبل للنشر في ٢٠٢٥/٥/٢٩)

□ ملخص □

تهدف الدراسة الى تقييم أداء شبكات منطقة الجسم اللاسلكية Wireless Body Area Networks (WBANs) باستخدام نماذج التعلم الآلي كالانحدار الخطي وشجرة القرار والغابة العشوائية. وقد ركزنا في هذا البحث على تطبيق تقنيات متقدمة مثل تقنية إعادة التوجيه الديناميكي وتقنية ضغط البيانات لتحسين أداء هذه الشبكات. يتمحور التحليل في الدراسة حول الأداء الإنتاجي وفاعلية نقل البيانات لشبكات WBAN، بالإضافة الى قياس التأخير الزمني في انتقال البيانات ومعدل خطأ البت وذلك بالاعتماد على مقاييس التقييم المعتمدة مثل معامل التحديد ومتوسط مربع الخطأ ومتوسط الخطأ المطلق، حيث تم تحليل وقياس أثر تلك التقنيات المتقدمة على عملية نقل البيانات وأداء WBAN وتم استنتاج ان استخدام هذه التقنيات تلعب دوراً كبيراً في تعزيز كفاءة شبكات WBAN وتحسين الاتصالات اللاسلكية في تطبيقات الرعاية الصحية. وتبرز النتائج أهمية هذه الابتكارات في توفير بيانات اتصال فعالة لتحسين تقديم الرعاية الصحية عن بعد ورعاية المرضى بشكل عام. وتم العمل على برنامج PyCharm.

**الكلمات المفتاحية:** شبكات منطقة الجسم اللاسلكية WBANs، تقنية إعادة التوجيه الديناميكي، تقنية ضغط البيانات، معامل التحديد ( $R^2$ )، متوسط مربع الخطأ (MSE)، متوسط الخطأ المطلق (MAE).

\*أستاذ مساعد في قسم هندسة تكنولوجيا الاتصالات- كلية هندسة تكنولوجيا المعلومات والاتصالات- جامعة طرطوس - سوريا

\*\*أستاذ في هندسة تكنولوجيا المعلومات والاتصالات في جامعة طرطوس-سوريا

\*\*\*طالب ماجستير في كلية هندسة تكنولوجيا المعلومات والاتصالات - هندسة تكنولوجيا الاتصالات - جامعة طرطوس - سوريا

## Evaluating WBAN Performance Using Artificial Intelligence Techniques

Dr. Naji Ibrahim Mohammad\*

Dr. Ghassan Mohammad\*\*

Eng. Alaa Ibrahim Alsheikh\*\*\*

(Received 3/3/2025 . Accepted 29/5/2025)

### □ ABSTRACT □

The study aims to evaluate the performance of wireless body area networks (WBANs) using machine learning models such as linear regression, decision tree, and random forest. In this research, we focused on applying advanced techniques such as dynamic rerouting and data compression to improve the performance of these networks.

The analysis in the study revolves around the production performance and data transfer efficiency of WBANs, in addition to measuring the time delay in data transmission and the bit error rate based on approved evaluation measures such as the coefficient of determination, mean square error, and mean absolute error. The impact of these advanced technologies on the data transfer process and WBAN performance was analyzed and measured. It was concluded that the use of these technologies plays a major role in enhancing the efficiency of WBANs and improving wireless. The results highlight the importance of these innovations in providing effective communication environments to improve the provision of remote healthcare and patient care in general. The PyCharm program was worked on.

**Keywords:** Wireless Body Area Networks (WBANs), Dynamic Forwarding, Data Compression, Coefficient of Determination( $R^2$ ), Mean Square Error (MSE), Mean Absolute Error (MAE)

---

\*Assistant Professor, Department of Communication Technology Engineering, Faculty of Information Technology and Communication Engineering, Tartous University, Syria

\*\*Professor of Information Technology and Communication Engineering, Tartous University, Syria

\*\*\*Master Student, Faculty of Information Technology and Communication Engineering, Communication Technology Engineering, Tartous University, Syria

## ١. المقدمة:

شبكات الجسم اللاسلكية (WBAN (Wireless Body Area Networks تعتبر نوعاً مبنكراً من شبكات الاتصالات اللاسلكية تهدف الى ربط أجهزة استشعار صغيرة ومتناهية الصغر داخل او على سطح الجسم. تستخدم WBANs في تطبيقات الرعاية الصحية لمراقبة الحالة المرضية للمرضى، تسجيل البيانات الحيوية، ونقل المعلومات الطبية بشكل امن. وتلعب تقنيات الذكاء الاصطناعي دوراً حيوياً في تعزيز أداء شبكات WBAN عن طريق تحسين كفاءة نقل البيانات وتقليل التأخير وتخفيض معدل البت وبالتالي تجمع بين الابتكار التقني والتحليل الذكي للبيانات لتوفير بيانات اتصال امنة وفعالة تعزز تجربة الرعاية الصحية عن بعد وتحسين رعاية المرضى [1].

## ٢. أهمية البحث وأهدافه:

تتمثل الطريقة التشغيلية لشبكات WBANs في وضع عدد قليل من عقد التحسس في الجسم او حوله ومن المفترض ان تعمل في ظروف محدودة مع توفير أداء عالٍ من عمر الشبكة والإنتاجية العالية والموثوقية العالية للبيانات. ويرجع ذلك الى اعتماد WBAN في التطبيقات الطبية في تطبيقات انقاذ الحياة حيث تراقب شبكة مستشعرات الجسم سلوكيات وعلامات الجسم الفيزيولوجية الحيوية، وتبلغ عن ذلك الى نظام مراقبة صحي مركزي او عن بعد. يهدف البحث الى استخدام نماذج التعلم الآلي لتقييم أداء شبكات منطقة الجسم WBAN وفقاً لثلاث معايير الإنتاجية والتأخير ومعدل خطأ البت بالاعتماد على مقاييس التقييم: معامل التحديد ومتوسط مربع الخطأ ومتوسط الخطأ المطلق وتحسين أداء النماذج بالاعتماد على تقنية إعادة التوجيه الديناميكي وتقنية ضغط البيانات وبالتالي تحسين أداء شبكات WBANs وزيادة معدل نقل البيانات وتقليل التأخير وتخفيض معدل الخطأ وتقديم رعاية صحية أفضل للمرضى.

