

تحليل باستخدام الشبكات العصبونية الاصطناعية للهبوط السطحي الأعظمي أعلى الأنفاق المنفذة بالطريقة النمساوية الحديثة

د. ريم بوبو¹

ملخص

يتناول هذا البحث دراسة هبوط سطح الأرض الناتج عن تنفيذ الأنفاق قليلة العمق بالطرق التقليدية التي تتطلب حفر وتدعيم النفق على مراحل متتالية. تضمنت الدراسات المرجعية اقتراح العديد من العلاقات التجريبية لحساب قيمة الهبوط السطحي الأعظمي أعلى الأنفاق اعتماداً على خصائص الوسط المحفور بالإضافة لبعض الخصائص الجيومترية مثل قطر النفق وسماكة طبقة التغطية أعلاه. بالرغم من أهمية طريقة تنفيذ النفق وما يمكن أن تلعبه من دور في حدوث الهبوطات إلا أنها لم تؤخذ بعين الاعتبار بشكل واضح في الأبحاث السابقة عند حساب قيمة الهبوط أعلى النفق. يقترح هذا البحث دراسة العلاقة بين الهبوط السطحي الأعظمي أعلى النفق وقيمة التشوه القطري convergence الناتج في محيط حفرة النفق أثناء تنفيذه بالطريقة النمساوية الحديثة. حيث يتناول البحث دراسة دور سماكة طبقة التغطية أعلى النفق في تخامد التشوهات الناتجة عن أعمال الحفر وعلاقتها بقيمة الهبوط السطحي الأعظمي. تضمنت الدراسة تحليل معطيات عدد هام من الحالات المرجعية باستخدام منهجية معتمدة على توظيف الشبكات العصبونية الاصطناعية للتنبؤ بقيمة الهبوط السطحي الأعظمي أعلى النفق.

كلمات مفتاحية: هبوط، أنفاق، الطريقة النمساوية الحديثة، تشوه قطري، شبكات عصبونية اصطناعية.

1. أستاذ مساعد - قسم الجيوتكنيك - كلية الهندسة المدنية - جامعة حمص.

ANN analysis of maximum surface settlement above NATM tunnels.

Abstract

This research contains a study of the ground surface settlement resulting from shallow tunnels construction using traditional methods that require tunnel excavation and support in successive steps. Many previous studies have addressed the issue of the maximum settlement above tunnels, where many experimental relationships have been proposed to calculate the value of the maximum settlement, taking into account the characteristics of the excavated ground in addition to some geometric parameters such as the tunnel diameter and its cover thickness. Despite the importance of the tunnel excavation method and the role it plays in causing settlements, it was not clearly taken into account when calculating the value of the settlement above tunnels. This research proposes to study the relationship between the maximum surface settlement and the tunnel convergence. The research studies the role of the cover thickness above the tunnel in depreciation the deformations resulting from excavation works and its relationship to the maximum surface settlement. The study included analyzing the data of a large number of reference cases using a methodology based on artificial neural networks to predict the value of the maximum settlement above the tunnel.

Keywords: Settlement, tunnel, NATM, convergence, ANN.

مقدمة

يتسبب حفر وتنفيذ الأنفاق بتشوهات تبدأ في محيط حفرة النفق وتنتقل عبر الطبقات المحيطة وقد تصل لسطح الأرض الطبيعية وذلك تبعاً لعمق النفق وللطريقة المعتمدة لحفره وتدعيمه. يتضمن تنفيذ الانفاق بالطرق التقليدية ومنها الطريقة النمساوية الحديثة NATM [1] العمل على مراحل متتالية حيث يتم التقدم بخطوة حفر معينة ومن ثم التوقف لتنفيذ تدعيم مؤقت للجزء المحفور. يترافق تسلسل هذه المراحل مع نشوء تشوهات مرتبطة بأسباب عديدة منها تفريغ كتلة التربة المحفورة في واجهة الحفر، التأخير في تنفيذ التدعيم المؤقت أو بسبب تشوه التدعيم المنفذ أو عدم كفايته. إن هذه التشوهات من الأهمية بحيث يجب ألا تهمل عند دراسة وتقدير قيم الهبوط السطحي أعلى الأنفاق كونه مرتبط بتكنولوجيا تنفيذ النفق التقليدية التي لا تضمن التدعيم الكافي الذي تؤمنه الطرق الأخرى كالآلات الدرعية على سبيل المثال.

أهمية وأهداف البحث


تتجلى أهمية هذا البحث في دراسة هبوط سطح الأرض الأعظمي الناتج أعلى الأنفاق المنفذة بالطريقة التقليدية NATM والذي يؤثر على الأبنية والمنشآت المجاورة وبالتالي يعتبر تقديره والتنبؤ به أمراً بالغ الأهمية.

تهدف هذه الدراسة لتحليل العوامل المؤثرة على الهبوط السطحي الأعظمي وبشكل خاص دور التشوهات الناشئة في محيط حفرة النفق Convergence والعلاقة المشتركة مع قطر النفق وسماكة التغطية أعلاه. إذ أن الدراسات التجريبية والتحليلية لم تأخذ هذه التشوهات بعين الاعتبار في العلاقات المقترحة لحساب الهبوط الأعظمي أعلى الأنفاق. كذلك يهدف البحث لدراسة تأثير خصائص الوسط المحفور على قيم الهبوط المدروس وذلك من خلال توظيف منهجية معتمدة على الشبكات العصبونية الاصطناعية.

هبوط سطح الأرض أعلى حفريات الأنفاق

تناول العديد من الأبحاث السابقة دراسة هبوط سطح الأرض أعلى حفريات الأنفاق، حيث استخدمت الطرق التجريبية [2,3,4] لدراسة هذه الهبوطات بشكل واسع جداً في حين اعتمد البعض الطرق التحليلية [5, 6,7] أو الرقمية [8, 9,10]. اعتمدت الطرق التجريبية على معالجة البيانات التي تم الحصول عليها من الملاحظات الحقلية وبرامج المراقبة المعتمدة للعديد من الأنفاق المنفذة بالطرق التقليدية [11, 12, 13].

اتفق في معظم الدراسات على أن هبوط سطح الأرض يأخذ شكل حوض يعبر عنه في مقطع عرضي على محور النفق بمنحني غوسي يسمى حوض الهبوط [2] Settlement Trough يأخذ قيمته الأعظمية S_{max} أعلى محور النفق كما يبين الشكل 1:



الشكل 1: حوض الهبوط السطحي في مقطع عرضي على النفق [14].

اقترح Peck [2] المعادلات التالية المستخدمة لتمثيل حوض الهبوط أعلى الأنفاق السطحية:

$$S(x) = S_{max} \cdot \exp\left(\frac{-x^2}{2i^2}\right) \quad (1)$$

$$S_{max} = \frac{V_s}{\sqrt{2\pi} \cdot i} \quad (2)$$

$$V_s = V_L * \pi D^2 / 4 \quad (3)$$

حيث أن:

$S(x)$: الهبوط في نقطة تبعد مسافة x عن محور النفق الشاقولي (محور تناظر حوض الهبوط)، S_{max} : الهبوط الأعظمي أعلى مستوي محور النفق، i : احداثي نقطة الانعطاف لمنحني حوض الهبوط، V_s : حجم حوض الهبوط في متر طولي، V_L : فاقد الحجم في محيط النفق Volume Loss، D : قطر النفق.

