

LỰA CHỌN CẤU TRÚC MẠNG NƠ RON NHÂN TẠO (ANN) DỰ BÁO CHỈ SỐ NÉN CỦA ĐẤT

TS. VŨ VĂN TUẤN

Học viện Kỹ thuật quân sự

Tóm tắt: Mạng nơ-ron nhân tạo (artificial neural network - ANN) đã được áp dụng thành công trong nhiều bài toán địa kỹ thuật. Tuy nhiên, trong quá trình xây dựng mạng nơ-ron ANN, việc lựa chọn cấu trúc mạng để đạt được kết quả chính xác hơn vẫn chưa thực sự thống nhất. Bài báo này sẽ thử dần, và lựa chọn những kết luận của các tác giả trước để xây dựng mô hình nơ-ron ANN với mục tiêu dự đoán chính xác hơn chỉ số nén C_c của đất đá. Tính chính xác của mô hình sẽ được đánh giá qua bốn chỉ số: R^2 (hệ số xác định), RMSE (độ lệch bình phương trung bình gốc), MAPE (độ lệch phần trăm tuyệt đối trung bình), MAD (trung bình độ lệch tuyệt đối). Các kết luận về cấu trúc và ảnh hưởng của các tham số đầu vào sẽ được rút ra khi so sánh tính chính xác của các mô hình nơ-ron ANN với nhau.

Từ khóa: Dự đoán, mạng nơ-ron nhân tạo (ANN), chỉ số nén.

Abstract: Artificial neural networks (ANNs) have been successfully applied to many problems of technical engineering. However, during the development of the ANN model, the selection of the model geometry to get more accuracy is still not agree. This paper will try and choose the reasonable conclusions of formal authors in order to make the ANN model which can predict the compression index of soil more accuracy of. The criterions to evaluate the accuracy of the models are R^2 , RMSE, MAPE, MAD. After comparing the accuracy between different ANN models, the following conclusions of the model geometry and the influence of input variables would be drawn.

Keywords: Prediction, artificial neural network (ANN), compression index.

1. Đặt vấn đề

Hiện nay trí tuệ nhân tạo (AI) đang được áp dụng thành công và tiếp tục được chú trọng nghiên cứu phát triển trong rất nhiều các lĩnh vực. Tuy nhiên đối với lĩnh vực xây dựng thì việc nghiên cứu áp dụng trí

tuệ nhân tạo (AI) lại chưa thực sự nổi bật, đặc biệt là ở nước ta. Lý do lớn nhất có lẽ là chúng ta chưa có những bộ dữ liệu quy mô và mới chỉ bắt đầu nhen nhóm để xây dựng các bộ số liệu lớn (big data).

Mạng nơ-ron nhân tạo ANN là một nhánh của trí tuệ nhân tạo. Ưu điểm của nó là mô hình rõ ràng, dễ thực hiện, chính xác và hiệu quả. Vì vậy mạng nơ-ron nhân tạo ANN được áp dụng khá rộng rãi. Một số nghiên cứu chủ yếu trên thế giới có thể kể đến là: tác giả [11] đã nghiên cứu áp dụng mạng nơ-ron ANN trong các công trình hầm mỏ; tác giả [9] đã áp dụng trong các công trình đập lớn; tác giả [15] áp dụng trong các hầm giao thông; trong ổn định mái dốc có thể kể đến nghiên cứu của tác giả [7]; trong lĩnh vực địa kỹ thuật nổi bật là nghiên cứu của tác giả [18].

