

研究報告

人工智慧深度學習在臺灣地區臺灣杉人工林樹幹材積推估之研究

汪大雄¹、王兆桓²

摘要

單株立木材積之推估，在林分經營上一直是重要之議題。由於單株立木樹幹生長之高複雜性，必須使用和測量較多的變數進行材積之推估。過去在進行林分屬性(如材積)之推估時常用統計方法，進行線型和非線型迴歸模式之推估，然而近年來機器學習和人工智慧技術如人工神經網路(Artificial Neural Network, ANN)和深度學習演算(Deep Learning Algorithms, DLA)在單木和林分屬性推估上提供了一種新的模式研究方法。本研究是探討使用深度學習法，去推估臺灣杉立木材積，並和傳統之迴歸模式在精度上做一比較。本研究使用之臺灣杉立木，是來自臺灣人工林分布在各地永久樣區的所屬林分。以伐倒木的樹幹解析圓盤，進行林木區段求積，採用Newton法得到單株之實測材積。

樣木共170株，其中127株用來供擬合迴歸模式(擬合資料)與深度學習訓練模式(訓練資料)，另外43株用來進行驗證模式(驗證資料)。在迴歸模式法上使用5種模式，深度學習演算上之隱藏層從3層到10層，每層神經元數量從10開始，每次增加10，直到100，各隱藏層與神經元數量的組合模擬10次，總共執行模擬800次。使用9種準則進行模式效益評估。迴歸方法與深度學習法之比較：就擬合數據集的RMSE而言，DLA方法中的6層模型比迴歸方法的最佳模型具有高出15.6%的預測精度。對於擬合數據集的AAE，DLA方法中的6層模型比迴歸方法的最佳模型具有高出17.5%的預測準確度。對於驗證數據集，在DLA方法中，測試的8個模式中有6個顯示觀察到的數量和預測的數量之間沒有差異，但是在迴歸方法中，只有三個模型可以達到此效果。因此本研究顯示DLA方法在估計單株樹幹材積方面優於迴歸模式。

關鍵詞：樹幹材積，迴歸模式，深度學習

汪大雄、王兆桓。2024。人工智慧深度學習在臺灣杉人工林樹幹材積推估之研究。台灣林業科學 39(2): 113-27。

¹ 林業試驗所森林經營組，100051臺北市南海路53號 Forest Management Division, Taiwan Forestry Research Institute, No. 53 Nanhai Rd., Taipei 100051, Taiwan.

² 國立宜蘭大學森林暨自然資源學系，260007宜蘭縣宜蘭市神農路1段1號 Department of Forestry and Natural Resources, National Ilan University, No. 1, Sec. 1, Shennong Rd., Yilan City, Yilan County 260, Taiwan.

通訊作者：王兆桓 Corresponding author, Chao-Huan Wang, E-mail: wangandwen@yahoo.com.tw

2023年10月送審2024年5月通過。Received October 2023, Accepted May 2024.

Research paper

Using Deep Learning of Artificial Intelligence to Estimate Stem Volume in a *Taiwania* Plantation in Taiwan

Dar-Hsiung Wang,¹ Chao-Huan Wang²

ABSTRACT

Traditionally, regression models of the statistical framework are commonly used to model the relationships between various stand and tree attributes. Recently, artificial intelligence techniques, notably artificial neural network (ANN) and deep learning algorithms (DLA) have emerged as innovative alternatives for modeling and predicting certain tree and stand attributes. This paper investigates the use of deep learning algorithm (DLA) models to estimate the total tree volume of *Taiwania* trees (*Taiwania cryptomerioides*) in a plantation as an alternative to traditional regression models. Data was sourced from *Taiwania* trees from permanent plantation plots across Taiwan. Real tree volume was derived from stem analysis. A total of 170 trees were used, among which 127 trees were used for fitting and 43 trees were used for validation. For the statistical approach, five regression models were used. For the deep learning approach, the number of hidden layers varied from 3 to 10. For each hidden layer, the number of neurons ranged from 10 to 100, in increments of 10. Several evaluation criteria were used for modeling performance, including maximum absolute error (Max.AE), average absolute error (AAE), root mean squared error (RMSE), percent root mean squared error (RMSE%), average bias (BIAS), percent average bias (BIAS%), Akaike's information criterion (AIC), and Bayesian information criterion (BIC). In the fitting setting, model 4 achieved the best performance with the lowest RMSE of 0.0430. In the DLA approach, the model with 6 hidden layers and 90 neurons performed best, achieving an RMSE of 0.0363. Comparison of these two approaches showed that the DLA approach outperformed the regression approach by 15.6% in terms of RMSE. This study highlights the superiority of the DLA approach in estimating the volume of individual trees.

Keywords: stem volume, regression model, deep learning approach

Wang DH, Wang CH. 2024. Using Deep Learning of Artificial Intelligence to Estimate Stem Volume in a *Taiwania* Plantation in Taiwan. *Taiwan J For Sci* 39(2):113-27.

