



تقييم حالة الرصف باستخدام الشبكات العصبية الاصطناعية

إسلام ميلاد التريكي^{1,*}، عمر القذافي المنصوري¹، عبد العزيز عبد الله الأسطى¹
قسم الهندسة المدنية، كلية الهندسة، جامعة مصراتة، مصراتة، ليبيا
* المؤلف المراسل

المخلص	تاريخ الورقة
المحافظة على أداء الرصف وتحديد أولويات الصيانة الدورية يعتبر من أهم أهداف أنظمة إدارة الرصف الحديثة التي تساهم في خفض النفقات وتحديد التوزيع الأمثل للموارد المتاحة. يعتبر مؤشر حالة الرصف (PCI) من أهم الأدوات الدقيقة المستخدمة لتقييم الحالة الإنشائية لاعتماده على تقييم العيوب المختلفة وتحويلها إلى قيمة عددية تصف حالة الرصف. تهدف هذه الدراسة إلى بناء نموذج تعلم آلي لغرض التنبؤ بقيمة مؤشر حالة الرصف باستخدام الشبكات العصبية الاصطناعية. تم تصميم 3 نماذج شبكات عصبية بهيكلية مختلفة لغرض المقارنة احتوت على أعداد مختلفة من الطبقات والعقد. احتوت جميع النماذج على طبقة مدخلات واحدة بها 7 أنواع من عيوب الرصف، وطبقة مخرجات واحدة تمثل قيمة PCI لقطاعات الطريق التي تم حسابها وفقاً للمواصفة ASTM 6433. تم عمل 3 نماذج بطبقة مخفية واحدة وبعدها عقد 4، 8، 16. تم تهيئة البيانات بمقياس وزني واحد وذلك بتحويل البيانات الوصفية إلى قيم عددية ثم حساب الأوزان بها لكل نوع من العيوب حسب مستوى الشدة. أظهرت النتائج أن النماذج تجاوزت فيها معامل التحديد 0.95 مما يعزز من قدرة الشبكات العصبية الاصطناعية على نمذجة العلاقات غير الخطية المعقدة. بمقارنة النماذج يتبين أن النموذج (7-8-1) له المستوى الأعلى من الموثوقية بين النماذج، وأن قيمة معامل التحديد كانت 0.98 وبخطأ معياري أقل من 4%. تم اختبار النموذج باستخدام التحقق المتقاطع وأظهرت النتائج ثبات أداء النموذج بقيمة معامل تحديد 0.95 وقيمة $RMSE=5.72 \pm 0.49$ مما يظهر إمكانية الاعتماد على النموذج في حساب قيمة PCI والمساعدة في اتخاذ قرارات الصيانة وإعادة التأهيل للطرق.	استلمت الورقة بالكامل في: 21 مايو 2025 وروجعت في: 16 يونيو 2025 وقبلت للنشر في: 19 يونيو 2025 ونشرت وممتاحة على الشبكة العنكبوتية في: 18 أغسطس 2025 DOI: https://doi.org/10.36602/ijeit.v14i1.565
	الكلمات المفتاحية مؤشر حالة الرصف، شبكات عصبية، طبقة مخفية، نموذج

Prediction of Pavement Condition Index using Artificial Neural Networks

Isslam Eltariki^{1,*}, isslam.eltariki@eng.misuratau.edu.ly, Omar Elmansouri¹, Elmansouri@eng.misuratau.edu.ly, Abdulaziz Alossta¹, aalossta@eng.misuratau.edu.ly

¹ Civil Engineering Department, Engineering College, Misurata University, Misurata, Libya.

* Corresponding author

Abstract

Modern pavement management systems aim to maintain performance and prioritize maintenance, reducing costs, and optimizing resources. Pavement Condition Index (PCI) is one of the most accurate tools to assess the structural condition of pavement, as it relies on evaluating various pavement distresses and converting them into a numerical value describes the pavement condition. This study aims to build a machine learning model to predict the pavement condition index using artificial neural networks (ANN). Three ANN models with different number of layers and nodes were designed for comparison. All models had one input layer consisting of seven types of pavement distresses, and one output layer consisting of the PCI value. Three models had one hidden layer with 4, 8, and 16 nodes. The data was normalized with a single weight scale by converting the descriptive data into numerical values and then calculating the weights for each type of distress according to its severity level. The results revealed that models had a coefficient of determination exceeding 0.95, which indicated the capability of artificial neural networks to model complex nonlinear relationships. Comparing the three models, the (7-8-1) architecture demonstrated the highest level of reliability with R2 achieving 0.98 and a standard error of less than 4%. In addition, K-fold cross-validation approach with 5-folds was conducted to validate the model. The average results of folds showed R2=0.95 and RMSE=5.72±0.49 which confirm the model's reliability in calculating PCI and assisting pavement M/R decision makers.