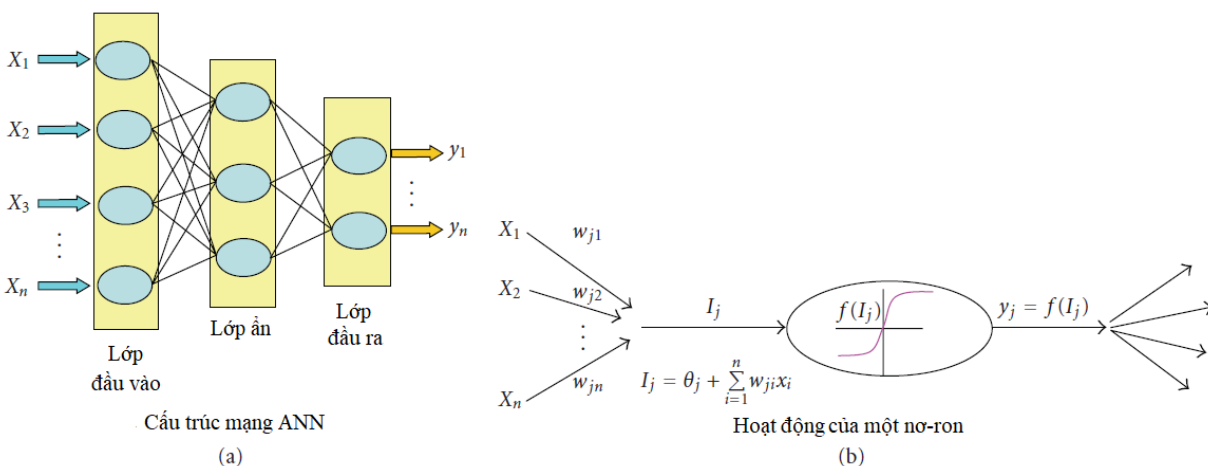
Tại Việt Nam cũng đã có một vài tác giả nghiên cứu áp dụng mạng nơ-ron nhân tạo ANN trong việc giải quyết một số vấn đề. Tác giả [14] đã nghiên cứu khả năng ứng dụng mạng nơ-ron nhân tạo trong dự báo kích thước trung bình của cục đá và thể tích phá mẫu sau nổ trên mô hình nổ điện. Tác giả [4] đã nghiên cứu giới thiệu mạng nơ-ron nhân tạo dự báo độ rỗng của giếng khoan từ tài liệu địa cơ học cho trước bằng sử dụng công cụ “nnstart” của phần mềm Matlab. Tác giả [2] đã nghiên cứu ứng dụng mạng nơ-ron nhân tạo để dự báo tốc độ ăn mòn thép CT3 trong khí quyển. Tác giả [3] đã sử dụng mạng nơ-ron nhân tạo để dự báo lưu lượng nước đến hồ chứa Cửa Đạt. Tác giả [1] đã nghiên cứu ứng dụng mô hình mạng nơ-ron nhân tạo để dự đoán sức chịu tải giới hạn của cấu kiện thép chữ Y. Tác giả [5] đã áp dụng mô hình mạng nơ-ron nhân tạo vào dự báo độ lún của các lớp đất khi thi công hầm metro... Có thể nói việc nghiên cứu ứng dụng mạng nơ-ron nhân tạo trong lĩnh vực xây dựng ở Việt Nam còn chưa nhiều và cần phải có thêm nhiều nghiên cứu để làm rõ hơn vấn đề này.

Chỉ số nén của đất là một tham số hết sức quan trọng đối với các bài toán địa kỹ thuật. Đã có rất nhiều các công trình nghiên cứu, các công thức thực nghiệm được đưa ra. Tác giả [16] trong bài viết của

mình cũng đã tổng hợp một loạt các công thức thực nghiệm và đánh giá tính chính xác của từng công thức qua việc sử dụng 400 số liệu thí nghiệm xác định chỉ số nén C_c của đất. Ngoài ra, trong bài viết này tác giả cũng đề xuất thêm công thức thực nghiệm và đặc biệt hơn là đã sử dụng MATLAB 7.6 xây dựng mạng nơ-ron nhân tạo ANN với cấu trúc hai lớp ẩn để xây dựng mô hình dự đoán. Kết quả sau khi so sánh mô hình ANN với công thức thực nghiệm cho thấy: mô hình ANN vượt trội hơn về tính chính xác.

Mặc dù đã có không ít các nghiên cứu về việc áp dụng mạng nơ-ron ANN nhân tạo trong địa kỹ thuật. Tuy nhiên, việc lựa chọn cấu trúc mạng để đạt được kết quả chính xác hơn vẫn chưa thực sự thống nhất. Tác giả [8] cho rằng mạng ANN với một lớp ẩn có thể đáp ứng được yêu cầu một hàm liên tục với điều kiện sử dụng đủ các trọng số (w_{ji}), tác giả [6] khi nói về số nút của lớp ẩn đề xuất số lượng nút tối thiểu là $2l+1$, tác giả [16] sau khi so sánh lại thấy mạng ANN với hai lớp ẩn cho giá trị chính xác hơn. Từ lý do đó, bài viết này sẽ thử dần, và lựa chọn những kết luận của các tác giả trước để xây dựng mô hình nơ-ron ANN có thể dự đoán chính xác hơn chỉ số nén C_c của đất dựa trên số liệu thí nghiệm trong bài viết của tác giả [16]. Độ chính xác của mô hình sẽ được đánh giá qua bốn chỉ số: R^2 , RMSE, MAPE, MAD [16]. Các kết luận về cấu trúc và ảnh hưởng của các tham số đầu vào sẽ được rút ra khi so sánh tính chính xác của các mô hình nơ-ron ANN với nhau.