بالاعتماد على الفرضيات الأساسية التي وضعها Peck [2] تم اقتراح العديد من العلاقات التجريبية لحساب قيمتي كلاً من i ، S_{max} حيث اقترح O'Reilly and New [11] علاقة مبسطة لحساب قيمة i لاقت قبولاً واسعاً وهي:

$$i = k * Z \quad (4)$$

حيث أن Z هو عمق محور النفق، k : ثابت تتراوح قيمته 0.2-0.3 في حالة الأنفاق السطحية المنفذة في الترب المفككة ويأخذ القيمة 0.4-0.7 في حالة الترب الغضارية أو السلتنية الناعمة. يوضح الجدول 1 المزيد من العلاقات التجريبية التي اقترحت من قبل باحثين آخرين لحساب قيمة الهبوط السطحي الأعظمي S_{max} أعلى النفق:

الجدول 1: علاقات تجريبية اقترحت لحساب الهبوط السطحي الأعظمي أعلى الأنفاق.

المرجع	العلاقة المقترحة
Sagasetta [15]	$S_{max} = \frac{\gamma D^2}{E} (0.85 - \nu)$
Farmer [16]	$S_{max} = \frac{D}{1000} \left(\frac{kD}{H} \right)^{\frac{1}{n}}$
Poupelloz [3]	$S_{max} = \frac{R}{1000} \left(\frac{AD}{H} \right)^{\frac{1}{n}}$
Herzog [17]	$S_{max} = 0.785(\gamma z + \sigma_s) \left(\frac{D^2}{i.E} \right)$
Chakeri and Ünver [18]	$S_{max} = 398.744 \left(\frac{D}{Z} \right) \times \left[\left(\frac{\gamma z + \sigma_s - (c + 0.3\sigma_T)}{E} \right) (1 - \nu) (1 - \sin\phi) \right]^{0.8361}$

تحليل باستخدام الشبكات العصبونية الاصطناعية للهبوط السطحي الأعظمي أعلى الأنفاق المنفذة بالطريقة النمساوية الحديثة

Mair <i>et al.</i> [19]	$S_{max} = 0.313 \left(\frac{V_L * D^2}{i} \right)$
Wang <i>et al.</i> [20]	$S_{max} = 384 V_L / 105 \pi R$

كما يبين الجدول السابق اعتمدت علاقات Farmer, Poupellouz على استخدام ثوابت تجريبية A, k, n تأخذ قيمتها بحسب نوع التربة المحفورة إلا أنه لم تعطى أي قيمة تتناسب تنفيذ الأنفاق في الأوساط الصخرية. يمكن اعتبار العلاقة المقترحة من قبل Sagaseta أبسط وأشمل هذه العلاقات إلا أنها لم تأخذ بعين الاعتبار سماكة التغطية أعلى النفق وهو عامل لا يمكن إهماله. في حين اعتمد Peck على حجم حوض الهبوط أعلى النفق وهو قيمة تتأثر بطريقة تنفيذ النفق وبظروف الوسط المحفور.

نلاحظ أيضاً أن بعض العلاقات السابقة أخذت بعين الاعتبار قيم الهبوط في قمة النفق المحفور والمسماة فاقد الحجم (VL) Volume loss أما حجم حوض الهبوط أو حجم الهبوط على سطح الأرض Vs غالباً ما اعتبر أنه يساوي قيمة VL وهو تقريب غير واقعي يهمل تخامد التشوهات الحاصل في الطبقات التي تعلو النفق في حال سماكات التغطية الكبيرة أعلى النفق.

لقد لاقت العلاقات التجريبية رواجاً واسعاً نظراً لبساطة المعادلات المقترحة التي تقدم تقديراً سريعاً لقيم الهبوط المتوقع بشكل تقريبي. بالرغم من ذلك فإن دقة العلاقات التجريبية محدودة في الحالات الجيولوجية المعقدة حيث أن غالبية العلاقات التجريبية بنيت على اعتبارات تجانس الوسط المحفور واعتبرت حالات محددة لطريقة تنفيذ النفق وخصائص الوسط المحفور والتي يصعب تعميمها في حالات أخرى. إن معظم العلاقات التجريبية تعتبر صالحة في حالات تنفيذ الأنفاق في الأوساط الترابية وبصعب تطبيقها في الأوساط الصخرية. ولهذا فإن الاعتماد على الطرق التجريبية لوحدها لدراسة هبوطات سطح الأرض أعلى الأنفاق لا يمكن اعتباره كافياً في الظروف المعقدة التي تتطلب دقة عالية.

قدمت الطرق التحليلية والرقمية نموذجاً أكثر شمولية مبني على معادلات رياضية دقيقة معتمدة على قوانين سلوك الأوساط الصلبة ولكن الأمر يتطلب استخدام الكثير من الفرضيات

لتبسيط المسألة المطروحة للدراسة ومنها فرضيات السلوك الخطي وفرضيات الأوساط المستمرة المتجانسة متماثلة الخواص وغيرها.

في حين تقدم طرق الذكاء الصناعي وسيلة جديدة تساعد في حل المسائل المعقدة بتقنيات عديدة متطورة أهم ما يميزها المقدرة على استيعاب كمية ضخمة من البيانات ومعالجة عدد كبير من بارامترات الدراسة مع إمكانية تمثيل عدم التجانس أو العلاقات اللاخطية المعقدة. يعود ذلك إلى المبدأ الأساسي وهو التعلم بالتدريب باستخدام تطبيقات عديدة منها: الشبكات العصبونية الاصطناعية ANN [21, 41]، شعاع الدعم الآلي SVM [22]، أشجار اتخاذ القرار (DTs) [23]، تحليل الانحدار غير الخطي (MARS) [24]، نظام الاستدلال العصبوني الضبابي المكيف ANFIS [42] وغيرها.