Index Terms

PCI, ANN, Hidden Layer, Model

1. المقدمة

تهدف أنظمة إدارة الرصف الحديثة إلى تحسين استراتيجيات الصيانة الوقائية لشبكات الطرق لأجل زيادة العمر الخدمي وتقليل النفقات مع ضمان أداء مستدام. يتدهور أداء الرصف بمرور الوقت نتيجة للتأثير المشترك للظروف المناخية مع حركة المرور، مما يستلزم صيانة دورية للحفاظ على جودة الرصف وإطالة العمر الخدمي للطريق [1]. تشمل مقاييس أداء الرصف الرئيسية الأكثر شيوعاً مؤشر حالة الرصف PCI، ومقياس التشغيلية الحالية للرصف (PSR)، ومؤشر الخشونة الدولي (IRI). يستخدم مؤشر حالة الرصف PCI، الذي طوره فريق المهندسين في الجيش الأمريكي، خلال سبعينيات القرن الماضي وتم اعتماده من قبل الجمعية الأمريكية للاختبارات والمواد تحت الموصوفة ASTM 6433 على نطاق واسع لتقييم حالة الرصف [2]. يتم حساب قيمة مؤشر حالة الرصف عن طريق تقسيم الطريق إلى قطاعات وفحص العيوب الظاهرة على الرصف وتحديد كمياتها ومستويات الشدة لها. تتراوح قيمة مؤشر الرصف بين 0 (أسوأ حالة للرصف) و 100 (أفضل حالة للرصف) [3]. تستخدم النماذج الرياضية لتقدير حالة الرصف وتساعد على اتخاذ القرارات اللازمة لتحديد نوع ومواعيد الصيانة المطلوبة. توقع حالة الرصف باستخدام النماذج الرياضية بدأ العمل فيها منذ أوائل ستينيات القرن الماضي [4]. يمكن تقسيم نماذج التوقع إلى نماذج حتمية (Deterministic Models) ونماذج احتمالية (Probabilistic Models). هذه النماذج يمكن أن تأخذ الصيغة الخطية مثل الانحدار الخطي المتعدد (Multilinear Regression) أو أن تأخذ الصيغة الغير خطية مثل النموذج السيني (Sigmoidal Model)، والانحدار التدريجي (Stepwise Regression) [5]. تستخدم تقنيات الذكاء الاصطناعي (Artificial Intelligence)، بما في ذلك الشبكات العصبية الاصطناعية ANN على نطاق واسع في مجال الهندسة المدنية، وشهد هذا الاستخدام تطوراً سريعاً خلال السنوات الماضية. فكرة عمل الشبكات العصبية الاصطناعية مستوحاة من طريقة عمل الدماغ البشري، حيث تستخدم مجموعة خوارزميات إحصائية غير خطية تكون قادرة على التنبؤ لنمذجة العلاقات المعقدة بين مجموعة من المدخلات والمخرجات [2]. في هذا البحث تم بناء 3 نماذج شبكات عصبية للتنبؤ بقيمة مؤشر حالة الرصف اعتماداً على حصر عيوب الرصف لقطاع من طريق نقل ثقيل. مصفوفة المدخلات تمثلت في نتائج الحصر لعدد 7 عيوب للرصف، بينما شكلت قيم مؤشر الرصف المحسوبة وفقاً للموصوفة ASTM 6422 مصفوفة المخرجات.


