

بناء نموذج فقد المسار للاتصالات اللاسلكية في المناطق القروية بمدينة مصراته في ليبيا باستخدام تقنيات تعلم الآلة

www.doi.org/10.62341/ammr2324

علي عبدالحفيظ الروياتي محمد محمود الشوماني عبد القادر محمد الروياتي
كلية التقنية الصناعية المعهد العالي للعلوم كلية التقنية الصناعية
مصراته والتقنية مسلاته مصراته
elrowayati@yahoo.com mohamedshumani@yahoo.com abdo1997th@gmail.com

الملخص

يعد التنبؤ بخسارة المسار ذا أهمية كبيرة في دراسات بناء وتطوير وتحسين أداء الشبكات اللاسلكية و الانتشار التدريجي لأنظمة الاتصالات الخليوية أو المتقلة من الجيل الخامس (5G) وما تطلبه من دقة في الأداء وتقليل في الخسائر، عليه ينبغي اقتراح طرق جديدة للتنبؤ بخسارة المسار بدقة عالية وأقل تعقيد. في هذه الورقة تم تصميم وتنفيذ نماذج فقد المسار باستخدام تقنيات الذكاء الصناعي والتعلم الآلي والتي توظف قاعدة بيانات حقيقية مقاسة من أبراج شركة المدار الجديد في بيئة ريفية بمدينة مصراتة تعمل بتقنية GSM ضمن النطاق الترددي 900 ميجاهرتز. تظهر نتائج تقييم أداء النماذج المختلفة من تقنيات الذكاء الاصطناعي كشبكة الانحدار المعممة وشبكة الملائمة تقوفاً في الأداء على النماذج التقليدية كالنموذج البسيط والنموذج الخطي، حيث أظهرت النتائج أن متوسط مربعات الخطأ لنموذج فقد المسار البسيط (simplified model) يساوي 5.87، بينما تقل نسبة مربعات الخطأ في نموذج شبكة الانحدار المعممة (GRNN) إلى 0.26، وفي نموذج شبكة الملائمة (Fitnet) تصل نسبة مربعات الخطأ إلى 0.97، وفي نموذج التغذية الأمامية (Feedforward net) تساوي 1.35. وهذا يشير إلى أن نماذج فقد المسار المستخدمة بتقنيات الذكاء الاصطناعي أفضل من الطرق التقليدية. كما أظهرت الدراسة أن الترابط بين قيم القدرة المتنبئ به بواسطة نماذج الذكاء الصناعي والقدرة المقاسة تشير أن دقة التنبؤ عالية للنماذج المقترحة في الدراسة، حيث قيمة الترابط الكلية لنموذج

الملاءمة (Fit net) تساوي $R=0.9962$ وكانت قيمة الترابط الكلية لنموذج التغذية الأمامية (Feedforward net) تساوي $R=0.99399$. ومن هنا يتضح جلياً أن النماذج المقترحة تمتاز بالدقة و الموثوقية ويمكن تطبيقها والاستفادة منها لحساب فقد المسار في المناطق الريفية والضواحي بدولة ليبيا.
الكلمات الدالة: الاتصالات اللاسلكية، الاتصالات الخليوية، فقد المسار، الشبكات العصبية الاصطناعية، تعلم الآلة، المناطق القروية.

Misurata Rural Area Path Loss Propagation Prediction and Optimization Using Machine Learning Techniques

www.doi.org/10.62341/ammr2324

Ali A.
Elrowayati

College of
Industrial
Technology,
Misurata, LIBYA
elrowayati@yahoo.com

Shumani M. M

High Institute Science
and Technology
Mesallata, Mesallata,
LIBYA
mohamedshumani@yahoo.com

Abdulqadir M.
Alrouyati

College of Industrial
Technology, Misurata,
LIBYA
abdo1997th@gmail.com

Abstract

Path loss prediction is of great importance in studies of designing, developing, and improving the performance of wireless networks and mobile communication systems of the 5G which requires of accuracy in performance and reduction in losses. Therefore, new models should be proposed to predict path loss propagation with high accuracy and less complexity. In this paper, a path loss model was designed and implemented using artificial intelligence and machine learning techniques, which training and testing on a real database created based on maximum measured distance and received power from the base station in a GSM system operating in

900 MHz band, in a rural environment, Misurata, Libya. Traditional methods like the "simple path loss model" performed poorly, with an average error of 5.87. In contrast, modern models based on artificial intelligence (AI) like GRNN, Fitnet, and Feedforward Net achieved significantly lower errors, ranging from 0.26 to 1.35. Furthermore, the AI models showed a strong correlation between the predicted and actual signal strengths (correlation coefficient R reaching 0.9962 for Fitnet and 0.99399 for Feedforward Net). This indicates highly specific and reliable predictions.

Keywords: wireless communications, propagation loss prediction, ANN, machine learning, GRNN, urban area.

مقدمة

في الاتصالات اللاسلكية، تنتشر المعلومات التي يتم إرسالها من طرف إلى آخر فيشكل موجات كهرومغناطيسية. علاوة على ذلك، فإن آليات انتشار الموجات الكهرومغناطيسية متنوعة ويمكن تصنيفها عموماً على أنها انعكاس وانحراف وتشتت وهي السبب الرئيسي لفشل المكالمات وخدمة الانترنت الخليوية. وبالتالي الهدف الرئيسي في مرحلة التخطيط للشبكة اللاسلكية هو توقع فقدان قوة الإشارة أو التغطية في موقع معين، ومن ثم فإن تصميم الجيد لأنظمة الشبكات اللاسلكية يتطلب بناء نماذج فقد المسار قادر على التنبؤ بالقدرة المستقبلية وتحديد مساحات التغطية للإشارة وقد بذل الباحثون والمهندسون جهوداً كبيرة لاكتشاف نماذج معقولة لـ التنبؤ بفقدان المسار في سيناريوهات مختلفة وبترددات مختلفة. هناك العديد من الدراسات تم إجراؤها في جميع أنحاء العالم لجمع البيانات، واستخدامها لبناء وتعديل وتقييم نماذج تخدم هذا الهدف. رأى الباحث في المرجع [1]، أن تصميم الشبكات اللاسلكية للحصول على تغطية ذات جودة عالية يعتمد على دقة نموذج فقد المسار المستخدم في التصميم، وبالتالي فإن موثوقية (Reliability) تصميم الشبكات اللاسلكية للحصول على تغطية ممتازة يعتمد على إيجاد نموذج فقد مسار يعطي نتائج قريبة من القيم الحقيقية المقاسة. بينما وصف المرجع [2] نموذج فقد المسار هاتا التقليدي وكيف تطبقه على نظام CDMA في

المناطق الحضرية في نيجيريا، و أعطى هذا النموذج نتائج مقبولة في التنبؤ في بقدر المسار في البيئة الحضرية.