وظفت الشبكات العصبونية الاصطناعية بشكل واسع لدراسة الهبوط الناتج عن تنفيذ الأنفاق وبرهنت مهارة عالية في التنبؤ بقيم الهبوط وفي تحليل العوامل المؤثرة عليه [25]. إن معظم الأبحاث التي وظفت الشبكات العصبونية لدراسة الهبوط تناولت حالات أنفاق منفذة بالآلات الدرية حيث ركزت بشكل أساسي على تحليل تأثير عوامل تشغيل الآلات الدرية على قيم الهبوط. في حين نجد عدد أقل من الدراسات تناول موضوع الأنفاق المنفذة بالطرق التقليدية وذلك يعود لعدة أسباب منها عدم توفر كم كافي من المعطيات كتلك التي تسجلها أجهزة التحكم في الآلات الدرية بشكل اوتوماتيكي أثناء تقدمها [21]، والسبب الثاني يرتبط بظروف تنفيذ الأنفاق بالطرق التقليدية التي لا تتصف باستمرارية وانتظام طريقة الحفر والتدعيم في ظل العوامل الكثيرة التي يمكن أن تتدخل وتؤثر على قيم الهبوط. وظف Bizjak and Petkovšek [26] الشبكات العصبونية الاصطناعية لدراسة نفق Golovec المنفذ بالطريقة النمساوية الحديثة ووجد أن العامل الأكثر تأثيراً على هبوط سطح الأرض هو معامل الزمن المرتبط بتدعيم النفق بالإضافة لصلابة طبقة التدعيم المؤقتة.

درس Kim *et al.* [27] نفق Seoul المنفذ بالطريقة التقليدية بالاعتماد على الشبكات العصبونية الاصطناعية حيث تضمنت الدراسة 19 عاملاً شكلت مداخل الشبكة العصبونية. بالاعتماد على شبكة مؤلفة من ثلاث طبقات مخفية تم دراسة عاملين هما هبوط سطح

الأرض الأعظمي وقيمة المعامل i (أحداثي نقطة انعطاف حوض الهبوط) حيث تم التوصل إلى أن أهم العوامل المؤثرة على الهبوط السطحي أعلى النفق هي: عمق النفق، ارتفاع حفرة النفق، منسوب المياه الجوفية، نوعية الصخور المحفورة وسرعة تقدم الحفر. وجد *Leu et al.* [28] مستخدماً الشبكات العصبونية أن العوامل المرتبطة بطريقة تنفيذ النفق هي العوامل الأساسية التي تتحكم في استقرار نفق منفذ بالطريقة التقليدية في وسط صخري متوسط المقاومة في تايوان.

كما أعطت الشبكات العصبونية الاصطناعية نتائج جيدة لدى تحليل الهبوطات الناتجة عن تنفيذ الأنفاق المزدوجة Twin tunnels في الدراسة التي أجريت على معطيات نفق Shiraz في إيران [29].

استخدم *Adoko et al.* [30] الشبكات العصبونية بنجاح للتنبؤ بقيمة التشوهات القطرية convergence في محيط نفق Daguan المنفذ بالطريقة النمساوية الحديثة حيث استخدمت خصائص الوسط الصخري المحفور والخصائص الجيومترية للنفق واقترح الباحث إضافة عامل الزمن لمدخلات للشبكة باعتباره عنصر هام عند التنفيذ بالطريقة النمساوية الحديثة.

وجد *Satici and Topal* [23] أن سماكة التغطية أعلى النفق تعتبر من أهم العوامل المؤثرة في نشوء التشوهات في محيط النفق وذلك مقارنةً بخصائص الوسط المحفور c, φ, E وخصائص الفواصل متمثلة بقيمتي RMR, Q ، حيث وظف الشبكات العصبونية الاصطناعية للتنبؤ بقيمة التشوهات القطرية convergence في محيط مجموعة من الأنفاق المنفذة بالطريقة النمساوية الحديثة.

أجرى *Mohammadi et al.* [31] دراسة مقارنة بين الطرق التجريبية والاحصائية (تحليل الانحدار) وطريقة الشبكات العصبونية لتقييم الهبوط أعلى نفق Niayesh المنفذ بالطريقة النمساوية الحديثة. بالاعتماد على خصائص الوسط المحفور (c, φ, γ, E) كمدخلات في الدراسة وجد أن الشبكات العصبونية أعطت أفضل تقييم للهبوط السطحي أعلى النفق ووجد أن الوزن الحجمي للتربة هو أقل العوامل تأثيراً على الهبوط السطحي أعلى النفق.

وجد *Mahmoodzadeha et al.* [32] في دراسة مقارنة لسبع طرق مختلفة من طرق الذكاء الصناعي أن الشبكات العصبونية الاصطناعية كانت أفضل هذه الطرق في التنبؤ بقيم الهبوط السطحي الأعظمي وذلك بتحليل معطيات 300 نقطة قياس في ثمانية أنفاق في إيران.

قام *Shi et al.* [33] بتتبع هبوط سطح الأرض مع تقدم الحفر لنفق Brasili (6.5km) المنفذ بالطريقة NATM وذلك في مقطع طولاني حيث تم توظيف معطيات 600m الأولى من النفق من أجل تدريب الشبكة التي تم اختبارها باستخدام معطيات 500m الأخيرة من النفق.

أكدت معظم الدراسات التي وظفت الشبكات العصبونية الاصطناعية في مجال دراسة الأنفاق مقدرتها العالية على التنبؤ بالرغم من تنوع وعدم تجانس العوامل المدروسة في بعض الحالات، سواء باعتبار العوامل المتعلقة بالخصائص الجيولوجية أو الجيومترية، العوامل المتعلقة بتكنولوجيا التنفيذ والتدعيم أو العوامل المرتبطة بالزمن التي يصعب أخذها بين الاعتبار بالطرق التقليدية. بجميع الأحوال تتوقف دقة التنبؤ باستخدام الشبكات العصبونية الاصطناعية على نوعية وحجم البيانات التي توظف لتدريب الشبكة.


التنبؤ باستخدام الشبكات العصبونية الاصطناعية

تمثل الشبكات العصبونية الاصطناعية أحد تقنيات الذكاء الاصطناعي (AI) الذي يحاكي آلية عمل الخلايا العصبية في العقل البشري [34]. تتكون الشبكة العصبونية من مجموعة مركبة من عناصر معالجة مترابطة وموضوعة في بنية متعددة الطبقات تتألف من 3 مكونات أساسية: طبقة إدخال Input layer، وطبقة مخفية hidden layer لمعالجة البيانات، وطبقة إخراج Output layer لإظهار المتغيرات التي قامت الشبكة بحسابها، حيث يمكن أن تتعدد كل طبقة منهم وفقاً لمدى تعقيد الشبكة.

تتضمن الخطوات الأساسية لتصميم شبكة عصبونية: تحديد متغيرات الدخل والخرج بحسب المسألة المطروحة للدراسة، تحديد بنية الشبكة، تنفيذ مرحلة تدريب الشبكة العصبونية وفي النهاية تعميم الموديل المستخدم من قبل الشبكة من أجل معالجة معطيات جديدة.


توجد أنواع مختلفة من الشبكات العصبونية الاصطناعية وحيدة أو متعددة الطبقات، ذات التغذية الأمامية أو الخلفية تنافسية أو متكررة وغيرها [35].

تتألف بنية الشبكة العصبونية الاصطناعية من العديد من العصبونات المرتبة في تعاقب من الطبقات. العصبون هو نموذج رياضي بسيط يستقبل العديد من المدخلات ليجمعها على شكل قيمة واحدة هي المخرج كما يبين الشكل 2 بنية Perceptron بسيط ينقل المعلومات في اتجاه واحد feedforward:



الشكل 2: بنية Perceptron بسيط مع تابع تجميع (Σ) وتابع تحويل (f).