緒言

在面臨工業4.0之今天，人類生活環境充滿各式各類數據資料如物聯網、網路安全、智慧城市、電子商務、智慧通訊、電子媒體、和醫療健康等，為了能迅速聰明地分析各領域資料，發展出資料導向之智能和自動化應用體系，人工智慧，特別是機器學習，便是仰賴之主要工具(Sarker 2021a)。不僅在工業，近年內，機器學習在農業和自然資源之經營管理自動化應用上也有長足之進展。

機器學習(Machine Learning, ML)是指透過電腦產生，不須經人為編碼特別設計，就具有能自動從資料和經驗中學習能力和預測能力之系統或過程(Sarker et al 2020)。在學習過程中，機器學習模型會藉演算法處理資料，並試著朝特定方向調整參數，讓模型能夠產生最接近實際資料的結果。模型建立後輸入新資料進行結果之預測。

在過去數十年間，依據資料結構和演算法之類別，學者開發出多種機器學習演算模型，其中人工神經網路在機器學習上屬於無監督學習類(Liu et al. 2018, Sarker 2021a)。人工神經網路是指能模仿生物神經網路結構和功能之數學和計算模型(Liu et al. 2018)。人工神經網路是由許多人工神經元組成，所以，人工類神經網路是人工神經元構成的網路，而人工神經元則是一個數學單元，可在對輸入值進行簡單計算後，提供一些輸出值。人工神經網路內之人工神經元會組成不同之層數。典型之多層前饋神經網路(multi-layer feed-forward network)是由輸入層(input layer)、隱藏層(hidden layer)、和輸出層(output layer)構成(Pedregosa et al. 2011, Sarker 2021b)。神經網路可以依據內部訊息改變內部結構，因此，是種調整式體系(Haykin 2001)。

深度學習是機器學習的一個子領域，是一種以人工神經網路為架構，對資料進行表徵學習的演算法。此種演算法類似於人腦中使用神經元的方式。和傳統之機器學習相比，在處理學習大量資料時，深度學習之成效遠比機器學習高(Xin et al. 2018, Sarker et al. 2020)。深度學習根據人腦

的工作方式創建人工神經網路。通過人類遇到的例子，深度學習可教電腦學習一些我們人類可以輕鬆自然地做到的事情。一般人工神經網路是由1個輸入層，1個輸出層和1-2個隱藏層組成。

深度學習之人工神經網路含有較多個(超過3個)隱藏層。由於深度學習之人工神經網路需要很多層神經元(而且層層堆疊)才能從資料中學習，因此學者加了「深度」二字表示多個隱藏層，強調其結構之複雜性(Ercanli 2020)。深度學習演算之人工神經網路因能利用多數量之隱藏層，配合強有力之影像處理單元(graphical processing unit, GPU)，可以較人工神經網路更能表現出複雜系統、如森林生態系(Sarker 2021a)。

在傳統使用迴歸模式處理森林資料時，處理前資料必須滿足統計上資料來自獨立和常態分布、均質性殘差、變數間無多元共線性關係、和資料間無時間和空間自我相關之統計假設(Ercanli 2020)。在模式設置時須設定不同形式之模式，使用迴歸法推估各模式之參數。但在機器學習中，對資料不須有任何分布之要求，同時在學習中也不需預設定模式形式，純粹由機器自行在資料中學習資料間之相關性。

單株立木材積之推估，在林分經營上一直是重要之議題。由於單株立木樹幹生長之高複雜性，必須使用和測量較多的變數進行材積之推估。過去在進行林分屬性(如材積)之推估時常用統計方法，進行線型和非線型迴歸模式之推估(Schumacher and Hall 1933, Honer 1965, Baskerville 1972, Yen et al. 2008, Lee et al. 2017, Arturo et al. 2020, Sharma 2021, Valverde 2022)，然而近年來機器學習和人工智慧技術如人工神經網路(Artificial Neural Network, ANN)和深度學習演算(Deep Learning Algorithms, DLA)在單木和林分屬性推估上提供了一種新的模式研究法(Sarker 2021a)。

在遙測和製圖領域，機器學習能有效地改善物種分布模式之正確度(Pouveau et al. 2012)。在森林生態上，機器學習也應用在危險評估(hazard assessment) (Fassnacht et al. 2014, Hlásny et al. 2011)。此外，機器學習還用在單木尖削度(Nunes and Gorgens 2016)，和立木樹皮材積推估

(Diamantopoulou and Milios 2010)。

前人研究顯示深度學習演算能成功地推估立木樹高和胸高直徑間之關係(Ercanli 2020)，然而，到目前為止，尚未有利用深度學習演算進行單株立木材積推估之報告。國內第三次森林資源調查應用的臺灣杉材積式之年代已經久遠，且當時並無單獨針對臺灣杉人工林而發展，然而臺灣杉人工林的生長量常優於其他針葉樹種的林型，在臺灣森林碳吸存的角色越來越重要。本研究整理臺灣杉人工林圓盤資料，除了傳統的迴歸模式外，同時嘗試使用深度學習法，進行臺灣杉立木材積推估研究。本研究之目的如下：

1. 使用迴歸分析法推估臺灣杉立木材積。
2. 使用深度學習法推估臺灣杉立木材積。
3. 比較前述兩種方法推估結果之精度。

材料與方法

本研究使用之臺灣杉立木，是來自3個資料集的整合：(1)發展地位指數的樹幹解析資料，(2)發展尖削度方程式的圓木資料，(3)森林碳貯存量調查的圓木資料。前兩者取樣位於林試所六龜分所臺灣杉造林地之健康林木，第三者分散於林務局永久樣區臺灣杉未經疏伐造林地之健康立木。以伐倒木的圓盤資料，進行林木區段求積，採用Newton法得到單株之實測材積。總共有170株，其中127株用來供擬合迴歸模式(擬合資料)與深度學習訓練模式(訓練資料)，另外43株用來進行驗證模式(驗證資料)。另外，要取得圓盤資料成本高且耗時，所以要獲得大量的圓盤資料很困難，而本研究的深度學習模型之獨立變數只有樹高和胸徑兩個，且會檢測當胸徑和樹高越來越大時，預測的材積值“無下降走勢”(non-declining trend)，因此所需樣本可以較少。

