Prediction of the Bearing Capacity Values of Course and Fine Soils (CBR) Using the Artificial Neural Network Method

Zeina Tayseer Nofal *
Dr. Rami Hana **

(Received 8/ / 5 / 2025. Accepted 27 / 7 / 2025)

□ ABSTRACT □

Soft computing-based forecasting is a vital tool in engineering and is used successfully to make informed decisions. Therefore, it is crucial for engineers to predict the behavior of geotechnical engineering elements used in infrastructure, such as earth dams, road fills, road pavements, and airports. The bearing capacity of soil in road foundations and pavement layers is usually expressed by the California Bearing Capacity (CBR). This index evaluates the soil's ability to withstand loads under certain conditions. Engineers use various techniques to estimate and determine soil bearing capacity, but they have difficulty in arriving at accurate estimates due to the wide variation in soil properties and the multitude of factors affecting them. Locally, determining soil bearing capacity is difficult, so in this research, we attempted to develop valid models to determine the CBR value using information and data on soil properties (Atterberg limits, sand equivalent, density, and CBR). Predictive models were built to estimate soil bearing capacity values (CBR) using artificial neural networks (ANN). These models were applied to two real-world projects: the northern ring road of Latakia and latakia-Hamma road. Both models demonstrated good flexibility in calculating the design bearing capacity values (CBR) using ANN.

Keywords: Prediction, Soil Bearing Capacity (CBR), Artificial Neural Networks (ANN)

* **Postgraduate Student (Master) - Department of Transportation Engineering - Faculty of Civil Engineering - Lattakia University (Formerly Tishreen) - Lattakia – Syria. zeinanofal8@gmail.com**
** **Associate Professor - Department of Transportation Engineering - Faculty of Civil Engineering - Lattakia University (Formerly Tishreen)- Lattakia- Syria.**

التنبؤ بقيم قدرة تحمل الترب الخشنة والناعمة (CBR) باستخدام منهج الشبكات العصبونية الاصطناعية

زينه تيسير نوفل *

الدكتور رامي حنا **

(تاريخ الإيداع 8 / 5 / 2025. قُبِل للنشر في 27/ 7 / 2025)

□ ملخّص □

يعد التنبؤ المستند الى الحوسبة الذكية أداة حيوية في الهندسة ويسُتخدم بنجاح لاتخاذ القرارات الصحيحة. لذلك، من المهم جداً للمهندسين التنبؤ بسلوك العناصر الجيوتكنيكية الهندسية المستخدمة في البنى التحتية، مثل السدود الترابية والردميات الطرقية وأرصفة الطرق والمطارات. يعبر عادةً عن قدرة تحمل التربة في أساسات الطرق وطبقات رصفها بواسطة معامل كاليفورنيا لتحمل التربة (CBR) هذا المؤشر يستخدم لتقييم مدى قدرة التربة على تحمل الأحمال تحت ظروف معينة. يستخدم المهندسون تقنيات مختلفة لتقدير وتحديد تحمل التربة ولكنهم يواجهون صعوبة في الوصول إلى تقديرات دقيقة بسبب التباين الكبير في خصائص التربة وتعدد العوامل المؤثرة عليها. محلياً هناك صعوبة في تحديد قدرة تحمل التربة لذلك حاولنا من خلال البحث هذا وضع وتطوير نماذج صالحة لتحديد قيمة CBR من خلال معلومات وبيانات عن خصائص التربة (حدود أتربرغ – المكافئ الرملي – الكثافة –CBR).

تم بناء نماذج تنبؤية لتقدير قيم قدرة تحمل التربة (CBR) بالاعتماد على الشبكات العصبونية الاصطناعية (ANN).

تم تطبيق النماذج السابقة على حالتي دراسة وهما المتحلق الشمالي لمدينه اللاذقية وطريق اللاذقية – حماة، كلا النموذجين أظهرا مرونةً جيدة في إحصاء قيم قدرة التحمل التصميمية CBR باستخدام (ANN).

الكلمات المفتاحية: التنبؤ، قدرة تحمل التربة (CBR)، الشبكات العصبونية الاصطناعية (ANN).

* طالب دراسات عليا(ماجستير)– قسم هندسة المواصلات والنقل–كلية الهندسة المدنية–جامعة اللاذقية(تشرين سابقاً)– اللاذقية– سورية
zeinanofal8@gmail.com

** أستاذ مساعد – قسم هندسة المواصلات والنقل–كلية الهندسة المدنية–جامعة اللاذقية(تشرين سابقاً)– اللاذقية– سورية

مقدمة :

يُعد التقييم الدقيق لقدرة التحمل في طبقات الرصف، وخاصة من خلال مؤشر نسبة تحمل كاليفورنيا(CBR) ، أساساً محورياً في تصميم المنشآت الطرقية، نظراً لارتباط هذا المؤشر بتكلفة وموثوقية المشروع الإنشائي. إلا أن تحديد قيم CBRلا يزال يواجه تحديات كبيرة تتعلق بتباين الخصائص الجيوتكنيكية للتربة وصعوبة تمثيلها بدقة في كامل مسار الطريق، لا سيما عندما يعتمد التقييم على عامل واحد فقط دون مراعاة التفاعل المعقد بين الخصائص المختلفة مثل حدود أتربرغ، الكثافة الجافة، والمكافئ الرملي. وقد أكدت دراسات متعددة أن تجاهل هذا التفاعل يؤدي إلى أخطاء في تقدير القيمة الحقيقية لقوة تحمل التربة، سواء بزيادة مبالغ بها أو نقصان يهدد السلامة الإنشائية.[1,2]

في هذا السياق، تتزايد أهمية النماذج التنبؤية التي تعتمد على تقنيات الذكاء الاصطناعي، وبشكل خاص الشبكات العصبونية الاصطناعية (ANN)، في تحسين دقة تقدير مؤشر CBR .إذ أثبتت هذه النماذج كفاءتها في التعامل مع التعقيدات غير الخطية بين الخصائص الجيوتكنيكية ومؤشرCBR ، متفوقة على الأساليب التقليدية سواء في التربة الطبيعية أو المعالجة [3,4]. كما عرضت دراسات أخرى قدرة نماذج ANN على التنبؤ بخصائص الترب المختلفة، من بينها الترب الخشنة والطينية، بدقة عالية عند تزويدها بالمدخلات المناسبة.[5,6]