في سنة 2022م تم الاستفاده من نماذج فقد المسار التقليدية في تصميم الشبكات اللاسلكية للجيل الخامس وتقنيات المدى الطويل (Long Range) أو ما يسمى LoRa، وتستخدم هذه التقنية مع انترنت الأشياء نظرا لمداهها الكبير واستهلاكها المنخفض للطاقة وسعرها المنخفض مقارنة بغيرها من تقنيات الشبكات اللاسلكية. أثبتت النماذج التقليدية قدرة جيدة للتنبؤ بفقد المسار لهذا النوع من الشبكات في البيئة الريفية وشبه الريفية [3].

ولكن تكمن الإشكالية الأساسية لنماذج الفقد التقليدية في ضعف الدقة والمرونة لهذه النماذج المستخدمة في حساب فقد المسار وخاصة مع التطور السريع لأنظمة الاتصالات وحاجتها للتخطيط الدقيق في مشاريعها لتوفر خدمات بأكثر مرونة وقل تكلفة.

في العقد الأخير ظهرت عديد الدراسات التي تناولت تقنيات تعلم الآلة، هذه التقنيات واعدة وبرزت نتائج طيبة وسنستعرض أهمها هنا لنعطي للقارئ خلفية حول موضوع الدراسة. في سنة 2015 قام بن موسى وآخرون وفقا لما ورد بالمرجع [4] باستخدام شبكة عصبية اصطناعية لتحليل مسار فقدان الانتشار في النطاقات الترددية 900 ميجاهرتز و 1800 ميجاهرتز و 2100 ميجاهرتز بمدينة طرابلس، ليبيا. جمع الباحثون قياسات الإشارة وقاموا بتدريب نموذج الشبكة من نوع التغذية الأمامية ثم قارنوا دقته بنموذج هاتا (Hata) الشائع الاستخدام. وأظهرت الدراسة أن نموذج الشبكة العصبية الاصطناعية ذات التغذية الأمامية كان أكثر دقة في توقع مسار فقدان الانتشار. ولكنه اقل دقة مقارنة بغيره من نماذج تعلم الآلة. في سنة 2017، قدم الباحثون وفقا للمرجع [5] بحثا يركز على التنبؤ بفقدان المسار في نطاق تردد فوق العالي (VHF) في نطاق 200 ميجاهرتز وذلك باستخدام نموذج عصبي ضبابي (Neuro-Fuzzy). تم مقارنة النموذج المقترح مع أربعة نماذج تجريبية تقليدية: Hata و COST 231 و Egli و ECC-33. وظهرت النتائج أن النموذج العصبي الضبابي أكثر دقة من النماذج

التجريبية في توقع فقدان المسار. قام البُحاث في المرجع [6] باستخدام شبكة عصبية اصطناعية ذات تغذية أمامية لتحليل مسار فقدان الانتشار وهو مشابهة للنموذج في المرجع [4] مع اختلاف بيئة و مدخلات النموذجين.

مؤخرا اختبر البُحاث في المرجع [7] نموذجين من نماذج الشبكات العصبية الاصطناعية: شبكة ذات مدرك متعددة الطبقات (MLP) Multi-Layer perceptron ومتجه دعم الآلة (SVM) Support Vector Machine. هذا النموذج الهجين أعطى نتائج جيدة وبنسبة متوسط مربع خطأ لم تتجاوز 1.369. الجدول (1) التالي يلخص عددا من الدراسات التي اهتمت ووظفت تقنيات الذكاء الاصطناعي في التنبؤ بفقد المسار لنظم الاتصالات اللاسلكية، حيث أن الهدف الرئيسي من استخدام تقنيات تعلم الآلة هو استخدام أحدث الخوارزميات لتدريب النماذج على مجموعات كبيرة من البيانات التي تمثل خصائص البيئة التي يراد حساب فقد المسار بها، بالإضافة إلى خصائص أجهزة الإرسال والاستقبال. وبعد الانتهاء من التدريب والاختبار يمكن أن نحصل على نماذج عالية الدقة في حساب فقدان المسار لتلك البيئة. عملية التنبؤ بفقد المسار يمكن اعتبارها مسألة انحدار مراقب (Supervised regression problem) [7].

الجدول (1) ملخص لتقنيات الذكاء الاصطناعي المستخدمة للتنبؤ بنماذج فقد المسار

المرجع	نوع التقنية المستخدمة	الخوارزمية	النتائج الرئيسية
[4]	شبكة عصبية اصطناعية	خوارزمية التغذية الأمامية	أظهرت الدراسة أن نموذج الشبكة العصبية الاصطناعية ذات التغذية الأمامية كان أكثر دقة من النماذج التقليدية، حيث متوسط مربعات الخطأ للنموذج تساوي 4.0763
[5]	شبكة عصبية اصطناعية	نموذج عصبي ضبابي (Neuro-Fuzzy)	متوسط مربعات الخطأ للنموذج تساوي 5.25
[6]	شبكة عصبية اصطناعية	خوارزمية التغذية الأمامية	متوسط مربعات الخطأ للنموذج تساوي 5.25
[7]	نموذج مختلط	شبكة عصبية اصطناعية + متجه دعم الآلة	متوسط مربعات الخطأ للنموذج تساوي 1.369

تهدف هذه الورقة إلى دراسة تقنيات تعلم الآلة متنوعة منها ما استخدم أعلاه ولكن بخوارزميات ومنهجية مغايرة، كما تهدف هذه الدراسة إلى توظيف نماذج غير تلك التي استخدمت في الدراسات السابقة أعلاه للتنبؤ بفقد المسار على نظام اتصالات لاسلكي

يعمل بتقنية GSM ضمن النطاق الترددي 900 ميغاهرتز. وتوظيفها في بناء نماذج جديدة لفقد المسار تكون أكثر كفاءة ومرونة وتكيف.

نماذج فقد المسار التقليدية Traditional Path loss models

إن عملية فقد المسار تصف التوهين الذي يحدث لقدرة الإشارة بسبب الانتشار لمسافات مختلفة، في نموذج فقد المسار يتم إهمال التغير الذي يحدث نتيجة لتغير المكان وكذلك يُهمل تأثير تعدد المسارات، حيث أن تغير المكان له علاقة بتأثير التظليل أما تعدد المسارات فله علاقة بتأثير الخبوء، فقد المسار الخطي (Linear path loss) يمكن أن يعرف على أنه نسبة بين قدرة الإشارة المرسله لقدرة الإشارة المستقبله [9][8]. ويمكن حساب فقد المسار بالديسبل dB كما في المعادلة (1).

$$PL_{(dB)} = 10 \log \left(\frac{P_t}{P_r} \right) \quad (1)$$

حيث:

$PL_{(dB)}$: معامل فقد المسار.

P_t : القدرة المرسله.

P_r : القدرة المستقبله.