2. دراسات سابقة

يُعد الاستثمار في شبكات الطرق عاملاً رئيسياً لنمو البنية التحتية مما يساعد بشكل كبير على الاستقرار الاقتصادي والازدهار العام للدول. تحرص هيئات النقل على تطوير نظام مراقبة الرصف على أسس علمية تساهم في استدامة شبكات الطرق. ضمن الصعوبات التي تواجه متخذي القرار هو نقص البيانات والأدوات اللازمة التي تساعد على اتخاذ قرارات الصيانة المناسبة في الوقت المناسب لضمان التوجيه الأمثل للتمويل المتاح. تمثل النماذج الرياضية أدوات فعالة يمكن بواسطتها محاكاة عناصر شبكة النقل والتنبؤ بأداء الشبكة مما يساهم في الحفاظ على مكونات شبكة النقل والعمل على تطويرها. يُمكن استخدام هذه النماذج في أنظمة إدارة الرصف لتقليل التكاليف وتحسين قرارات الصيانة. تمتاز طرق التعلم الآلي بالقدرة العالية على بناء نماذج عالية الدقة من خلال خوارزميات تربط قيم المدخلات والمخرجات، حيث توفر أدوات تقييم توفر الوقت والجهد ويمكن الاعتماد عليها في اتخاذ قرارات الصيانة. قام الباحث عيسى وآخرون بتطوير نموذج يستخدم الشبكات العصبية الاصطناعية ANN لتوقع قيمة PCI وذلك بالاعتماد على نوع عيوب الرصف ومستويات الشدة لها وعدد فتحات التصريف على الطريق. تم جمع البيانات لعدد 348 قطاعاً، حيث أظهرت النتائج أن الترابط بين عيوب الرصف وقيم مؤشر الرصف ضعيفة بشكل عام، مما يعزز الحاجة لاستخدام نماذج تعتمد على التعلم الآلي. حقق النموذج المطور باستخدام الشبكات العصبية الاصطناعية دقة عالية بمعامل تحديد $(R^2 = 0.997)$ [2].

باستخدام الشبكات العصبية الاصطناعية قام الباحث أفارين وآخرون بدراسة تهدف إلى تطوير مؤشر جديد يقيم حالة الرصف. تم تصنيف 20 نوعاً من العيوب إلى 4 مجموعات رئيسية شملت السعة الإنشائية للرصف، خشونة سطح الرصف، السلامة على الطريق، والعيوب السطحية للرصف. تم بواسطة الشبكات العصبية ANN تطوير نموذج لحساب UCI بدقة تزيد عن 80% ويشبه في نتائجه مؤشر حالة الرصف التقليدي ولكنه أكثر توفيراً للوقت. أظهرت النتائج أن النموذج يقلل من جهد تحليل العيوب بنسبة تقارب 85% [6]. أظهرت نتائج الدراسة التي قام بها الباحث علي وآخرون أن نموذج الشبكات العصبية الاصطناعية كان الأكثر دقة مقارنة بأداء نموذجين آخرين للتنبؤ بمؤشر حالة الرصف PCI. تم جمع بيانات الدراسة لعدد 19 مقطع في كندا خلال عامي 2018 و 2021 وشملت مقارنة نموذج ANN مع كل من نموذج الانحدار الخطي المتعدد (MLR)، ونظام الاستدلال المنطقي الضبابي (FIS). حيث سجل نموذج ANN تحسناً بمقدار يزيد عن 50% مقارنة بالانحدار الخطي المتعدد [7]. قام الباحث زيادة وآخرون بدراسة لتطوير نماذج لتقييم أداء الرصف في المناطق الحارة باستخدام تقنيات التعلم الآلي. تم جمع بيانات من قاعدة برنامج أداء الرصف طويل المدى. تم استخدام خوارزمية اختيار الميزات (ANN-FSFS) لاكتشاف أهم العوامل المؤثرة، وتضمنت: الخشونة الابتدائية للرصف، الرطوبة النسبية، سرعة الرياح، كمية حرارة الشمس التي يعكسها سطح الطريق (الألبيدو)، متوسط الانبعاثات، الأحجام المرورية، والسعة الإنشائية للرصف. تم تطبيق 5 تقنيات تعلم آلي، حيث أظهرت النتائج أن استعمال الشبكات العصبية الاصطناعية ANN هي الأفضل أداءً بدقة تصل إلى $(R^2 = 0.87)$ [8].

3. منهجية العمل

تبدأ العملية بتجميع بيانات عيوب الرصف الظاهرة سطح الطريق، يلي ذلك مرحلة معالجة البيانات والتي تشمل تهيئتها للقياس (Normalization). بعد ذلك، يتم بناء نموذج الشبكة العصبية وتدريبه باستخدام البيانات المعالجة. يتم بعد ذلك تقييم أداء النموذج من خلال اختباريه باستخدام طريقة التحقق المتقاطع (K-fold cross validation). في النهاية يتم استخدام النموذج للحصول على القيم المتوقعة لمؤشر حالة الرصف. المخطط الانسيابي المبين بالشكل 1 يبين خطوات تطوير نموذج تنبؤي باستخدام الشبكة العصبية الاصطناعية ANN لتقدير مؤشر حالة الرصف PCI:



شكل 1. منهجية البحث

تم استخدام دوال تحويل (تنشيط) مختلفة ضمن الطبقات المخفية لدراسة تأثيرها على قدرة النموذج على التعلم ودقة التنبؤ. تم تقسيم البيانات إلى ثلاث مجموعات: 70٪ للتدريب، و30٪ للاختبار، وذلك لضمان تدريب النموذج بكفاءة وتقييمه بصورة مستقلة. وقد تم تدريب النموذج على مجموعة التدريب باستخدام 200 دورة (Epochs). يُعد التأكد من دقة النموذج والتحقق من صحة التنبؤات الناتجة عن التحليل من الجوانب الأساسية في تطوير النماذج. تم في هذه الدراسة اتباع أسلوب التقييم المتقاطع (Cross-Validation) باستخدام 5 طيات (5 folds) لضمان عدم وجود تدريب زائد للنموذج (Overfitting). تم تقييم أداء النموذج باستخدام مجموعة من المؤشرات الإحصائية، منها: متوسط مربع الخطأ (MSE)، الانحراف المعياري للخطأ (SD)، الجذر التربيعي لمتوسط مربع الخطأ (RMSE)، ومعامل التحديد (R^2).

$$MSE = \frac{1}{n} \sum_{i=1}^n (O_i - t_i)^2 \quad (1)$$

$$SD = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - \bar{t}_i)^2} \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - t_i)^2} \quad (3)$$

$$R^2 = \frac{\sum_{i=1}^n (O_i - \bar{O}_i)(t_i - \bar{t}_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2 \cdot \sum_{i=1}^n (t_i - \bar{t}_i)^2} \quad (4)$$

حيث:


O_i : القيم المحسوبة

t_i : القيم المتوقعة

$\bar{O}_i$: متوسط القيم المحسوبة

$\bar{t}_i$: متوسط القيم المتوقعة

n : عدد العينات



شكل 2. هيكلية النموذج 1-4-7

4. تجميع ومعالجة البيانات

تم في هذه الدراسة تقييم حالة الرصف في طريق نقل ثقيل يعاني من ظهور عيوب واضحة في سطحه المتقادم، والذي لم يتم صيانته منذ بداية إنشائه في ثمانينيات القرن الماضي. استند التقييم وتجميع البيانات على الفحص البصري للعيوب باستخدام نماذج أعدت وفقاً لدليل تحديد العيوب لبرنامج أداء الرصف طويل الأمد بناءً على نوع وشدة كل عيب حسب Distress identification manual for the long-term pavement performance program

أ. مؤشر حالة الرصف Pavement condition index

مؤشر حالة الرصف PCI هو مقياس رقمي يُستخدم لتقييم الحالة السطحية للطريق، يعبر عنه من خلال مؤشرات خارجية (تظهر على سطح الرصف المرص) تُعرف باسم "العيوب" (Distresses)، والتي تنشأ نتيجة لعوامل بيئية، أو أحمال مرورية، أو مزيج من الاثنين معاً. من أبرز العيوب الشائعة في الرصف المرص: التآكل (Rutting)، والتشققات، وتآكل السطح. تُصنف هذه العيوب إلى ثلاث درجات من الشدة (منخفضة - متوسطة - عالية) وفقاً لتأثيرها على الأداء الإنشائي والوظيفي للطريق.

اعتمدت هذه الدراسة في حسابها لقيمة PCI على الأسلوب المستخدم في دليل الإدارة الفيدرالية للطرق السريعة الأمريكية (FHWA) الصادر عام 2014 [9]، والذي يُعد مرجعاً شاملاً في تصنيف وتحديد العيوب في الرصف المرص، ومن بين 19 نوعاً من العيوب المعروفة، تم تسجيل 7 عيوب فقط ضمن منطقة الدراسة. لكل عيب ودرجة شدته، يُطبق ما يُعرف بقيمة الخصم (Deduct Value - DV)، وهي رقم يُستخرج من منحنيات معيارية، وتُستخدم في احتساب القيمة النهائية للمؤشر. يُجمع إجمالي القيم المخصومة للحصول على إجمالي الخصم (Total Deduct Value - TDV)، ثم يُجرى تعديل عليها لإنتاج ما يُعرف بالقيمة المصححة (Corrected Deduct Value - CDV) والتي تكون قيمة من 0 إلى 100. وأخيراً، يُحسب مؤشر PCI وفق المعادلة:

$$PCI = 100 - \max CDV$$

ب. الشبكات العصبية الاصطناعية

الشبكات العصبية الاصطناعية ANN هي نموذج حسابي مأخوذ من الطريقة التي تعالج بها الشبكات العصبية البيولوجية في دماغ الإنسان المعلومات. وتتمتع هذه الشبكات بالقدرة على تعلم العلاقات المعقدة من مجموعة من البيانات المرتبطة بين المدخلات والمخرجات. توفر الشبكات العصبية الاصطناعية طريقة فعالة لنمذجة الأنظمة المعقدة غير الخطية أو غير المؤكدة أو غير المعروفة، دون الحاجة إلى معرفة صريحة بالعلاقة بين المدخلات والمخرجات. ومن أبرز مزايا الشبكات العصبية الاصطناعية قدرتها العالية على معالجة كميات كبيرة من البيانات بسرعة. بالإضافة إلى ذلك، فإن استخدام الشبكات العصبية يمكن أن يجعل النماذج أكثر سهولة ودقة عند التعامل مع الأنظمة الطبيعية المعقدة ذات المدخلات المتعددة.

ج. تطوير نموذج الشبكة العصبية الاصطناعية ANN

نظراً لتعقيد العلاقة بين العيوب ومؤشر PCI، وصعوبة تمثيلها بنماذج إحصائية تقليدية، فقد تم بناء نموذج تنبؤي باستخدام الشبكات العصبية الاصطناعية. تُمكن هذه الطريقة من التعامل مع المتغيرات النوعية (مثل نوع العيب وشدته) بدقة وكفاءة. شمل بناء النموذج ما يلي:

- المعالجة الأولية بتحويل بيانات عيوب الرصف إلى بيانات ذات مقياس واحد one-weight scale.
- بناء هيكل النموذج العصبي:
 - المدخلات: 7 متغيرات تمثل أنواع العيوب ودرجات الشدة المختلفة لكل منها إضافة إلى قيمة مؤشر حالة الرصف.
 - المخرجات: قيمة مؤشر PCI لكل قطاع.

في هذه الدراسة، تم تطوير نموذج شبكة عصبية اصطناعية ANN بهدف التنبؤ بقيمة مؤشر حالة الرصف PCI بالاعتماد على بيانات العيوب السطحية. يتكون هيكل النموذج من طبقة إدخال تمثل العيوب المختلفة مثل التشققات الطولية والعرضية، وتشققات التعب، بالإضافة إلى طبقة واحدة خاصة بالمخرجات تمثل قيمة مؤشر PCI. تم اختيار عدة سيناريوهات للنموذج من خلال تغيير عدد العقد داخل كل طبقة مخفية للنماذج الثلاثة. النموذج الأول (1-4-7)؛ كان بطبقة واحدة للإدخال محتوية على المدخلات السبعة لعيوب الرصف، وطبقة مخفية واحدة بعدد 4 عقد (neuros). بينما كانت المخرجات ممثلة في طبقة واحدة كما مبين بالشكل 2. النموذجان الآخران كانا بهيكلية (1-8-7) و (1-16-7).

جدول 2. ملخص تحويل الأوزان لكل عيب

الخطأ المعياري SE	المتوسط Mean	المجموع Sum	
0.0232	0.1666	13.7	تشققات التعب
0.0216	0.0567	4.7	التشققات الطولية
0.0314	0.3007	24.7	التشققات العرضية
0.0076	0.0077	0.63	الرقع
0.0124	0.0175	1.44	الحفر
0.0221	0.1921	15.8	الركام المصقول
0.0170	0.0395	3.24	الهبوط


4. مناقشة النتائج

تم تحليل البيانات الخاصة بعيوب الرصف وفق المنهجية المعتمدة في هذه الدراسة، وذلك باستخدام ثلاثة نماذج من الشبكات العصبية الاصطناعية. أظهرت النتائج أن استخدام هذه النماذج في تقييم سطح الرصف يعد مجدياً ويعطي نتائج دقيقة يمكن الاعتماد عليها من قبل مهندسي الطرق بشكل خاص ومتخذي القرار عموماً. بينت النتائج أيضاً أن قيم PCI المتوقعة لكل النماذج كانت مقاربة للقيم الحقيقية في جميع القطاعات التي شملتها الدراسة. وقد عزز التحليل الإحصائي هذا الاستنتاج، مما يعكس موثوقية النتائج. إذ أكدت اختبارات الدلالة الإحصائية وقيم اختبار ت (T-test) لجميع النماذج ارتفاع قيم t-statistic وانخفاض في مستويات الدلالة الإحصائية α كما هو مبين بالجدول 3. كشفت النتائج أن النموذج المعتمد على الهيكلية (7-8-1) قدم أداءً متميزاً مقارنة ببقية النماذج الأخرى، حيث سجل معامل تحديد قيمة مرتفعة $R^2 = 0.98$. كما أن الخطأ المعياري يعتبر منخفضاً جداً، وهو ما يعد مؤشراً قوياً على جودة التنبؤ ويدعم دقة النموذج.