迴歸模式法使用5種模式(Schumacher and Hall 1933, Honer 1965, Baskerville 1972, Yen et al. 2008, Lee et al. 2017, Arturo et al. 2020, Sharma 2021, Valverde 2022)，

$$V = b_1 + b_2 D^2 H \dots\dots\dots(\text{Model 1})$$

$$V = b_1 + b_2 D^2 + b_3 H + b_4 D^2 H \dots\dots\dots(\text{Model 2})$$

$$V = b_1 D b_2 H b_3 \dots\dots\dots(\text{Model 3})$$

$$V = b_1 + b_2 D b_3 H b_4 \dots\dots\dots(\text{Model 4})$$

$$V = \frac{D^2}{\left(b_1 + b_2 \frac{1}{H}\right)} \dots\dots\dots(\text{Model 5})$$

式中 V 為樹幹材積，以 m^3 為單位； D 為胸高直徑，以 m 為單位； H 為樹高，以 m 為單位； b_1, b_2, b_3, b_4 為迴歸係數。

深度學習演算

隱藏層從3層到10層，每層神經元數量從10開始，每次增加10，直到100，各隱藏層與神經元數量的組合模擬10次，總共執行模擬800次。資料分析在迴歸模式是使用SAS軟體，在深度學習演算上是使用R平台人工智慧H2O套裝軟體(R Development Core Team, 2018)。

模式評估準則(evaluation criteria)

本文使用下列準則進行模式效益評估(Ercanli 2020)，相關係數(correlation coefficient, r)，最大絕對誤差(maximum absolute error, Max.AE)，平均絕對誤差(average absolute error, AAE)，均方誤差根(root mean squared error, RMSE)，均方誤差根百分比(percent root mean squared error, RMSE%)，平均偏差(average bias, BIAS)，平均偏差百分比(percent average bias, BIAS%)，赤池資訊準則(Akaike's information criterion, AIC)，貝氏資訊準則(Bayesian information criterion, BIC)，個別公式如下所示：

$$r = \frac{\sum_{i=1}^n [(v_i - \bar{v}) \cdot (\hat{v}_i - \bar{\hat{v}}_i)]}{\sqrt{\sum_{i=1}^n (v_i - \bar{v})^2 \cdot \sum_{i=1}^n (\hat{v}_i - \bar{\hat{v}}_i)^2}}$$

$$\text{AAE} = \sum_{i=1}^n |v_i - \hat{v}_i| / n$$

$$\max. AE = \max(|v_1 - \hat{v}_1| \dots |v_i - \hat{v}_i| \dots |v_n - \hat{v}_n|)$$

$$RMSE = \sqrt{\sum_{i=1}^n (v_i - \hat{v}_i)^2 / (n - k)}$$

$$RMSE\% = \left[\sqrt{\sum_{i=1}^n (v_i - \hat{v}_i)^2 / (n - k) / \bar{v}} \right] \times 100$$

$$Bias = \sum_{i=1}^n (v_i - \hat{v}_i) / n$$

$$Bias\% = \left[\left(\sum_{i=1}^n (v_i - \hat{v}_i) / n \right) / \bar{v} \right] \times 100$$

$$AIC = n \cdot \ln(RMSE) + 2k$$

$$BIC = n \cdot \ln(RMSE) + k \cdot \ln(n)$$

式中 v_i 是第 i 株樣木的實測材積； \hat{v}_i 是第 i 株樣木的預測材積； \bar{v} 是實測材積的平均值； n 是樣木株數； \ln 是自然對數； k 於擬合模式時為迴歸模式的係數個數或為深度學習的解釋變數個數，但在驗證模式時 k 設為零。

除了對模式進行上述單一準則之評估外，使用相對排名法(Relative rank)(Poudel and Cao 2013, Ercanli 2020, Lin 2022)進行評估整體模式間的相對排名(Relative rank among methods)，合計所有評估準則的相對排名，得到越小值則為較佳的模式。評估某個準則的模式間相對排名之公式如下：

$$R_i = 1 + \frac{(m - 1)(S_i - S_{min})}{S_{max} - S_{min}}$$

式中 R_i 第 i 個模式的相對排名， S_i 是第 i 個模式的適合度統計量， S_{min} 是所有模式裡的最小值， S_{max} 是所有模式裡的最大值， m 是模式的總數。

模式的等效性檢驗(Equivalence Tests)

等效性檢驗是通過迴歸實測樹幹材積(X)和預測樹幹材積(Y)之間的關係來進行，採用兩個單側檢驗方法(Two one-sided tests method, TOST)

(Robinson and Froese 2004, Robinson et al. 2005) 計算截距和斜率參數的信賴區間。本研究基於迴歸的TOST是使用R中「equivalence」套裝程式(R Development Core Team, 2018)的拔靴法(bootstrap function)，以TOST測試截距(b_0)在 $\bar{v} \pm 10\%$ 的範圍內，以及斜率(b_1)在 $1 \pm 10\%$ 的範圍內(Ercanli 2020)。

過度擬合的理性檢查(checking rationality of overfitting)