وفي إطار تعزيز هذه الاتجاهات البحثية، يقدم هذا البحث دراسة تطبيقية على مشروعين حيويين في سوريا: المتحلق الشمالي لمدينة اللاذقية وطريق اللاذقية–حماة. تم خلال هذه الدراسة بناء نماذج تنبؤية باستخدام ANN بعد جمع وتحليل بيانات أساسية شملت حدود أتربرغ، المكافئ الرملي، الكثافة الجافة، وقيمCBR ، بهدف التوصل إلى قيم دقيقة تعكس الواقع التصميمي للتربة. ويمثل هذا العمل إحدى المحاولات المحلية النادرة لتطبيق تقنيات الذكاء الاصطناعي في التنبؤ بقدرة تحمل الترب، مما يعزز من موثوقية القرار التصميمي ويقلل من الهدر في الموارد والمواد الإنشائية.[7,8]

إشكالية البحث (Research problem):

تعتمد معظم الدراسات الجيوتكنيكية في تقدير مؤشر تحمل كاليفورنيا (CBR) على تنفيذ تجارب ميدانية مباشرة، غالبًا ما تُجرى على عدد محدود من العينات، مما يفرض تحديات حقيقية في اعتماد قيمة تصميمية دقيقة تمثل قدرة التحمل الفعلية للتربة [9]. هذا الأسلوب التقليدي، رغم انتشاره، يتطلب وقتًا وتكلفة عالية، ويؤدي أحيانًا إلى اعتماد قيم وسطية تقريبية على كامل مسار الطريق، متجاهلًا التغيرات المحلية في خصائص التربة [10]. وتبرز هذه المشكلة بوضوح في مشاريع الطرق بمحافظة اللاذقية، حيث تواجه الترب الناعمة والخشنة تحديات في ضمان الاستقرار الإنشائي للبنية التحتية، لا سيما في ظل اعتماد نهج تقليدي غير مرن في التقييم.

ومع توفر بيانات موثوقة حول خصائص التربة في عدة مشاريع طرقية في المنطقة، مثل طريق اللاذقية–حماة والمتحلق الشمالي، والتي تشمل حدود أتربرغ، التحليل الحبيبي، الكثافة الجافة، والمكافئ الرملي، فإن الاستفادة من هذه البيانات في تطوير نموذج تنبؤي يعتمد على تقنيات الذكاء الاصطناعي، وتحديدًا الشبكات العصبونية الاصطناعية (ANN)، قد يوفر بديلاً علمياً فعالاً وأكثر دقة [8,7]. ومن هنا تنشأ الإشكالية البحثية المرتبطة بإمكانية توظيف هذه النماذج الذكية لتقدير قيم CBR اعتماداً فقط على الخصائص الجيوتكنيكية، بما يسهم في تقليل التكاليف وتحسين دقة التصميمات الإنشائية في المشاريع الطرقية مستقبلاً.[11]

أهمية البحث وأهدافه:

أهمية البحث (The importance of research):

تنبع أهمية هذا البحث من الحاجة الملحة لتحسين أدوات التنبؤ بقيم تحمل التربة باستخدام منهج الشبكات العصبونية الاصطناعية حيث يمكّن ذلك من:

- ✓ تحسين دقة التنبؤ: تقديم نموذج قادر على التنبؤ بقيم تحمل التربة بدقة عالية اعتماداً على خواص التربة الأساسية (حدود أتربرغ – بروكتور–التحليل الحبي –المكافئ الرملي)، مما يساعد في تصميم منشآت أكثر أماناً واستقراراً.
- ✓ تخفيض تكاليف الدراسة وزمن تنفيذها: تطوير حلول أكثر كفاءة لتقدير قيمة قدرة تحمل التربة وأقل تكلفة ووقت مما يقلل من النفقات الإجمالية للمشاريع الهندسية ويسرع من وتيرة تنفيذها.
- ✓ التعامل بمرونة مع قيم التباين في خصائص التربة: تقديم نموذج يمكنه التعامل مع التباين الكبير في خصائص التربة مما يزيد من موثوقية النتائج في مواقع مختلفة.
- ✓ توفير وسيلة فحص وتأكد لمنطقية وصحة اختبارات ال CBR حيث يلعب توقع (CBR) دوراً أساسياً في تصميم الطرق.

اهداف البحث (Research objectives):

تبحث هذه الدراسة في إمكانية وضع موديل مرن بالتعامل مع الخصائص المتنوعة للتربة (حدود أتربرغ – بروكتور– التحليل الحبي –المكافئ الرملي) باستخدام الشبكات العصبونية الاصطناعية للتنبؤ بقيمة ال CBR للتربة.

- ☒ بناءً على الموديلات التنبؤية باستخدام تقنية الشبكات العصبونية يمكن أن نحدد لبعض الطرق الرئيسية الهامة في محافظة اللاذقية قيم ال CBR التصميمية.
- ☒ تحليل البيانات لتحديد العوامل الرئيسية التي تؤثر على تحمل التربة وعلى نتائج التنبؤ.
- ☒ تقديم توصيات عملية لاستخدام النموذج ال(ANN) في المشاريع الهندسية وتحديد المجالات التي يمكن أن يساهم فيها بشكل فعال.

طرائق البحث ومواده:

تم الاعتماد في هذه الدراسة في بناء النماذج على مجموعة من البيانات المتوفرة من عدة مواقع في منطقة اللاذقية (طريق اللاذقية – حماة، طريق المتحلق الشمالي).

حيث تم جمع الخصائص الهندسية الجيوتكنيكية الهامة ل (30) عينة تربة ومن كلا الطريقين وإيجاد بارامتراتها: الكثافة الجافة القصوى(Y_{dmax}) ، نسبة تحمل كاليفورنيا (CBR%)، حد السيولة (LL%)، حد اللدونة (PL%)، مؤشر اللدونة (PI%)، رطوبة التربة (W%).

جرى إدخال هذه البيانات وتحليلها إحصائياً باستخدام برنامج Microsoft Excel، وذلك لضمان جودة البيانات ومدى ملاءمتها للنمذجة.

بعد ذلك تم بناء نموذج للتنبؤ بقيم CBR:

نموذج الشبكات العصبونية الاصطناعية (ANN):

ANN :هي نظم معلومات محوسبة مصممة على غرار بنية الدماغ البشري ويحاكي طريقة عمله، غير أن الشبكة العصبونية المحوسبة هي أبسط بكثير من هيكلية الدماغ البشري ومن بنية الخلية العصبونية نفسها. الشبكات العصبية الاصطناعية (ANNs) وهي شكل من أشكال الذكاء الاصطناعي الذي يحاول محاكاة سلوك الدماغ البشري والجهاز العصبي، يتكون الهيكل النموذجي للشبكات العصبية الاصطناعية من عدد من عناصر المعالجة (PEs)، أو عدد من العقد، التي يتم ترتيبها عادةً في طبقات: طبقة الإدخال، وطبقة الإخراج، وطبقة مخفية واحدة أو أكثر فيما بينهم [12].