## ٣. طرائق البحث ومواده:

يتناول هذا البحث تقييم أداء شبكات منطقة الجسم اللاسلكية WBANs باستخدام تقنيات الذكاء الاصطناعي (الانحدار الخطي - الغابة العشوائية - شجرة القرار) بناءً على مقاييس ( $MAE-MSE-R^2$ ) وتقييم الإنتاجية والتأخير الزمني ومعدل خطأ البت (BER) من أجل دراسة أداء شبكات منطقة الجسم اللاسلكية والحفاظ على صحة البيانات المنقولة ضمن الشبكة وزيادة معدل النقل وتحسين الموثوقية. وبناء على هذه الدراسة بالاعتماد على نتائج ( $R^2-MAE-MSE$ ) يمكن تحديد النموذج الأفضل من بين النماذج المدروسة لتقييم أداء شبكات منطقة الجسم. توفر هذه الدراسة نظرة شاملة حول كيفية استخدام نماذج التعلم الآلي لتقييم أداء شبكات منطقة الجسم وتحسينها باستخدام تقنية إعادة التوجيه الديناميكي وتقنية ضغط البيانات. وبالتالي باستخدام المعايير المناسبة وتحليل النتائج، يمكن تحسين أداء الشبكة وتقديم الرعاية الصحية الأمثل.


عن طريق هذا البحث سوف نجري التقييم التالي:

- تقييم أداء شبكات WBANs وذلك من خلال دراسة كل من الإنتاجية ومعدل خطأ البت والتأخير باستخدام تقنيات الذكاء الاصطناعي.
- تحسين أداء هذه الشبكات باستخدام تقنية إعادة التوجيه الديناميكي وتقنية ضغط البيانات.
- الحفاظ على بيانات المريض.

- تخفيف الآثار الناتجة عن التأخير لضمان ارسال البيانات بنجاح.
  - تخفيف الآثار الناتجة عن الأخطاء التي تعرض حياة المريض للخطر.
- تم العمل باستخدام برنامج PYCHARM من أجل اظهار المخططات البيانية ودراسة وتقييم النتائج.
- ٤- شبكات منطقة الجسم اللاسلكية WBANs والذكاء الاصطناعي.

WBAN تمثل شبكة لاسلكية على جسم الانسان تتألف من مجموعة من العقد تتراوح بين 6 و 256 عقدة حيث كل عقدة مزودة بجهاز استشعار وتقع في مواقع مختلفة على جسم الإنسان اعتمادًا على وظيفة عقدة المستشعر، وتقيس هذه العقد الحالات الصحية المختلفة للجسم، ثم يتم نقل البيانات الطبية إلى عقدة الهدف. حيث الشكل (1) يُظهر بنية شبكة WBAN مع أنواع مختلفة من العقد الموزعة في / على / حول جسم الإنسان وطبقاته المتعددة [2]. تقوم عُقد المستشعر مثل EEG و ECG و EMG ومستشعرات ضغط الدم وأجهزة استشعار الحركة بنقل البيانات الطبية الحيوية إلى أجهزة الخادم الشخصي (PS). بعد ذلك، من خلال اتصال WLAN (شبكة المنطقة المحلية اللاسلكية) أو Bluetooth، يتم نقل هذه البيانات الطبية الحيوية عن بُعد إلى موقع الطبيب للتشخيص، أو لطلب المساعدة بشأن مشكلة طارئة، أو لحفظ السجلات في قاعدة بيانات طبية. يمكن فصل بنية الاتصالات الخاصة بشبكات WBAN إلى ثلاثة مستويات مختلفة: الاتصالات داخل WBAN (تصميم Tier-1-Comm)، والاتصال بين WBAN (تصميم Tier-2-Comm)، وما وراء اتصالات WBAN (تصميم Tier-3-Comm) [3].

الشكل (1) بنية شبكات WBAN



ويفضل تطور التكنولوجيا، تمتلك شبكات WBANs القدرة على توفير رصد صحي دقيق وفعال لمختلف البيانات الطبية مثل معدل ضربات القلب، ضغط الدم، مستويات السكر في الدم وغيرها الكثير. يعتبر استخدام الذكاء الاصطناعي في WBAN من اهم الابتكارات التي تعزز من أداء هذه النظم، حيث يمكن للذكاء الاصطناعي تحليل البيانات الطبية بشكل فوري ودقيق [4].

وباستخدام تقنيات الذكاء الاصطناعي مثل التعلم الآلي، يتم تحسين قدرة WBAN على توفير تشخيص سريع ودقيق للحالات الصحية، وبالتالي تحسين جودة الرعاية الصحية المتقدمة. إضافة الى ذلك، يمكن للذكاء الاصطناعي ان يساهم في تنبؤ المخاطر الصحية وتحسين إدارة الامراض المزمنة، وتحسين توجيه العلاجات

الصحية. هذا المزيج المثير بين تكنولوجيا WBAN والذكاء الاصطناعي يفتح الأفق لابتكارات مستقبلية تعتمد على التكنولوجيا في مجال الرعاية الصحية ويوفر فرصاً كبيرة لتحسين جودة الرعاية الصحية [5]. حيث سيتم تقييم أداء شبكات منطقة الجسم اللاسلكية اعتماداً على ثلاث مقاييس تقييم:

- **معامل التحديد ( $R^2 - score$ ):** يقيس مدى تفسير النموذج للتباين في البيانات.