تم تطوير بنى أكثر تعقيداً مؤلفة من شبكات متعددة الطبقات MLP [36] حيث ترتبط العصبونات بطريقة تجعل كل عصبون في طبقة معينة مرتبط كلياً بعصبونات الطبقة التالية
شكل:



الشكل 3: بنية شبكة عصبونية متعددة الطبقات MLP.

تعتبر الشبكات ذات المستقبلات متعددة الطبقات (MLP) Multilayer Perceptrons من أهم أنواع الشبكات العصبونية وأكثرها انتشاراً، فهي تستطيع تحليل العلاقات الخطية واللاخطية بين البيانات بالاعتماد على مبدأ الانتشار العكسي Backpropagation. وهي شبكات عصبية ذات تغذية أمامية، مما يعني أن المعلومات تتدفق في اتجاه واحد من طبقة الإدخال إلى طبقة الإخراج، كما يمكن زيادة عدد الطبقة المخفية لجعل النموذج أكثر دقة وتعقيداً وفقاً للمهمة المطلوب إنجازها.

يعتمد مبدأ عمل الشبكات العصبونية الاصطناعية على استخدام تابعين (شكل 2) حيث يتم تجميع المدخلات العديدة x_j لكل عصبون (باستخدام تابع تجميع) في قيمة وحيدة يتم معالجتها لاحقاً باستخدام تابع تحويل من أجل الحصول على مخرج العصبون. إن تابع التجميع الأكثر استخداماً هو تابع المجموع المثلث للمدخلات x_j مع استخدام الأوزان w_j التي يضاف إليها قيمة ثابتة w_0 وبالتالي يعطى المخرج المرتبط بالمدخل x_j بالعلاقة التالية:


$$w_0 + \sum_{j=1}^m w_j x_j \quad (5)$$

حيث أن m هو عدد المدخلات.



أما توابع التحويل الأكثر استخداماً فهي كما يبين الجدول 2: التابع السيني Sigmoid function، التابع الخطي Linear function، تابع الظل Tangent function حيث يمكن أن يكون تابع التحويل مختلفاً من طبقة لأخرى [37].

الجدول 2: توابع التحويل المستخدمة في الشبكات العصبونية ضمن بيئة برنامج

.Matlab

الصيغة الرياضية	الرسم البياني	اسم التابع
$f(x) = x$		التابع الخطي (Linear) Purelin


تحليل باستخدام الشبكات العصبونية الاصطناعية للهبوط السطحي الأعظمي أعلى الأنفاق المنفذة
بالطريقة النمساوية الحديثة

التابع السيجموئيد المنطقي Logistic Sigmoid Logsig		$f(x) = \frac{1}{1 + e^{-x}}$
تابع الظل القطعي Hyperbolic Tangent Sigmoid Tansig		$f(x) = \frac{2}{1 + e^{-2x}} - 1$

من أجل تحديد بنية شبكة عصبونية يجب تحديد عدد الطبقات المخفية، عدد العصبونات في كل طبقة ونوع توابع التحويل المستخدمة [35], [38]. يحدد عدد مداخل ومخارج الشبكة حسب المسألة المدروسة حيث أن متغيرات المسألة تشكل مداخل الشبكة والمخرج هو المتغير المطلوب حسابه من قبل الشبكة. أما عدد الطبقات المخفية فهو عشوائي يحدد بالتجريب وهو مرتبط بدرجة تعقيد المسألة التي يتم معالجتها وبنوعية معطياتها. يؤثر عدد العصبونات في الطبقة المخفية على النتائج كونه يؤثر على مقدرة الشبكة على تعميم المعلومات التي تعلمتها في مرحلة التدريب [39].

يلي مرحلة بناء الشبكة مرحلة تدريب تتضمن البحث عن التوزيع الأفضل لأوزان التنقيط لمداخلات الشبكة حيث تتجلى أهمية هذه المرحلة في مقدرة الشبكة - باستخدام أمثلة معينة - على معالجة أمثلة مشابهة ولكن مختلفة عن أمثلة التدريب. إن التعلم هو أحد الميزات الأساسية للشبكات العصبونية الاصطناعية ويمكن القيام به بطريقتين: التعلم الموجه أو غير الموجه.


يعتبر التعلم الموجه هو الأكثر استخداماً في مسائل التنبؤ التقليدية حيث تتدرب الشبكة في هذا النوع من التعلم من خلال مقارنة النتائج التي قامت بحسابها مع القيم الأصلية للمخرج (المحدد للشبكة ضمن معطيات التدريب). تستمر الشبكة في تعديل الأوزان والتحديث حتى تجد المخرج المطلوب حيث يسمى هذا التدريب بالتدريب عبر الأمثلة. تستخدم الشبكة من أجل القيام بالتعلم في هذه الحالة قاعدة الانتشار الخلفي Backpropagation من أجل تهيئة الشبكة [34].



الشكل 4: مبدأ قاعدة الانتشار الخلفي Backpropagation في التعلم.

تعتمد قاعدة الانتشار الخلفي أو العكسي على تعديل أوزان العصبونات من خلال تحديد الفرق e_i بين القيم المحسوبة والقيم الأصلية (المعطاة في بيانات التدريب) لمخرج الشبكة i ذو الوزن w_i . يتم تقليل قيمة تابع أداء $F(w)$ المعتمد على قيمة e_i . بالانطلاق من قيمة أولية w_0 يجب الوصول أو الاقتراب من قيمة أصغرية للتابع $F(w)$ حيث تعطى القيمة w_{i+1} للقيمة التي تلي w_i وفق العلاقة التالية:

$$w_{i+1} = w_i + \Delta w_i \quad \text{where} \quad \Delta w_i = \varepsilon_i \cdot g_i \quad (6)$$



الشكل 5: التعلم عن طريق البحث عن قيمة أصغرية لتابع الأداء gradient descent method.

حيث أن ε_i هو الخطوة learning rate و g_i هو الاتجاه الذي يتم البحث وفقه عن القيمة الأصغرية. يكون الهدف في هذه الحالة إيجاد قيم ε_i و g_i بحيث تكون قيمة $F(w_{i+1})$ أقل من قيمة $F(w_i)$ وبالتالي:

$$w_{i+1} = w_i - \varepsilon_i \dot{F}(w_i) \quad (7)$$

تتوصل الشبكة في نهاية هذه المرحلة إلى حساب قيم المخرج الأقرب للقيم المطلوب حسابها.

في النهاية لا بد أن نذكر معيار هام وهو اختيار المعطيات المستخدمة في كل من مرحلتي التدريب وتفعيل الشبكة. يجب أن تكون معطيات التدريب متجانسة ومعبرة عن كل النماذج التي يمكن مصادفتها في مرحلتي عمل الشبكة، حيث يجب أن تكون الخصائص الإحصائية (الانحراف المعياري على سبيل المثال) متشابهة لكل من معطيات التدريب والتفعيل المستخدمة في الشبكة من أجل ضمان الأداء الجيد للشبكة [40].