معادلة فريز (Friis equation) في الفضاء الحرمن أبسط معادلات فقد المسار عند مسافة معينة. حيث يمكن كتابة معادلة نموذج فقد المسار في الفضاء الحر $PL_{(dB)}$ بدلالة القدرة المرسله (P_t) والقدرة المستقبله (P_r) وكسب هوائي الارسل والاستقبال كما في المعادلة (3):

$$P_r = \frac{P_t G_t G_r \lambda^2}{(4\pi)^2 d^2} \quad (2)$$

$$PL_{(dB)} = \frac{P_t}{P_r} = \frac{(4\pi)^2 d^2}{G_t G_r \lambda^2} \quad (3)$$

حيث:

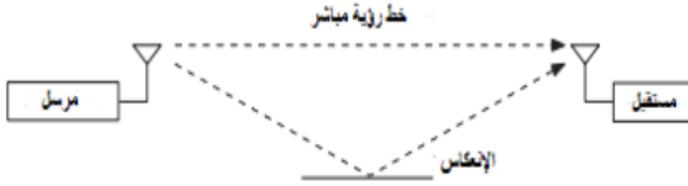
G_t : كسب هوائي الارسل.

G_r : كسب هوائي الاستقبال.

λ : الطول الموجي.

d : المسافة بين المرسل والمستقبل.

ولأن المعادلة (3) خاصة بالبيئة عندما تكون فضاء حراً فهي تصلح للتطبيقات التي توجد فيها خط رؤية مباشرة بين المرسل والمستقبل، ولكن في البيئة العملية الحقيقية يكون هناك العديد من مسارات انتشار الموجات بين المرسل والمستقبل، في هذه الحالة فإنه على الأقل يكون هناك مسار منعكس من الأرض كما هو موضح بالشكل (1). يسمى هذا النموذج بنموذج الانتشار ثنائي الإشعاع (two-ray propagation model) وهو يستخدم عادة في المناطق القروية [8].



شكل (1) سيناريو انتشار مسارين [8]

نموذج فقد المسار التجريبي (Empirical path loss model)

النموذج التجريبي المشهور يسمى (Okumara-Hata-model) تم بناؤه وتكوينه بواسطة اكومورا بمدينة طوكيو باليابان، حيث النموذج الابتدائي تم بناؤه للترددات في المدى من (50MHz-1500MHz) وذلك للتنبؤ بمتوسط فقد المسار في أكثر من بيئة مثل المدن الكبيرة كما مبين بالمعادلة (4) [10].

$$PL_{(dB)} = 69.55 + 26.16 \log(f_c) - 13.82(h_t) - a(h_r) + (44.9 - 6.55 \log(h_t)) \cdot \log(d) \quad (4)$$

If $f_c > 300\text{MHz}$

$$a(h_r) = 3.2(\log_{10}(11.75h_r))^2 - 4.97\text{dB} \quad (5)$$

حيث:

$a(hr)$ تمثل معامل فقد المسار الأسّي ولها قيمة تختلف باختلاف البيئة الجغرافية ،
فمثلا في البيئة القروية موضوع الدراسة تتراوح بين (3 و 3.5) [8]. في البيئة الريفية
أو القروية حيث تكون المباني بها متوسطة الارتفاع ويتم حساب فقد المسار بناء على
متوسط فقد المسار للبيئة الحضرية (المدينة) المبين في المعادلة (4) أعلاه، ويمكن
كتابة معادلة فقد المسار في هذه البيئة القروية وفقا للمعادلة (6) [7] كالتالي:

$$PL_{Ru} = PL_{(dB)} - 2\left(\log \frac{f}{28}\right)^2 - 5.4 \quad (6)$$

حيث:

PL_{Ru} : معامل فقد المسار للبيئة الريفية بالديسبل
 $PL_{(dB)}$: معامل فقد المسار للبيئة الحضرية
 f : تردد الارسال بالميجاهرتز

2.2 نموذج فقد المسار البسيط (Simplified path loss model)

إن اختلاف طرق انتشار الإشارة تجعل من الصعب الحصول على نموذج فقد
مسار يصف مجموعة من البيئات المختلفة، يمكن الحصول على نماذج قريبة للواقع
بالقياسات التجريبية من محطات رئيسية (Base Stations) داخل تلك البيئة، من
الأفضل أحيانا استخدام نموذج بسيط يحتوي على أهم المعاملات التي تصف انتشار
الإشارة عوضا عن استخدام نماذج معقدة تكون نتائجها قريبة لنتائج النماذج البسيطة،
فقد المسار البسيط يعرف كدالة في المسافة وفقا للمعادلات (7) و (8) كالتالي [8].

$$L_p = K \left[\frac{d}{d_0} \right]^\alpha \quad (7)$$

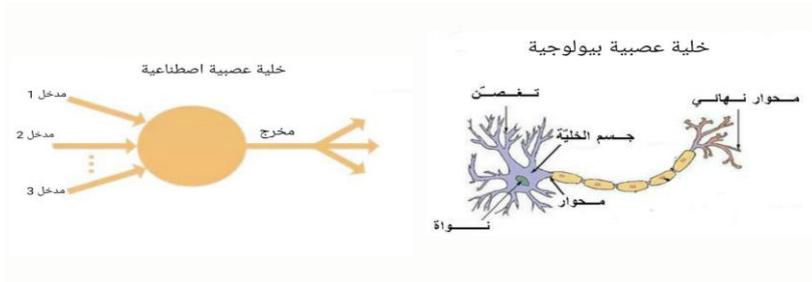
$$L_{p(dB)} = K_{dB} + 10\alpha \log_{10} \left(\frac{d}{d_0} \right) \quad (8)$$

حيث (K) ثابت يعتمد على خصائص الهوائي، (d_0) هي المسافة المرجعية، (d) تمثل
بعد مسافة العينات المقاسة، α تمثل معامل الفقد الأسّي [1].

الشبكات العصبية الاصطناعية

يمكن اعتبار الشبكة العصبية للإنسان نظام تشغيل معلومات بالغ التعقيد، وهو نظام متوازي وغير خطي. فالمعلومات تخزن ويتم تشغيلها في نفس الوقت خلال الشبكة كلها. لاحظ الباحثين إن إمكانية التعلم هي السمة الأساسية والضرورية للشبكات العصبية الحيوية، كما أنها قادرة على تسجيل وتذكر وتخزين واسترجاع مختلف الإشارات والمعلومات، وهذا ما قاد الإنسان إلى تقليدها من خلال بناء شبكات عصبية اصطناعية يمكنها أيضاً التعلم والتذكر والحفظ واسترجاع المعلومات، كما تكون قادرة أيضاً على محاكاة كيفية عمل الذاكرة، وأنماط الإدراك، بالإضافة إلى القدرة على التدريب و إعادته عدة مرات إلى أن يتم تعلم الشكل الوارد في المعلومات [11].

تتكون الشبكة العصبية الاصطناعية من عدد من الخلايا البسيطة جداً والمتشابهة مع بعض تسمى العصبونات (Neurons)، أو الخلايا العصبية الاصطناعية وهي تقليد للخلايا العصبية الحيوية. وتتصل العصبونات مع بعض بواسطة روابط موزونة تمرر إشارات من عصبون آخر. ويستقبل كل عصبون عدداً من المدخلات عن طريق تشابكاته، إلا إنه لا ينتج إلا إشارة خرج واحدة فقط. حيث تنتقل إشارة الخرج عن طريق الرابط الخارج من الخلية، وهو مناظر للمحور العصبي للخلية الحيوية. ينقسم الرابط الخارج من الخلية إلى عدد من الفروع التي تنقل نفس الإشارة (بدون انقسام) وكل فرع يتصل بمدخل إحدى الخلايا الأخرى في الشبكة. الشكل (2) يوضح شكل خلية بيولوجية و خلية عصبية اصطناعية [11].