2. Tổng quan về mạng nơ-ron nhân tạo ANN



Hình 1. Cấu trúc và cách thức hoạt động một mạng ANN [13]

Mạng nơ-ron nhân tạo (ANN) là một họ các quá trình xử lý thông tin (dạng số) dựa trên mô hình các nơ-ron thần kinh của con người. Mục đích của ANN giống như các mô hình truyền thống, đó là xác định mối quan hệ giữa các tham số đầu vào và các tham số đầu ra của mô hình. Tuy nhiên, ANN chỉ sử dụng các tập dữ liệu mà không cần chỉ định trước các hàm toán xác định mối quan hệ giữa các tham số đầu vào và đầu ra của mô hình. Điều này cho phép ANN khắc phục những nhược điểm của các mô hình truyền thống.

Bài viết này sẽ sử dụng mạng nơ-ron nhiều tầng (Multi-layer feed-forward) tập học với giải thuật lan truyền ngược (back-propagation algorithm) [12]. Mạng nơ-ron này được cấu thành từ một loạt các phần tử xử lý (processing elements) hay có thể gọi là nơ-ron hoặc nút. Các nơ-ron này kết nối một phần hoặc toàn bộ với nhau thông qua các trọng số (connection weights, w_{ji}) và thường được chia làm 3 lớp (tầng): lớp đầu vào (input layer), lớp đầu ra (output layer), các lớp ẩn (hidden layers).

Đã có rất nhiều các bài viết về cấu trúc và cách thức hoạt động của mạng ANN. Hình 1 trình bày cấu trúc và cách thức hoạt động của một mạng ANN [13]. Tại mỗi một nơ-ron, giá trị (x_i) của lớp trước sẽ được nhân với trọng số (w_{ji}), tổng của các (x_i) (w_{ji}) sẽ được cộng (hoặc trừ) với biến hiệu chỉnh bias (θ_j) để hợp thành một giá trị tổng đầu vào (I_j). Giá trị tổng đầu vào (I_j) sẽ được hàm truyền ($f(\cdot)$) (hàm sigmoidal hoặc hàm tanh) dùng để tính toán ra các tham số đầu ra (y_j) của nơ-ron.

Quá trình tập học mạng ANN bắt đầu từ dữ liệu đầu vào (vector thông số đầu vào được nhập vào các nơ-ron ở lớp đầu vào). Tại nơ-ron lớp ẩn thứ j , giá trị tín hiệu nhận từ lớp đầu vào sẽ được hợp thành một giá trị tổng đầu vào theo công thức sau:

$$I_j = \theta_j + \sum_{i=1}^n w_{ji}x_i \quad (1)$$

Trong đó: x_i là các thông số đầu vào; các trọng số (w_{ji}) và biến hiệu chỉnh bias (θ_j) ban đầu sẽ được sinh ra ngẫu nhiên.

Sau đó, hàm truyền sẽ được sử dụng để tính giá trị đầu ra theo công thức sau:

$$y_j = f(I_j) \quad (2)$$

Giá trị đầu ra này lại làm đầu vào cho nơ-ron lớp tiếp theo. Cứ như vậy giá trị được truyền cho đến nơ-ron ở lớp đầu ra. Đối với mạng một lớp ẩn (mạng sử dụng trong bài viết) thì hết bước này sẽ chuyển sang bước lan truyền ngược. Sự khác biệt giữa giá trị đầu ra (y_j) và giá trị thực tế (t_j) được gọi là tín hiệu lỗi (Cost function), được tính như sau:

$$J = t_j - y_j \quad (3)$$

Từ tín hiệu lỗi tính đạo hàm trọng số lớp nhập và lớp ẩn. Từ đó hiệu chỉnh các trọng số và biến bias làm cho đầu ra dự đoán của mạng gần hơn với dự kiến.

$$\Delta w_{ji} = \frac{\partial J}{\partial w_{ji}} \quad (4)$$


$$\Delta \theta_j = \frac{\partial J}{\partial \theta_j} \quad (5)$$

$$w_{ji}(new) = w_{ji}(old) - \eta \Delta w_{ji} \quad (6)$$

$$\theta_j(new) = \theta_j(old) - \eta \Delta \theta_j \quad (7)$$

Trong đó: $w_{ji}(new)$, $\theta_j(new)$ - giá trị trọng số, giá trị bias sau điều chỉnh; $w_{ji}(old)$, $\theta_j(old)$ - giá trị trọng số, giá trị bias cũ; η - tần số học hay tốc độ học (learning rate).