النتبؤ بالهبوط السطحي الأعظمي أعلى حفريات الأنفاق

تم توظيف الشبكة العصبونية للنتبؤ بقيمة الهبوط الأعظمي S_{max} أعلى الأنفاق السطحية المنفذة بالطريقة التقليدية NATM آخذين بعين الاعتبار خصائص الوسط المحفور والخصائص الجيومترية للنفق المدروس.

نفذت الدراسة باستخدام تطبيق NNtool (Neural Network Tool) الموجودة في بيئة MATLAB R2017a.

تضمنت المرحلة الأولى من العمل بناء قاعدة البيانات المتضمنة نتائج القياسات الحقلية لمجموعة من الأنفاق المذكورة في الدراسات المرجعية. تم جمع بيانات 70 حالة لأنفاق سطحية منفذة ضمن أوساط صخرية متوسطة المقاومة تحت سماكات تغطية تتراوح بين 2.5D-5D. تضمنت بيانات الأنفاق المدروسة قيم الخصائص الجيوتكنيكية للوسط المحفور، سماكة التغطية أعلى النفق وقطر النفق في كل حالة، بالإضافة لقيم القياسات الحقلية لكل من الهبوط السطحي الأعظمي والتشوهات القطرية convergence في محيط حفرة النفق.

تم توظيف العوامل التالية كمدخلات للشبكة العصبونية:

- خصائص الوسط المحفور متمثلة بالعوامل التالية: الوزن الحجمي، التماسك، زاوية الاحتكاك الداخلي، معامل يونغ، معامل بواسون.
- الخصائص الجيومترية: قطر النفق، سماكة التغطية أعلى قمة النفق.
- أضيف للعوامل السابقة: التشوه القطري U المقاس في محيط النفق المحفور قبل التدعيم.

قسمت المعطيات إلى مجموعتين حيث وظفت نسبة 70% من البيانات (50 حالة) لتدريب الشبكة والنسبة 30% المتبقية (20 حالة) من أجل مرحلة التنبؤ النهائية. ومخرج الشبكة الذي ستقوم بالتنبؤ به هو قيمة الهبوط السطحي الأعظمي S_{max} أعلى النفق في كل حالة. تم اقتراح بنية أولية للشبكة تتألف من أربع طبقات هي التالية:

- طبقة إدخال تتضمن عدد من العصبونات يساوي عدد العوامل المستخدمة في التنبؤ.
- طبقتين مخفيتين في كل منهما عشرة عصبونات.
- طبقة المخرج وتتألف من عصبون واحد يعطي قيمة S_{max} .

تم اعتماد معيارين من أجل تقييم أداء الشبكة في مرحلة التنبؤ النهائية وهما:

- جذر متوسط مربعات الأخطاء (RMSE) الذي يمثل دقة التنبؤ بقيمة S_{max} لعدد n من الحالات، معبراً عنه من خلال الفرق بين القيمة المقاسة S والقيمة التي تم التنبؤ بها C ويعطى بالعلاقة التالية:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (S-C)^2}{n}} \quad (8)$$

كلما انخفضت قيمة RMSE كلما كان النموذج أكثر دقة، وكانت جودة التنبؤ أعلى.

- معامل التحديد R^2 : وهو مقياس إحصائي يمثل نسبة التباين بين القيم المقاسة والمحسوبة تقع قيمته بين 0 و 1 حيث يجب أن تكون قيمته أقرب ما يكون للواحد.


تم في البدء التحقق من مقدرة الشبكة على القيام بعملية التنبؤ بناءً على المعطيات المقترحة. بالرجوع للعلاقات المذكورة في الجدول 1 والمقترحة لحساب قيمة S_{max} أعلى النفق نجد أن بعض الفرضيات اعتمدت فقط على خصائص الوسط المحفور بينما أخذ آخرون بعين الاعتبار عمق وقطر النفق المحفور. لذلك وبناءً على هذه الفرضيات المختلفة تم تزويد الشبكة بالمعطيات على مراحل وذلك باعتبار الحالات الثلاث التالية:

- الشبكة 1: التنبؤ بهبوط سطح الأرض بناءً على خصائص الوسط المحفور فقط (γ, c, ϕ, E, v) .

- الشبكة 2: إضافة سماكة التغطية أعلى النفق Z لتصبح مدخلات الشبكة هي: $(\gamma, c, \phi, E, v, Z)$.


➤ الشبكة 3: إضافة قطر النفق وقيمة التشوهات القطرية U وبالتالي أصبحت مدخلات الشبكة هي $(\gamma, c, \varphi, E, v, Z, R, U)$.

أعطت الشبكة الأولى النتائج الموضحة في الشكل 6 حيث بلغت دقة الحساب $RMSE=1.42mm$ وكما نجد من الشكل فالشبكة لم تعطي توافق جيد مع القيم المقاسة.




الشكل 6: نتائج التنبؤ بقيمة الهبوط في الشبكة الأولى بالاعتماد على خمسة عوامل.

تم في الشبكة الثانية إضافة المعامل Z لكن الشبكة ما زالت غير قادرة على التنبؤ بشكل دقيق كما يبين الشكل 7 حيث بلغت قيمة $RMSE=1.77mm$:



الشكل 7: نتائج التنبؤ بقيمة الهبوط في الشبكة الثانية بالاعتماد على ستة عوامل.
في الشبكة الثالثة أضيف معاملان إضافيان هما قطر النفق D وقيمة التشوهات القطرية U حيث نجد أن الشبكة أعطت نتائج مقارنة جداً للقيم المقاسة حقلياً كما يبين الشكل 8 وبلغت قيمة $RMSE=0.26mm$ والمعامل $R^2 = 0.95$.



الشكل 8: نتائج التنبؤ بقيمة الهبوط في الشبكة الثالثة بالاعتماد على ثمانية عوامل.

بعد التحقق من مقدرة الشبكة على التنبؤ، تم في المرحلة التالية معايرة البنية الداخلية للشبكة للوصول إلى أفضل النتائج. حيث تم بدايةً اختبار كل توابع التحويل transfer functions المتاحة في بيئة Matlab (جدول 2) لاستخدامها في الطبقات المخفية للشبكة وذلك وفق التسلسل المبين في الجدول التالي:

الجدول 3: قيم R^2 , RMSE بحسب أنواع توابع التحويل المستخدمة في الطبقات المخفية.

توابع التحويل	قيمة R^2	قيمة RMSE
Logsig – Logrisg	0.27	1.38
Purlin – Purlin	0.94	0.26
Tansig – Tansig	0.69	0.87
Purelin – Tansig	0.92	0.32
Tansig – Purlin	0.93	0.29

كما يبين الجدول 3 وجد أن استخدام تابع التحويل الخطي Purlin في كل من الطبقتين المخفيتين للشبكة يعطي أفضل النتائج (أقل قيمة لـ RMSE وأعلى قيمة لـ R^2) وبناءً على ذلك تم اعتماده في بنية الشبكة في الحسابات اللاحقة.