جدول 3 ملخص التحليل الإحصائي للنتائج

النموذج	R^2	SE	RMSE	t-stat	p-value
1-4-7	0.977	3.79	3.76	57.7	<0.001
1-8-7	0.978	3.68	3.66	59.5	<0.001
1-16-7	0.97	4.31	4.26	50.6	<0.001

يبين الشكل 4 تأثير كل من العيوب السبعة على قيم مؤشر حالة الرصف بناءً على النتائج المتحصل عليها من النموذج (7-8-1). حيث يتبين أن الشقوق الانعكاسية وتشققات التعب تمثلان أعلى العوامل تأثيراً على مؤشر حالة الرصف عند مقارنتها ببقية العيوب. كما تظهر النماذج الأخرى نتائج مشابهة مع تغييرات طفيفة في نسب المساهمة لكل عيب. وهو ما يدل على استقرار وموثوقية النتائج في مختلف البنى الهيكلية لنماذج الشبكات العصبية الاصطناعية.



شكل 4. ترتيب العوامل من حيث الأهمية

تم تجميع البيانات المفصلة لقطاع الرصف لأنواع العيوب الظاهرة وهي تشققات التعب Fatigue cracking والتشققات الطولية cracking Longitudinal والتشققات العرضية أو الانعكاسية cracking Transverse والحفر Potholes والرقع Patches والركام المصقول Polished aggregate وهبوط الرصف Depression. ملخص نتائج الحصر للقطاعات المستهدفة مبينة بالجدول 1.

جدول 1 ملخص الوصف الإحصائي للبيانات

الكمية	المتوسط Mean	الخطأ المعياري SE	الحد الأدنى Min	الحد الأعلى Max
تشققات التعب م ²	2048	31.0	2.9	100
التشققات الطولية م	93	8.5	1.8	17
التشققات العرضية م	5311	31.2	2.8	164
الرقع م ²	48	24.2	0.3	48
الحفر م ²	34	1.1	0.7	20
الركام المصقول م ²	3178	42.4	4.3	150
الهبوط م ²	188	26.9	6.2	50

تباينت الأضرار في القطاعات المستهدفة بالحصر والتقييم والتي بلغت اثنان وثمانون قطاعاً بين الخفيفة والمتوسطة والعالية الشدة. حيث تشير البيانات المتحصل عليها إلى أن أغلب القطاعات متضررة بسبب تقادم سطح الرصف وتأخر عمليات الصيانة، وأن الجزء الأكبر من مساحة القطاع تعاني من ظهور تشققات التعب بشكل واضح والتي تجعل سطح الرصف غير مناسب للقيادة كما هو مبين بالشكل 3. من ناحية أخرى فإن التشققات الطولية والعرضية وصلف الركام تنتشر وتغطي كامل مساحة القطاع مع اختلاف شدة تأثيرها من مقطع إلى آخر. بالنسبة لبقية العيوب كالحفر والرقع فإنها تتواجد بنسب محدودة مقارنة ببقية العيوب وتظهر في قطاعات قليلة وبشدة منخفضة.




شكل 3. الأضرار في بعض قطاعات الرصف

تم في المرحلة التالية معالجة البيانات وتحضيرها للنمذجة والتي يطلق عليها توحيد البيانات Normalization. يتم أولاً توحيد المقاييس Min-Max Scaling بتحويل البيانات الوصفية مثل شدة العيوب إلى قيم عديدة (أرقام) يمكن للنماذج التعامل معها بسهولة. يليها حساب الأوزان التي يؤثر بها كل نوع من العيوب الموجودة بناءً على مستوى خطورته ومدى تأثيره على حالة الرصف عند إجراء عملية تقييم سطح الرصف أو حساب مؤشر حالة الرصف لكل قطاع. يبين الجدول 2 ملخصاً لقيم الأوزان النهائية لكل عيب حسب القيم التي تم استعمالها كمدخلات عند تصميم النماذج.