Tốc độ học tập là tham số quan trọng thuật toán tối ưu (gradient descent). Nếu tham số này nhỏ, sẽ cần nhiều bước lặp để hàm số có thể đạt tới điểm cực tiểu. Ngược lại, nếu tham số này lớn, thuật toán sẽ cần ít vòng lặp hơn, tuy nhiên khi đó, có thể hàm số sẽ bỏ qua điểm cực tiểu và không thể hội tụ được.



Hình 2. Các trường hợp của tốc độ học tập

Để khắc phục việc các trọng số (w_{ji}) và các giá trị bias (θ_j) của bước lặp tiếp theo không rơi vào một điểm cực tiểu cục bộ (local minimum), người ta dùng thêm thuật toán Momentum. Thuật toán này tính lượng thay đổi của các biến ở thời điểm t (v_t) để cập nhật giá trị mới.

$$w_{ji}(new) = w_{ji}(old) - \gamma v_{t-1} - \eta \Delta w_{ji} \quad (8)$$

$$\theta_j(new) = \theta_j(old) - \gamma v_{t-1} - \eta \Delta \theta_j \quad (9)$$

Trong đó: γ - hệ số mômen (momentum term).

Với mạng nhiều lớp ẩn các công thức giải thuật sẽ tương tự. Sau quá trình tập học, mô hình sẽ được kiểm chứng bằng các tập dữ liệu thực tế độc lập. Các bước xây dựng, tập học và kiểm chứng như trên (theo [10]) sẽ được sử dụng trong bài viết này.

3. Phát triển mô hình nơ-ron ANN dự đoán chỉ số nén C_c

Mô hình ANN trong bài viết này được xây dựng với sự trợ giúp của bộ phần mềm PYTHON Version 3.6. Đây là bộ phần mềm rất mạnh về học máy (deep learning) và trí tuệ nhân tạo (AI). Bộ số liệu dùng để huấn luyện, kiểm chứng mô hình cùng với các chỉ tiêu để so sánh tính chính xác của các mô hình đều được tham khảo từ bài viết của tác giả [16]. Tham số đầu ra của mô hình là chỉ số nén C_c , tham số đầu vào của mô hình là: e_0 - hệ số rỗng ban đầu; w_n - độ ẩm tự nhiên; LL - giới hạn chảy; PI - giới hạn dẻo; G_s - tỷ trọng hạt.

3.1 Phân loại và tiền xử lý dữ liệu

Để so sánh kết quả của mô hình ANN trong bài viết với kết quả của mô hình ANN được tác giả [16] xây dựng (gồm 9 nơ-ron trong lớp ẩn đầu tiên và 3 nơ-ron trong lớp ẩn thứ 2) thì cần phải có sự tương đồng về tập dữ liệu tập học và tập dữ liệu kiểm tra. Tuy nhiên điều này là rất khó khăn khi tập dữ liệu công bố của tác giả có tổng là 391 số liệu và ít hơn so với tổng 400 số liệu mà tác giả đã sử dụng để tập học và kiểm tra mô hình (360 số liệu cho tập học, 40 số liệu cho kiểm tra). Vì vậy việc lựa chọn 360 số liệu bất kỳ để tập học và 31 số liệu để kiểm tra là cũng có thể chấp nhận được và đảm bảo tính công bằng

tương đối trong hoàn cảnh này. Tham số của các tập dữ liệu được trình bày trong Bảng 1.

Bài viết của tác giả [16] đã trình bày kết quả dự đoán của một số công thức thực nghiệm. Trong số đó công thức của Azzouz et al. (1976) mặc dù chỉ cần 3 tham số đầu vào (e_0 ; w_n ; LL) vẫn cho kết quả chính xác nhất ($R^2 = 0,97$; MAPE = 16,51; RMSE = 0,0428; MAD = 0,0339). Như vậy, để xem xét ảnh hưởng của số lượng các tham số đầu vào tới kết quả dự đoán, ngoài việc xây dựng mô hình ANN 1 với đầy đủ 5 tham số đầu vào, bài viết này cũng xây dựng thêm mô hình ANN 2 với 3 tham số đầu vào để so sánh kết quả, đánh giá.