منطقة الدراسة:

تم اختيار خط طريق اللاذقية حماة (الواصل بين محافظتي اللاذقية وحماة– طريق الغاب) بالإضافة إلى طريق المتحلق الشمالي في محافظة اللاذقية كمنطقتي دراسة وتحليل، تم الحصول على جميع معلومات وخصائص التربة ونتائج الاختبارات من الشركة العامة للطرق والجسور والشركة العامة للدراسات فرع المنطقة الساحلية.

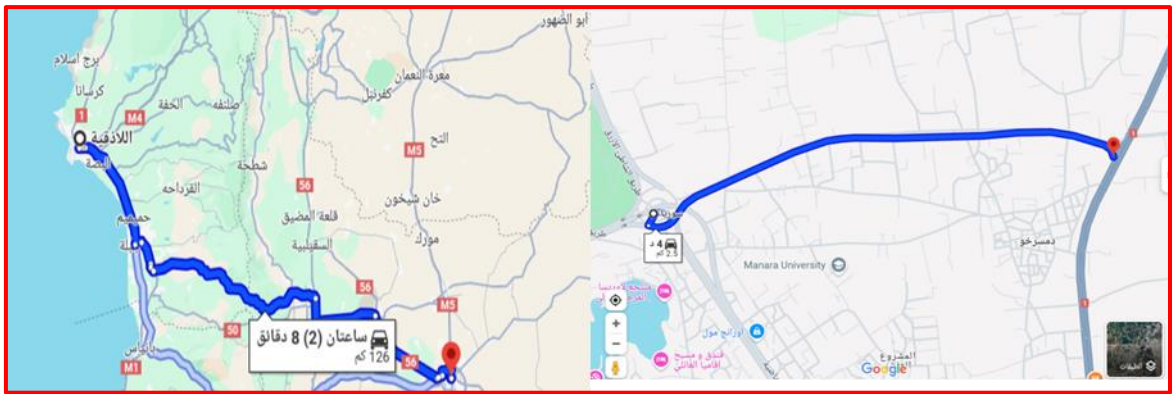

الشكل رقم (1): منطقة الدراسة (طريق المتحلق الشمالي – طريق اللاذقية حماه).

منهجية البحث

اعتمد هذا البحث على منهجية كمية تحليلية تهدف إلى تطوير نماذج تنبؤية دقيقة لقيم قدرة تحمل التربة (CBR) باستخدام الشبكات العصبونية الاصطناعية (ANN). وتم تنفيذ البحث وفق الخطوات التالية:

- **جمع البيانات** من منطقتين مختلفتين: طريق اللاذقية – حماة وطريق المتحلق الشمالي.
- **المعالجة الإحصائية الأولية** للبيانات من خلال برنامج Excel.
- **بناء نموذج** الشبكات العصبونية الاصطناعية.
- **مقارنة وتحليل النتائج.**
- **تقديم مقترحات** لتحسين التنبؤ بقدرة تحمل التربة (CBR) بناء على نتائج التحليل.

البيانات وادوات الدراسة اللازمة

أولاً: البيانات

تمثلت بپارامترات التربة المتوفرة لكل من طريق اللاذقية – حماة وطريق المتحلق الشمالي (تم الحصول على جميع معلومات التربة ونتائج الاختبارات من الشركة العامة للطرق والجسور والشركة العامة للدراسات فرع المنطقة الساحلية).

ثانياً: الأدوات والبرامج المستخدمة

- **برنامج** Microsoft Excel:

استخدم في تنظيم البيانات وإجراء العمليات الإحصائية الأولية عليها، مثل حساب المتوسطات الحسابية، الانحرافات المعيارية، معاملات الارتباط.[13]

- برنامج MATLAB:

تم استخدامه لبناء وتدريب الشبكات العصبونية الاصطناعية حيث تمكنا من تدريب الشبكة باستخدام خوارزمية Levenberg–Marquardt التي تُعد من أكثر خوارزميات التدريب كفاءةً وسرعةً في تقليل الخطأ أثناء مراحل التعلم.[14]

إعداد البيانات (بارامترات التربة) اللازمة للتحليل والنمذجة

i. البيانات المستخدمة في التحليل والنمذجة (طريق اللاذقية – حماة):

يظهر الجدول رقم (1) بارامترات التربة المستخدمة في تحليل ونمذجة طريق اللاذقية – حماة.

الجدول (1) بارامترات التربة المستخدمة في تحليل طريق اللاذقية – حماة.

رقم العينة	الكثافة الجافة القصوى Yd (g/cm³)	نسبة تحمل كاليفورنيا CBR (%)	حد السيولة LL (%)	حد اللدونة PL (%)	مؤشر اللدونة PI (%)	رطوبة التربة W (%)
1	1.65	3	59	26	33	17
2	1.67	3	58	25	33	16
3	1.63	3	62	25	37	18
4	1.69	1.9	62	25	37	17
5	1.73	5	43	28	15	14.5
6	1.84	13.4	39	29	10	14
7	1.76	5	41	28	13	13
8	1.68	2	60	25	35	16
9	1.7	4	42	27	15	14.5
10	1.61	3	62	25	37	17.5
11	1.62	3	61	25	36	18
12	1.65	3	68	26	42	18
13	1.78	4	40	27	13	14
14	1.73	5	41	28	13	15
15	1.82	9	35	29	6	14.5
16	1.71	3.6	41	28	13	14
17	1.8	8.5	35	29	6	14.6
18	1.79	10	36	29	7	14
19	1.64	2.8	58	25	33	15.5
20	1.62	3	60	26	34	18
21	1.66	4.5	58	26	32	16.5
22	1.71	6	45	22	23	14.2
23	1.68	3.5	61	25	36	17.2
24	1.62	2.7	63	27	36	18
25	1.64	3.2	55	24	31	16.5
26	1.69	5.5	50	20	30	15
27	1.74	9	38	17	21	13.5
28	1.6	2.2	60	29	31	18.2

رقم العينة	الكثافة الجافة القصوى Yd (g/cm³)	نسبة تحمل كاليفورنيا (%) CBR	حد السيولة LL (%)	حد اللدونة PL (%)	مؤشر اللدونة PI (%)	رطوبة التربة W (%)
29	1.67	4	52	23	29	14.8
30	1.7	5	48	21	27	14.9

تحليل بيانات طريق اللاذقية – حماة:

تم إجراء تحليل إحصائي أولي للبيانات بهدف فهم طبيعة توزيع المتغيرات الأساسية، وتحديد العلاقات المبدئية بينها. شمل هذا التحليل حساب المتوسط الحسابي، والوسيط، والانحراف المعياري، بالإضافة إلى تحديد القيم العظمى والصغرى لكل من المتغيرات كما هو موضح في الجدول (2):

الجدول رقم (2): القيم الإحصائية الأساسية لعينات التربة من طريق اللاذقية – حماة.