جدول 5 مقارنة أداء النموذج 1-8-7 باستخدام بيانات التدريب وبيانات الاختبار

مصدر البيانات	متوسط الخطأ RMSE	مدى الخطأ Error Range	معامل التحديد R^2	اختبار t-stat
بيانات التدريب	5.04	10 - 0	0.96	46
بيانات الاختبار	5.74	10 - 0	0.95	

نتائج المقارنة بين قيم PCI الحقيقية والمتوقعة عند استخدام كل من: جميع البيانات، بيانات التدريب، وبيانات الاختبار للنموذج (1-8-7) مبينة بالشكل 6. تظهر النتائج نمط خطي (ميل يقترب من 1) في الحالات الثلاثة، مما يشير إلى مقدرة النموذج على التنبؤ بقيم PCI بدقة عالية. يوضح الشكل توافق بين القيم الحقيقية والقيم المتوقعة، الأمر الذي يعزز من كفاءة النموذج وإمكانية الاعتماد عليه في مثل هذا النوع من الحسابات.




شكل 6. قيم PCI الحقيقية والمتوقعة للنموذج 1-8-7

6. الخلاصة

هدفت هذه الدراسة إلى بناء نموذج شبكي اصطناعي للتنبؤ بمؤشر حالة الرصف باستخدام عيوب الرصف حيث تم إنشاء عدة هياكل Architectures لنموذج التنبؤ الاصطناعي لتحديد أفضلها لاستخدامه مع البيانات. تم دراسة هذه الهياكل المختلفة للشبكة العصبية من خلال

تظهر النتائج أيضاً أن قيم مؤشر حالة الرصف المتوقعة والمتحصل عليها من النموذج (1-8-7) على سبيل المثال تعتبر مقاربة جداً للقيم الحقيقية المحسوبة، مما يدل على قدرة النموذج على محاكاة الواقع بدقة. يوضح الشكل 5 الفروقات بين القيم الحقيقية والقيم المتوقعة، حيث يظهر الشكل أن مدى الفروقات في التوقع يتراوح بين (0-10) %، مع توزيع منتظم حول الصفر.



شكل 5. الفروقات بين قيم PCI الحقيقية والمتوقعة

5. التحقق النموذج

تم تدريب النموذج (1-8-7) باستخدام 70% من بيانات قطاع الرصف، واختبار قدرة نموذج الشبكة العصبية الاصطناعية على التنبؤ باستخدام 30% من البيانات. تم تهيئة البيانات قبل إدخالها للنموذج بمقياس وزني واحد ثم حساب أوزان لها تبعاً لمستوى الشدة لعيوب الرصف. لتجنب عدم وجود تجهيز زائد للنموذج (Overfitting) تم اتباع أسلوب التحقق المتقاطع (Cross-Validation) باستخدام 5 طيات (5folds)، ثم أخذ متوسط المحاولات الخمسة كما هو مبين بالجدول 4 وذلك لتقييم استقرار أداء النموذج.

جدول 4 نتائج اختبار التحقق المتقاطع

الطية Fold	عدد العينات Samples	RMSE	R^2	MAE
1	17	5.61	0.96	4.18
2	16	5.18	0.95	4.06
3	17	5.71	0.92	4.29
4	16	6.51	0.96	5.56
5	16	5.58	0.94	4.56
Mean	16	5.72	0.95	4.53
SD	0	0.49	0.02	0.61

تم مقارنة الأداء لنتائج كل من بيانات التدريب وبيانات الاختبار بواسطة اختبارات إحصائية ملخصها مبين في الجدول 5. تظهر النتائج أن أداء النموذج باستخدام بيانات الاختبار والتدريب يعتبر جيداً بمقارنة متوسط الخطأ بين القيم المتحصل عليها. أيضاً تظهر نتائج اختبار ت فرق غير معنوي بين أداء النموذج باستخدام بيانات التدريب مقارنة ببيانات الاختبار ($p\text{-value} < 0.001 < \alpha = 0.05$).

[6] Kheirati, Afarin, and Amir Golroo. "Machine learning for developing a pavement condition index." *Automation in Construction* 139 (2022): 104296.

[7] Ali, Abdualmtalab Abdualaziz, et al. "Predicting pavement condition index based on the utilization of machine learning techniques: A case study." *Journal of Road Engineering* 3.3 (2023): 266-278.

[8] Zeiada, Waleed, et al. "Machine learning for pavement performance modelling in warm climate regions." *Arabian journal for science and engineering* 45.5 (2020): 4091-4109.