كما تم التحقق من عدد العصبونات الأمثل في كل من الطبقتين المخفيتين حيث تم اختبار الحالات المبينة في الجدول 4. تبين من هذا التحليل أن عدد العصبونات في الطبقات المخفية لا يؤثر بشكل كبير على نتائج التنبؤ حيث أن نوع توابع التحويل المستخدمة في الشبكة يعتبر أكثر أهمية من هذا العامل. كذلك وجد أن استخدام اثني عشر عصبوناً في كل طبقة مخفية يعطي أفضل النتائج وبناءً عليه تم اعتماده في البنية النهائية للشبكة.

الجدول 4: قيم R^2 , RMSE بحسب عدد العصبونات المستخدمة في طبقات الشبكة المخفية.

عدد العصبونات	قيمة R^2	قيمة RMSE
6	0.947	0.29
8	0.949	0.28
10	0.957	0.26
12	0.959	0.25
14	0.915	0.32


وبالتالي أصبحت بنية الشبكة المعتمدة:

- طبقة إدخال: تتكون من ثماني عصبونات هي العوامل التي اعتمدت ليتم توظيفها في التنبؤ $(\gamma, c, \varphi, E, v, Z, R, U)$.
- طبقتين مخفيتين: تتضمن كل منهما من 12 عصبون وتستخدم تابع التحويل الخطي Purlin في كلا الطبقتين.
- طبقة خرج وتتكون من عصبون واحد هو هبوط سطح الأرض الأعظمي S_{max} الذي ستقوم الشبكة بالتنبؤ به.

النتائج والمناقشة

بعد الانتهاء من بناء النموذج ومعايرته تم التوجه للتعمق في تحليل العلاقة بين الهبوط الأعظمي والعوامل المستخدمة في التنبؤ. بدايةً تم رسم العلاقة بين S_{max} المقاس حقلياً و Z سماكة التغطية أعلى النفق كما يبين الشكل 9:

تحليل باستخدام الشبكات العصبونية الاصطناعية للهبوط السطحي الأعظمي أعلى الأنفاق المنفذة بالطريقة النمساوية الحديثة




الشكل 9: العلاقة بين سماكة طبقة التغطية وقيم الهبوط السطحي المقاسة حقلياً.

لم نجد أن هناك علاقة واضحة بين قيم S_{max} و Z وذلك نظراً لتأثير العوامل الأخرى والتي تأخذ قيمة متفاوتة جعلت من الصعب استنباط علاقة واضحة، خاصة وأن قيم الهبوطات مقاسة في ورشات أنفاق مختلفة في ظروف جيولوجية متنوعة. لذلك ولدراسة تأثير سماكة طبقة التغطية على الهبوط تم اتباع المنهجية التالية:


تدريب الشبكة كما سبق ذكره، ومن ثم تم في مرحلة التنبؤ التالية إعطاء العامل Z قيم متغيرة (تتراوح بين قيمته الأصغرية والأعظمية) مع تثبيت قيم العوامل السبعة الأخرى (باعتداد القيم الوسطية لكل منها) حيث تم الحصول على النتيجة الموضحة في الشكل 10.

بين التحليل باستخدام المنهجية المقترحة (التي تفترض حفر نفق ذو قطر ثابت D في وسط متجانس ثابت الخواص) أن ازدياد سماكة طبقة التغطية يترافق مع تناقص الهبوط السطحي الأعظمي أعلى النفق.



الشكل 10: العلاقة بين سماكة طبقة التغطية Z والهبوط S_{max} الذي تتبأت بها الشبكة.

تم بأسلوب مماثل لما سبق التحري عن دور المعامل U المعبر عن التشوهات القطرية convergence المقاسة في محيط حفرة النفق غير المدعم (وذلك بإعطاء U فقط قيم متغيرة مع تثبيت قيم العوامل السبعة الأخرى). يبين الشكل 11 ازدياد قيم S_{max} بازدياد قيم التشوهات U في محيط النفق:




الشكل 11: العلاقة بين التشوهات القطرية U في محيط النفق والهبوط السطحي

الأعظمي S_{max} الذي تتبأت بها الشبكة.

نلاحظ أن هذين العاملين U , Z متعاكسين في التأثير حيث:

○ تنشأ التشوهات في محيط حفرة النفق وتبدأ بالتخامد عبر طبقات التغطية التي تعلوه، وكلما ازدادت سماكة التغطية أعلى النفق تناقصت قيمة التشوهات الواصلة للسطح S_{max} .


○ بنفس الوقت إن التشوهات القطرية في محيط حفرة النفق U تتأثر بسماكة التغطية أعلى النفق حيث أن ازدياد سماكة التغطية أعلى النفق يترافق مع قيم تشوهات أكبر في محيط حفرة النفق كما يبين الشكل 12:



الشكل 12: العلاقة بين التشوهات القطرية U وسماكة طبقة التغطية أعلى النفق Z .

بالمخلص تلعب سماكة التغطية أعلى النفق دورين متعاكسين في تأثيرها على S_{max} : حيث أن ازدياد سماكة التغطية أعلى النفق يتسبب بقيم أكبر للتشوهات U ، وهو بنفس الوقت عامل مساعد على تخامد هذه التشوهات في طبقات التغطية أعلى النفق وصولاً إلى قيم أقل للهبوط السطحي S_{max} .


لدراسة هذا التخماد عبر طبقة التغطية أعلى النفق وعلاقته مع كل من U ، S_{max} تم حساب قيمة δ الممثلة للتخماد والمعبّرة عن الفارق بين قيمتي U المقاسة في محيط النفق والهبوط الذي تتبأت به الشبكة S_{max} في كل مقطع مدروس ($\delta = U - S_{max}$). تم رسم العلاقة بين δ, Z التي أكدت تزايد قيمة التخماد δ بازدياد سماكة التغطية أعلى النفق كما يبين الشكل 13:



الشكل 13: العلاقة بين مقدار تخامد التشوهات δ وسماكة طبقة التغطية Z أعلى النفق.

لدراسة العوامل المؤثرة على تخامد التشوهات تم رسم العلاقة التي تربط D/Z مع S_{max}/U والمبينة في الشكل 14:

تحليل باستخدام الشبكات العصبونية الاصطناعية للهبوط السطحي الأعظمي أعلى الأنفاق المنفذة
بالطريقة النمساوية الحديثة




الشكل 14: العلاقة التي تربط كلاً من العاملين D/Z مع S_{max}/U .

