

## Developing Artificial Neural Network Models to Predict the Bearing Capacity of Cohesionless Soil for Shallow Foundations

Dr. Mohannad Mhanna\*  
Amira A. Rajab\*\*

(Received 2 / 5 / 2023. Accepted 8 / 6 / 2023)

### □ ABSTRACT □

The bearing capacity of soil is considerably very important for geotechnics and engineering geology, since it is a significant parameter for the foundations design. This research proposes the use of artificial neural network to predict the bearing capacity of cohesionless soil for shallow foundation. In this paper 145 datasets were used to train and validate the model. Four parameters (friction angel of the soil ( $\phi$ ), unit weight ( $\gamma$ ), footing width (B) and footing length (L)) were used as the model inputs. Relating to these input parameters, in the ANN model is forecasted the ultimate bearing capacity. The last parameter been set as the required target (i.e. output) in the ANN model. Performance comparison of the developed models (interms of coefficient of correlation (R) and Mean Squared Error (MSE) ) revealed that the developed artificial neural network models could be effectively used at the preliminary stage of estimating the bearing capacity of cohesionless soil for shallow foundations, instead of the coventional methods. Coefficient of correlation (R) equals to 0.989 and Mean Squared Error (MSE) equals to 0.000297, strongly implies that the ANN model shows a high level of reliability in forecasting the bearing capacity of cohesionless soil for shallow foundations.

**Keywords:** Shallow foundation, bearing capacity, Artificial Neural Network, cohesionless Soil.

**Copyright**



:Tishreen University journal-Syria, The authors retain the copyright under a CC BY-NC-SA 04

\*Ph.D., Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

\*\* Postgraduate Student (Master), Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.  
amirarajab@gmail.com

## تطوير نماذج شبكة عصبونية صناعية للتنبؤ بقدرة تحمل الترب المفككة لحالة الأساسات السطحية

د. مهند مهنا\*

أميره علي رجب\*\*

(تاريخ الإيداع 2 / 5 / 2023. قُبِلَ للنشر في 8 / 6 / 2023)

### □ ملخص □

تعتبر قدرة تحمل التربة مهمة للغاية بالنسبة للجيوتكنيك والجيولوجيا الهندسية، حيث أنها عامل أساسي لتصميم الأساسات. يقترح هذا البحث استخدام الشبكة العصبية الصناعية للتنبؤ بقدرة تحمل الأساسات السطحية في الترب المفككة. في هذا المقال تم استخدام 145 مجموعة بيانات لتدريب النموذج والتحقق من صحته. تم استخدام أربع بارامترات وهي ( زاوية الاحتكاك الداخلي للتربة، الوزن الحجمي، عرض الأساس وطوله) كمدخلات للنموذج، فيما يتعلق ببارامترات الإدخال هذه، في نموذج ANN يتم توقع قدرة التحمل الحدية. تم تعيين البارامتر الأخير على أنه الهدف المطلوب (أي المخرج) في نموذج ANN .

كشفت مقارنة أداء النماذج المطورة (من حيث معامل الارتباط ومتوسط مربع الخطأ) أنّ نماذج الشبكة العصبية المطورة يمكن استخدامها بفعالية للتنبؤ بقدرة التحمل في المرحلة الأولية. إنّ قيمة معامل الارتباط المساوية لـ 0.989 و قيمة متوسط مربع الخطأ المساوية لـ 0.0002971 يظهران مستوى عالي من الموثوقية في التنبؤ بقدرة تحمل الترب المفككة لحالة الأساسات السطحية.

الكلمات المفتاحية: أساس سطحي، قدرة التحمل، شبكة عصبونية صناعية، تربة مفككة.

حقوق النشر : مجلة جامعة تشرين- سورية، يحتفظ المؤلفون بحقوق النشر بموجب الترخيص



CC BY-NC-SA 04

\* دكتوراه، كلية الهندسة المدنية، جامعة تشرين، اللاذقية، سورية.

\*\* طالبة ماجستير، كلية الهندسة المدنية، جامعة تشرين، اللاذقية، سورية. ameerarajab@gmail.com

**مقدمة:**

إن حساب قدرة تحمل الأساسات يتميز بأهمية كبرى في مجال الهندسة الجيوتكنيكية حيث أن التأسيس الصحيح يساعد في تقليل تكاليف البناء مع ضمان الاستقرار والأمان خلال العمر الاستثماري للمنشأ. عند تصميم الأساسات السطحية فإن قدرة التحمل والهبوط النهائي هما المعياران الرئيسيان اللذان يتحكمان في التصميم، في العديد من الدراسات ركز العديد من العلماء على معرفة المعايير المؤثرة على قدرة التحمل، وغالباً ما يتم تقدير قدرة التحمل هذه بالاعتماد على مقاومة القص بناءً على سطح انزلاق التربة (Raj & Bharathi, 2013).

اعتمد معظم المهندسين الجيوتكنيكيين في حساب قدرة تحمل التربة على العلاقات المقترحة من قبل (Terzaghi, 1967)، (Meyerhof, 1968)، (Hansen, 1970)، (Vesic, 1975) والتي تستند دراساتهم إلى العديد من الافتراضات التقريبية مثل فرض سطح الانزلاق وإهمال تأثير بعض العوامل أحياناً مثل مقاومة القص فوق قاعدة الأساس، ثم ظهرت الطرائق العددية لتحديد قدرة تحمل التربة لكن نتائجها تحتاج إلى المعايرة و المقارنة مع نتائج تجارب مخبرية أو حقلية. إضافة لما سبق يمكن تحديد قدرة التحمل حقلياً من خلال التجارب الحقلية مثل تجربة صفائح التحميل وتجربة الاختراق القياسية (Ghavami et al., 2019).

إن التباين في النتائج بين الحسابات التحليلية والحقلية والحاجة إلى مقارنة نتائج المحاكاة العددية مع نتائج التجارب أعطى أولوية تفضيلية للقياسات الحقلية كونها تعطي قدرة التحمل بشكل مباشر وبدقة مع اختبار التربة بظروفها الحقلية.