إذا كانت قيمته قريبة من الواحد فهذا يعني ان النموذج يفسر البيانات بشكل جيد [6] ، ويعطى بالعلاقة (1):

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (1)$$

حيث:  $y_i$ : القيم الفعلية

$\hat{y}_i$ : القيم المتوقعة

$\bar{y}$ : متوسط القيم الفعلية

- **MAE (Mean Absolute Error):** يمثل متوسط القيم المطلقة للخطأ بين

القيم المتوقعة والقيم الفعلية [7] ، ويعطى بالعلاقة (2):

$$MAE = \sum |y_i - \hat{y}_i| / n \quad (2)$$

حيث:  $y_i$ : القيم الفعلية

$\hat{y}_i$ : القيم المتوقعة

n: عدد العينات

- **MSE (Mean Squared Error):** يمثل متوسط القيم المربعة للفروق بين

القيم المتوقعة والقيم الفعلية [8] . ويعطى بالعلاقة (3):

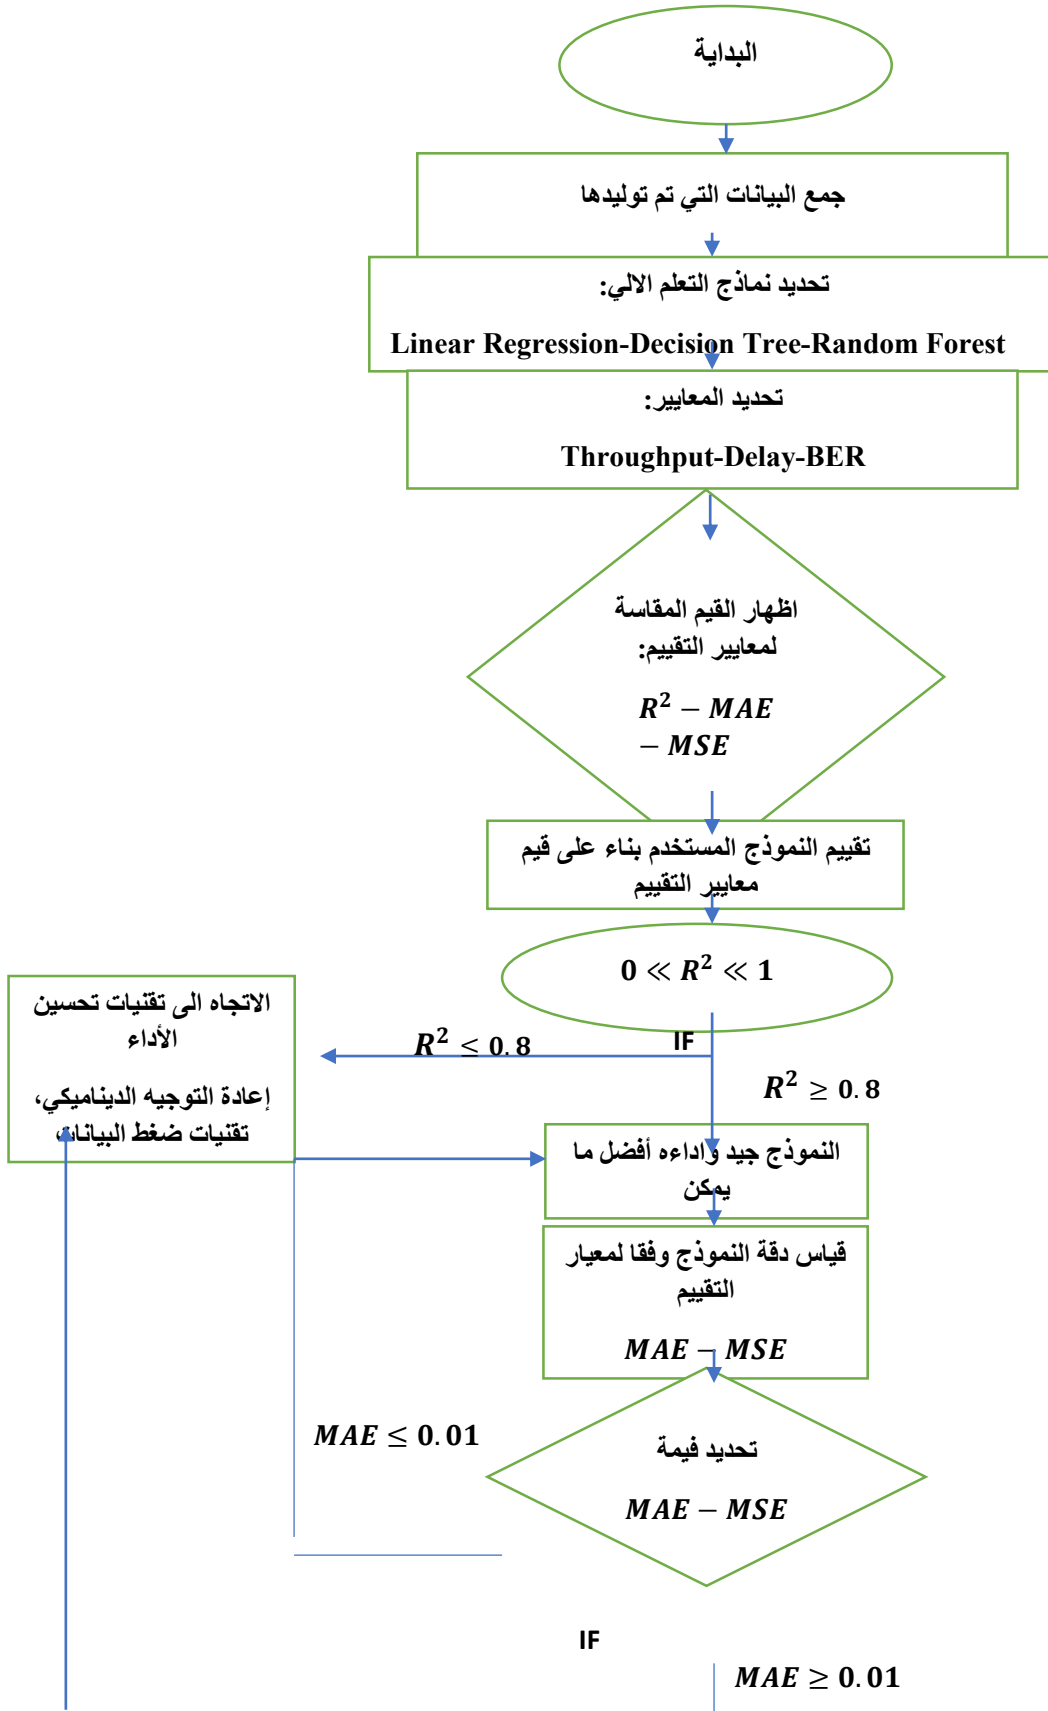
$$MSE = \sum (y_i - \hat{y}_i)^2 / n \quad (3)$$

حيث:  $y_i$ : القيم الفعلية

$\hat{y}_i$ : القيم المتوقعة

n: عدد العينات

وبين الشكل (2) خوارزمية تقييم نماذج التعلم الآلي التي سوف يتم العمل عليها في دراستنا:



الشكل (2) خوارزمية تقييم نماذج التعلم الآلي

## ٥- النتائج والمناقشة:

سيتم اجراء المحاكاة باستخدام برنامج PyCharm وسيتم تقييم شبكات منطقة الجسم اللاسلكية WBAN باستخدام ثلاث نماذج من التعلم الآلي للمعايير الثلاث الإنتاجية والتأخير ومعدل خطأ البت BER بناء على مقاييس تقييم الأداء:  $R^2$ , MAE, MSE.