[9] Miller, J. S. & Bellinger, W. Y. 2014. Distress Identification Manual for the Long-term Pavement Performance Program. Report No. FHWA-HRT-13-092. McLean, VA: Office of Infrastructure Research and Development, Federal Highway Administration.

عملية التحسين، وتم تقييم أداء النموذج باستخدام مؤشرات متوسط النسبة المئوية للخطأ MAE، وجذر متوسط مربعات الخطأ RMSE، ومعامل التحديد R^2 . أظهرت نتائج التحليل المعتمد على نماذج الشبكات العصبية في تقييم عيوب الرصف عن مستويات عالية من الدقة والموثوقية في تقدير مؤشر حالة الرصف PCI، حيث تطابقت التوقعات النموذجية بشكل وثيق مع القيم الفعلية عبر جميع عينات الدراسة. تميزت النماذج الثلاثة المُختبرة بمعاملات تحديد مرتفعة (تزيد عن $R^2 = 0.97$) وبأخطاء معيارية منخفضة ($SE \leq 4.31$)، مما يعكس كفاءتها التنبؤية. كما أكدت المؤشرات الإحصائية لاختبار t-statistics المرتفعة التي تجاوزت 45، وقيم مستوى الدلالة $\alpha < 0.001$ ($p\text{-value} < 0.05$) على موثوقية النتائج ودقتها الإحصائية. أظهر النموذج ذو البنية 1-8-7 الأداء الأمثل، حيث سجل أعلى معامل تحديد ($R^2 = 0.978$) وأدنى خطأ معياري ($SE = 3.68$)، مما يجعله الأكثر ملاءمة للتطبيقات العملية في مراقبة حالة الرصف. من ناحية أخرى، أبرز تحليل الأهمية النسبية للعيوب أن التشققات العرضية وتشققات التعب تسهمان بأكبر تأثير سلبي في تدهور حالة الرصف. تؤكد هذه النتائج على فاعلية منهجيات الذكاء الاصطناعي، وخاصة الشبكات العصبية، في رصد وتقييم حالة البنية التحتية للطرق بدقة عالية، مما يوفر أداة قوية لدعم قرارات الصيانة الاستباقية وتحسين إدارة الأصول. من جهة أخرى، يعد استخدام الشبكات العصبية الاصطناعية في التنبؤ بقيمة مؤشر حالة الرصف أداة عملية بالمقارنة بالطرق اليدوية والمستعملة في جمع البيانات وتقييم حالة الرصف. هذه الأداة (النموذج الاصطناعي) يمكن أن تقلل التكاليف المرتبطة بعمليات جمع وتحليل البيانات، وتزيد من سرعة وكفاءة اتخاذ القرارات المتعلقة بصيانة الطرق خاصة مع شبكات الطرق الكبيرة. توصى الدراسة بتطوير نماذج الذكاء الاصطناعي بناءً على كميات أكبر من بيانات الاختبار والذي يمكن أن يحسن دقتها، حيث تعتمد قابليتها للتكيف على حجم البيانات التي يتم تدريبها عليها. إن استعمال النموذج الأمثل 1-8-7 في أنظمة مراقبة الرصف الميدانية يمكن أن يكون له دور في تعزيز فعالية قرارات الصيانة. من جهة أخرى، يُنصح بالتركيز على معالجة التشققات العرضية وتشققات التعب بشكل استباقي، نظرًا لتأثيرهما البالغ على تدهور حالة الرصف، مع دعم ذلك بتقنيات رصد ذكية كالاستشعار عن بُعد.

المراجع

[1] Elhadidy, Amr A., Sherif M. El-Badawy, and Emad E. Elbeltagi. "A simplified pavement condition index regression model for pavement evaluation." *International Journal of Pavement Engineering* 22.5 (2021): 643-652.

[2] Issa, Amjad, Haya Samaneh, and Mohammad Ghanim. "Predicting pavement condition index using artificial neural networks approach." *Ain Shams Engineering Journal* 13.1 (2022): 101490.

[3] ASTM D6433-18; Standard Practice for Roads and Parking Lots Pavement Condition Index Surveys. ASTM International: West Conshohocken, PA, USA, 2018.

[4] Shah, Yogesh U., et al. "Development of overall pavement condition index for urban road network." *Procedia-Social and Behavioral Sciences* 104 (2013): 332-341.

[5] Vyas, Vidhi, and Ajit Pratap Singh. "Modeling asphalt pavement condition using artificial neural networks." *Materials Today: Proceedings* 62 (2022): 1671-1676.