المتغير	المتوسط الحسابي	الوسيط	الانحراف المعياري	أصغر قيمة	أكبر قيمة
Yd	1.694333	1.685	0.06	1.6	1.84
CBR	4.693333	3.8	2.713432	1.9	13.4
LL	51.1	53.5	10.38683	35	68
PL	25.63333	26	2.87058	17	29
PI	25.46667	30.5	11.27014	6	42
W	15.73	15.25	1.628867	13	18.2

ii. البيانات المستخدمة في التحليل والنمذجة (طريق المتحلق الشمالي):

يظهر الجدول 3 بارامترات التربة المستخدمة في تحليل ونمذجة طريق المتحلق الشمالي.

الجدول رقم (3) بارامترات التربة المستخدمة في تحليل طريق المتحلق الشمالي.

رقم العينة	الكثافة الجافة القصوى Yd (g/cm³)	نسبة تحمل كاليفورنيا (%) CBR	حد السيولة LL (%)	حد اللدونة PL (%)	مؤشر اللدونة PI (%)	رطوبة التربة W (%)
1	1.78	4	52	26	26	17.2
2	1.8	5.5	55	25	30	16.8
3	1.7	3.3	58	24	34	17.2
4	1.74	3	57	25	32	16.9
5	1.75	4	54	26	28	17.2
6	1.72	3.5	54	26	28	17.4
7	1.73	4	53	27	26	17.2
8	1.75	3.5	52	27	25	17.2
9	1.72	5	49	27	22	17.6
10	1.72	4.8	50	27	23	17.2
11	1.78	4.2	52	26	26	17.9
12	1.81	5.1	54	25	29	16.7
13	1.71	3.6	56	25	31	17.0
14	1.70	3.8	55	25	30	16.98
15	1.73	4.1	54	27	27	17.41
16	1.66	3.3	54	26	28	17.91
17	1.7	3.6	55	27	28	18.1
18	1.74	3.7	58	27	31	16.6
19	1.78	4.3	52	27	25	15.6

رقم العينة	الكثافة الجافة القصوى Yd (g/cm³)	نسبة تحمل كاليفورنيا CBR (%)	حد السيولة LL (%)	حد اللدونة PL (%)	مؤشر اللدونة PI (%)	رطوبة التربة W (%)
20	1.76	5	52	27	25	15.2
21	1.75	3.2	55	25	30	17.63
22	1.72	3.3	------	-----	-------	17.8
23	1.76	3.5	55	26	29	17.12
24	1.75	3.6	55	26	29	17.0
25	1.702	3.7	54	25	29	17.92
26	1.712	3.8	54	26	28	18.3
27	1.742	3.9	55	25	30	17.33
28	1.705	3.4	53	28	25	17.11
29	1.72	3.6	54	27	27	17.42
30	1.75	4	55	27	28	17.21

يتضمن الجدول بيانات خاصة بثلاثين عينة من التربة تم تحليلها لتقييم خصائصها الفيزيائية والجيوتكنيكية المتعلقة بتطبيقات الهندسة المدنية. تتنوع هذه الخصائص بين الكثافة الجافة القصوى (Yd) التي تتراوح بين 1.66 و1.81 جرام/سم³، ونسبة تحمل كاليفورنيا (CBR) التي تتراوح بين 3.0% و5.5%، مما يعكس تبايناً في قدرة تحمل التربة تحت الأحمال.

أما حدود السيولة (LL) فتتراوح بين 49% إلى 58%، وحد اللدونة (PL) بين 24% و28%، وهو ما يشير إلى وجود تباين في المحتوى الطيني وخصائص اللدونة في العينات. يتراوح مؤشر اللدونة (PI) بين 22% و34%، مما يعكس درجة متفاوتة من اللدونة التي تؤثر على سلوك التربة تحت الظروف المختلفة.

أما نسبة رطوبة التربة (W) فتتراوح بين 15.2% و18.3%، وهي قيمة مهمة تؤثر في خصائص التربة الميكانيكية ومدى استقرارها. بشكل عام، تعكس هذه البيانات تنوعاً معقولاً في الخصائص الهندسية للتربة التي تم تحليلها، مما يتيح استخدامها في نماذج تنبؤية دقيقة لتقييم قدرة تحمل التربة.

iii. <u>بناء نموذج الشبكات العصبونية الاصطناعية:</u>

تم تطوير نموذج تنبؤي باستخدام الشبكات العصبية الاصطناعية (**Artificial Neural Networks–ANN**) بهدف التنبؤ بقيم ال (CBR) بناءً على مجموعة من الخواص التربة. تم اختيار برنامج **MATLAB** لتنفيذ النموذج نظراً لما يقدمه من أدوات فعالة ومتقدمة في مجال التعلم الآلي وتحديث النماذج وتحليل بياناتها.

النتائج والمناقشة:

<u>أولاً: طريق المتحلق الشمالي:</u>

- **استخدام الشبكات العصبونية الاصطناعية للتنبؤ بقيم ال CBR للترب الواقعة على طريق المتحلق الشمالي:**

تم تطوير نموذج تنبؤي باستخدام الشبكات العصبية الاصطناعية (**Artificial Neural Networks–ANN**) بهدف التنبؤ بقيم قدرة التحمل (CBR) بناءً على مجموعة من خواص التربة. تم اختيار برنامج **MATLAB** لتنفيذ النموذج نظراً لما يقدمه من أدوات فعالة ومتقدمة في مجال التعلم الآلي وتحليل البيانات.

تم استخدام قاعدة بيانات لخصائص (30) عينة تربة تتمثل ب (حدود أتربرغ، الكثافة الجافة القصوى، الرطوبة، CBR) تم الحصول عليها من المؤسسة العامة للطرق والمواصلات في اللاذقية، كما في الشكل رقم 2.

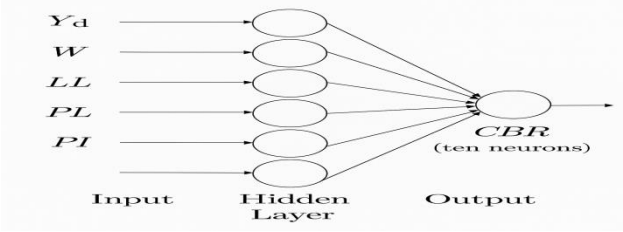

الشكل رقم (2): بنية شبكة ANN لطريق المتحلق الشمالي.