Bảng 1. Tham số của các tập dữ liệu

Tham số		Tập học (360 số liệu)			Kiểm tra (31 số liệu)		
		Trung bình	Lớn nhất	Nhỏ nhất	Trung bình	Lớn nhất	Nhỏ nhất
Đầu vào	e_0	0.77	1.88	0.36	0.73	0.97	0.50
	w	28.75	70.00	10.20	26.95	38.20	11.50
	LL	39.84	81.00	24.00	39.35	58.00	25.00
	PI	18.63	50.00	3.00	18.03	36.00	5.00
	G_s	2.63	2.80	2.44	2.65	2.77	2.43
Đầu ra	C_c	0.21	0.63	0.05	0.18	0.27	0.10


Trong quá trình tập học, các biến cần được chú ý như nhau, do đó phải thu gọn kích thước tập dữ liệu. Tức là giá trị trong các tập dữ liệu sẽ được tỉ lệ và rút gọn xuống nằm trong khoảng 0 và 1. Công thức để rút gọn với mỗi biến như sau:

$$x = (x - x_{min}) / (x_{max} - x_{min}) \tag{10}$$


Trong đó: x_{min} – giá trị nhỏ nhất; x_{max} – giá trị lớn nhất.

3.2 Cấu trúc, thuật toán tối ưu và điều kiện dừng học của mô hình

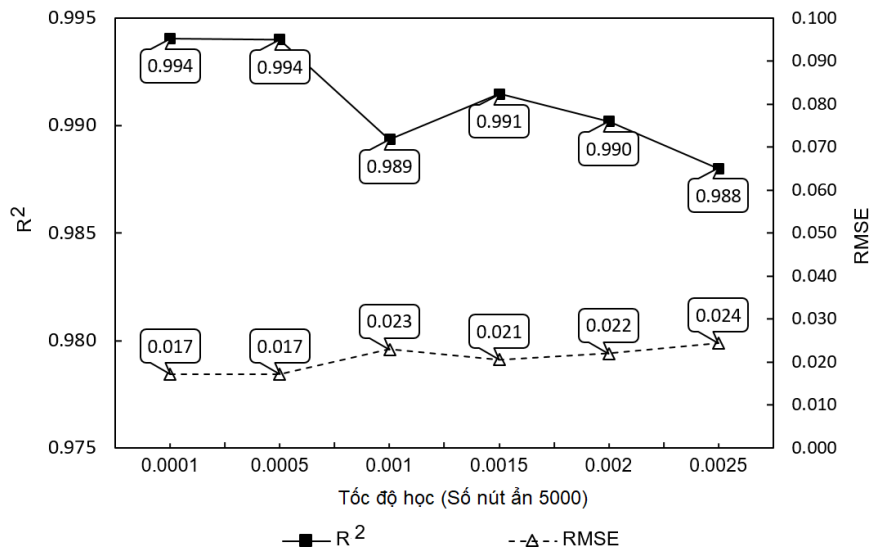
Cấu trúc gồm: số lớp ẩn, số nơ-ron trong từng lớp. Thuật toán tối ưu (Gradient descent) gồm: tần số học (learning rate), mô men (momentum term). Các yếu tố này có một vai trò vô cùng quan trọng khi xây dựng mô hình ANN.



Hình 3. Quan hệ giữa số lần lặp (Epoch) và giá trị sai lệch (Loss) của mô hình ANN1



Hình 4. Ảnh hưởng của số nút trong lớp ẩn tới tính chính xác của mô hình ANN1



Hình 5. Ảnh hưởng của tốc độ học tới tính chính xác của mô hình ANN1

Cấu trúc của mô hình ANN 1 và mô hình ANN 2 tuy có đôi chút khác nhau (mô hình ANN 1 với 5 nơ-ron ở lớp đầu vào, mô hình ANN 2 với 3 nơ-ron ở lớp đầu vào) tuy nhiên số lớp ẩn, số nơ-ron trong từng lớp còn lại cũng như cách thức xây dựng mô hình là giống nhau. Vì vậy phần này chỉ trình bày chi tiết cách thức xây dựng cho mô hình ANN 1, mô hình ANN 2 sẽ được thực hiện tương tự.