لكن صعوبة وكلفة إجراء التجارب أحياناً وبعض العوامل الأخرى مثل الزمن أبرز أهمية اللجوء إلى الذكاء الصناعي لتقدير قدرة تحمل التربة بناءً على نتائج حقلية أو مخبرية منقّدة مسبقاً إضافة إلى تأثير الذكاء الاصطناعي على مستقبل كل قطاع حيث من المتوقع أن يلعب الذكاء الاصطناعي دوراً أكبر في كل المجالات خلال السنوات القادمة.

تعتبر الشبكات العصبونية الصناعية (ANN: Artificial Neural Network) نهجاً محتملاً لنمذجة قدرة تحمل التربة يحاول محاكاة الدماغ البشري، وأصبحت مركزاً للاهتمام عبر العديد من الدراسات العلمية في مجال الهندسة الجيوتكنيكية نظراً لقدرتها على تحديد العلاقات المعقدة غير الخطية بين بيانات المدخلات والمخرجات حيث أعطت نتائج مقارنة للقيم المقاسة وبالتالي قدرة تنبؤ عالية (Baginska & Srokosz, 2019). طور (Ikizler et al., 2009) نموذج تنبؤ لضغط الانتفاخ الجانبي المنقول وضغط الانتفاخ الشاقولي على الجدران الاستنادية باستخدام الشبكات العصبونية (ANNs). في المرحلة الأولى من هذه الدراسة، تم قياس ضغوط الانتفاخ الجانبية والرأسية بسماكات مختلفة من البوليسترين الممدد (EPS) الموضوع بين أحد الجدران الشاقولية لصندوق الاختبار الصلب والتربة. ثم تم تدريب الشبكة العصبونية باستخدام 139 مجموعة بيانات من هذه الضغوط لتوقع ضغط الانتفاخ الجانبي وضغط الانتفاخ الشاقولي المنقول إلى المنشأ. تتألف هيكلية هذه الشبكة من طبقة مدخلات واحدة تضم مدخلين هما الزمن وسماكة البوليسترين الممدد (EPS)، بالإضافة إلى طبقة خفية واحدة مؤلفة من ست عصبونات، وطبقة مخرجات تضم مخرج وحيد هو ضغط الانتفاخ الجانبي والعمودي. أظهرت النتائج التي تم الحصول عليها من هذه الدراسة أنه يمكن استخدام الشبكات العصبونية الصناعية والحصول على نتائج مرضية عند التنبؤ بضغط الانتفاخ للتربة حيث يقدر النموذج معامل تحديد عالي ( $R^2=0.999$ ) بالنسبة لضغط الانتفاخ الجانبي و ( $R^2=0.977$ ) بالنسبة لضغط الانتفاخ الشاقولي.

**في تدعيم التربة:** قدم (Kung et al., 2007) نموذج شبكة عصبونية اصطناعية للتنبؤ بانقالات جدران التدعيم الناجم عن الحفر في الغضار الناعم جداً إلى متوسط النعومة. كانت مدخلات نموذج الشبكة هي عمق الحفر، صلابة

المجموعة، عرض الحفرية، قوة القص الناتجة عن الإجهاد الشاقولي الفعال، ومعامل يونغ. بينما كان المخرج الوحيد للشبكة هو أقصى انتقال الجدار في الحفرية المدعمة. وتم إنشاء قاعدة البيانات الخاصة بتدريب واختبار الشبكات العصبية الاصطناعية من حالات افتراضية باستخدام طريقة العناصر المحدودة حوالي (3486 حالة). تتألف الشبكة العصبونية التي تم تطبيقها من طبقة خفية واحدة بسبع عصبونات وتم استخدام خوارزمية Levenberg-Marquardt (LM). تم استخدام 12 حالة موثقة في الموقع لحفرية في الغضار للتحقق من صحة النموذج، أظهر التحقق أنه يمكن التنبؤ بدقة بانحراف الجدار الناجم عن الحفر المدعم بواسطة نموذج ANN.

في التنبؤ بقدرة تحمل التربة للأساسات السطحية: قام (Nazir et al., 2015) بتجميع قاعدة بيانات لـ 75 حالة لتجارب صفائح التحميل في التربة الغير متماسكة حيث تضم معلومات حول طول الأساس (L)، عرضه (B)، عمق التأسيس (Df)، متوسط الضغط الشاقولي الفعال المطبق على التربة على عمق B/2 أسفل القدم ( $\sigma'$ )، وزاوية الاحتكاك للتربة ( $\Phi$ ) وقدرة التحمل الحدية القصوى (Qu). تم تعيين البارمتر الأخير على أنه المخرج المطلوب في نموذج ال ANN، بينما تم استخدام الباقي كمدخلات للنموذج. تم تقسيم قاعدة البيانات بشكل عشوائي إلى ثلاث مجموعات فرعية: مجموعة للتدريب ومجموعة للاختبار ومجموعة للتحقق من الصحة حيث استخدمت 70 بالمئة من البيانات للتدريب، وتم استخدام 15% للاختبار، و 15% للتحقق من الصحة. وتم استخلاص أن شبكة مكونة من ستة عقد في طبقة واحدة مخفية تقدم أفضل أداء؛ ومن ثم تم اختيار هذا النموذج كنموذج ANN الأمثل.