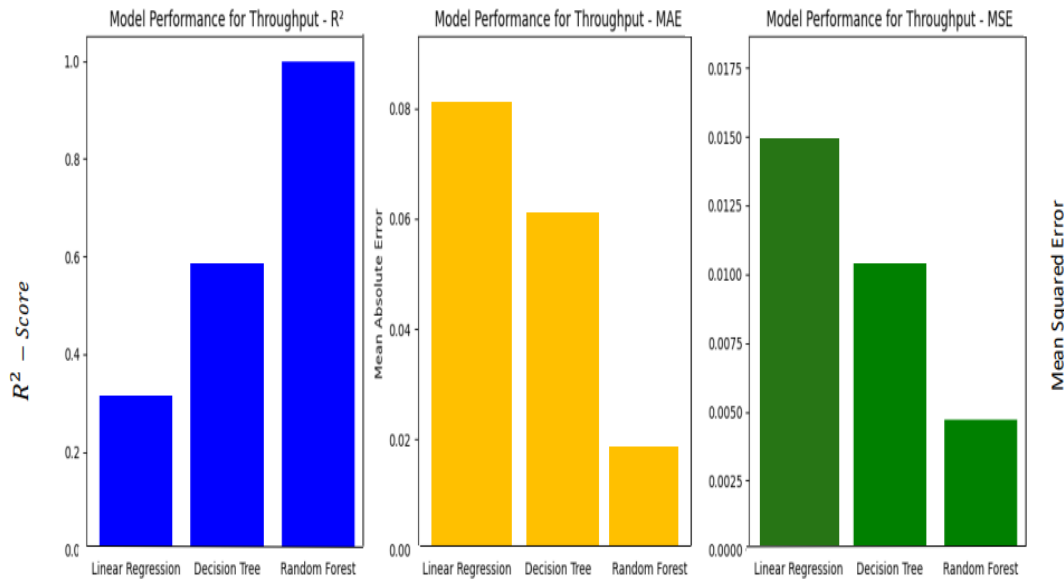
١-٥ دراسة إنتاجية الشبكة: كما هو ملاحظ في الشكل (3) وجود ثلاث مخططات للإنتاجية لثلاث نماذج للتعلم الآلي (Linear Regression-Decision Tree-Random Forest) وفقا لمعايير التقييم:

• معامل التحديد ( $R^2 - score$ ): نلاحظ من المخطط ان معامل التحديد في نموذج الغابة العشوائية هو الأفضل نظرا لتميزه بدقة عالية في التنبؤ بقيمة الإنتاجية في شبكات WBAN، ويعتبر نموذج الانحدار الخطي اقل فعالية في تقدير معامل التحديد للإنتاجية في شبكات WBAN لأنه يعطي تقديرات بدقة محدودة عند التعامل مع البيانات ذات تباين كبير او تفاوت كبير بين القيم المتوقعة والفعلية.

• مخطط MAE (Mean Absolute Error): يعتبر نموذج الغابة العشوائية مفيدا لتقليل MAE في تنبؤ إنتاجية شبكات WBAN وذلك لقدرته على التعامل مع بيانات تدريب كبيرة وسهولة التعامل مع البيانات غير الهيكلية وهذا يساهم في تقليل MSE وزيادة دقة التنبؤ بإنتاجية الشبكة.

• مخطط MSE (Mean Squared Error): حيث يعرض متوسط الخطأ المطلق لكل نموذج ويساعد هذا المخطط في تحديد النموذج الذي يقدم أقل خطأ مطلق، كلما كان قيمته أقرب للصفر كانت دقة النموذج أفضل. وهذا يظهر في نموذج الغابة العشوائية حيث ان قيمة الخطأ اقل من النماذج الأخرى أي تقدم توقعات أكثر دقة ويتجنب التأثيرات السلبية للقيم الشاذة بشكل أفضل من النماذج الأخرى.

ونستنتج مما سبق ان أفضل نموذج لدراسة الإنتاجية هو نموذج الغابة العشوائية وذلك لقدرتها على التقاط العلاقات المعقدة وغير الخطية في بيانات WBAN ومقاومتها للتجاوز (overfitting) مما يؤدي الى تنبؤات أكثر دقة على البيانات الجديدة.



الشكل (3) تقييم إنتاجية شبكات WBAN باستخدام مقاييس التقييم ( $R^2$  و MSE و MAE).

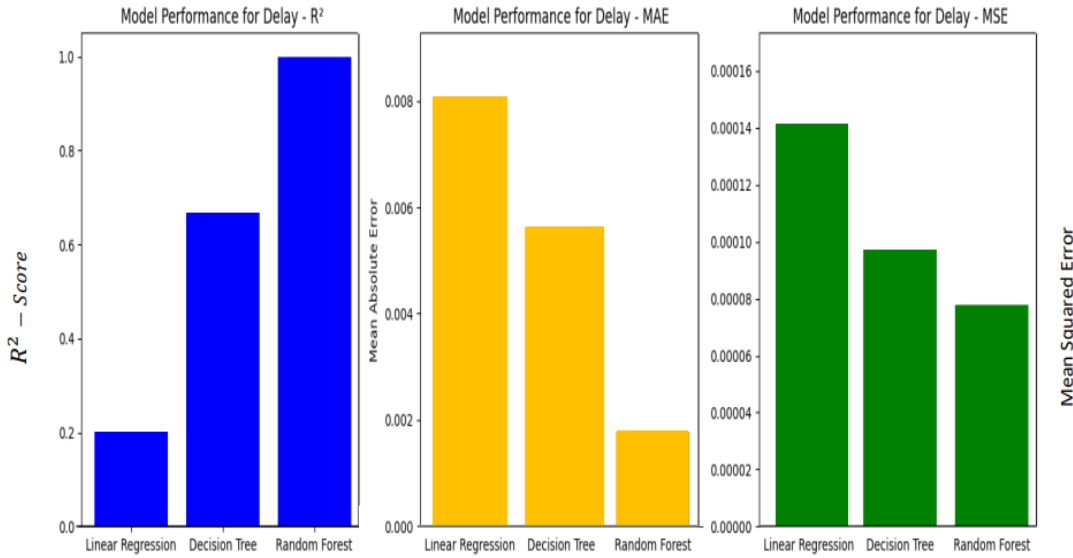
٢-٥ دراسة تأخير الشبكة: يبين الشكل (4) نتائج دراسة التأخير حيث نلاحظ ان:

• **معامل التحديد ( $R^2 - score$ ):** كما هو الحال مع الإنتاجية، الغابة العشوائية تقدم قيم ( $R^2$ ) مرتفعة تصل تقريباً للواحد وبالتالي يمكنه من توقع التأخير بدقة وتحليل البيانات بشكل فعال لتحسين أداء الشبكة

• **مخطط (MAE (Mean Absolute Error):** الغابة العشوائية تقدم أداء أفضل فيما يتعلق ب (MAE) عند تحليل تأخير شبكات WBAN حيث يمكنه من تحسين الدقة والأداء في التوقع والتقدير وبالتالي تحسين كفاءة الشبكة وجودتها.

• **مخطط (MSE (Mean Squared Error):** تعتبر نموذج الغابة العشوائية خياراً مناسباً لتحسين (MSE) في تقدير تأخير شبكات WBAN حيث يتمتع بالدقة والمرونة والقدرة على التعامل مع البيانات المعقدة بشكل فعال.

وبالتالي نموذج الغابة العشوائية هو أداة قوية لتقييم التأخير في WBANs بسبب مرونته في التعامل مع أنواع مختلفة من البيانات وكفاءته ويساعد في تحديد العوامل الأكثر تأثيراً على التأخير مما يتيح تحسين تصميم الشبكة.



الشكل (4) تقييم تأخير شبكات WBAN باستخدام مقاييس التقييم ( $R^2$  و MSE و MAE).

٣-٥ دراسة معدل الخطأ في البت (BER): يبين الشكل (5) نتائج دراسة معدل خطأ البت حيث نلاحظ


ان:

• **معامل التحديد ( $R^2 - score$ ):** الغابة العشوائية تقدم قيم ( $R^2$ ) مرتفعة لمعدل خطأ البت مما يعني قدرتها على تفسير التباين في BER بشكل جيد كما هو واضح في الشكل (5-a).

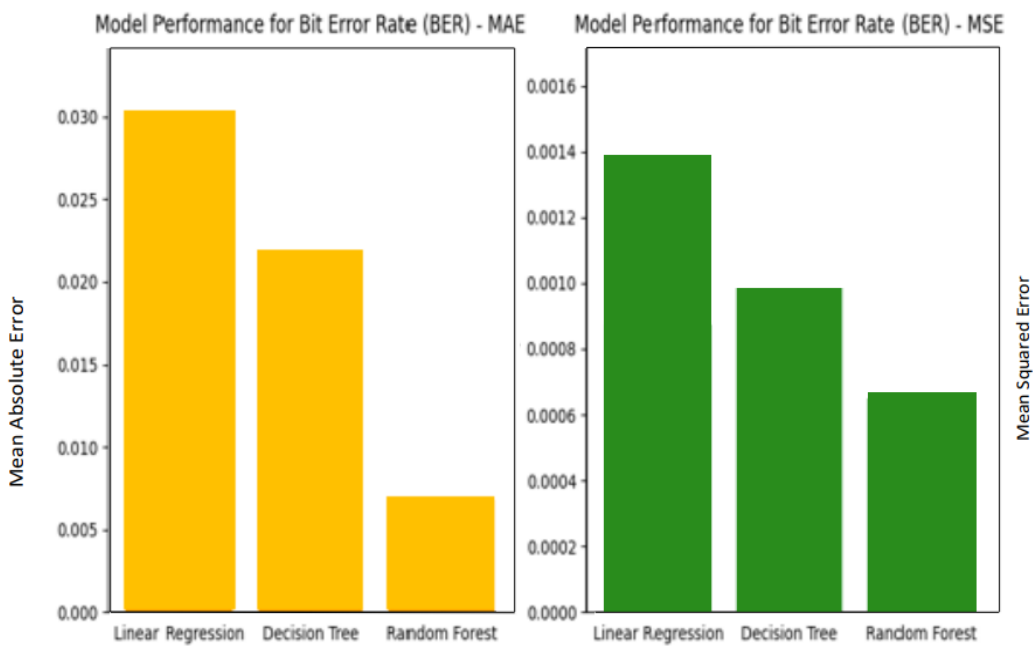
• **مخطط (MAE (Mean Absolute Error):** كما واضح في الشكل (5-b) الغابة العشوائية تحقق أيضاً (MAE) منخفض مما يعني ان لها تقديرات دقيقة لمعدل خطأ البت وهو امر حاسم في ضمان جودة الاتصال

• **مخطط MSE (Mean Squared Error)**: كما واضح في الشكل (5-c) MSE المنخفض في الغاية العشوائية يشير الى ان النموذج ينجح في تقليل الأخطاء الكبيرة مما يجعله مثاليا لتقدير (BER) وبالتالي أداء أفضل لشبكات WBAN.

ونستنتج ان نموذج الغاية العشوائية هو الأفضل لتقييم معدل خطأ البت لأنه يتعامل مع العلاقات المعقدة بسبب تأثر BER بعوامل غير خطية وبالتالي قدرته على ضبط هذه العلاقات المعقدة غير الخطية بين العوامل المختلفة و BER مما يؤدي الى تنبؤات اكثر دقة.



الشكل (5-a) تقييم معدل خطأ البت BER لشبكات WBAN باستخدام مقياس التقييم ( $R^2$ ).



الشكل (5-b) تقييم BER لشبكات WBAN باستخدام (MAE)

الشكل (5-c) تقييم BER لشبكات WBAN باستخدام (MSE)

الشكل (5) تقييم معدل خطأ البت BER لشبكات WBAN باستخدام مقياس التقييم ( $R^2$  و MSE و MAE).