人工智慧有時候會出現過度擬合的現象，它會在預測值裡顯現出不合理的跳點(pitfall)，因此必須檢查其預測值之間的合理性。以樹幹材積模式為例，一般而言，當胸徑和樹高越來越大時，合理的材積值不會反而減少，因此必須檢查各模式的預測結果是否符合“無下降走勢”(non-declining trend)。在迴歸模式中，由方程式與迴歸係數即可推論其結果是否合理，但是在人工智慧深度學習的結果，無法立即看出。因此須對個別深度學習模式的訓練資料集(training data set)與驗證資料集(validation data set)之預測結果，進行所有兩兩配對比較，對於任何配對林木，如果其中一株林木的胸高直徑和樹高皆不小於另一株林木的值時，則其材積應該不會小於另一株林木的材積，當所有配對都通過這項要求，才算是符合無下降走勢，也就沒有過度擬合。

結果

本研究使用於擬合模式與驗證模式的資料之統計量如Table 1所示，用為擬合資料的平均DBH、H、V分別為28.71 cm、17.93 m、0.64 m³，而用為驗證資料的平均DBH、H、V分別為28.46 cm、17.09 m、0.59 m³；擬合資料集裡有1株臺灣杉的DBH為78.8 cm較其他資料為大，故也具有較大的H為30.1 m和V為6.25 m³。雖然擬合資料集的平均DBH、H、V分別略為高於驗證資料集的平均值，但在 α 為0.05的顯著水準之下，各別DBH、H、V的兩資料集平均數無顯著的差異。

擬合迴歸模式的迴歸參數推算值、根均方誤

Table 1. Summary statistics for sample trees from fitting and validation data

	Number of trees and sample plots	Variables	Mean	Std. Deviation	Min.	Max.
Training	127 trees	DBH (cm)	28.71	9.47	10.40	78.80
		H (m)	17.93	4.10	8.57	30.10
		V (m ³)	0.64	0.63	0.05	6.25
Validation	43 trees	DBH (cm)	28.46	9.48	12.00	52.50
		H (m)	17.09	3.75	8.50	26.40
		V (m ³)	0.59	0.42	0.05	1.78

DBH: Diameter at breast height (cm); H: Total tree height (m), V: Tree stem volume (m³)

差(RMSE)、根均方誤差百分率(RMSE%)、平均絕對誤差(AAE)與平均偏差(Bias)如Table 2所示。模式1和模式2屬於線性迴歸模式(linear regression model)，故此兩個模式的Bias都會等於零。模式3至5屬於非線型迴歸模式，故常會顯現出些微的偏差，而其中的模式4的Bias非常小0.0001 m³。整體而言，迴歸模式中以模式4表現最好，RMSE為0.0430 m³，RMSE%為6.72%，AAE為0.0315 m³，以及Bias為0.0001 m³。

在人工智慧深度學習依照不同數量之隱藏層和神經元數量，以選擇預測表現最佳的最適網路結構，和前述的5個迴歸模式並列，共13個模式的適合度統計量(Goodness-of-fit statistics)如Table 3所示，預測值與觀測值的r值為0.9972 ~ 0.9986，RMSE為0.0363 ~ 0.0501，Bias為0.000 ~ 0.0107。迴歸模式5在任一個適合度統計量裡，都是表現最差的。將Table 3的適合度統計量的值依照相對

排名法的公式計算，並予合計，結果如Table 4所示。深度學習具6個隱藏層暨90個神經元的人工智慧模式在r、AAE、max.AE、RMSE、RMSE%、AIC和BIC表現最佳，迴歸分析的模式1和模式2在Bias和Bias%表現最佳。綜合相對排名以深度學習具6個隱藏層暨90個神經元的模式為最佳，其次為深度學習具5個隱藏層暨10個神經元的模式；整體而言，人工智慧深度學習的模式較迴歸模式為佳。

以驗證資料集進行模式的驗證結果如Table 5所示，等效性檢驗是透過迴歸實測樹幹材積(X)和預測樹幹材積(Y)之間的關係來進行。在測試截距下界與上界(b_0 limits)方面，設定 $\pm 10\%$ 的界線如該表的第3欄和第4欄所示，下界為0.5307，上界為0.6486，而拔靴法模擬結果顯示13個模式的拔靴法 b_0 下界與上界(Bootstrap b_0 limits)皆在(0.5307, 0.6486)的範圍內。在測試斜率下界與上

Table 2. Parameter estimations and variance components for the tree stem volume regression models

Regression Models	b_1	b_2	b_3	b_4	RMSE	RMSE%	AAE	Bias
Model 1	0.03780*	0.33188*			0.04484	7.0126	0.0331	0.0000
Model 2	0.00015555	-0.46176	0.00330*	0.34326*	0.04332	6.7749	0.0316	0.0000
Model 3	0.2320*	1.8861*	1.0966*		0.04549	7.1115	0.0333	0.0058
Model 4	0.0390*	0.1952*	1.9269*	1.1502*	0.04301	6.7218	0.0315	0.0001
Model 5	0.0105*	2.6659*			0.05010	7.8294	0.0374	0.0107

*Significant level at $\alpha = 0.05$

Table 5. Results of equivalence tests checking the rationality of overfitting for the best predictive deep learning algorithms of the number of neurons, the number of hidden layers and the 5 stem volume regression models