قام (Soleimanbeigi & Hataf, 2005) باستخدام شبكة عصبية للتنبؤ بقدرة تحمل الأساسات السطحية على تربة مفككة مدعمة، وتم استخدام 351 بيان موثق من تجارب مخبرية وحقلية لقدرة تحمل أساسات سطحية على تربة مفككة مدعمة، استخدمت عشر مدخلات في هذه الشبكة وهي: عرض الأساس (B)، ومعامل شكل الأساس (L/B)، نسبة عمق التأسيس (DF/B)، زاوية الاحتكاك الداخلي للتربة ( $\theta$ )، الوزن الحجمي للتربة ( $\gamma$ )، عدد طبقات التدعيم (N)، نسبة عمق الطبقة الأولى (u/B)، نسبة التباعد الشاقولي لطبقات التدعيم (h/B)، نسبة عرض التدعيم (b/B)، وصلابة التدعيم (K)، بينما كان المخرج الوحيد هو قدرة تحمل التربة (qu). تم تدريب الشبكة باستخدام طبقة خفية واحدة مع تغيير عدد عصبونات الطبقة، كانت النتيجة أن شبكة مكونة من عشر مدخلات وطبقة خفية بست عصبونات ومخرج واحد هي أفضل شبكة حيث أعطت قيمة لـ R مساوية لـ 0.975 وهذا يشير إلى درجة جيدة جداً من دقة التنبؤ. كما قام (Khudier, 2018) بتجميع قاعدة بيانات لتجارب تربة مؤلفة من 87 عينة مأخوذة على عمق 3m في أماكن مختلفة من محافظة البصرة كانت مدخلات النموذج تسعة وهي حد السيولة (LL)، حد اللدونة (PL)، نسبة الرمل، نسبة النواعم، النسبة المئوية المثلى للرطوبة، ثالث أكسيد الكبريت (SO3)، نسبة الكلور (CL)، وإجمالي المواد الصلبة (TSS)، ونسبة الجبس بينما كان المخرج الوحيد هو قدرة تحمل التربة (qu). وفي هذه الدراسة تم تقسيم البيانات: 70% لهدف التدريب و 20% لاختبار النموذج واستخدام تابع سيغمويد لظل الزاوية (Tan-Sigmoid Transfer Function). وتم استخدام التدريب على عدد من الطبقات الخفية من طبقة إلى ثلاث طبقات، كانت النتيجة أن التدريب باستخدام طبقة واحدة أعطى أفضل نموذج حيث أعطى قيمة لمعامل التحديد  $R^2$  مساوية لـ 0.986 للتدريب ومساوية لـ 0.9915 للاختبار وهذا يشير إلى أن نموذج ANN يظهر مستوى عالي من الموثوقية في التنبؤ بقدرة تحمل الأساسات المستمرة.

## أهمية البحث وأهدافه:

إنّ لمعرفة قدرة تحمل الأساسات أولوية دائمة وأهمية بالغة لدى المهندس الجيوتكنيكي نظراً لما يقدمه الأساس المناسب من أمان وطول عمر للمنشأ مع تكلفة قليلة، في بعض الأحيان تكون كلفة التحريات الحقلية والزمن اللازم لإجرائها من أبرز المعوقات. إن استخدام الشبكات العصبونية للتنبؤ بقدرة التحمل يساعد في سرعة اتخاذ القرار لدى القائمين على الدراسة وتقليل الوقت والجهد.

يهدف هذا البحث إلى اختبار أداء إحدى تطبيقات الذكاء الصناعي المتمثلة بالشبكات العصبونية الصناعية في تقدير قدرة تحمل التربة للأساسات السطحية في التربة المفككة باستخدام برنامج (MATLAB) وهو لغة برمجية هندسية يتعامل مع الثوابت والمتحولات كمصفوفات رياضية، للتوصل إلى أفضل نموذج من خلال التحديد الأمثل لهيكلية الشبكة العصبونية الصناعية، من خلال دراسة كل من البارامترات التالية:

- مدخلات الشبكة العصبونية (Inputs).
- تحديد النسب المئوية لتقسيم البيانات (DR: Dividing Ratio) إلى: مجموعة تدريب (Training)، مجموعة معايرة (Validation)، ومجموعة اختبار (Test).
- عدد العصبونات في الطبقة الخفية (HN: Hidden Neurons).
- عدد الطبقات الخفية.
- تابع التفعيل.

## طرائق البحث ومواده:

### الشبكات العصبونية الصناعية (Artificial Neural Network):

تُعرّف الشبكات العصبونية الصناعية بأنها عبارة عن نظام لمعالجة المعلومات بشكل يشابه ويحاكي طريقة عمل الجملة العصبية البيولوجية عند الإنسان، لأنها تتّصف بنفس خصائصها التي تعتمد على فكرة تخزين المعلومات وتعلّمها والاستفادة منها لاحقاً.

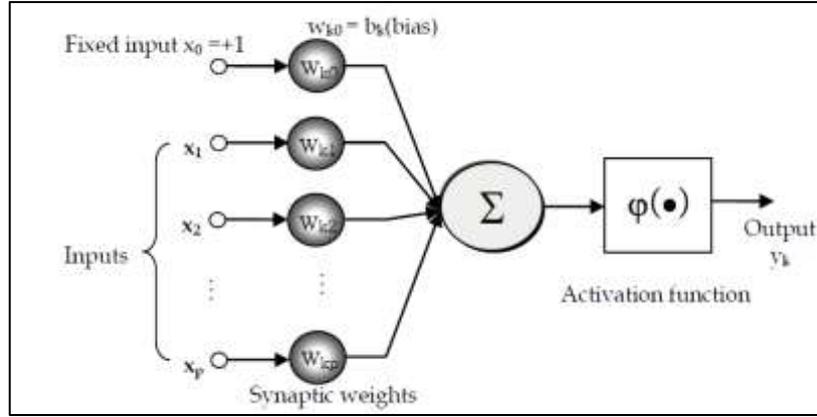
لقد زاد الاهتمام بالشبكات العصبونية الصناعية بسبب الخصائص المميزة لها مثل: القدرة الجيدة على التعميم، التعامل مع البيانات المفقودة أو العشوائية، وقدرتها أيضاً على تجاوز مُحدّدات الحلّ التقليدي. وتتميز الشبكة بخاصة التوازي (Parallelism) وهو أساس الشبكات العصبونية الصناعية، إذ إنّ كل العصبونات في الشبكة تعمل بتزامن، أي أنّ التوازي يمثّل قدرة الشبكات على معالجة البيانات بسرعة عالية جداً مهما كانت ضخامة تلك البيانات (Juwaied, 2018).