Tác giả [8] chỉ ra rằng một mạng ANN với một lớp ẩn có thể đáp ứng được yêu cầu một hàm liên tục với điều kiện sử dụng đủ các trọng số (w_{ij}). Vì vậy cả 2 mô hình ANN ở đây sẽ chỉ sử dụng một lớp ẩn.

Hàm truyền sử dụng trong cả hai mô hình (cụ thể là trong lớp ẩn và lớp đầu ra) sẽ đều là hàm ReLU. Về lý thuyết, nếu số vòng lặp (training cycles - epochs) càng lớn thì mô hình càng chính xác. Tuy nhiên, nếu số vòng lặp quá lớn thì sẽ mất nhiều thời

gian tập học trong khi đó tính chính xác của mô hình chưa chắc đã được cải thiện. Sau khi chạy thử, số vòng lặp lý tưởng của mô hình ANN 1 là 5000. Hình 3 trình bày sự chênh lệch giữa giá trị dự đoán và giá trị thực tế (training loss) của mô hình sau mỗi vòng lặp. Có thể thấy giá trị chênh lệch không biến động nhiều tại cuối của quá trình tập học.


Tác giả [6] đã đề xuất số lượng $2l+1$ là số nút tối thiểu của lớp ẩn để xây dựng một hàm liên tục cho một mạng ANN với số lượng l nút đầu vào. Tuy nhiên, dựa vào phân tích ảnh hưởng của số nút trong lớp ẩn đến tính chính xác của mô hình (Hình 4) thì mô hình ANN với 5000 nút trong lớp ẩn sẽ có độ chính xác cao nhất (R^2 và RMSE đối với tập dữ liệu tập học). Có thể thấy số nút trong lớp ẩn của mô hình ANN trong bài báo này lớn hơn rất nhiều so với số nút được tác giả [6] đề xuất trước đó.

Tốc độ học (learning rate) càng nhỏ thì mô hình lâu hội tụ, tốc độ học càng lớn thì mô hình sẽ nhanh hội tụ nhưng tính chính xác sẽ không cao. Sau khi phân tích ảnh hưởng của tốc độ học (learning rate) đến tính chính xác của mô hình (Hình 5) thì 0.0005 là tốc độ học hợp lý. Thuật toán lặp tối ưu (gradient descent optimization algorithm) là Adam [17]. Đây là thuật toán tiên tiến đã ngầm lựa chọn giá trị mô men (momentum term). Vì vậy trong bài viết này bỏ qua

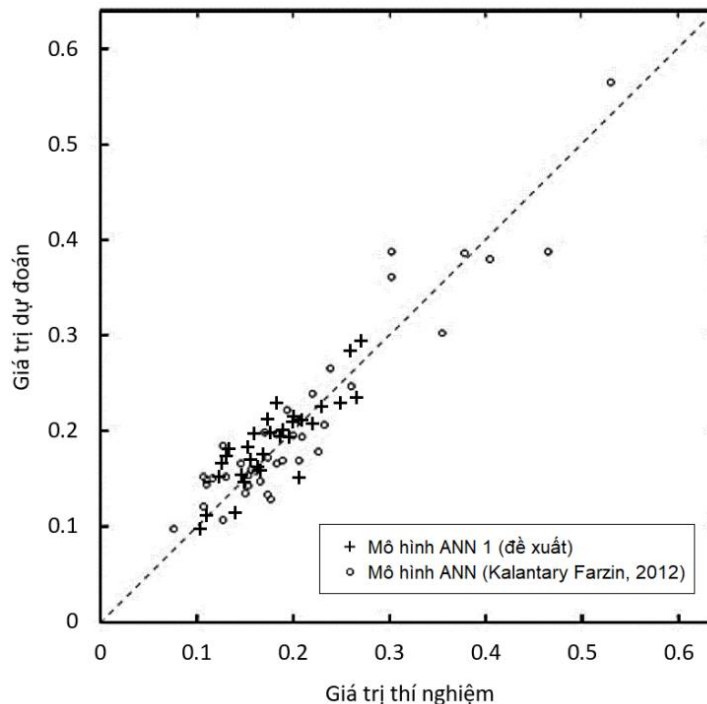
việc xem xét ảnh hưởng của momentum tới tính chính xác của mô hình.

Với mô hình ANN 2 cũng làm tương tự, tuy nhiên với 3 tham số đầu vào và để đạt được sai lệch giá trị (loss) tương đương như mô hình ANN 1 thì quá trình học tập khá “vất vả” cần tới 30000 vòng lặp, với 6000 nơ-ron trong lớp ẩn, và tốc độ học khá chậm là 0.00007.