حيث وجد من الشكل 14 أن هذه العلاقة هي علاقة خطية يمكن بتقريب مقبول كتابتها كالتالي $D/Z = S_{max}/u$ ومنه يمكن التوصل إلى أن قيمة الهبوط السطحي الأعظمي هي نسبة من قيمة التشوهات القطرية المتولدة في محيط النفق U وفق العلاقة:

$$S_{max} = \frac{D}{Z} * U \quad (9)$$


نلاحظ من العلاقة 9 أن قطر النفق يعتبر من العوامل المؤثرة على الهبوط السطحي S_{max} للتحقق من ذلك تم رسم العلاقة بين D , S_{max} (بنفس المنهجية المذكورة أعلاه بإعطاء D قيم متغيرة وثبتت قيم مدخلات الشبكة الأخرى في مرحلة التنبؤ النهائية) فوجد أن قطر النفق ذو تأثير هام على قيمة S_{max} الذي يزداد بازدياد قطر النفق كما يبين الشكل 15:



الشكل 15: العلاقة بين قطر النفق D والهبوط السطحي S_{max} الذي تنبأت بها الشبكة.

تم في النهاية إجراء دراسة بارامترية لجميع العوامل المعبرة عن خصائص الوسط المحفور (γ, c, φ, E) فتبين أن العامل الأهم من هذه العوامل الخمسة هو E معامل مرونة الوسط المحفور (شكل 16). بينت الدراسة تناقص قيم S_{max} بازدياد قيم معامل المرونة E بينما لم يكن هناك تأثير واضح للعوامل γ, c, φ على قيم الهبوط في الحالة المدروسة.

تحليل باستخدام الشبكات العصبونية الاصطناعية للهبوط السطحي الأعظمي أعلى الأنفاق المنفذة بالطريقة النمساوية الحديثة



الشكل 16: دراسة بارامتريّة لتأثير خصائص الوسط المحفور (γ, c, ϕ, E) على الهبوط السطحي الأعظمي S_{max} الذي تنبأت به الشبكة.

الاستنتاجات والتوصيات

استخدمت الشبكات العصبونية الاصطناعية لدراسة الهبوط السطحي الأعظمي الناتج عن حفر الأنفاق السطحية بالطريقة التقليدية NATM. تضمنت قاعدة البيانات دراسة 70 حالة مرجعية لحالات أنفاق منفذة في أوساط صخرية متوسطة المقاومة حيث تناولت الدراسة خصائص الوسط المحفور بالإضافة لقطر النفق وسماكة التغطية أعلاه وعامل إضافي هو قيمة التشوهات القطرية convergence المقاسة في محيط النفق غير المدعم.

أظهرت النتائج مقدرة الشبكات العصبونية الاصطناعية على التنبؤ بقيمة الهبوط السطحي الأعظمي بالاعتماد على العوامل المقترحة في الدراسة. حيث أعطت الشبكات العصبونية نتائج تنبؤ مقارنة جداً للقيم المقاسة حقلياً.

بينت النتائج أن ثلاثة عوامل أساسية تعتبر هي المؤثرة على قيم الهبوط السطحي الأعظمي وهي قطر النفق وسماكة التغطية اعلى النفق وقيمة التشوهات القطرية في محيط النفق. حيث وجد أن ازدياد قطر النفق وازدياد التشوهات القطرية في محيطه يترافق مع ازدياد الهبوط السطحي الأعظمي أعلى النفق. أما سماكة التغطية أعلى النفق فهي تقوم بدور مزدوج: فمن ناحية إن ازدياد سماكة التغطية أعلى النفق يترافق مع ازدياد التشوهات في محيط النفق ومن ناحية أخرى تساعد سماكة التغطية الكبيرة على تخامد هذه لتشوهات في طبقات التغطية أعلى النفق الأمر الذي يقلل من قيم الهبوط السطحي، حيث بينت الدراسة أن قيمة تخامد التشوهات تزداد بازدياد سماكة التغطية أعلى النفق.

تم إجراء دراسة بارامترية لتأثير خصائص الوسط المحفور على الهبوط السطحي الأعظمي التي بينت أن معامل يونغ في الحالات المدروسة كان من أهم هذه الخصائص حيث ترافق ازدياد قيمته مع تناقص قيمة الهبوط الأعظمي أعلى النفق.

ركز البحث على ضرورة الأخذ بعين الاعتبار لقيم التشوهات القطرية في محيط النفق عند دراسة الهبوط السطحي أعلى النفق، الأمر الذي لم تأخذه الدراسات التجريبية السابقة بعين الاعتبار (قد يكون ذلك عائداً لصعوبة القيام بالقياسات الحقلية لهذه التشوهات).

إن النتائج التي تم التوصل إليها في نهاية هذا البحث تشجع وتدعو لتوظيف الشبكات العصبونية الاصطناعية لدراسة حالات مرجعية أخرى لحفر أنفاق في أوساط ذات طبيعة جيولوجية مختلفة وباستخدام تقنيات حفر أخرى.

وهنا نؤكد على ضرورة التحقق من الدور الهام لقيمة التشوهات القطرية في محيط حفرة النفق في ورشات أخرى منفذة في ترب ضعيفة معرضة للانهيال حيث يمكن أن تكون قيم هذه التشوهات أكبر. كما يوصي البحث بضرورة إضافة معامل الزمن بعين الاعتبار الذي يتناول التأخير الزمني في تنفيذ تدعيم محيط النفق ودوره في تطور التشوهات الداخلية أو السطحية الأمر الذي لم يكن متاحاً في هذا البحث لعدم توفر معطيات كافية لدراسة هذا العامل.

- [1] AFTES. GT6. Recommandation (1979). Présentation de la méthode de construction des tunnels avec soutènement immédiat par béton projeté et boulonnage-texte provisoire. Tunnel et Ouvrages Souterrains, (31).
- [2] Peck, R.B. (1969). Deep excavations and tunnelling in soft ground, Proceeding of the 7th International Conference on Soil Mechanism Foundation Engineering. Vol.3, pp.225-290.
- [3] Poupelloz, B. (1984) Tassements engendrés par le creusement des galeries de petite section à faible profondeur – exemples en région parisienne. Rapport du laboratoire régional de l'est parisien, 78 p.
- [4] Sagaseta, C. (1987). Analysis of undrained soil deformation due to ground loss. Geotechnique, 37 (3), 301–320.
- [5] Loganathan, N., Poulos, H.G. (1998). Analytical prediction for tunnelling-induced ground movements in clay. J. Geotech. Geoenviron. 124 (9), 846–856.
- [6] Bobet, A. (2001). Analytical solutions for shallow tunnels in saturated ground. J. Eng. Mech. – ASCE 12, 1258–1266.
- [7] Verruijt, A., Booker, J.R. (1996). Surface settlement due to deformation of a tunnel in an elastic half plane. Geotechnique. 46 (4), 753–756.
- [8] Ercelebi, S.G., Copur, H., Ocak, I. (2011). Surface settlement predictions for Istanbul Metro tunnels excavated by EPB-TBM. Earth Sci. Res. J. 62, 357–365.
- [9] Melis, M., Medina, L., Rodriguez, J.M. (2002). Prediction and analysis of subsidence induced by shield tunnelling in the Madrid Metro extension. Can. Geotech. J. 39, 1273–1287.
- [10] Suwansawat, S., Einstein, H.H. (2006). Artificial neural networks for predicting the maximum surface settlement caused by EPB shield tunnelling. Tunn. Undergr. Space Technol. 21, 133–150.