Number of neuron alternatives and regression models	Number of hidden layers	b_0 limits		Bootstrap b_0 limits			b_1 limits		Bootstrap b_1 limits			Non-decline
		lower	upper	lower	upper	H_0 : not Equivalent	lower	upper	lower	upper	H_0 : not Equivalent	Pass / No Pass
90 # neuron	3	0.5307	0.6486	0.5779	0.6151	Reject	0.9	1.1	0.9478	1.1052	not Reject	Pass
10 # neuron	4	0.5307	0.6486	0.5727	0.6083	Reject	0.9	1.1	0.9686	1.1157	not Reject	No Pass
10 # neuron	5	0.5307	0.6486	0.5757	0.6049	Reject	0.9	1.1	0.9686	1.0924	Reject	Pass
90 # neuron	6	0.5307	0.6486	0.5838	0.6093	Reject	0.9	1.1	0.9585	1.0429	Reject	Pass
50 # neuron	7	0.5307	0.6486	0.5804	0.6090	Reject	0.9	1.1	0.9211	1.0270	Reject	Pass
10 # neuron	8	0.5307	0.6486	0.5738	0.6024	Reject	0.9	1.1	0.9880	1.0758	Reject	Pass
80 # neuron	9	0.5307	0.6486	0.5813	0.6104	Reject	0.9	1.1	0.9383	1.0318	Reject	Pass
70 # neuron	10	0.5307	0.6486	0.5795	0.6064	Reject	0.9	1.1	0.9230	1.0185	Reject	Pass
model 1		0.5307	0.6486	0.5808	0.6100	Reject	0.9	1.1	0.9828	1.0930	Reject	Pass
model 2		0.5307	0.6486	0.5779	0.6069	Reject	0.9	1.1	0.9826	1.0810	Reject	Pass
model 3		0.5307	0.6486	0.5713	0.6014	Reject	0.9	1.1	1.0130	1.1093	not Reject	Pass
model 4		0.5307	0.6486	0.5756	0.6060	Reject	0.9	1.1	0.9733	1.0722	Reject	Pass
model 5		0.5307	0.6486	0.5699	0.6023	Reject	0.9	1.1	1.0152	1.1361	not Reject	Pass

“Reject”: no difference exists between observed and predicted volumes in the validation data set;

“Pass”: non-declining trend found in the procedure checking rationality of overfitting.

界(b_1 limits)方面，以及斜率(b_1)在 $1 \pm 10\%$ 的範圍內。設定 $1 \pm 10\%$ 的界線如該表的第8欄和第9欄所示，下界為0.9，上界為1.1，而拔靴法模擬結果顯示，有9個模式的拔靴法 b_1 下界與上界(Bootstrap b_1 limits)皆在(0.9, 1.1)的範圍內，但有4個模式的拔靴法 b_1 上界超出1.1，此4個模式包括：人工智慧深度學習3個隱藏層模式的拔靴法 b_1 上界為1.1052、而人工智慧深度學習4個隱藏層模式為1.1157，迴歸模式3的拔靴法 b_1 上界為1.1093、而迴歸模式5為1.1361。因此13個模式裡有9個模式通過等效性檢定，有4個未通過。未通過等效性檢定的模式主要在斜率 b_1 部分沒有通過，且都是拔靴法估算的上界值過大，意味著對於大材積的林木，其材積的預測值會有過大的風險。本研究模型的 r 值都大於0.99，解釋能力都很高。如果以更嚴格的標準來評估，採用5%的容忍度時，則 b_1 虛無假說的下界與上界為(0.95, 1.05)，表5顯示只有DLA 6

隱藏層拔靴法的下界與上界為(0.9585, 1.0429)還在範圍內，其他12個模式已經超出範圍，無法通過等效性檢驗。本研究參考迴歸模式已經有些實務上的應用先例，因此在實際應用上，本研究採用10%的容忍度是可被接受的。在Table 5的最後一欄為過度擬合的檢查，其要求當胸徑和樹高越來越大時，預測的材積值“無下降走勢”(non-declining trend)，通過者代表符合此要求；人工智慧深度學習的3、5、6、7、8、9和10個隱藏層模式通過此項檢查，只有4個隱藏層的模式未通過此項檢查，而5個迴歸模式皆符合此項檢查的要求。未通過等效性檢定的模式，其在驗證資料集具有較差的RMSE%(Table 6)，也具有較差的綜合相對排名合計值(Table 7)。

本研究幾乎所有的樣木樹幹材積皆小於2.5 m^3 ，僅有1株特別大樹的材積為6.25 m^3 且該株林木的預測良好，因此本研究對實測樹幹材積(X)和

Table 6. Goodness-of-fit statistics for the best predictive deep learning algorithms using the validation-data set of the number of neuron alternatives, the numbers of hidden layers, and the 5 regression models

Number of neuron alternatives and regression models	Number of hidden layers	r	AAE	max.AE	RMSE%	Bias%
90 # neuron	3	0.9903	0.0400	0.2572	10.4467	-1.0744
10 # neuron	4	0.9917	0.0407	0.2432	10.1601	-0.2909
10 # neuron	5	0.9936	0.0370	0.1830	8.6712	-0.1009
90 # neuron	6	0.9945	0.0304	0.1360	7.4477	-1.1280
50 # neuron	7	0.9934	0.0359	0.1338	8.1065	-0.9440
10 # neuron	8	0.9934	0.0379	0.1653	8.4291	0.3539
80 # neuron	9	0.9927	0.0358	0.1753	8.5617	-0.9000
70 # neuron	10	0.9937	0.0334	0.1412	8.0730	-0.4411
model 1		0.9932	0.0381	0.1809	9.0596	-1.0973
model 2		0.9933	0.0401	0.1689	8.8454	-0.4945
model 3		0.9939	0.0438	0.1817	9.5366	0.5511
model 4		0.9935	0.0402	0.1632	8.5669	-0.4009
model 5		0.9930	0.0442	0.2160	10.5783	0.5346

Table 7. Relative Rank values for the best predictive deep learning algorithms using the validation-data set of the number of neuron evaluated for various numbers of hidden layers and the 5 tree stem volume regression models