4. So sánh và đánh giá mô hình



Hình 6. Giá trị thí nghiệm và giá trị dự đoán của mô hình ANN 1 và mô hình ANN của tác giả [16] (tập học)



Hình 7. Giá trị thí nghiệm và giá trị dự đoán của mô hình ANN 1 và mô hình ANN của tác giả [16] (kiểm tra)

Bảng 2. Tổng hợp các tham số đánh giá tính chính xác của các mô hình

STT	Chi tiết mô hình	R ²	RMSE	MAPE	MAD
1	ANN 1 (tập học)	0.994	0.0177	6.54	0.0136
2	ANN 2 (tập học)	0.992	0.0201	6.90	0.0143
3	ANN theo [16] (tập học)	0.975	0.0348	13.30	0.0274
4	ANN 1 (kiểm tra)	0.980	0.0259	11.47	0.0205
5	ANN 2 (kiểm tra)	0.950	0.0410	18.24	0.0326
6	ANN theo [16] (kiểm tra)	0.978	0.0337	13.17	0.0272

Hình 6, Hình 7 thể hiện giá trị thí nghiệm và giá trị dự đoán của hai mô hình (mô hình ANN 1 và mô hình ANN của tác giả [16]) trong cả hai trường hợp: tập học và kiểm tra. Có thể thấy các điểm thể hiện giá trị của mô hình ANN1 nằm gọn hơn và tập trung hơn vào hai bên đường chuẩn (đường mà giá trị dự đoán trùng với giá trị thí nghiệm), đặc biệt là trong trường hợp tập học. Như vậy mô hình ANN 1 cho kết quả tốt hơn. Điều này được thể hiện rõ nét hơn khi so sánh các tham số đánh giá tính chính xác của các mô hình (bảng 2). Tất cả các tham số thể hiện tính chính xác của mô hình ANN1 đều vượt trội hơn các mô hình khác.

Khi so sánh các tham số của mô hình ANN 2 (với 3 tham số đầu vào) và mô hình ANN 1 (với đủ 5 tham số đầu vào) có thể thấy chúng đều có chung quy luật. Đó là tính chính xác cao trong quá trình tập học và giảm dần trong quá trình kiểm tra. Đây là một quy luật thường thấy khi xây dựng các mô hình dự đoán. Ngoài ra, mặc dù mô hình ANN 2 có quá trình tập học "vất vả" hơn nhưng các tham số thể hiện tính chính xác đều không bằng mô hình ANN 1. Điều này cho thấy: với tập dữ liệu đầu vào có xét đến nhiều hơn các tham số liên quan và đủ lớn thì kết quả dự báo của mô hình nơ-ron ANN càng chính xác.

5. Kết luận

Sau khi so sánh kết quả của mô hình được xây dựng (01 lớp ẩn và rất nhiều nơ-ron) với kết quả của mô hình được tác giả [16] xây dựng có thể đưa ra một số kết luận sau:

- Việc thiết lập mô hình là phù hợp và mạng nơ-ron nhân tạo ANN có một lớp ẩn với số nơ-ron đủ lớn vẫn có thể cho kết quả dự báo chính xác hơn với thời gian học tập ít hơn. Trong tập hợp này, ảnh hưởng của số lớp ẩn ít bị tác động đến kết quả và việc học sâu sớm cho kết quả hội tụ;

- Số lượng nơ-ron trong lớp ẩn cần phải khảo sát kỹ trong từng bài toán cụ thể. Trong bài viết này mạng nơ-ron nhân tạo ANN với 5000 nơ-ron trong lớp ẩn cho kết quả dự báo chính xác nhất. Số lượng nơ-ron này lớn hơn rất nhiều lần so với số lượng nơ-ron được tác giả [6] đề xuất;

- Đây là phương pháp tin cậy để xử lý số liệu tập hợp lớn và khi tập dữ liệu đầu vào có xét đến nhiều hơn các tham số liên quan và đủ lớn thì kết quả dự báo của mô hình nơ-ron ANN càng chính xác.