ويمكن للشبكات العصبونية الصناعية أن تُتيح لنفسها تعلّم الحالة غير الخطية (Non-Linear Behavior) أو أن تُتيح لنفسها تعلّم السلوك الديناميكي (Dynamic Behavior) من خلال المُعطيات المُقاسة. (Thibault, 1991)

### الخلية العصبونية الصناعية (Artificial Neural cell):

- صُمّمت الشبكات العصبونية الصناعية لتحاكي عمل الشبكات العصبية الطبيعية كما هو موضّح في الشكل (1) وفقاً لما يلي:
- تحدث عمليات المعالجة ضمن عدّة عناصر مُعالجة بسيطة (Process Element) تدعى العصبونات (Neurons).
- تُعبّر الإشارات الناتجة عن تفعيل العصبون إلى العصبون الآخر من خلال وصلة بينهما (Connection).
- لكلّ وصلة وزن مرتبط بها (Weight)، يُضرب بالإشارة المُرسلة عبر الوصلة.
- تجمع وحدات المعالجة المُدخلات الموزونة لتُشكّل مُدخلاً صافياً للعصبون (Net input).

- يُطبَّق العصبون على مُدخله الصافي دالة تفعيل (Activation Function) ليعطي قيمة وحيدة تُمثِّل خرج العصبون ليعاد انتشارها إلى العصبونات التالية.



الشكل (1): الخلية العصبونية الصناعية (Park, 2011).

ينقسم عمل الوحدة العصبونية الصناعية إلى مرحلتين رئيسيتين هما:

-المرحلة الأولى: تجري في هذه المرحلة معالجة المُدخلات بضرب كل مُدخل منفرد بوزن معين ( $W$ )، ثم تُجرى عملية جمع المُدخلات الموزونة، ويُضاف إليها عامل انحياز ( $b$ )، ويعبر عنها رياضياً بالمعادلة الآتية:

$$Net = \sum_{i=1}^q W \cdot P_i + b \quad (1)$$

حيث:

Net: ناتج المرحلة الأولى.

$P_i$ : المُدخلات.

$W$ : أوزان المُدخلات.

$b$ : عامل الانحياز (وهو بمثابة الحدّ الثابت من المعادلات الرياضية في كثيرات الحدود الذي يساعد في حلّ تلك المعادلة بصورة أسهل وأسرع).

$q$ : عدد المُدخلات.

-المرحلة الثانية: تتولى معالجة مُخرجات المرحلة السابقة باستخدام دوال رياضية تدعى بدوال التفعيل ( Activation Function) وفق المدى المُحدد لكلّ نوع من أنواع هذه الدوال لينتج عنها مُخرجات يُعبّر عنها بالمعادلة الآتية:

$$Output = f_{(Net)} = a \quad (2)$$

تُرتَّب العصبونات ضمن عدد من الطبقات كما هو موضَّح في الشكل (2) وهذه الطبقات هي:

1- طبقة الدخل: Input Layer

تتكون طبقة الدخل من مجموعة من الوحدات أو عناصر المُعالجة Nodes التي تعمل على توزيع القيم المُدخلة إليها من الوسط الخارجي إلى الطبقة الخفية التي تليها عبر الارتباطات الموجودة بينهما، فهي بذلك لا تقوم بأيّ عملية حسابية .

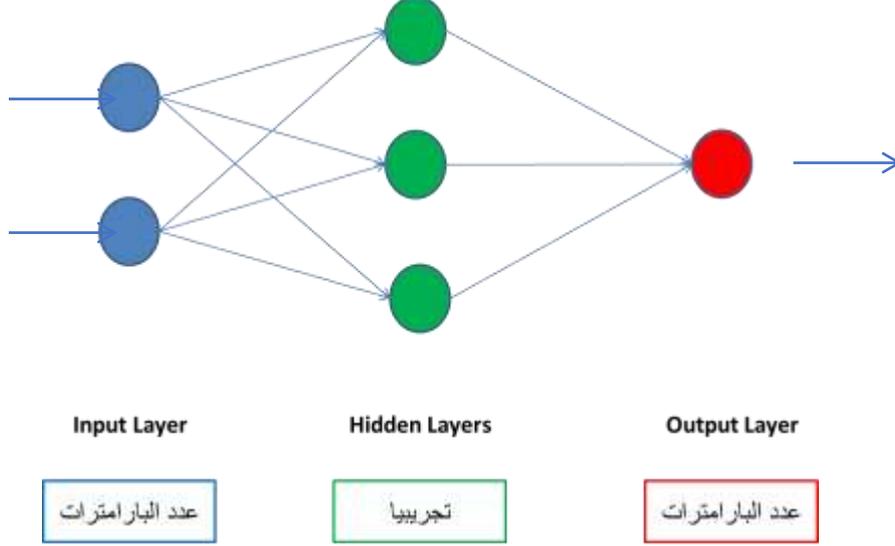
2- الطبقات الخفية: Hidden Layers

وهي مجموعة الطبقات التي تقع بين طبقتي الدخل والخرج، وتكون مُكوّنة من طبقة واحدة أو أكثر وذلك حسب حجم المشكلة وطبيعتها، وقد تبين أنّ (85%) من التطبيقات المُطورة تمّ فيها الاكتفاء بطبقة واحدة أو طبقتين.

إنّ عناصر أو وحدات المُعالجة الموجودة في هذه الطبقات هي التي تقوم بالعمليات الحسابية حيث تتلقى الإشارات من وحدات طبقة الدخل لتعالجها وتطبق تابع التنشيط على تلك الإشارات ثمّ تُحوّلها إلى الطبقة الخفية التالية أو إلى طبقة الخرج.