Number of neuron alternatives and regression models	Number of hidden layers	r	AAE	max.AE	RMSE%	Bias%	Σ
90 # neuron	3	13.00	9.34	13.00	12.50	12.37	60.21
10 # neuron	4	9.20	9.94	11.64	11.40	3.22	45.40
10 # neuron	5	3.60	6.78	5.78	5.69	1.00	22.85
90 # neuron	6	1.00	1.00	1.21	1.00	13.00	17.21
50 # neuron	7	4.14	5.77	1.00	3.53	10.85	25.29
10 # neuron	8	4.11	7.56	4.06	4.76	3.96	24.45
80 # neuron	9	6.26	5.67	5.04	5.27	10.34	32.58
70 # neuron	10	3.49	3.60	1.72	3.40	4.98	17.19
model 1		4.71	7.74	5.58	7.18	12.64	37.85
model 2		4.46	9.47	4.41	6.36	5.60	30.30
model 3		2.83	12.68	5.66	9.01	6.26	36.44
model 4		3.89	9.56	3.85	5.29	4.51	27.10
model 5		5.23	13.00	9.00	13.00	6.07	46.30

預測樹幹材積(Y)的關係圖，專注在樹幹材積小於 2.5 m^3 的樣木。人工智慧深度學習的訓練資料集擬合結果如Fig. 1所示，迴歸模式的擬合資料擬合結果如Fig. 2所示；一般而言，模式的擬合結果越好，其實測樹幹材積(X)和預測樹幹材積(Y)的分布點會越靠近斜率為1的對角線，而迴歸模式的分布點較為略寬於人工智慧深度學習模式的分布點。

Fig. 3與Fig. 4顯示驗證資料集的實測樹幹材積(X)和預測樹幹材積(Y)的關係圖，分別在人工智慧深度學習模式與迴歸模式的結果；並以圈號代表通過有效性檢定，而以叉號代表未通過，而未通過有效性檢定的4個模式的離開對角線的離群點略遠於其他模式的狀況。

討論

本研究是國內首度使用人工智慧技術中之深度學習法探討建立立木材積推估模式，並和傳統之迴歸模式在精度上做一比較。使用9種統計準則

評估不同之深度學習網路架構(隱藏層數和神經元數)，並選出最適之網路架構。相對排名顯示大部份所使用之DLA模式在預測立木材積時會較迴歸模式在統計上有較佳之表現。尤其DLA方法中的6層和90個神經元模型產生最佳之預測效果(Table 4)。

迴歸方法與深度學習法之比較：對於擬合數據集的RMSE，DLA方法中的6層模型比迴歸方法的最佳模式具有高出15.6%的預測精度。對於擬合數據集的AAE，DLA方法中的6層模型比迴歸方法的最佳模型具有高出17.5%的預測準確度。對於驗證數據集，在DLA方法中，測試的8個模式中有6個顯示觀察到的數量和預測的數量之間沒有差異，但是在迴歸方法中，只有三個模型可以達到此效果。

過度擬合是指預測力很高之AI訓練模型在面對新的資料時其預測力有顯著下降之現象。本研究使用獨立資料(驗證資料)。以等效性檢驗法來檢定DLA模式之過度擬合。從Table 5和統計準則來看DLA模式對驗證資料提供可接受結果，並產

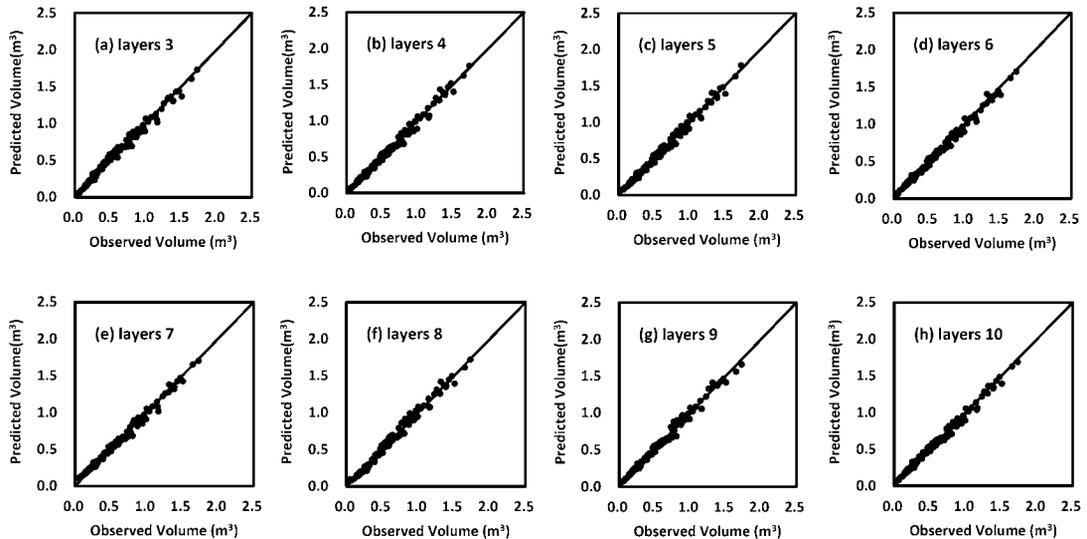


Fig. 1. Fitness of relationships between observed (x-axis) and predicted volume (y-axis) by the best performing deep learning network models using the training-data set: (a) 3 hidden layers, (b) 4 hidden layers, (c) 5 hidden layers, (d) 6 hidden layers, (e) 7 hidden layers, (f) 8 hidden layers, (g) 9 hidden layers, (h) 10 hidden layers