تم استخدام أداة Neural Net Fitting Tool في MATLAB

لتحديد معمارية الشبكة تم تحديد ما يلي:

- عدد عصبونات الإدخال يساوي عدد المتغيرات المستقلة، وهي: MOD,LL,PL,MDD,PI وبالتالي عددها 5 وكل متغير مكون من 30 عينة.
- عدد الطبقات المخفية والذي حدد آلياً بطبقة واحدة.
- عدد العصبونات في الطبقة المخفية والذي يحدد عن طريق التجربة.
- عدد العصبونات في طبقة الإخراج يساوي واحداً، لتمثيل قيمة CBR.
- تم استخدام دالة تنشيط غير خطية sigmoid في الطبقة المخفية، ودالة تنشيط خطية Linear في طبقة المخرجات.

قمنا بعدة اختبارات تجريب للحصول على أفضل معمارية باستخدام عدة عصبونات خفية تم اختيار أفضلها وكان عددها 10 عصبونات وبذلك حصلنا على الشبكة الموضحة في الشكل3:

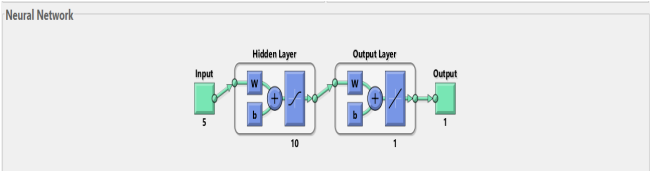

الشكل رقم (3): معمارية الشبكة العصبونية الخاصة بالتنبؤ بقيمة CBR لطريق المتحلق الشمالي.

تدريب الشبكة:

يتم في هذه المرحلة تحديد خيارات عملية التدريب وتحديد لوغاريتم التعلم وتنتهي باستخراج النتائج النهائية للشبكة ومستوى دقة تنبؤاتها حيث:

- تدريب الشبكة باستخدام خوارزمية الانتشار العكسي Levenberg–Marquardt [] والمعروفة باسم (TRAINLM)، والتي تهدف إلى تصغير قيمة متوسط الخطأ MSE للوصول إلى زيادة كفاءة المخرجات وتحسين أداء الشبكة.
- تم تقييم كفاءة تدريب الشبكة باستخدام معامل الارتباط (R) الذي يعكس مدى قوة العلاقة بين القيم الحقيقية والقيم المتوقعة، وحتما كلما اقتربت قيمة R من الواحد دل ذلك على وجود علاقة قوية بين النتائج.

بعد عدة اختبارات ومن خلال عملية التدريب للشبكة حصلنا على أفضل نتيجة، كما في الشكل 4:

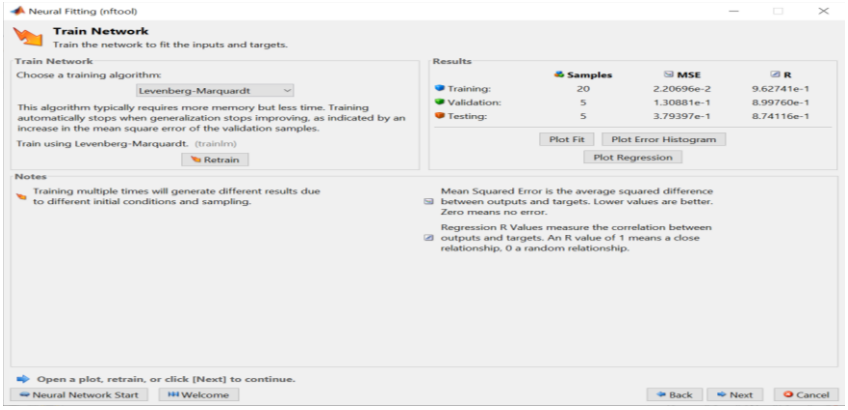

الشكل رقم (4): أفضل نتيجة تم الحصول عليها من خلال عملية تدريب الشبكة.

حيث كانت قيمة معامل R لمرحلة التدريب 0.962741، وللمرحلة التجريبية (الاختبار) 0.874116، أما بالنسبة لمرحلة التحقق كانت قيمة معامل الارتباط مساوية ل 0.899760 مما يشير إلى وجود علاقة جيدة بين القيم المتوقعة والقيم الحقيقية كما في الشكل (5)، بالإضافة إلى انخفاض قيمة متوسط مربع الخطأ MSEالذي بلغت قيمته 0.130881، الأمر الذي يدل على كفاءة النموذج المدرب كما في الشكل (6).

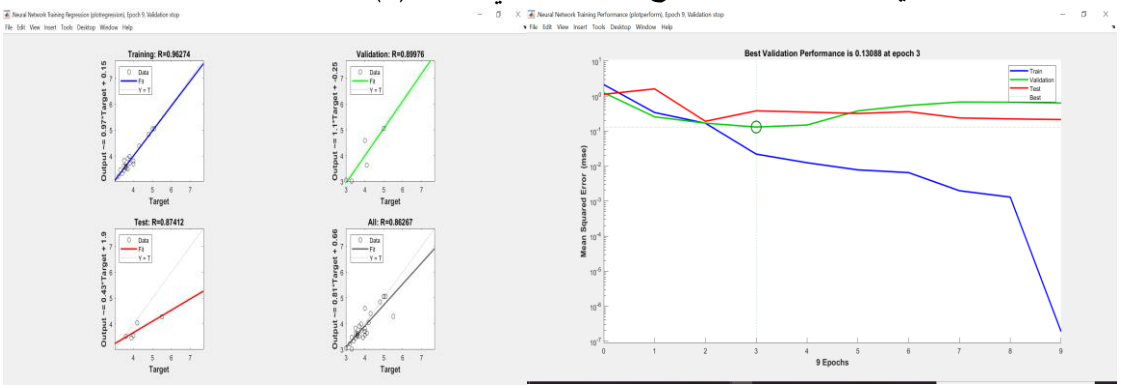

الشكل رقم (5): منحني الانحدار. **الشكل رقم (6): أداء النموذج.**

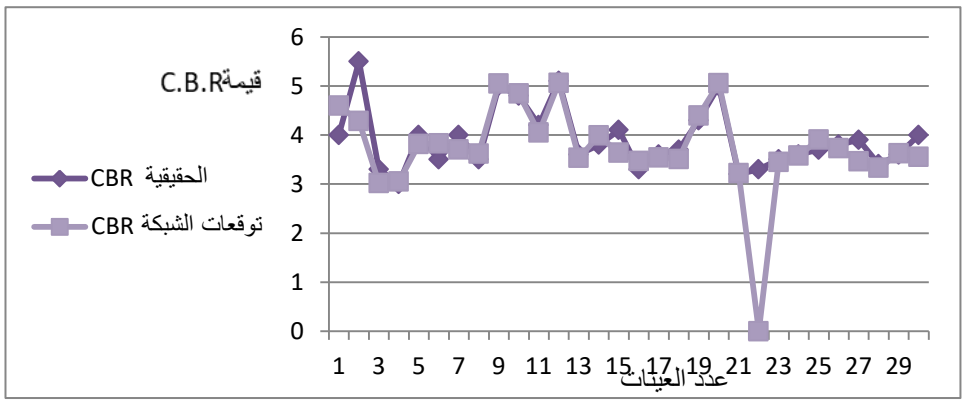

الشكل رقم (7) مقارنة بين القيم الحقيقية والقيم المتوقعة ل CBR لطريق المتحلق الشمالي.