الشكل (2) خلية عصبية بيولوجية و خلية عصبية اصطناعية [11]

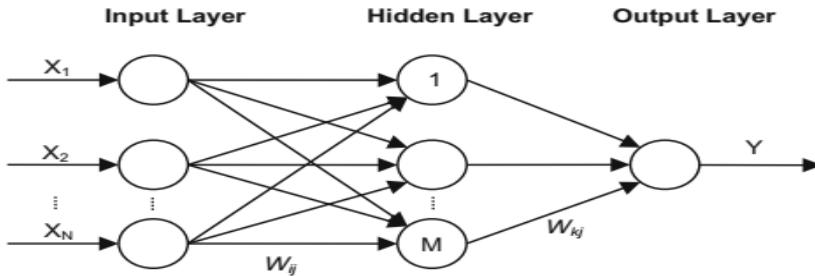
1.3 نماذج تعلم الآلة

تعلم الآلة (Machine Learning) هو أحد فروع الذكاء الصناعي وتطبيق للشبكات العصبية الاصطناعية، تعلم الآلة يهتم بتصميم خوارزميات تسمح للحواسيب بامتلاك خاصية "التعلم" بدون برمجة القواعد "Rules" لكل مسألة. يشبه تعلم الآلة بتعلم الطفل الصغير منذ ولادته على التعرف تدرجي على الأشياء و الأصوات عن طريق تدريبه و تصحيحه معلوماته وتكرار العملية لحين التعلم. وكلما ربط الطفل العلاقات وتدريبه على كم كبير من البيانات زادت المعرفة والخبرة لديه وقلت أخطأه. بتعلم الطفل بإحدى الخوارزميات التالية إما عن طريق الإشراف المباشر من قبل والديه، أو عن طريق التعرض مباشرة لحدث والتعامل معه مما يكسبه خبرة ويصبح يعرف كيف يتعامل مع أحداث مشابهة. يتم التعلم من خلال مجموعة من نماذج التعلم وهي عبارة عن مجموعة من الخوارزميات توضع بشكل عام ويقواعد عامة لمعالجة البيانات المدخلة بكافة الأشكال وتقوم بإيجاد العلاقات و الأنماط في البيانات عن طريق تطبيق معادلات إحصائية ورياضية، حيث تتسم كل خوارزمية بصفات ومخرجات معينة، لتستطيع تمثيل البيانات بطرق مختلفة أو التنبؤ بمخرجات جديدة بناء على العلاقات و الأنماط المستنتجة من البيانات المدخلة. وهناك الكثير من خوارزميات ونماذج تعلم الآلة التي تم استخدامها في مختلف المجالات. في هذه الورقة سيتم دراسة واستخدام ثلاث تقنيات لتعلم الآلة وبناء نماذج لفقد المسار من خلالها. وهذه النماذج كالتالي: -

أ. شبكة التغذية الأمامية Feedforward net

تعد الشبكات العصبية الخاصة بالتغذية الأمامية هي النماذج الأكثر شيوعًا والأكثر استخدامًا في العديد من التطبيقات العملية. وهي معروفة بالعديد من الأسماء المختلفة، مثل "الإدراك متعدد الطبقات (MLP)". الشبكة العصبية للتغذية الأمامية هي خوارزمية تصنيف مستوحاة من الناحية البيولوجية. يتكون من عدد من وحدات المعالجة البسيطة التي تشبه الخلايا العصبية، مرتبة في طبقات وكل وحدة في طبقة متصلة بجميع الوحدات الموجودة في الطبقة السابقة. هذه الوصلات ليست كلها متساوية، حيث قد

يكون لكل اتصال قوة أو وزن مختلف. تقوم الأوزان الموجودة على هذه الاتصالات بتشفير معرفة الشبكة. غالبًا ما تسمى الوحدات الموجودة في الشبكة العصبية بالعُقد. تدخل البيانات عند الإدخال وتمر عبر الشبكة، طبقة تلو الأخرى، حتى تصل إلى الخرج. تتكون طبقة الإدخال من مدخلات الشبكة فقط. ثم يتبع طبقة مخفية أو أكثر، تتكون من أي عدد من الخلايا العصبية، أو وحدات مخفية موضوعة على التوازي. الشكل (3) يوضح معمارية الشبكة العصبية الاصطناعية ذات التغذية الأمامية، والمكونة من ثلاث طبقات طبقة الدخل (Input Layer) و الطبقة المخفية (Hidden Layer) و طبقة الخرج (Output Layer)، حيث المدخلات تمثل المتجه X و $X=[X_1, X_2, \dots, X_N]$ و عدد الخلايا العصبية في الطبقة المخفية يعبر عنه بالحرف M و الأوزان يعبر عنها بالمتغير W و المخرجات يمثل بالمتغير Y [9][11].



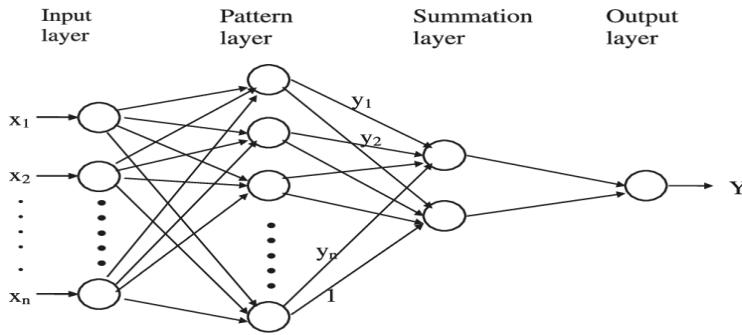
الشكل (3) معمارية الشبكة العصبية الاصطناعية ذات التغذية الأمامية [11]

ب. شبكة الملائمة FitNet

دالة FitNet هي إحدى أنواع شبكة التغذية الأمامية التي تستخدم لحساب الانحدار والتنبؤ بالبيانات بعد بناء نموذج الانحدار أو الملائمة (Fitting)، حيث تتم عملية التدريب للشبكة العصبية على مجموعة من المدخلات من أجل إنتاج مجموعة مرتبطة من المخرجات. وبمجرد أن تتلاءم الشبكة العصبية مع البيانات، فإنها تشكل تعميماً لعلاقة المدخلات والمخرجات. يمكنك بعد ذلك استخدام الشبكة المدربة للتنبؤ واستنباط مخرجات لمدخلات جديدة أي لم يتم تدريب النموذج أو الشبكة عليها [12].