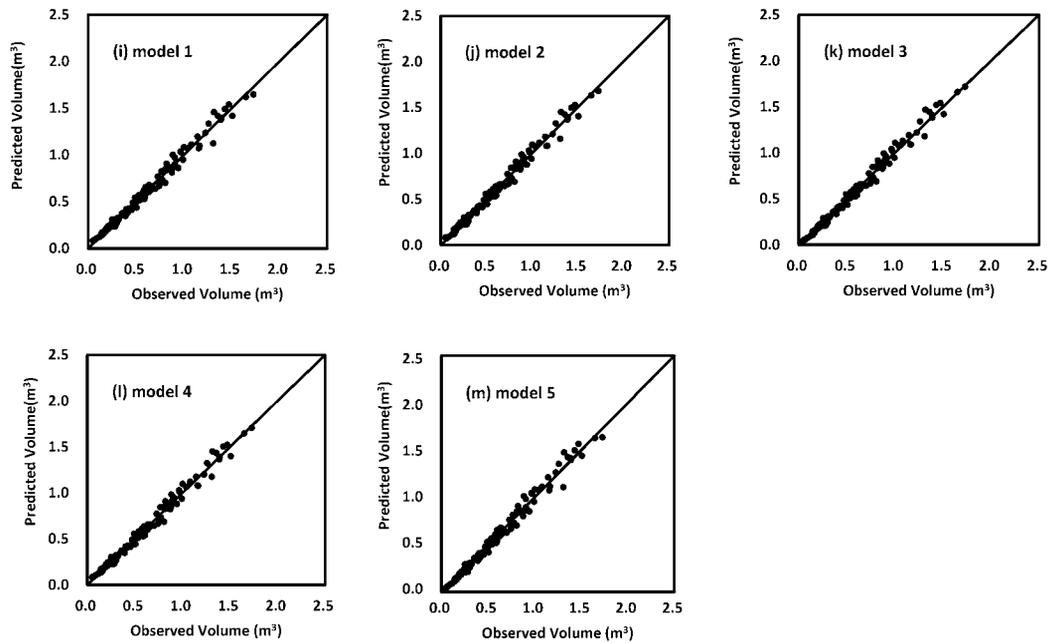


Fig. 2. Relationships between observed (x-axis) and predicted volume (y-axis) by the regression models using the training-data set: (i) model 1, (j) model 2, (k) model 3, (l) model 4, (m) model 5

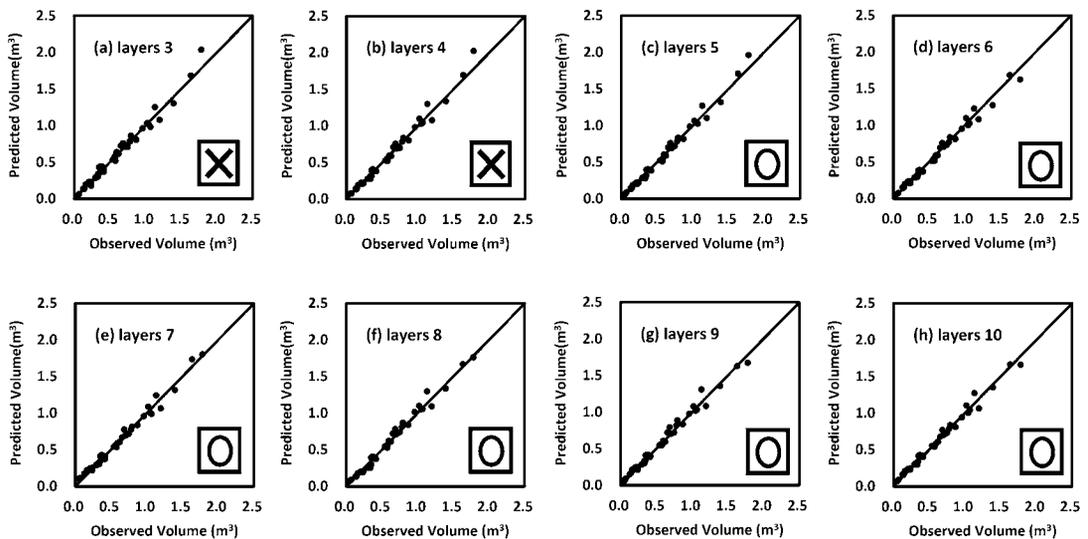


Fig. 3. Equivalence test results and relationships between observed (x-axis) and predicted volume (y-axis) by the best predictive deep leaning network models using the validation-data set: (a) 3 hidden layers, (b) 4 hidden layers, (c) 5 hidden layers, (d) 6 hidden layers, (e) 7 hidden layers, (f) 8 hidden layers, (g) 9 hidden layers, (h) 10 hidden layers. In each chart, an “X” indicates failure to pass the equivalence test, while an “O” indicates the equivalence test was passed.