يظهر الشكل رقم 7 ان القيم الحقيقية والمتوقعة لقدرة تحمل التربة تظهر فرقاً بنسبة 7%

ثانياً تحليل نتائج طريق المتحلق الشمالي:

تُعد قابلية التعميم أحد أهم معايير نجاح النماذج التنبؤية المعتمدة على تقنيات الذكاء الاصطناعي، وخصوصًا الشبكات العصبونية الاصطناعية(ANN) ، في التطبيقات الجيوتكنيكية. فبدلاً من بناء نموذج مستقل لكل موقع، يُفضل استخدام نموذج مدرّب مسبقًا شريطة أن يظهر سلوكاً متوازناً عند اختباره خارج نطاق تدريبه الأصلي، مما يُسهم في خفض التكاليف الزمنية والاقتصادية ويعزز من فعالية استخدام النموذج في بيئات واقعية متعددة [15,16] .في هذا السياق، أظهر نموذج المتحلق الشمالي كفاءة تنبؤية ملحوظة، وتميّز باستقرار معامل الارتباط وانخفاض متوسط الخطأ عبر مراحل التدريب والتحقق، مما يجعله مرشحًا مثاليًا للتطبيق في مواقع أخرى ذات خصائص مشابهة. وبما أن موقع طريق اللاذقية – حماة يمتلك تركيبة جيوتكنيكية ذات تداخل في المتغيرات الفيزيائية (مثل الكثافة الجافة، محتوى الرطوبة، وحدود أتربرغ) مع موقع المتحلق، فإن اختبار تعميم النموذج على بيانات هذا الطريق يُعد إجراءً منطقياً ينسجم مع التوجهات الحديثة في النمذجة الهندسية القائمة على البيانات .هذا الأساس المنهجي يمنح الدراسة مصداقية أعلى، ويضع إطارًا عمليًا للاستفادة من النماذج التنبؤية في تحسين تقييم قدرة تحمل التربة دون الحاجة لتكرار عمليات النمذجة المكلفة.[16]

- **استخدام الشبكات العصبونية الاصطناعية للتنبؤ بقيم ال C.B.R للترب الواقعة على طريق اللاذقية–حماة (تعميم نموذج المتحلق الشمالي على بيانات طريق اللاذقية – حماة):**

تم استخدام قاعدة بيانات مكونة من (30) عينة تربة تم قياس خواصها مخبرياً في مؤسسة الطرق والمواصلات في اللاذقية، تم استخدام أداة Neural Net Fitting Tool في MATLABوتطبيق خوارزمية الانتشار العكسي (LM) وتم الحصول على معمارية الشبكة في الشكل رقم 8:

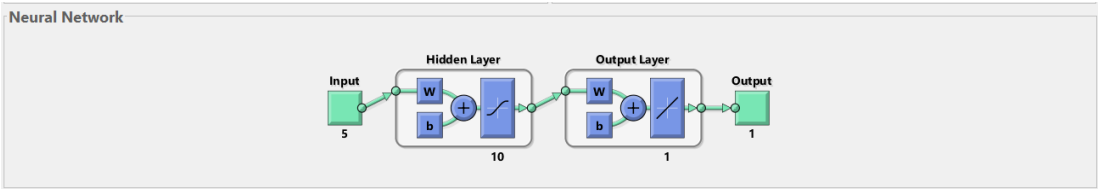

الشكل رقم (8): معمارية الشبكة العصبونية الخاصة بالتنبؤ بقيمة CBR لطريق اللاذقية – حماة.

بعد تدريب الشبكة حصلنا على النتائج الموضحة في الشكل رقم 9.

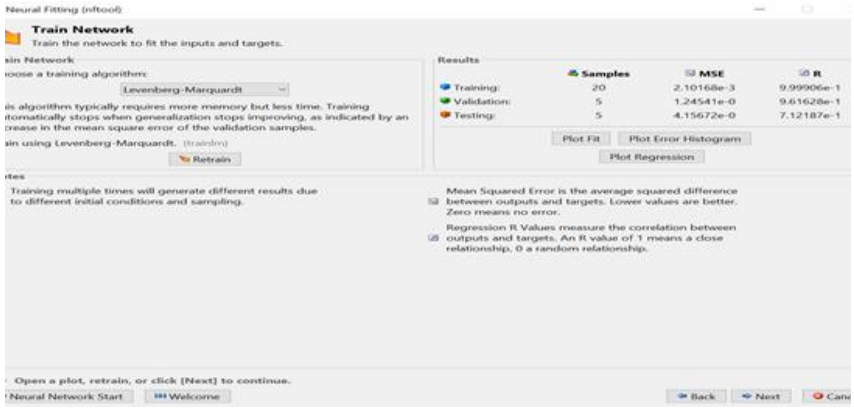

الشكل رقم (9): أفضل نتيجة تم الحصول عليها من خلال عملية تدريب الشبكة على بيانات طريق اللاذقية – حماة.

من خلال التجريب والتحليل كانت قيمة معامل R لمرحلة التدريب (0.9999)، ولمرحلة التجريبية (الاختبار) (0.7121)، أما بالنسبة لمرحلة التحقق كانت قيمة معامل الارتباط مساوية ل (0.9616) مما يشير إلى وجود علاقة جيدة بين القيم المتوقعة والقيم الحقيقية الفعلية كما هو موضح في الشكل رقم (10)، عدا عن انخفاض قيمة متوسط مربع الخطأ MSE الذي بلغت قيمته (1.24541)، الأمر الذي يدل على كفاءة النموذج المدرب كما في الشكل رقم (11).