ت. شبكة الانحدار المعممة (GRNN)

الشبكة العصبية المستخدمة تدعى شبكة الانحدار المعممة (Generalized Regression Neural Network (GRNN)، هذا النوع من الشبكات العصبية يحتوي على طبقتين ثابتتين ويدعا طبقتي الأنماط Patterns والجمع (الإيجاز) summation ولا تخضع الشبكة للزيادة ولهذا فإن هيكل هذه الشبكة ثابت وبسيط و تتميز هذه الشبكة بإمكانية التدريب السريع والبساطة كما إنها تعمل بشكل كفؤ حتى مع قواعد البيانات صغيرة الحجم [10]، حيث تمتاز الشبكة بأنها لا تحتاج إلى عملية التكرار أثناء التدريب (Iterative) وتسعي هذه الشبكة للوصول إلى حل معمم على كل الحالات المستخدمة في التدريب و تستطيع أن تتجاوز مشكلة الوقوع في حلول صغرى محلية هذه الشبكة يوجد بها متغيران فقط يجب تحديدهما. معمارية الشبكة أو الهيكل العام لها (Architecture Network) موضح بالشكل (4) ولكي تتمكن الشبكة من تمثيل العلاقة غير الخطية بين المدخلات والمخرجات، فإن الشبكة العصبية ستستخدم الدالة الأساس الإشعاعي [13] Radial (RBF) Basis Function.

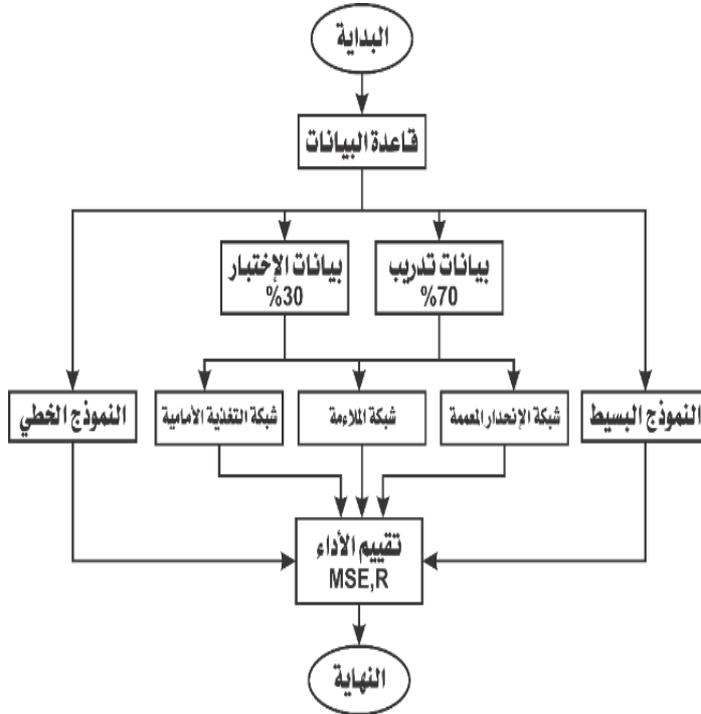


الشكل (4) الهيكل العام للشبكة الانحدار المعممة [13]

منهجية الدراسة

تم بناء نماذج لفقد المسار باستخدام الذكاء الصناعي ومحاكاتها ببرنامج الماتلاب، تم استخدام ثلاث تقنيات للوصول إلى ثلاث نماذج مختلفة ومقارنتها مع النموذج التقليدي

البسيط والنموذج الخطي بناء على بيانات حقيقية مقاسة من أبراج أو محطات قاعدية (Base Stations) لشركة المدار في منطقة الكراريم وهي من ضواحي مدينة مصراتة. المخطط الصندوقي الموضح في الشكل (5) يبين الفكرة العامة لخوارزمية عمل النماذج.



الشكل (5) مخطط الصندوقي لخوارزمية العمل المقترح

مقاييس تقييم الأداء

مقاييس تقييم الأداء لهذه النماذج المقترحة تتمثل في مقياس متوسط مربعات الخطأ ومقياس معامل الترابط. لمزيد التفاصيل عن هذه المقاييس اطلع على المراجع التالية [9][12]:

متوسط مربعات الخطأ (MSE)

$$MSE = \frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2 \quad (9)$$

حيث n هو العدد الكلي للعينات، y هي القيمة الحقيقية، و \hat{y} هي القيمة المحسوبة.

معامل الترابط (R)

$$R = \frac{\sum_{i=1}^n (T_i - \bar{T})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (T_i - \bar{T})^2 (O_i - \bar{O})^2}} \quad (10)$$

حيث T_i القيمة المحسوبة عند i و \bar{T} متوسط القيم المحسوبة، O_i القيمة الحقيقية عند i و \bar{O} متوسط القيم الحقيقية.

4.1 آلية جمع البيانات

لجمع البيانات تم استخدام جهاز هاتف محمول سامسونج اس 9 المجز ببرنامج قياس قدرة الاستقبال من البرج (Samsung s9 terms pocket + SM-G960F) لجمع العينات من البرج أو المحطة القاعدية (PHB67) الواقع في بيئة ريفية بمنطقة الكراريم بمدينة مصراتة، تم قياس قوة الإشارة المستقبلية عند مسافات مختلفة من البرج بداية من 100 متر من المحطة الأساسية وحتى 5000 متر. تم إجراء القياسات في الوضع النشط المتنقل وفي قطاعين من قطاعات البرج A و B، وبحيث أن الهاتف المحمول كان على اتصال دائم بالبرج دون توقف أو انتقال لبرج آخر، كما تم مراجعة القياسات التي تم استخدامها من قبل الباحث في المرجع [14]. الجدول (2) يوضح البيانات الرئيسية للبرج (PHB67)، ويبين الشكل (6) موقع البرج واتجاهات قطاعات الهوائي. كما يوضح الشكلان (7) و (8) مسار حركة جمع البيانات والتضاريس والارتفاع عن سطح البحر من قطاعات البرج A و B.

الجدول (2) بيانات البرج (PHB67)

خط الطول		32.1922524	
خط العرض		15.0957905	
القدرة المرسلة		43dBm	
قطاع Sector	التردد (MHz)	ارتفاع البرج بالمتر	Azimuth angle زاوية السمات
A	937.8	27	20°
B	937.2	27	195°



الشكل (6) موقع البرج واتجاه الهوائيات



الشكل (7): مسار حركة جمع البيانات والتضاريس للقطاع A



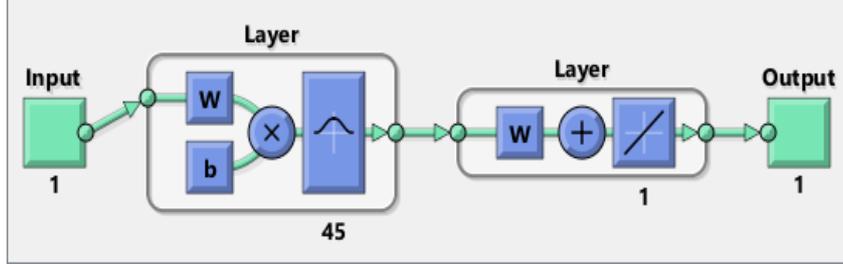
الشكل (8): مسار حركة جمع البيانات والتضاريس للقطاع B