ويمكن تحسين أداء شبكات WBAN باستخدام تقنيات عديدة منها:

(١) تقنية إعادة التوجيه الديناميكي (Dynamic Routing): تعتبر استراتيجية توجيه البيانات استجابةً بشكل تلقائي للتغيرات في شروط الشبكة وحركة البيانات. تستخدم هذه التقنية لضمان أفضل طريقة لتوجيه البيانات داخل الشبكة، مما يؤدي إلى تحسين توزيع البيانات وتقليل التأخير وتحسين أداء الشبكة بشكل عام في WBAN [9].

(٢) تقنية ضغط البيانات: وهو عملية تقليل حجم البيانات اللازمة لتخزينها ونقلها عبر الشبكة. عندما يتم ضغط البيانات بكفاءة، يمكن تقليل حجم البيانات المنقولة مما يؤدي إلى تقليل التأخير وتحسين أداء شبكات WBAN [10].

وبالتالي توجيه البيانات بشكل ديناميكي وضغطها بشكل فعال يمكن أن يحسن من أداء نماذج التعلم الآلي داخل شبكات WBAN مما يزيد من الإنتاجية ويقلل من التأخير.

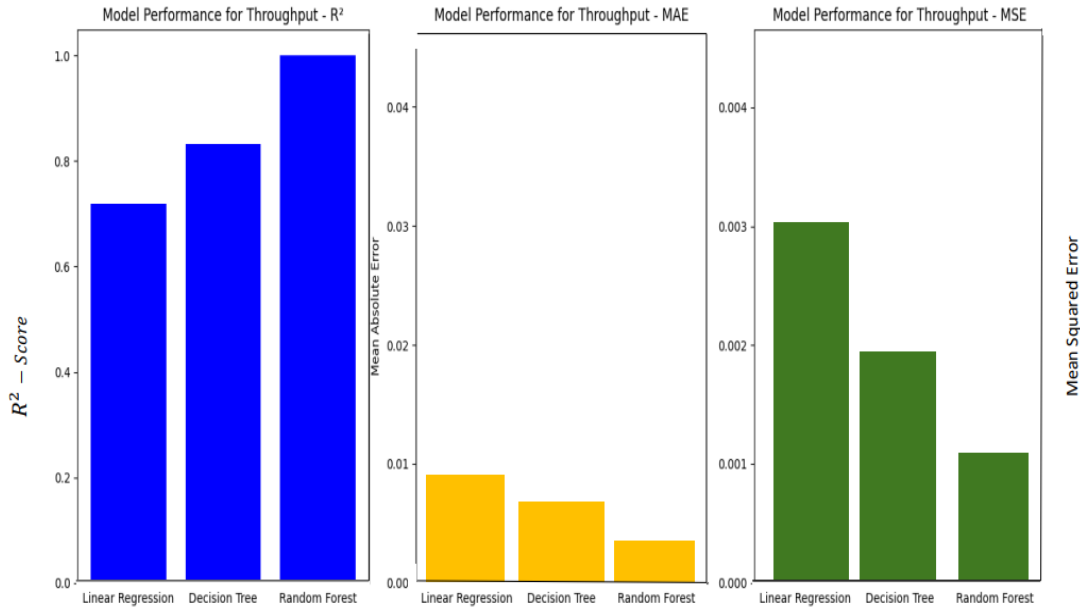
٦- استخدام تقنيات تحسين أداء شبكات WBAN لدراسة:

٦-١ إنتاجية الشبكة: يبين الشكل (6) نتائج دراسة الإنتاجية بعد استخدام تقنيتي إعادة التوجيه الديناميكي وضغط البيانات حيث نلاحظ أن:

معامل التحديد زاد في كل من النماذج الثلاث في شبكات WBAN حيث كما هو واضح في نموذج الانحدار الخطي أصبح قيمته 0.7 وفي نموذج شجرة القرار أصبح قيمته 0.83 وبالتالي زيادة في الإنتاجية لشبكات WBAN وتحسين أداء الشبكة.

وفي متوسط الخطأ المطلق MAE تم تقليله للنماذج الثلاث في شبكات WBAN وذلك بعد استخدام تقنية إعادة التوجيه الديناميكي وتقنية ضغط البيانات، كما هو واضح في نموذج الانحدار الخطي أصبح قيمته 0.009 وفي نموذج شجرة القرار أصبح 0.007 وبالتالي تحسين في إنتاجية شبكات WBAN

وفي متوسط مربع الخطأ MSE نلاحظ أن قيمة الخطأ في النماذج قد انخفضت كما هو واضح في نموذج الانحدار الخطي أصبحت قيمة الخطأ 0.003 وفي نموذج شجرة القرار أصبحت 0.0018 وبالتالي أداء الشبكة أفضل ما يمكن.