- [11] O'reilly, M.P., New, B.M. (1982). Settlements above tunnels in the United Kingdom - their magnitudes and prediction, 'Tunnelling' 82, London: IMM. pp.173-181.
- [12] Mair, R.J. (1983). Geotechnical aspects of soft-ground tunnelling. In: Proc. Conf. on Construction Problems in Soft Soils, N.T.I., Singapore.
- [13] Attewell, P.B., Yeates, J. and Selby, A.R. (1986). Soil movements induced by tunnelling and their effects on pipelines and structures, London: Blackies. Sons Ltd. pp. 64-74.
- [14] Zhou, J., Qi, H., Peng, K., Zhang, Y., & Khandelwal, M. (2024). Comprehensive review and future perspectives on prediction and mitigation of tunnel-induced ground settlement: A bibliometric analysis and methodological overview (2002–2022). Tunnelling and Underground Space Technology, 154.
- [15] Sagaseta, C. and Moya, J.F. (1980). Estimation of ground subsidence over urban tunnels, 2nd int. conf. «ground movements and structure». Cardiff, pp. 331-345.
- [16] Farmer, I.W. (1977). Case histories of settlement above tunnels in clay, Proc. of conf. « large ground movements and structures ». pp. 357-371.
- [17] Herzog, M. (1985) Surface subsidence above shallow tunnels, Bautechnik 62 (11), pp. 375–377.
- [18] Chakeri, H., Ünver, B. (2014). A new equation for estimating the maximum surface settlement above tunnels excavated in soft ground, Environ. earth Sci. 71 (7), pp. 3195–3210.
- [19] Mair, R.J., Taylor, R.N., Bracegirdle, A. (1993). Subsurface settlement profiles above tunnels in clays. Geotechnique 43 (2), pp. 315–320.
- [20] Wang, J., Zhou, P., Song, Z., Li, S., Zhang, Q. (2022). A new calculation method for tunneling-caused stratum settlement. KSCE J. Civ. Eng. 26 (6), 2624–2640.

- [21] Boubou, R., Emeriault, F., Kastner, R. (2010). Artificial neural network application for the prediction of ground surface movements induced by shield tunnelling. *Canadian Geotechnical Journal*, 47(11), pp. 1214-1233.
- [22] Yao B., Yao J., Zhang M., Yu L. (2014). Improved support vector machine regression in multistep-ahead prediction for rock displacement surrounding a tunnel. *Scientia Iranica. Transaction A, Civil Engineering*, 21(4), 1309.
- [23] Satıcı, Ö., Topal, T. (2020). Prediction of tunnel wall convergences for NATM tunnels which are excavated in weak-to-fair-quality rock masses using decision-tree technique and rock mass strength parameters. *SN Applied Sciences*, 2(4), 546.
- [24] Fei, J., Wu, Z., Sun, X., Su, D., & Bao, X. (2021). Research on tunnel engineering monitoring technology based on BPNN neural network and MARS machine learning regression algorithm. *Neural Computing and Applications*, 33, 239-255.
- [25] Shreyas, S. K., & Dey, A. (2019). Application of soft computing techniques in tunnelling and underground excavations: state of the art and future prospects. *Innovative Infrastructure Solutions*, 4(1), 46.
- [26] Bizjak, K. F., Petkovšek, B. (2004). Displacement analysis of tunnel support in soft rock around a shallow highway tunnel at Golovec. *Engineering Geology*, 75(1), 89-106.
- [27] Kim, C. Y., Bae, G. J., Hong, S. W., Park, C. H., Moon, H. K., Shin, H. S. (2001). Neural network based prediction of ground surface settlements due to tunnelling. *Computers and Geotechnics*, 28(6-7), 517-547.
- [28] Leu, S. S., Chen, C. N., Chang, S. L. (2001). Data mining for tunnel support stability: neural network approach. *Automation in construction*, 10(4), 429-441.
- [29] Khatami, S. A., Mirhabibi, A., Khosravi, A., Nahavandi, S. (2013). Artificial neural network analysis of twin tunnelling-induced ground

settlements. In 2013 IEEE International Conference on Systems, Man, and Cybernetics, pp. 2492-2497.

[30] Adoko, A. C., Jiao, Y. Y., Wu, L., Wang, H., & Wang, Z. H. (2013). Predicting tunnel convergence using multivariate adaptive regression spline and artificial neural network. Tunnelling and Underground Space Technology, 38, 368-376.

[31] Mohammadi, S. D., Naseri, F., Alipoor, S. (2015). Development of artificial neural networks and multiple regression models for the NATM tunnelling-induced settlement in Niayesh subway tunnel, Tehran. Bulletin of Engineering Geology and the Environment, 74, 827-843.

[32] Mahmoodzadeh, A., Mohammadi, M., Daraei, A., Ali, H. F. H., Al-Salihi, N. K., Omer, R. M. D. (2020). Forecasting maximum surface settlement caused by urban tunneling. Automation in Construction, 120, 103375.

[33] Shi J., Ortigao J.A.R., Bai J. (1998). Modular Neural Networks for Predicting Settlements During Tunneling. Journal of Geotechnical and Geoenvironmental Engineering, Vol. 124, n°5, pp. 389-395.

[34] Patterson D. (1996). Artificial neural networks. Singapore, Prentice Hall.

[35] Philippe D.W. (1997) Neural Network Models. Springer-Verlag, London.

[36] Hornik K., Stinchcombe M., White H. (1989) Multilayer Feedforward Networks are Universal Approximators. Neural Networks, Vol. 2, n°5, p. 359-366.

[37] Berry M.J.A., Linoff G. (1997). Data mining. Techniques appliquées au marketing, à la vente et aux services clients, Masson, 378 p.

[38] Fausett F. (1994). Fundamentals of Neural Networks: Architectures, Algorithms and Applications. Prentice-Hall, Englewood Cliffs, N.J.

[39] Maier H.R., Dandy G. C. (1998). The effect of internal parameters and geometry on the performance of back-propagation neural networks: an empirical study. Environmental Modelling & Software, vol. 13, p. 193-209.

[40] Maier H.R. Dandy G.C. (2000). Neural networks for the prediction and forecasting of water resources variables: A review of modeling issues and applications. Environmental Modeling & Software, vol. 15, p. 101-124.

[41] مردود فاطمة، سلامة معن، زقزوق عمار. (2022) نموذج شبكة عصبونية صناعية للتنبؤ بالتبخر الشهري من محطة سد الرستن، مجلة جامعة البعث، المجلد 44، العدد 9، 11-34.

[42] بوبو ريم. (2018) دراسة سلوك الأنفاق العميقة المعرضة للانهييار باستخدام المنطق العصبوني الضبابي Neuro-Fuzzy Logic، مجلة جامعة البعث، المجلد 40، العدد 35، 155-182.