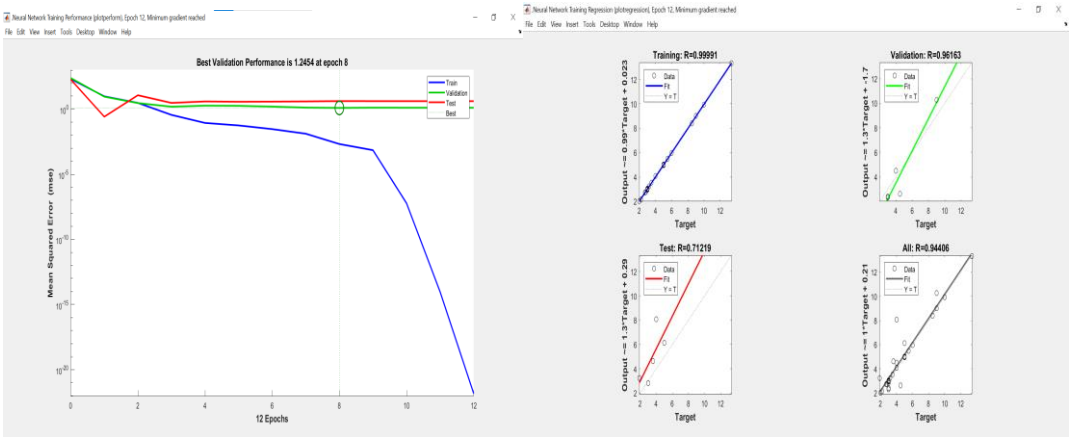

الشكل رقم(10): أداء النموذج (Performance Plot).

الشكل رقم (11): منحني الانحدار.

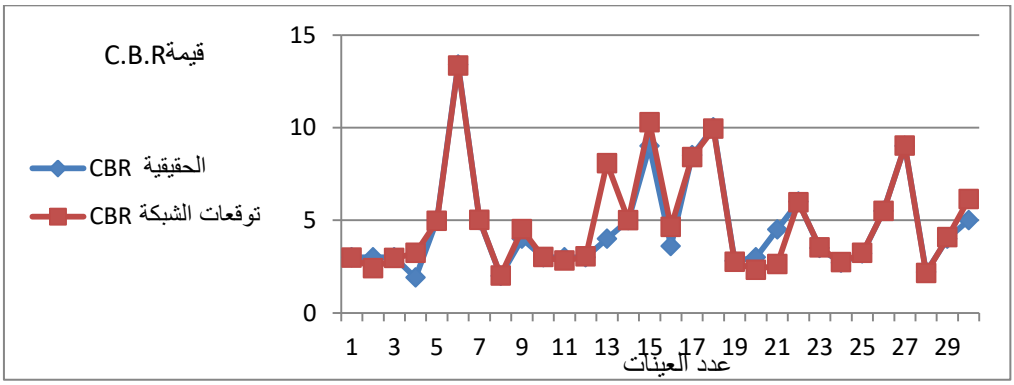

شكل رقم (12): مقارنة بين القيم الحقيقية والقيم المتوقعة ل CBR الناتجة عن ANN لطريق اللاذقية – حماة.

من الشكل رقم 12 نجد تقارب كبير بنسبة 90% بين القيم المتوقعة والقيم الحقيقية مما يدل على كفاءة النموذج المدرب.

ثالثاً: تقييم تعميم نموذج المتحلق الشمالي على طريق اللاذقية حماه:

تم تقييم أداء نموذج الشبكات العصبونية الاصطناعية (ANN) المطور باستخدام بيانات **طريق المتحلق الشمالي** عند تعميمه على بيانات **طريق اللاذقية – حماة (الساحل – الغاب)** بهدف اختبار قدرته على التنبؤ بقيم قدرة تحمل التربة (CBR)في بيئة تربة مغايرة نسبيًا. أظهرت نتائج التنبؤ أن النموذج احتفظ بدرجة معقولة من الدقة، حيث لوحظ تقارب مقبول بين القيم التنبؤية والقيم المخبرية لعينات طريق اللاذقية – حماة، مما يشير إلى وجود مرونة بنيوية في تركيبة النموذج تمكنه من التكيف مع اختلافات معتدلة في الخصائص الجيوتكنيكية. وعلى الرغم من أن الأداء لم يصل إلى مستوى دقة النموذج الأصلي المُدرَّب على بيانات اللاذقية – حماة، فإن انخفاض الانحرافات وتماسك نتائج الاختبار يعزز فرضية **قابلية التعميم الجزئي** في ظل ثبات المتغيرات الأساسية. ويُعزى نجاح هذا التعميم إلى التماثل النسبي بين مكونات التربة في الموقعين، خصوصًا من حيث الكثافة الجافة القصوى، ونسب الرطوبة، ومؤشر اللدونة، وهي من

العوامل الأساسية التي تؤثر مباشرة على مؤشر .CBR ويتماشى هذا التقييم مع ما أشارت إليه الدراسات السابقة بأن النماذج المصممة على بيانات متجانسة وتدريبها باستخدام خوارزميات فعالة مثل Levenberg–Marquardt تكون أكثر قدرة على ضبط السلوك التنبؤي عند نقلها إلى بيئات جديدة. وعليه، يمكن اعتبار نموذج المتحلق الشمالي أداة أولية صالحة للتطبيق في تقييم قدرة تحمل التربة على امتداد المحاور الطرقية ضمن إقليم الساحل السوري، مع الإشارة إلى أهمية إعادة المعايرة الموضعية لتحسين الدقة عند الضرورة.[15]

رابعاً: مقارنة أداء النماذج التنبؤية على الطريقين وتقييم دقتها وجدواها في دعم اتخاذ القرار الهندسي.

ظهر نموذج المتحلق الشمالي، عند تعميمه على بيانات طريق اللاذقية – حماة، قدرة مقبولة على التنبؤ بقيم CBR مع الحفاظ على مستوى جيد من الدقة وارتباط منطقي بالقيم الحقيقية، مما يعكس مرونة معمارية الشبكة وثباتها في مواجهة تغيرات جيوتكنيكية معتدلة.

تؤكد هذه النتائج أن نموذج المتحلق الشمالي، رغم تدريبه على بيانات موقع واحد، يمكن استخدامه كأداة أولية موثوقة في دعم القرارات التصميمية لمشاريع مشابهة من حيث الخصائص الهندسية. ومن الجدير بالذكر أن هذه النماذج لا تقتصر فائدتها على تحسين التقدير العددي فقط، بل تسهم بشكل مباشر في تقليل الحاجة للاختبارات الميدانية المكلفة، وتسريع عمليات التصميم، ورفع كفاءة الموارد في مشاريع البنى التحتية. وتتماشى هذه الاستنتاجات مع ما أشارت اليه الدراسات السابقة من أن النماذج العصبية المتوازنة في بنيتها، والتي يتم تدريبها بخوارزميات فعالة، تكون أكثر قدرة على دعم القرار الهندسي حتى عند تطبيقها في بيئات غير مدرّبة مسبقًا، شريطة تقارب المتغيرات المدخلة.[16]

الاستنتاجات والتوصيات:

الاستنتاجات:

1- أظهرت نتائج الدراسة أن استخدام الشبكات العصبونية الاصطناعية (ANN) يوفر نموذجًا تنبؤيًا عالي الدقة لقيم قدرة تحمل التربة (CBR)، وذلك بالاعتماد فقط على مدخلات بسيطة مثل الكثافة الجافة، حدود السيولة واللدونة، محتوى الرطوبة، ومؤشر اللدونة. إذ وصلت دقة النموذج (R) إلى أكثر من 0.96 في مراحل التدريب والتحقق، مع انخفاض ملحوظ في متوسط مربع الخطأ (MSE)، مما يعكس أداءً عاليًا للنموذج. وهذا يتوافق مع الدراسات السابقة التي اظهرت أن ANN تعطي نتائج تنبؤية دقيقة تتجاوز 90% عند استخدام خصائص التربة الفيزيائية.[16,3]

2- في المقابل، عند تعميم نموذج المتحلق الشمالي على بيانات طريق اللاذقية – حماة، حافظ على مستوى مقبول من الدقة (حوالي 90%)، مما يدل على قدرة النموذج على التكيف مع اختلافات معتدلة في الخصائص الجيوتكنيكية، ما يجعله صالحًا للتطبيق الأولي في مواقع جديدة ذات خصائص مشابهة. كما اكدت الدراسات السابقة أن النماذج المبنية على خصائص متجانسة وقوية الخوارزمية (مثل LM) يمكن تعميمها جزئيًا مع الحفاظ على الدقة، كما أثبتت هذه الدراسة.[7]

3- خفض التكلفة والجهد في التقييم الجيوتكنيكي: يُعتبر هذا النهج بديلاً فعالاً عن اختبارات CBR الميدانية التقليدية، والتي تُعرف بتكلفتها العالية ووقتها الطويل، مما يساهم في تسريع إجراءات التصميم وتحسين كفاءة الموارد في المشاريع الطرقية.

4- برزت أهمية بعض المتغيرات الجيوتكنيكية: أظهرت نتائج التحليل أن الكثافة الجافة القصوى ومؤشر اللدونة يلعبان دورًا مؤثرًا في دقة التنبؤ بقيم CBR، وهو ما يدعم أهمية دمج أكثر من خاصية في أي نموذج تنبؤي مستقبلي لتقوية قدرته التفسيرية.

التوصيات:

من النتائج التي حصلنا عليها خلال الدراسة النظرية والتطبيقية، واستناداً للمعطيات والبيانات المتوفرة لدينا يمكن تقديم التوصيات التالية:

1- ضرورة إجراء دراسات إضافية على أنواع متنوعة من الترب في مناطق مختلفة لتعزيز تعميم نتائج النماذج التنبؤية وتحسين موثوقيتها.

2- التوسع باستخدام الشبكات العصبونية الاصطناعية في مشروعات تقييم التربة، لما أثبتته من قدرة عالية على تمثيل العلاقات المعقدة بين الخصائص الفيزيائية للتربة وقدرة تحملها.

3- أهمية اعتماد تقنيات حديثة أخرى من الذكاء الاصطناعي مستقبلاً، ومقارنتها مع نتائج الشبكات العصبونية لتحسين اختيار النموذج الأمثل.

4- ضرورة دراسة تأثير إدخال متغيرات إضافية مثل عمق العينة، نوع التربة، ونسبة الغضار على أداء النماذج التنبؤية.

References:

[1]. J. Mandal, S. Bhatacharya, Soil Mechanics and Foundation Engineering, Springer, (2021).

[2]. S. Nazarian, D. Yuan, L.N. Mohammad, Prediction of CBR Using Soil Index Properties, Transportation Research Record, Vol. 2457(1), pp. 82–89, (2013).

[3]. M. Ghorbani, H.R. Naji, M.H. Kashani, Artificial Neural Network Model for Prediction of California Bearing Ratio Using Soil Physical Properties, Journal of Soft Computing in Civil Engineering, Vol. 3(2)، pp. 22–36, (2019).

[4]. M. Arifuzzaman, M.T. Rahman, S. Ahmed, Prediction of CBR for Stabilized Subgrade Soils Using ANN and Regression Models, International Journal of Pavement Research and Technology, Vol. 15, pp. 1–10, (2022).

[5]. D. Bui, H. Shahabi, B. Pradhan, Machine Learning for Subgrade Strength Classification: Comparative Study of ANN and SVM, Applied Soft Computing, Vol. 87, pp. 105–110, (2020).

[6]. I. Yilmaz, O. Kaynar, Predicting CBR of Fine-Grained Soils Using ANN and Adaptive Neuro-Fuzzy Inference System, Journal of Geotechnical and Geoenvironmental Engineering, Vol. 147(4), 04021015, (2021).

[7]. W. Zuo, L. Zhang, J. Zhang, Evaluation of AI Methods for Estimating Soil CBR Based on Limited Field Data, Computers and Geotechnics, Vol. 119, 103281, (2020).

[8]. K. Onyelowe, A. Ebid, A.I. Al-Hadidy, Artificial Intelligence Modeling of Soil Subgrade Strength Using CBR and Geotechnical Parameters, Engineering Reports, Vol. 4(7), e12489, (2022).

[9]. M. Rahman, S.R. Lo, Prediction of CBR from Index Properties Using Regression Models, Geotechnical and Geological Engineering, Vol. 32(2), pp. 419–429, (2014).

[10]. G. Saha, M.S. Khan, Limitations of Laboratory-Based CBR Testing and the Need for Predictive Approaches, International Journal of Pavement Engineering, Vol. 21(9), pp. 1110–1120, (2020).

[11]. A. Khoshghalb, A.A. Javadi, Use of ANN for Predicting the Bearing Capacity of Soils with Limited Input Data, Neural Computing and Applications, Vol. 33, pp. 2133–2145, (2021).

[12]. M. Shahin, M.B. Jaksa, H.R. Maier, ARTIFICIAL NEURAL NETWORK APPLICATIONS IN GEOTECHNICAL ENGINEERING, Australian Geomechanics. (2001)

[13]. Microsoft Corporation. Microsoft Excel (Version 365) [Software]. Redmond, WA: Microsoft Corporatio. (2021).
[14]. M. Hagan& MB. Menhaj. Training feedforward networks with the Marquardt algorithm. IEEE Transactions on Neural Networks, 5(6), 989–993. (1994).
[15]. I.basheer, & A. Hajmeer. *Artificial neural networks: Fundamentals, computing, design, and application*. Journal of Microbiological Methods, 43(1), 3–31. (2000).
[16]. A. Goh. *Back-propagation neural networks for modeling complex systems*. Artificial Intelligence in Engineering, 9(3), 143–151(1995)