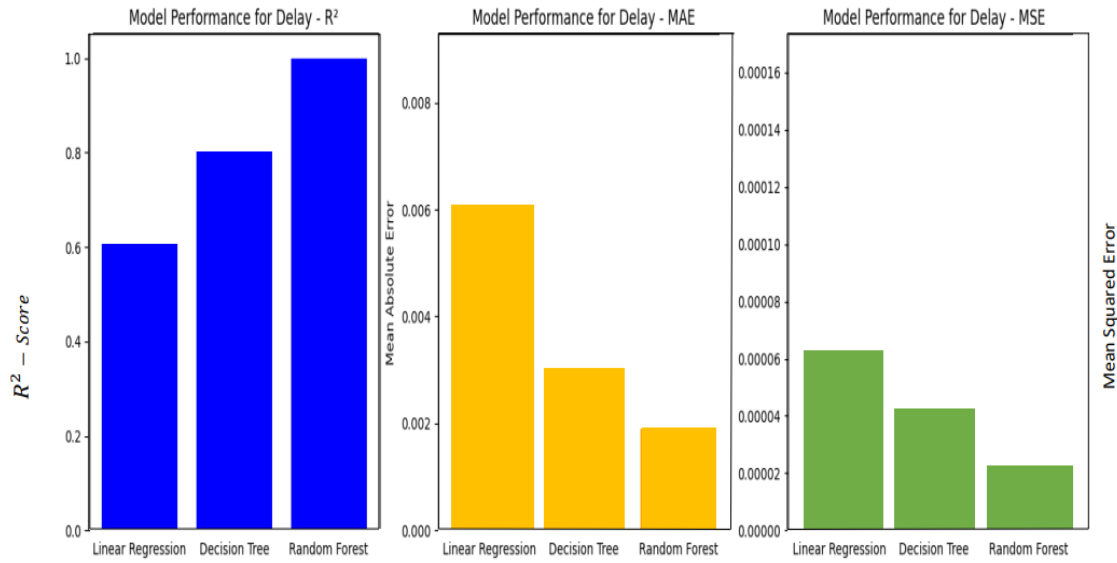


الشكل (6) تقييم إنتاجية شبكات WBAN باستخدام مقاييس التقييم ( $R^2$  و  $MSE$  و  $MAE$ ) اعتماداً على تقنيات إعادة التوجيه أميكي الديناميكي وضغط البيانات.

قيم ( $R^2$ ) قد ارتفعت بعد استخدام تقنية إعادة التوجيه الديناميكي وتقنية ضغط حيث ان قيمة ( $R^2$ ) في نموذج الانحدار الخطي أصبحت 0.6 وفي نموذج شجرة القرار أصبحت 0.8 وهذا يقلل من التأخير ويصبح أداء الشبكة أفضل.

وانخفضت قيمة MAE لنموذج الانحدار الخطي 0.006 ولنموذج شجرة القرار 0.003 وهذا يساهم في تقليل التأخير وبالتالي دقة أفضل في التنبؤ بالبيانات في شبكات WBAN.

وكما هو واضح أيضا في مخطط ( $MSE$ ) حيث أصبحت قيمة الخطأ منخفضة بعد استخدام التقنيات وهذا التقليل يعني ان النماذج قادرة على تقدير البيانات بشكل ادق، مما يساهم في تقليل التأخير وتحسين أداء شبكات WBAN حيث أصبح قيمة الخطأ في نموذج الانحدار الخطي 0.00006 وفي نموذج شجرة القرار 0.00004.



الشكل (7) تقييم تأخير شبكات WBAN باستخدام مقاييس التقييم ( $R^2$  و MSE و MAE) اعتماداً على تقنيات إعادة التوجيه الديناميكي وضغط البيانات.

الديناميكي وضغط البيانات حيث نلاحظ ان:

بعد تطبيق تقنية إعادة التوجيه الديناميكي وضغط البيانات لاحظنا تحسناً في قيم معامل التحديد  $R^2$  لنموذج الانحدار الخطي حيث أصبح قيمته 0.6 ونموذج الغابة العشوائية أصبح 0.8 كما في الشكل (8-a) وهذا يدل ان النماذج أصبحت أكثر قدرة على تفسير التباين في البيانات بعد استخدام هذه التقنيات وهذا يقلل من الأخطاء في شبكات WBAN ويحسن من أدائها.

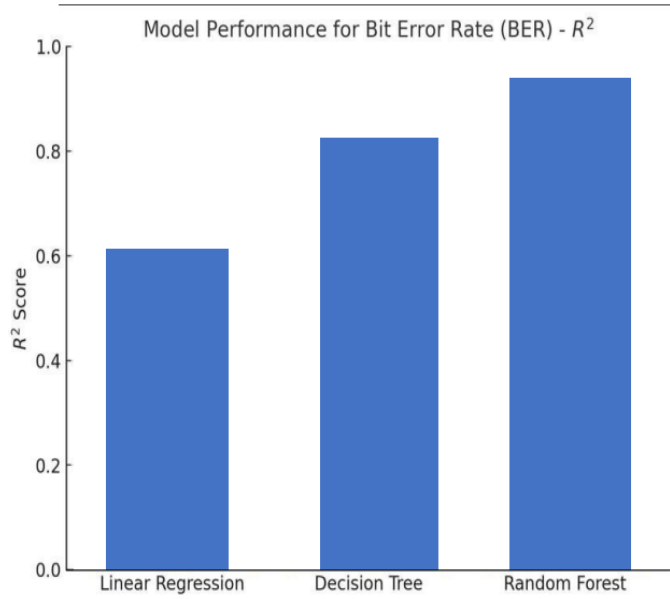
وانخفضت قيمة MAE لنموذج الانحدار الخطي 0.009 ولنموذج شجرة القرار 0.007 كما في الشكل (8-b)

(b) وها يساهم في تقليل معدل خطأ البت وبالتالي دقة أفضل في التنبؤ بالبيانات في شبكات WBAN.

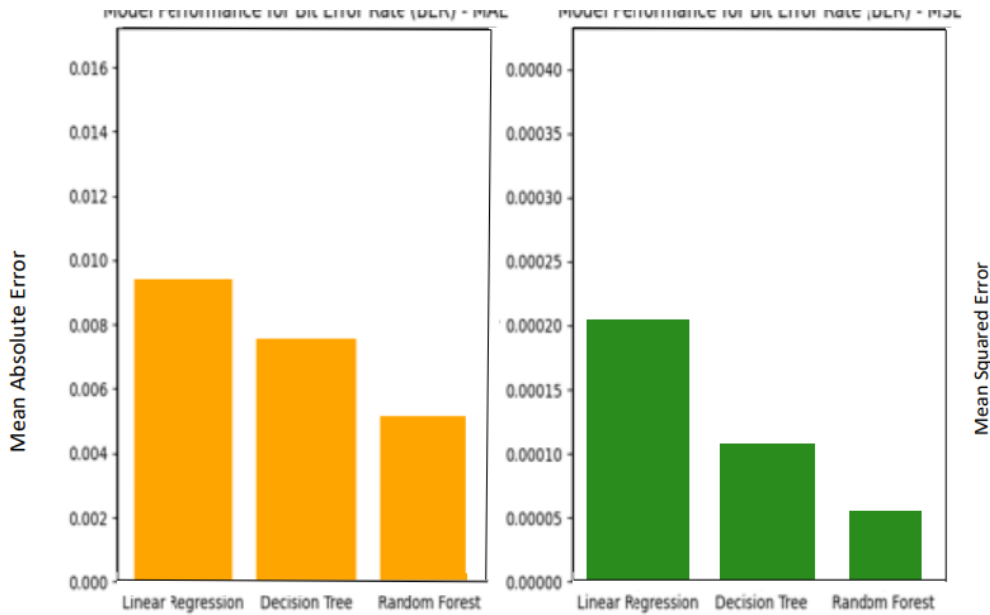
وكما هو ملاحظ في مخطط MSE ان القيم انخفضت للنماذج بعد استخدام التقنيات حيث أصبحت قيمة

MSE للانحدار الخطي 0.0002 وللغابة العشوائية 0.00005 كما في الشكل (8-c) وهذا يشير الى تحسين

الدقة في تقدير البيانات وبالتالي تحسين معدل خطأ البت في شبكات WBAN.