### 3- طبقة الخرج: Output Layer

وهي الطبقة النهائية التي تقع عند المخرج، حيث تقوم عناصر المُعالجة فيها باستلام الإشارات من الطبقة الخفية السابقة لتعالجها وتقوم بإجراء العمليات الحسابية بشكل مشابه تماماً للطبقات الخفية لتعطي بعد ذلك النتيجة النهائية للمشكلة.



الشكل: (2) شبكة عصبونية صناعية

يُحدّد عدد عصبونات الدخل والخرج تبعاً لأعداد مُدخلات ومُخرجات الشبكة، في حين يحدّد عدد عصبونات الطبقة الخفية تجريبياً، ويُدعى الإطار العام لمخطط الارتباط الداخلي بطوبولوجية الشبكة، وهو يُحدّد عدد الطبقات وعدد العصبونات في كل طبقة.

يعتمد هذا البحث آلية العمل باستخدام الحزمة البرمجية (MATLAB) بسبب أدائها العالي، وسرعتها في التنفيذ، فضلاً عن تضمينها دوال عدة للشبكات العصبونية الصناعية مع تطبيقاتها، وكذلك لقدرته على التعامل مع المصفوفات بسرعة وسهولة. حيث قمنا بإنشاء نماذج الشبكات العصبونية الصناعية في هذا البحث باستخدام الأداة NFTOOL التي يوفرها البرنامج والتي سهلت عملية معالجة البيانات الخاصة بهذه الدراسة.

وقد تم إنجاز البحث وفق مرحلتين أساسيتين:

- المرحلة الأولى (حالة مرجعية): تتضمن تجميع قاعدة بيانات حقلية ومخبرية لتحديد قدرة تحمل التربة لاستخدامها في مرحلة تدريب الشبكة العصبونية.
- المرحلة الثانية: تدريب الشبكة العصبونية للتنبؤ بقدرة تحمل التربة وفق نماذج مختلفة لهيكلية الشبكة عن طريق مكتبة (NFTOOL: Neural Network Fitting Tool) المتوفرة في برنامج (MATLAB) وهذه النماذج تشمل دراسة البارامترات الآتية (مدخلات الشبكة، نسبة تقسيم البيانات، عدد الطبقات الخفية، عدد العصبونات في الطبقة الخفية، وتابع التفعيل).

## النتائج والمناقشة:

### 1. جمع البيانات ومعالجتها:

في هذه الدراسة تم جمع البيانات المستخدمة لتدريب الشبكة العصبونية من مقالات موثقة والتي تتضمن بيانات تجارب صفائح التحميل. حيث تحتوي قاعدة البيانات هذه على 145 مجموعة بيانات لأساسات ذات أشكال مختلفة تم تطبيق الحملات عليها في طبقات تربة رملية مختلفة الخواص. يبين الجدول (1) القيم الإحصائية للبيانات المستخدمة.

الجدول (1): القيم الإحصائية للبيانات المستخدمة

البارامتر	Tan( $\theta$ )	L/B	b (m)	l (m)	$\theta$	$\gamma$ (kN/m <sup>3</sup> )	qult (kPa)
min	0.488	1.00	0.020	0.020	26.00	14.68	52.00
max	1.046	6.00	3.020	3.020	46.30	38.43	1800.00
average	0.792	2.05	0.567	0.690	38.21	16.88	454.36

### 2. بناء الشبكة العصبونية الصناعية:

#### 1.2. تأثير المدخلات وعدد العصبونات على تدريب الشبكة:

تم استخدام تابع السيغمويد لظل الزاوية (Tansig: Tan-Sigmoid Transfer Function) كتابع تفعيل للطبقة الخفية والتابع الخطي (Purelin: Linear Transfer Function) كتابع تفعيل لطبقة المخرجات. وبالنسبة للطبقة الخفية فقد جرى دراسة تغيير عدد عصبوناتها ما بين (1-50) وانتقاء عدد العصبونات الذي يحقق أقل متوسط مربع خطأ لكل نموذج. وتم تثبيت نسبة تقسيم البيانات لتكون 70% لتدريب البيانات و15% للمعايرة و15% للتحقق. حيث درست ثلاث نماذج من المدخلات في هذه الحالة بالاعتماد على أربع تراكيب من مدخلات الشبكة العصبونية الصناعية، يبين الجدول (2): نتائج النماذج لأفضل عدد عصبونات في الطبقة الخفية الموافقة لأفضل شكل ممكن من المدخلات.

الجدول (2): نتائج النماذج لأفضل عدد عصبونات في الطبقة الخفية الموافقة لأفضل شكل ممكن من المدخلات

Model	Inputs	عدد العصبونات (HN)	الوزن البدائي	DR:70-15-15	
				MSE	R
1	$\theta, \square, L, B$	32	21	0.00153	0.943
2	$\theta, \text{Tan}\square, L, B$	42	21	0.00199	0.93
3	$\theta, \text{Tan}\square, L/B$	34	21	0.00297	0.884

بناءً على ذلك سيتم اختيار النموذج الأول المكون من زاوية الاحتكاك الداخلي الفعالة والوزن الحجمي للتربة وطول وعرض الأساس ( $\square, \theta, B, L$ )، وإكمال دراسة هيكلية الشبكة.

## 2.2. تأثير نسبة التقسيم:

سندرس مدخلات النموذج الأول السابق (□, □, B, L) باستخدام نسبي تقسيم بيانات إضافية وهي على الترتيب: 80% لتدريب البيانات و 10% للمعايرة و 10% للتحقق أي (80-10-10)، ونسبة التقسيم الأخرى المدروسة 60% لتدريب البيانات و 20% للمعايرة و 20% للتحقق أي (60-20-20) إلى جانب نسبة التقسيم المدروسة سابقاً (70-15-15) والمقارنة بينهم. أما بالنسبة لعدد عصبونات الطبقة الخفية فقد تم دراستها كما في النموذج الأول أي ما بين (1-50) عصبون وانتقاء عدد العصبونات الذي يحقق أقل متوسط مربع خطأ.