TÀI LIỆU THAM KHẢO

1. Lý Hải Bằng và Nguyễn Thùy Anh (2020). "Nghiên cứu ứng dụng mô hình mạng nơ ron nhân tạo để dự đoán sức chịu tải giới hạn của cấu kiện thép chữ Y". *Khoa học công nghệ*, 3 pp 45-49.
2. Nguyễn Mạnh Thảo, Trần Thu Hằng và Phạm Văn Nguyên (2015). "Ứng dụng mạng nơ ron nhân tạo để dự báo tốc độ ăn mòn thép CT3 trong khí quyển". *Tạp chí khoa học và Công nghệ nhiệt đới*, 8 (6-2015) pp 57-64.
3. Quận Ngô Văn, Thịnh Nguyễn Xuân và Tiến Nguyễn Văn (2017). "Nghiên cứu ứng dụng mạng thần kinh nhân tạo (ANN) trong dự báo lưu lượng nước đến hồ chứa Cửa Đạt". *Tạp chí Khoa học và Công nghệ Thủy lợi*, (39), pp 1-7.
4. Tạ Quốc Dũng, Lê Thế Hà và Phạm Duy Khang (2019). "Ứng dụng mạng nơ ron nhân tạo (ANN) trong dự báo độ rỗng". *Tạp chí Dầu khí*, 7, pp 18-27.
5. Vũ Văn Tuấn (2019). "Mô hình mạng nơ ron nhân tạo ANN trong dự báo độ lún các lớp đất của hầm metro". *Tạp chí Khoa học công nghệ xây dựng*, 4 (186), pp 58-64.
6. Caudill Maureen (1988). "Neural networks primer, Part III". *AI Expert*, 3 (6), pp 53-59.
7. Goh ATC and Kulhawy FH (2003). "Neural network approach to model the limit state surface for reliability analysis". *Can Geotech Journal*, 40 (6), pp 1235-1244.

8. Hornik Kurt, Stinchcombe Maxwell, and White Halbert (1989). "Multilayer feedforward networks are universal approximators". *Neural networks*, 2 (5), pp 359-366.
9. Kim Y and Kim B (2008). "Prediction of relative crest settlement of concrete-faced rockfill dams analyzed using an artificial neural network model". *Comput Geotech*, 35 (3), pp 313-322.
10. Maier HR and Dandy GC (2000), Application of artificial neural networks to forecasting of surface water quality variables: issues, applications and challenges, in *Artificial neural networks in hydrology*. Springer. p. 287-309.
11. Rankine R and Sivakugan N (2005). "Prediction of paste backfill performance using artificial neural networks". in *Proceedings of 16th international society for soil mechanics and foundation engineering*. Osaka.
12. Rumelhart David E, Hinton Geoffrey E and Williams Ronald J (1985), Learning internal representations by error propagation, *California Univ San Diego La Jolla Inst for Cognitive Science*.
13. Shahin Mohamed A (2010). "Intelligent computing for modeling axial capacity of pile foundations". *Canadian Geotechnical Journal*, 47 (2), pp 230-243.
14. Vu Van Tuan (2020). "Research on the applicability of artificial neural network model to predict the average dimension of fragmentation and the volume of excavation for the electrical explosion model". *Journal of Science and Technique*, 4 (207), pp 25-36.
15. Yoo C and Kim J (2007). "Tunneling performance prediction using an integrated GIS and neural network". *Comput Geotech*, 34 (1), pp 19-30.
16. Kalantary Farzin and Kordnaeij Afshin (2012). "Prediction of compression index using artificial neural network". *Scientific Research and Essays*, 7 (31), pp 2835-2848.
17. Kingma Diederik P and Ba Jimmy (2014). "Adam: A method for stochastic optimization". *arXiv preprint arXiv:1412.6980*,
18. Shahin Mohamed A, Jaksa Mark B and Maier Holger R (2009). "Recent advances and future challenges for artificial neural systems in geotechnical engineering applications". *Advances in Artificial Neural Systems*, 2009, pp 5.

Ngày nhận bài: 04/6/2020.

Ngày nhận bài sửa lần cuối: 20/8/2020.

----- Original Message -----

Subject: Phan bien bai bao gui Tap chi KHCN Xay dung

From: <tapchi@ibst.vn>

Date: Tue, September 29, 2020 2:32 am

To: "nqviendhxd@hotmail.com" <nqviendhxd@hotmail.com>

**THE SELECTION OF THE MODEL GEOMETRY FOR ARTIFICIAL NEURAL NETWORK (ANN)
MODEL IN PREDICTING SOIL COMPRESSION INDEX**

The selection of the model geometry for artificial neural network (ANN) model in predicting soil compression index