مناقشة النتائج

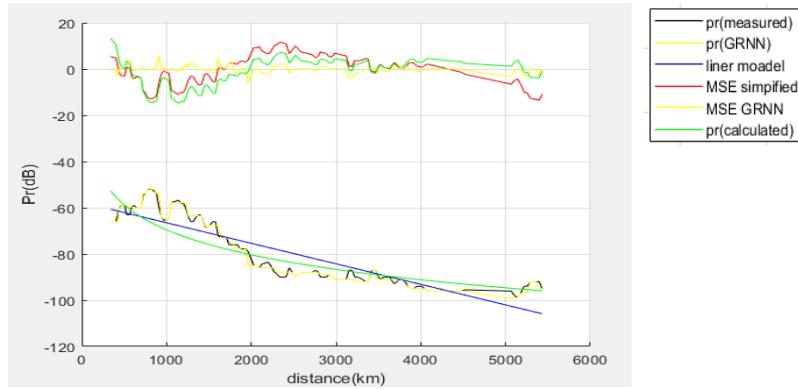
في هذا الجزء من الورقة سيتم مقارنة الأداء للنماذج المقترحة فيما بينها ومع النموذج البسيط، والنموذج الخطي. وكذلك مع الدراسات السابقة وبناء على مقاييس تقييم الأداء التالية: -متوسط مربعات الخطأ ومقياس معامل الترابط.

نموذج شبكة الانحدار المعممة (GRNN).

الشبكة العصبية المستخدمة في بناء أول نموذج تدعى شبكة الانحدار المعممة Generalized Regression Neural Network (GRNN)، تم التطرق إليه بالتفصيل في القسم الثالث من هذه الورقة قمنا بإدخال البيانات المقاسة من البرج الموجود في منطقة الكراريم للهوائي عبر عقدة دخل واحدة وطبقة مخفية مكونة من 45 عقدة وبعدة خرج واحدة وكما هو مبين بالشكل (9). تم أخذ 30% من العينات بطريقة عشوائية لاختبار النموذج و70% للتدريب. الشكل (10) يوضح العينات المقاسة والبيانات المتحصلة عليها من شبكة الانحدار المعممة. تم ضبط هذا النموذج لكي يتم استخدامه بحيث يحسب القدرة المستلمة بناء على المسافة من البرج، يشير الخط الأسود في الشكل إلى العينات المقاسة والأخضر إلى القيم المتنبئ بها من خلال هذا النموذج الذي تم بنائه باستخدام الشبكة الانحدار المعممة.



الشكل (9) هيكلية شبكة الانحدار المعممة (GRNN)

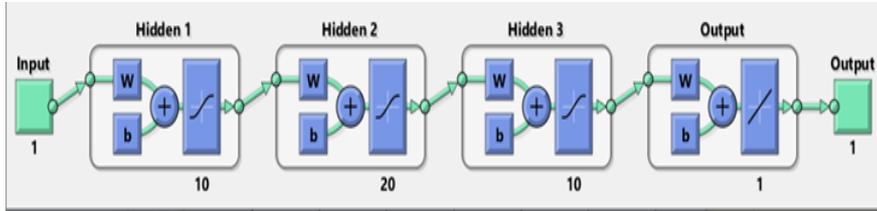


الشكل (10) يوضح العينات المقاسة والعيّنات المتحصّل عليها من شبكة الانحدار المعممة

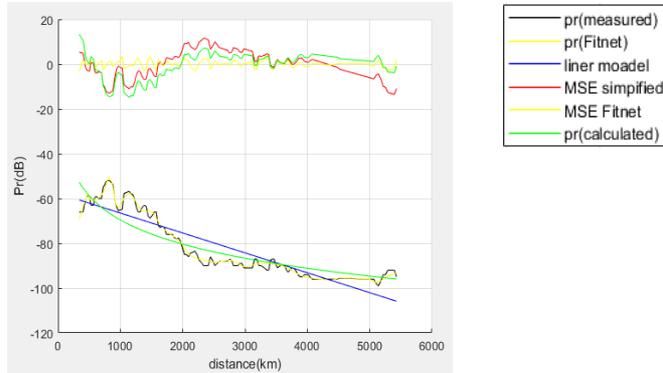
نموذج الملاءمة Fit net

نموذج الملاءمة (Fitting) هو نموذج لتدريب شبكة عصبية على مجموعة من المدخلات من أجل إنتاج مجموعة مرتبطة من المخرجات تم تتطرق إليها بالتفصيل في الفصل الثالث. تم أخذ العينات من برج الكراريم الهوائي، كما في المرة السابقة. تم اختيار خوارزمية (trainlm) لتدريب الشبكة وظيفه هذه الدالة تحسين قيم الأوزان للوصول إلى أفضل نتائج. تتكون شبكة (Fit net) التي تم بنائها لأجل تصميم نموذج لفقد المسار من دخل واحد (input)، وعدد من الطبقات المخفية [10 20 10]، كما هو موضح في الشكل (11) يمكن تحكّم في عدد الطبقات المخفية لتحسين أداء الشبكة، وخرج

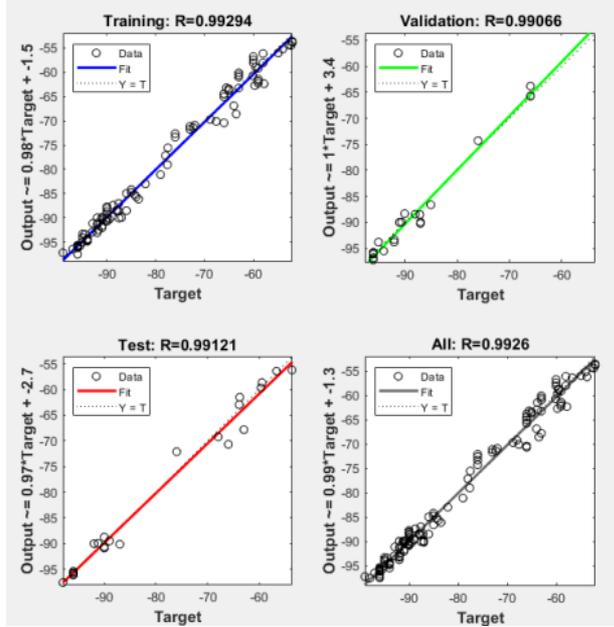
وحيد (output). الشكل (12) يبين الفرق بين العينات المقاسة والعينات المتحصل عليها من نموذج شبكة الملائمة وباقي النماذج. تم إدخال البيانات بشكل عشوائي للشبكة وتم تقسيمها كالتالي 70% لتدريب (training)، 15% تحقق من الصلاحية للنموذج (validation) و15% للاختبار (testing). كما تم استخدام خاصية الإسقاط لعقد الشبكة (Dropout) لتغلب على إشكالية الحفظ دون الربط للعلاقات (Overfitting) وتحدث هذه المشكلة عندما تتنبأ الشبكة بالقيم بشكل صحيح في مرحلة التدريب ولكنها تفشل في التنبؤ بها في مرحلة التحقق من الصلاحية أو المصادقية (validation)، الشكل (13) يوضح مدى دقة النموذج وقوة الترابط بين القيم المقاسة والقيم المتنبئ بها.