يبين الجدول (3) نتائج النماذج لأفضل عدد عصبونات في الطبقة الخفية الموافقة لأفضل نسبة تقسيم.

الجدول (3) نتائج النماذج لأفضل عدد عصبونات في الطبقة الخفية الموافقة لأفضل نسبة تقسيم

Model	نسبة التقسيم	HN	الوزن البدائي	MSE	R
1	70-15-15	32	21	0.00153	0.943
2	80-10-10	33	21	0.00179	0.929
3	60-20-20	18	21	0.0028	0.886

حيث أنه من الملاحظ أن نسبة التقسيم الأولى والثانية أعطت أفضل قيم لمعامل الارتباط وأقل قيم لـ (MSE) ويمكن تفسير ذلك أن زيادة عدد بيانات التدريب يعطي نموذج أفضل، لذلك سنقوم باعتماد نسب التقسيم (70-15-15) و (80-10-10) عند دراسة تأثير تغيير تابع التفعيل على اختيارنا للنموذج الأفضل.

## 3.2. تأثير تغيير تابع التفعيل:

سوف نستبدل تابع سيغمويد لظل الزاوية المستخدم كتاب تفعيل للطبقة الخفية في كل النماذج التي ذكرت أعلاه، بتابع السيغمويد اللوغاريتمي (Logsig: Log-Sigmoid Transfer Function) والتابع الخطي (Purelin: Linear Transfer Function) كتاب تفعيل لطبقة المخرجات.

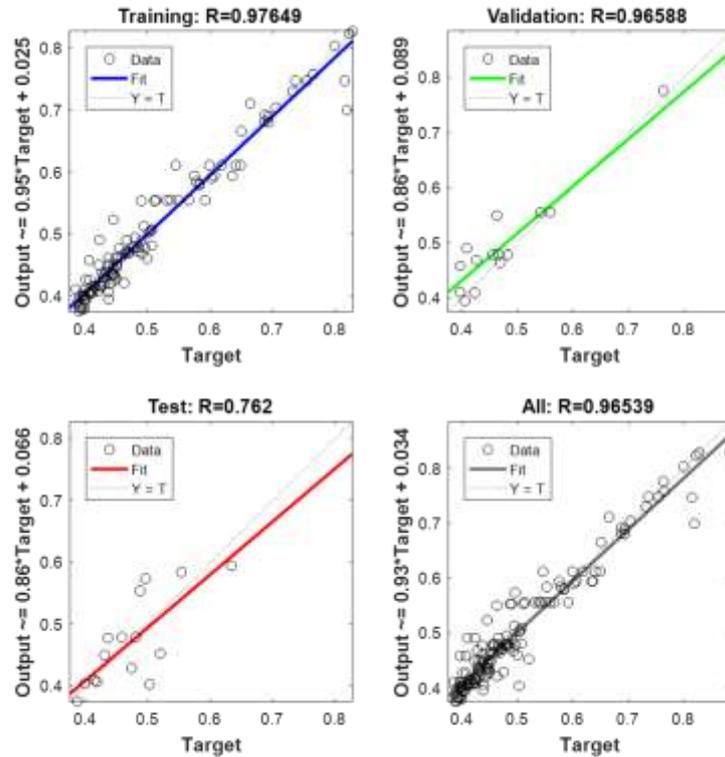
ويجب إعادة تدريب الشبكة من جديد عند تغيير تابع التفعيل واستخدام تابع سيغمويد اللوغاريتمي (Logsig: Log-Sigmoid Transfer Function)، لذلك تم اختيار النموذج الأول (□, □, B, L) وأعداد عصبونات من 1 إلى 50 عصبون، ونسبتي التقسيم (80-10-10) و (70-15-15)، وأوزان بدائية (1-50).

يبين الجدول (4) نتائج تطبيق تابع Logsig وتابع Tansig مع اختيار النموذج الأول للمدخلات ونسبتي التقسيم (80-10-10)(70-15-15)

الجدول (4): نتائج تطبيق تابع Logsig وتابع Tansig على النموذج الأول للمدخلات ونسبة التقسيم (70-15-15)، (80-10-10).

model	نسبة التقسيم	HN	الوزن البدائي	Logsig Function		Tansig Function	
				MSE	R	MSE	R
1	70-15-15	49	21	0.00205	0.918	0.001240	0.951
2	80-10-10	32	45	0.00138	0.945	0.000880	0.965