الشكل (8-a) تقييم BER لشبكات WBAN باستخدام مقياس التقييم ( $R^2$ ) اعتماداً على تقنيات إعادة التوجيه الديناميكي وضغط البيانات.



الشكل (8-b) تقييم BER لشبكات WBAN

الشكل (8-c) تقييم BER لشبكات WBAN

الشكل (8) تقييم BER لشبكات WBAN باستخدام مقاييس التقييم (MAE و MSE) اعتماداً على تقنيات إعادة التوجيه الديناميكي وضغط البيانات.

بناءً على التقييم الشامل لاداء شبكات منطقة الجسم اللاسلكية WBAN باستخدام نماذج التعلم الآلي (الانحدار الخطي، الغابة العشوائية، شجرة القرار) بالاعتماد على مقاييس التقييم (معامل التحديد، متوسط الخطأ المطلق، متوسط مربع الخطأ) وتحسين أداء هذه الشبكات من خلال استخدام تقنية إعادة التوجيه الديناميكي وتقنية ضغط البيانات نستنتج ما يلي:

- **عند دراسة إنتاجية** شبكات WBAN نلاحظ ان قيم معامل التحديد قد ارتفعت من 0.3 الى 1 بنسبة 70% للنماذج الثلاث، وقيم متوسط الخطأ المطلق قد انخفضت من 0.8 الى 0.004 بنسبة 99.5%، وقيم مربع خطأ البت قد انخفضت من 0.015 الى 0.001 بنسبة 93.33%.
- **عند دراسة التأخير:** في شبكات WBAN نلاحظ ان قيم معامل التحديد قد ارتفعت من 0.2 الى 1 بنسبة 80% للنماذج الثلاث، وقيم متوسط الخطأ المطلق قد انخفضت من 0.08 الى 0.002 بنسبة 97.5%، وقيم مربع خطأ البت قد انخفضت من 0.00014 الى 0.00002 بنسبة 85.71%.
- **عند دراسة معدل خطأ البت BER:** في شبكات WBAN نلاحظ ان قيم معامل التحديد قد ارتفعت من 0.2 الى 0.95 بنسبة 75% للنماذج الثلاث، وقيم متوسط الخطأ المطلق قد انخفضت من 0.03 الى 0.005 بنسبة 83.33%، وقيم مربع خطأ البت قد انخفضت من 0.0014 الى 0.00005 بنسبة 99.64%.
- نموذج الغابة العشوائية هو الأفضل في تقييم أداء هذه الشبكات وذلك لعدة أسباب منها يقدم توقعات دقيقة وموثوقة بشأن أداء شبكات WBAN بشكل شامل والقدرة على التعامل مع البيانات الكبيرة وتحليلها بكفاءة عالية ويحقق التوازن بين دقة النموذج وعدم التحامل (overfitting).
- استخدام تقنية إعادة التوجيه الديناميكي وتقنية ضغط البيانات ساهموا في تقليل التأخير ومعدل خطأ البت وزيادة الإنتاجية من خلال تحسين تدفق البيانات وبالتالي جعل الشبكة أكثر ملائمة لتطبيقات الرعاية الصحية.

#### ٧- التوصيات

يمكن ان نعمل على تحسين أداء هذه الشبكات بشكل أفضل بكثير من خلال استخدام تقنيات أخرى مثل تقنيات التعلم العميق والشبكات العصبونية وبالتالي الحصول على أداء أفضل لشبكات WBAN وتوقع أفضل لحالة المريض.

#### ٨- المراجع:

- [1] K. M. S. Thotahewa, J.-M. Redoute, and M. R. Yuce, *Ultra Wideband Based Wireless Body Area Networks*. New York: Springer Science & Business, 2014
- [2] M. Chen, S. Gonzalez, A. Vasilakos, H. Cao, and V. C. M. Leung, "Body area networks: A survey," *Mob. Networks Appl.*, vol. 16, no. 2, pp. 171–193, 2011
- [3] B. Braem, "Reliable and Energy Efficient Protocols for Wireless Body Area Networks," *Universiteit Antwerpen (Belgium)*, 2011
- [4] Mamoun Awad , Farag Sallabi , Khaled Shuaib , Faisal Naeem. " *Artificial intelligence-based fault prediction framework for WBAN*" 2021
- [5] Mohamed Bahache , Abdou El Karim Tahari , Jorge Herrera-Tapia , Nasreddine Lagraa , Carlos Tavares Calafate and Chaker Abdelaziz Kerrache. " *Towards an Accurate Faults Detection Approach in Internet of Medical Things Using Advanced Machine Learning Techniques*" 2023
- [4] Vera, D.; Costa, N.; Roda-Sanchez, L.; Olivares, T.; Fernández-Caballero, A.; Pereira, A. *Body area networks in healthcare: A brief state of the art*.2020
- [5] Jabeen, T.; Ashraf, H.; Ullah, A. *A survey on healthcare data security in wireless body area networks*. J. Ambient. Intell. Humaniz. Comput. 2021
- [6] Smith, j . " *Understanding the Coefficient of Determination: An Overview of Statistical Concepts*" 2022.

[7] Martinez, A. "*Comparative Analysis of Mean Absolute Error Calculation Methods*" 2017

[8] Wang,H. "*A Deep Dive into Mean Squared Error: Techniques and Challenges*" 2016

[9] "*Routing Protocols in Wireless Body Area Networks: A Review*" by S. Alam, et al., International Journal of Distributed Sensor Networks, 2014.

[10] "*Data Compression Techniques for Wireless Body Area Networks: A Review*" by A. Kumar, et al., Journal of Medical Systems, 2018.