الشكل (11) هيكلية شبكة نموذج الملائمة Fit net



الشكل (12) العينات المقاسة والعينات المتحصل عليها من شبكة الملائمة



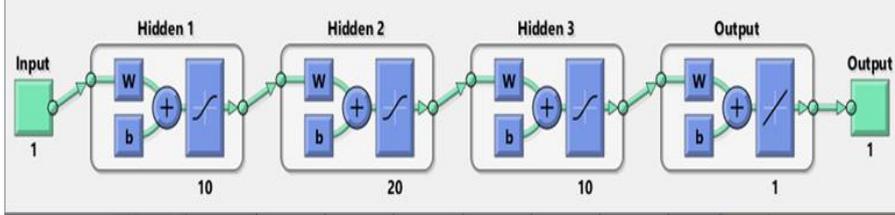
الشكل (13) الترابط بين القيم المقاسة والقيم المتنبئ بها من شبكة الملائمة

نموذج شبكة التغذية الأمامية Feedforward net

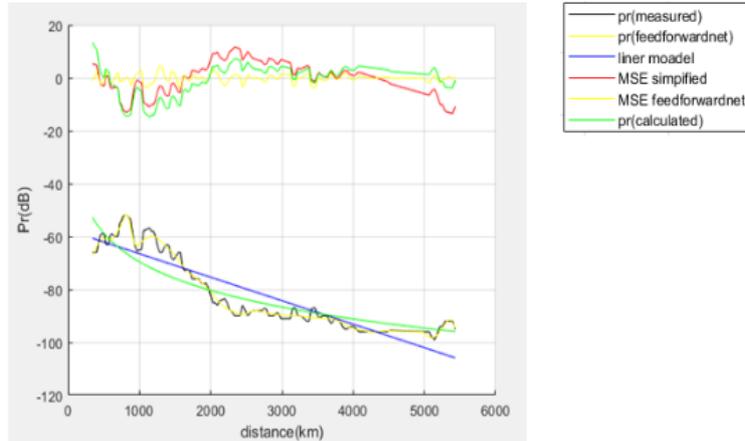
تعد الشبكات العصبية الخاصة بالتغذية الأمامية هي النماذج الأكثر شيوعًا والأكثر استخدامًا في العديد من التطبيقات العملية تم التطرق إليه بالتفصيل في الفصل الثالث. تم أخذ العينات من برج الكراريم الهوائي. تم اختيار الخوارزمية (trainlm) لتدريب الشبكة وظيفه هذه الدالة تحسين قيم الأوزان للوصول إلى أفضل نتائج. تتكون شبكة (Feedforward net) التي تم بنائها لأجل تصميم نموذج لفقد المسار من دخل واحد (input)، وعدد من الطبقات المخفية [10 20 10]. يمكن تحكم فيعدد الطبقات المخفية لتحسين أداء الشبكة، وخرج واحد (output)، كما في الشكل (14). الشكل (15) يبين الفرق بين العينات المقاسة والعينات المتحصل عليها من النماذج البسيط والخطي ونموذج التغذية الأمامية. تم إدخال البيانات بشكل عشوائي للشبكة وتم

تقسيمها كالتالي 70% لتدريب (training)، 15% تحقق من الصلاحية أو المصادقية (validation) و15% للاختبار (testing).

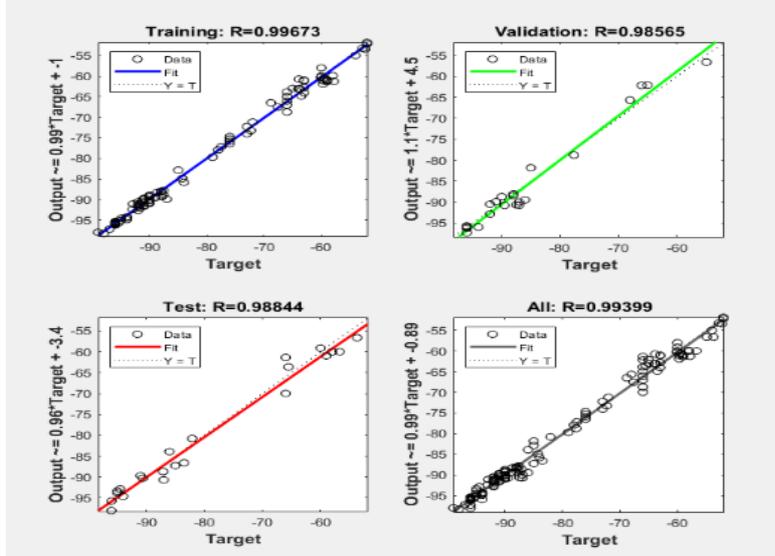
تم استخدام خاصية الإسقاط لعقد الشبكة (Dropout) لتغلب على إشكالية الحفظ دون الربط للعلاقات (Overfitting) وتحدث هذه المشكلة عندما تنتبأ الشبكة بالقيم بشكل صحيح في مرحلة التدريب ولكنها تفشل في التنبؤ بها في مرحلة التحقق من الصلاحية أو المصادقية (validation). الشكل (16) يظهر دقة النموذج من خلال قوة الترابط بين القيم المقاسة والقيم المتنبئ بها من شبكة التغذية الأمامية.



الشكل (14) هيكلية شبكة التغذية الأمامية



الشكل (15) العينات المقاسة والعينات المتحصل عليها من شبكة التغذية الأمامية



الشكل (16) الترابط بين القيم المقاسة والقيم المتنبئ بها من شبكة التغذية الأمامية

المقارنة بين العينات المحسوبة والمقاسة والمتنبئ بها

في هذا الجزء وضمن مرحلة الاختبار، تم مقارنة العينات التي تم قياسها فعلياً ومقارنتها بالقيم المتنبئ بها لكي يتم التأكد من صحة ودقة النماذج المقترحة، الجدول (3) يقدم مقارنة بين العينات للنماذج الثلاثة: النموذج الانحدار المعمم ونموذج الملائمة ونموذج التغذية الأمامية، مع النموذج الخطي والنموذج البسيط. من خلال التحليل للنتائج أعلاه وجد أن متوسط تشتت البيانات لنموذج فقد المسار البسيط (simplified model) يساوي 5.87 ونموذج شبكة الانحدار المعممة (GRNN) يساوي 0.26 بينما نموذج شبكة الملائمة (Fitnet) يساوي 0.97 ونموذج التغذية الأمامية (Feedforward net) يساوي 1.35 وهذا يشير إلى أن نماذج فقد المسار المستخدمة بتقنيات الذكاء الاصطناعي أفضل لقرب قيمة تشتتها من الصفر. أيضاً من الشكليات (6.4) و(9.4) أن الترابط بين قيم القدرة المتنبئ به بواسطة نماذج الذكاء الصناعي والقدرة المقاسة تشير أن دقة التنبؤ عالية للنماذج المقترحة في الدراسة، حيث كانت قيمة

الترابط الكلية لنموذج الملائمة (Fit net) تساوي $R=0.9962$ وكانت قيمة الترابط الكلية لنموذج التغذية الأمامية (Feedforward net) تساوي $R=0.99399$. من خلال مقارنة النماذج المستخدمة في هذه الدراسة مع ما ورد من دراسات سابقة نلاحظ تفوق النماذج المقترحة في هذه الدراسة، فمثلا في المرجع [4] كانت متوسط مربع الخطأ 4.0763 بينما في النماذج المقترحة في هذه الدراسة كانت أقصى قيمة لمتوسطات مربعات الخطأ لا تتجاوز 2.706 في نموذج التغذية الأمامية المقترح في هذه الدراسة وكما هو مبين في الجدول (3).