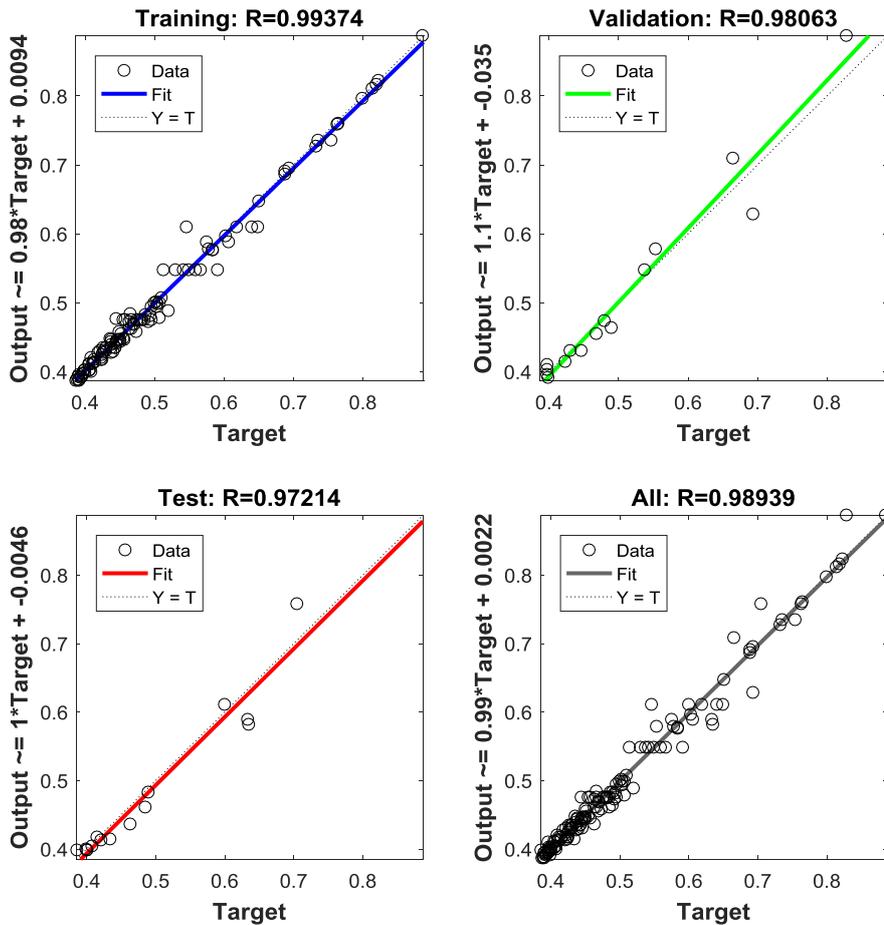
نلاحظ أنّ استخدام التابعين أعطى نتائج جيدة في التدريب ولكن تابع Tansig كان هو الأفضل حيث أعطى مع استخدام نسبة تقسيم (80-10-10) قيمة MSE مساوية للصفر تقريباً (0.00088).  
يبين الشكل (3) معاملات الارتباط بنسبة تقسيم (80-10-10) عند استخدام تابع سيغمويد لظل الزاوية.



الشكل (3): معاملات الارتباط بنسبة تقسيم (80-10-10)

#### 4.2. تأثير عدد الطبقات الخفية:

سندأ بدراسة تأثير استخدام طبقتين خفيتين بدلاً من طبقة خفية واحدة بالإضافة لطبقة المدخلات وطبقة المخرجات. تمّ استخدام تابع السيغمويد اللوغاريتمي (Logsig: Log-Sigmoid Transfer Function) كتابع تفعيل في الطبقتين الخفيتين ، والتابع الخطي (Purelin: Linear Transfer Function) كتابع تفعيل لطبقة المخرجات واختيار النموذج الأول (□, ⊞, B, L) ونسبة تقسيم (80-10-10)، ووزن بدائي 45.  
وباستخدام حلقة i,j لمعرفة عدد العصبونات الأفضل في الطبقتين تبين أن عدد العصبونات الأفضل في الطبقة الأولى هو 40 وفي الطبقة الثانية هو 5 حيث كانت قيمة (MSE = 0.000297) وقيمة معامل الارتباط الكلي R = 0.989. نلاحظ ارتفاع أداء الشبكة العصبونية عند استخدام طبقتين خفيتين حيث قل متوسط مربع الخطأ ليصبح صفر تقريباً، واقترب معامل الارتباط من 1.  
يبين الشكل (4) معاملات ارتباط التدريب والتحقق والاختبار والكلي بين القيم المتوقعة والقيم المقاسة باستخدام طبقتين خفيتين و نسبة تقسيم (80-10-10).



الشكل (4): معاملات الارتباط لأفضل نموذج باستخدام طبقتين خفيتين

إنّ زيادة عدد الطبقات الخفية عن طبقتين سينقلنا إلى مفهوم الشبكات العصبية العميقة **Deep Neural Network DNN**.

سنقوم بدراسة تأثير الشبكات العصبية العميقة مع عدد مختلف من الطبقات يصل إلى خمس طبقات على البيانات السابقة وتأثيرها على التدريب ثم سنقوم بحساب دقة التنبؤ للشبكات مختلفة الطبقات.

- تمّ تدريب شبكة مكونة من ثلاث طبقات خفية باستخدام تابع السيغمويد اللوغاريتمي (Logsig: Log-Sigmoid Transfer Function) كتابع تفعيل في الطبقات الخفية جميعها وتمّ استخدام التابع الخطي (Purelin: Linear Transfer Function) كتابع تفعيل لطبقة المخرجات وتطبيق نسبة تقسيم (80-10) والمدخلات الخاصة بالنموذج الأول ( $\square$ ,  $\boxplus$ , **B**, **L**) وتمّ تجريب عدد عصبونات مختلف واختيار النموذج الذي أعطى أقل قيمة لـ MSE وأفضل قيمة لـ R.

يبين الجدول (5) نتائج تدريب شبكة مكونة من ثلاث طبقات مع قيم R و MSE الموافقة لعدد مختلف من العصبونات في الطبقات الثلاثة حيث أظهرت النتائج أنّ عدد العصبونات (35,30,25) أعطى أفضل أداء.

الجدول(5): أداء نماذج الشبكة العصبونية لحالة ثلاث طبقات خفية

Inputs	model	عدد العصبونات في الطبقات HN	الوزن البدائي	DR:80-10-10	
				MSE	R
□,□,L,B	1	(37,32,30)	45	0.00264	0.922
	2	(35,30,25)	45	<b>0.00108</b>	<b>0.958</b>
نسبة التقسيم	3	(40,35,20)	45	0.00377	0.86
	4	(45,40,35)	45	0.0017	0.943
<b>80-10-10</b>	5	(30,25,20)	45	0.00176	0.861

ثم تم التدريب لحالة أربع طبقات خفية باستخدام تابع السيغمويد اللوغاريتمي (Logsig) كتابع تفعيل في الطبقات الخفية جميعها، والتابع الخطي (Purelin) كتابع تفعيل لطبقة المخرجات، وتطبيق نسبة تقسيم (80-10-10) والمدخلات الخاصة بالنموذج الأول (□, □, B, L). وتم تجريب عدد عصبونات مختلف واختيار النموذج الذي أعطى أقل قيمة لـ MSE وأفضل قيمة لـ R.