الجدول (3) مقارنة بين العينات المقاسة والعينات النظرية والمتحصل عليها من النماذج الثلاثة المقترحة مع النموذج الخطي والقيم المقاسة

Rx_level calculations(dBm) القيم المحسوبة بالنموذج البسيط	Rx_level Feedforward net (dBm) القيم المحسوبة بنموذج التغذية الأمامية	Rx_level Fitnet (dBm) القيم المحسوبة بنموذج الملائمة	Rx_level GRNN (dBm) القيم المحسوبة بنموذج الانحدار المعمم	Rx_level Measurements (dBm) القيم المقاسة بالمقياس ديسبل	Distance المسافة بالمتر (m)
-55.4	-63.1	-63.03	-62.9	-63.0	420
-56.2	-62.4	-61.4	-59.4	-59.0	450
-58.3	-60	-60.1	-60.3	-59.7	500
-60.2	-60.9	-62.17	-62	-63.0	560
-62.4	-59.9	-59	-59.5	-60.0	650
-94.9	-97.8	-95.9	-97.3	-98.0	5100
-95.2	-97.1	-95.1	-93.3	-94.0	5200
-95.4	-91.1	-94	-93.5	-92.0	5300
-95.6	-92.4	-93	-92.0	-92.0	5360
-95.8	-95.6	-93.9	-94.6	-95.0	5430
11.737	2.706	1.943	0.517	متوسط مربعات الخطأ	
5.87	1.35	0.97	0.26	التشتت	

الخلاصة

تم تصميم وتنفيذ عدة نماذج تعتمد على تقنيات تعلم الآلة، هذه النماذج تتنبأ بقيم فقد المسار وتصف مستوى قدرة إشارة الهاتف النقال في بيئة قروية (الضواحي) وبدقة عالية مقارنة بالنماذج التقليدية وبنماذج الدراسات السابقة [10]، [7]، [4]، حيث بمعلومية القدرة المرسل من الهوائي أو المحطة القاعدية و عند أي مسافة منها. للعمل المستقبلي وتطوير

وتحسين هذا البحث يستحسن الحصول على أكبر قدر من القراءات (زاوية السمات و زاوية الارتفاع لكل من جهاز الاستقبال والبرج، المسافة بين البرج وجهاز الاستقبال، ارتفاع البرج عن سطح البحر) لزيادة دقة النموذج. كما نوصي بدراسة فقد المسار في المدينة وعمل نماذج تصف تلك البيئة مع الأخذ في الاعتبار تأثيرات التظليل والخبو بالإضافة إلى تأثير فقد المسار.

الشكر والعرفان

نتقدم بالشكر والعرفان للإدارة الفنية بشركة المدار الجديد للهاتف المحمول فرع الوسطى على تعاونهم وتوفيرهم أجهزة القياس ومراجعتهم الفنية للنتائج.

المراجع

- [1] K. R. Manoj, "Coverage Estimation for Mobile Cellular Networks from Signal Strength Measurement," University of Texas at Dallas, 1999.
- [2] I. J. Isabona Joseph, "Urban Area Path loss Propagation Prediction and Optimisation Using Hata Model at 800MHz," *IOSR J. Appl. Phys.*, vol. 3, no. 4, pp. 8–18, 2013, doi: 10.9790/4861-0340818.
- [3] C. M. M. Cardoso *et al.*, "SNR Prediction with ANN for UAV Applications in IoT Networks Based on Measurements," *Sensors*, vol. 22, no. 14, 2022, doi: 10.3390/s22145233.
- [4] T. A. Benmus, R. Abboud, and M. K. Shatter, "Neural network approach to model the propagation path loss for great Tripoli area at 900, 1800, and 2100 MHz bands," *16th Int. Conf. Sci. Tech. Autom. Control Comput. Eng. STA 2015*, pp. 793–798, 2015, doi: 10.1109/STA.2015.7505236.
- [5] M. A. Salman, S. I. Popoola, N. Faruk, N. T. Surajudeen-Bakinde, A. A. Oloyede, and L. A. Olawoyin, "Adaptive Neuro-Fuzzy model for path loss prediction in the VHF band," *Proc. IEEE Int. Conf. Comput. Netw. Informatics, ICCNI 2017*, vol. 2017-Janua, pp. 1–6, 2017, doi: 10.1109/ICCNI.2017.8123768.
- [6] S. I. Popoola, E. Adetiba, A. A. Atayero, N. Faruk, and C.

- T. Calafate, “Optimal model for path loss predictions using feed-forward neural networks,” *Cogent Eng.*, vol. 5, no. 1, 2018, doi: 10.1080/23311916.2018.1444345.
- [7] S. Ojo, A. Sari, and T. P. Ojo, “Path Loss Modeling: A Machine Learning Based Approach Using Support Vector Regression and Radial Basis Function Models,” *Open J. Appl. Sci.*, vol. 12, no. 06, pp. 990–1010, 2022, doi: 10.4236/ojapps.2022.126068.
- [8] هشام عرو دكي، نظم الاتصالات الخلوية: أسس ومبادئ، الطبعة (1). دمشق، سوريا: مكتبة الاسد، 2013.
- [9] I. Izonin *et al.*, “Optimal model for path loss predictions using feed-forward neural networks,” *Sci. African*, vol. 3, no. 7, pp. 990–1010, 2021, doi: 10.1016/j.sciaf.2023.e01550.
- [10] A. Deme, D. Dajab, B. Bajoga, M. Mu, and D. Choji, “Hata-Okumura Model Computer Analysis for Path Loss Determination at 900MHz for Maiduguri , Nigeria,” vol. 3, no. 3, pp. 1–10, 2013.
- [11] A. A. Elrowayati, “Medical Images Compression using a Hybrid Adaptive DWT-ANN Algorithm,” Misurata University, 2011.
- [12] M. Acı and M. Avcı, “Artificial neural network approach for atomic coordinate prediction of carbon nanotubes,” *Appl. Phys. A Mater. Sci. Process.*, vol. 122, no. 7, 2016, doi: 10.1007/s00339-016-0153-1.
- [13] I. Izonin, R. Tkachenko, M. Gregus ml, K. Zub, and P. Tkachenko, “A GRNN-based approach towards prediction from small datasets in medical application,” *Procedia Comput. Sci.*, vol. 184, pp. 242–249, 2021, doi: 10.1016/j.procs.2021.03.033.
- [14] ا. زيدانوعبدالقادر التواتي، “حساب معامل فقد المسار الأسّي لنموذج الفقد المبسط باستخدام قياسات عملية في مدينة مصراته،” كلية التقنية الصناعية مصراته، 2020.