حيث يبين الجدول(6) نتائج تدريب شبكة مكونة من أربع طبقات مع قيم R و MSE الموافقة لعدد مختلف من العصبونات في الطبقات الأربعة .

الجدول(6): أداء نماذج الشبكة العصبونية لحالة أربع طبقات خفية

Inputs	model	عدد العصبونات في الطبقات الخفية HN	الوزن البدائي	DR:80-10-10	
				MSE	R
(□,□,L,B)	1	(45,35,30,25)	45	0.0021	0.917
	2	(39,34,29,24)	45	0.0039	0.838
	3	(35,30,25,20)	45	0.00424	0.825
	4	(50,45,40,35)	45	0.00785	0.668
	5	(40,36,32,28)	45	<b>0.00145</b>	<b>0.944</b>
	6	(60,55,50,45)	45	0.0033	0.865





الشكل (5): دقة التنبؤ الموافقة لعدد الطبقات الخفية المستخدم

### الاستنتاجات والتوصيات:

#### الاستنتاجات:

يمكن تلخيص أهم النتائج التي توصلت لها الدراسة:

1. تشكل النماذج التي تم التوصل إليها باستخدام الشبكات العصبونية أداة تنبؤ جيدة بقدرة تحمل التربة للأساسات السطحية في الترب المفككة، ويمكن من خلالها تقليل زمن وتكاليف التحريات الحقلية.
2. إنَّ زيادة عدد بيانات التدريب تحسّن من أداء نموذج الشبكة العصبونية الصناعية لذلك تكون نسبة تقسيم البيانات 80% للتدريب، و 10% للمعايرة، و 10% للاختبار هي الأفضل.
3. إنَّ استخدام مدخلات الشبكة العصبونية المكونة من طول وعرض الأساس وزاوية الاحتكاك الداخلي للتربة والوزن الحجمي للتربة يعطي نتائج أفضل من استخدام النسبة البعدية L/B أو استخدام ظل الزاوية  $\tan(\square)$ .
5. إنَّ استخدام تابع النفعيل سيغمويد لظل الزاوية يعطي نتائج أفضل عند تدريب شبكة مؤلفة من طبقة خفية واحدة، بينما استخدام تابع سيغمويد اللوغاريتمي لتنشيط الخلايا العصبية في حال الشبكات العميقة يعطي نتائج أفضل.
6. إنَّ استخدام الشبكات العصبية العميقة (DNNs) يؤدي إلى ارتفاع أداء الشبكة العصبونية عن نماذج الشبكات العصبونية الضحلة (ANNs) وفي هذه النماذج كان الفارق لا يتجاوز 1%.

#### التوصيات:

1. من الضروري إنشاء قاعدة بيانات تتضمن كافة المعلومات المتعلقة بقدرة تحمل التربة للاستفادة منها لاحقاً في تطوير موديلات شبكات عصبونية صناعية أكثر دقة، ويجب الحرص على أن تكون هذه البيانات موثقة بشكل جيد وغير مشوبة بالأخطاء لتقليل الأخطاء إلى حدودها الدنيا.
2. يمكن تطوير نماذج للشبكة العصبية من خلال دراسة عوامل إضافية مثل تأثير منسوب المياه الجوفية ووجود ترب متماسكة أسفل الأساس.
3. يمكن استخدام نظام هجين من الشبكات العصبونية والخوارزميات الجينية في نمذجة قدرة تحمل التربة.

**References:**

1. Bagińska, M., & Srokosz, P. E. (2019). *The Optimal ANN Model for Predicting Bearing Capacity of Shallow Foundations trained on Scarce Data*. *KSCE Journal of Civil Engineering*, 23(1), 130–137.
2. Ghavami, M., Tamizdoust, M. M., & Ghasemi-Fare, O. (2019). *Determination of allowable bearing capacity of shallow foundation using modified hyperbolic stress-strain model*. *Journal of Applied Geophysics*, 166, 1–9.
3. Hornik, K. (1991). *Approximation Capabilities of Multilayer Feedforward Networks*. In *Neural Networks* (Vol. 4).
4. İkizler, S. B., Aytikin, M., Vekli, M., & Kocabaş, F. (2010). *Prediction of swelling pressures of expansive soils using artificial neural networks*. *Advances in Engineering Software*, 41(4), 647–655.
5. Juwaied, N. S. (2018). *APPLICATIONS OF ARTIFICIAL INTELLIGENCE IN GEOTECHNICAL ENGINEERING*.
6. Khudier, A. S. (2018). Article ID: IJCIET\_09\_04\_096 Cite this Article: Ahmed Sagban Khudier, *Prediction Of Bearing Capacity For Soils in Basrah City Using Artificial Neural Network (ANN) and Multi-Linear Regression (MLR) Models*. In *International Journal of Civil Engineering and Technology* (Vol. 9, Issue 4).
7. Nazir, R., Momeni, E., Marsono, K., & Maizir, H. (2015). *Jurnal Teknologi An Artificial Neural Network Approach for Prediction of Bearing Capacity of Spread Foundations in Sand*.
8. Park, H. il. (2011). *Study for Application of Artificial Neural Networks in Geotechnical Problems*.
9. Raj, D., & Bharathi, M. (2013). *BEARING CAPACITY OF SHALLOW FOUNDATION ON SLOPE: A REVIEW Bearing Capacity of Shallow Foundation on Slope*.
10. Soleimanbeigi, A., & Hataf, N. (2005). *Predicting ultimate bearing capacity of shallow foundations on reinforced cohesionless soils using artificial neural networks*.
11. Thibault, J. (1991). *Feedforward Neural Networks for the Identification of Dynamic Processes*. *Chemical Engineering Communications*, 105(1), 109-128.