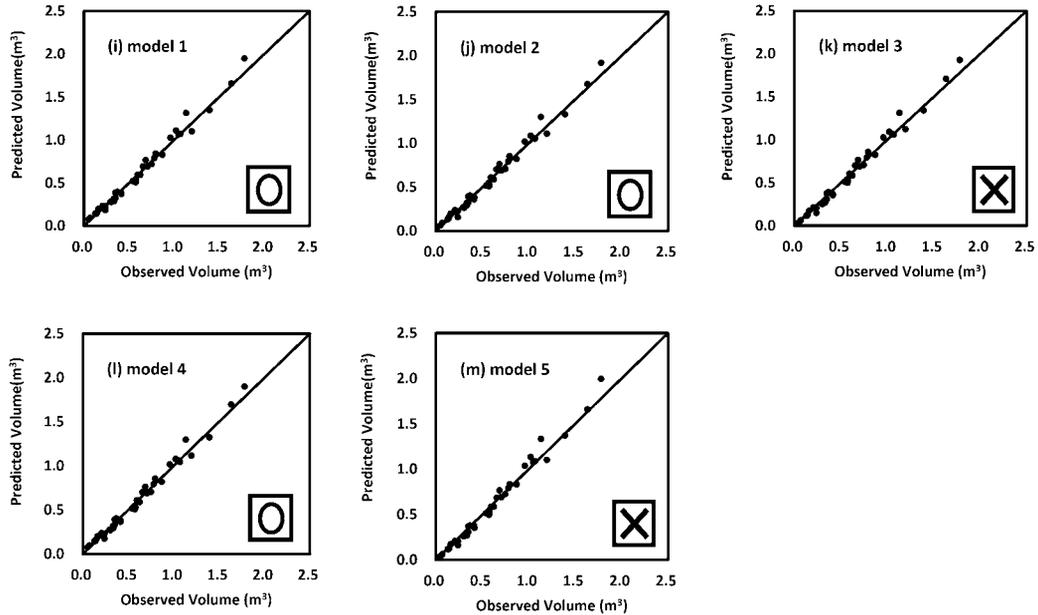


Fig. 4. Equivalence test results and the relationships between observed (x-axis) and predicted volume (y-axis) using regression models using the validation-data set: (i) model 1, (j) model 2, (k) model 3, (l) model 4, (m) model 5. In each chart, an “X” indicates the equivalence test failed, while an “O” indicates the equivalence test was passed.

生類似訓練資料之預測效果，顯示本研究產生之DLA模式沒有過度擬合現象。這可能是DLA模式在訓練時因有適當之重複，因而能成功地表現資料間之相關性之故(Ruder 2017)。因此決定最適DLA網路結構不但能增加DLA模式預測能力，還能克服在訓練DLA模式面臨獨立資料時產生過度擬合之問題(Ercanli 2020)。

在DLA雖然配置能力隨著隱藏層數量增加有明顯的改善，但是改善程度到某一數量就停止，甚至有變壞之情形。這可能是過多之層數造成模式變得太複雜，導致DLA模式因內含不成功之參數值，因此不能良好的掌握DBH、H和材積間之關係。Ercanli(2020)在使用DLA預測單木樹高和胸高直徑之研究也有類似之現象。本研究僅在從3個隱藏層足漸加到6個隱藏層的區間，有前述類似的現象；但在達到7個隱藏層後則會時好時壞，這可能是本研究的資料數量比較少，過多之層數造成模式變得太複雜。

在神經元數量方面DLA配置能力會隨著神經元數量增加呈現持續改善，這可能是雖然神經元數量增加會造成模式之複雜度，但因不會引致DLA模式參數值之不成功之故。Ercanli(2020)在使用DLA預測單木樹高和胸高直徑之研究也有類似之現象。然而本研究並沒有此現象，有些DLA模式如Table 3與Table 4所示的4、5和8個隱藏層模式，反而以10個神經元數的模式較佳；這可能是本研究的資料數量比較少，在訓練資料集裡只有127筆，而在驗證資料集裡也只有43筆，因而不一定會有DLA配置能力會隨著神經元數量增加(從10 到100)呈現持續改善。當考慮隱藏層數量和神經元數量間之交感作用，最適網路架構會得到不同結果。

由於DLA在應用時之計算過程複雜，因此需要密集使用電腦軟體。雖然有些DLA之應用平台是用不同之電腦語言發展出，但以R軟體語言發展出之H2O套裝軟體因具有使用者友善、找出解

答和比較不同網路結構之能力，成為人工智慧領域應用中之佼佼者(Ercanli 2020)。

網路參數如隱藏層數、神經元數和轉化函數(transfer function)等會影響DLA在訓練模式時之表現。本研究參考前人研究(Ercanli 2020)使用Rectifier 轉化函數。H2O套裝軟體在DLA訓練時採用調適學習率計算法(adaptive learning rate algorithm) ADADELTA，參數Rho 表示ADADELTA率，Epsilon表示DLA模式之學習率。本研究使用Rho值為0.999，Epsilon值為 1×10^{-8} 。除了上述之參數外，在訓練DLA模式時隱藏層數和每一層隱藏層所含之神經元數之選擇也很重要。本研究使用從DHA最小之3層到10層之8種隱藏層數和每層從10開始依序增加10到100之神經元數組合進行DLA之訓練。

迴歸模式中分析者可同時知曉方程結構式和參數數值，雖然DLA模式在預測上優於迴歸模式，但在DLA模式分析者雖然知道模式內隱藏層和神經元數量，但對模式內成千上萬之權數值不清楚，因此對結果不能進一步解釋說明。這也是DLA模式被稱為黑盒子之緣故。

深度學習模型和迴歸模型基本上有很大之差別，各有優缺點。

迴歸分析法推估臺灣杉立木材積，在實務應用上的優缺點如下：

優點：分析快速，且可解釋獨立變數與應變數之間的關係。其結果比較容易使用，只要使用一般能列出迴歸式的計算機、工作表或程式軟體，即可利用胸徑與樹高預測材積值。

缺點：限於已列出的迴歸式，無法自動處理複雜的多段非線性關係。

深度學習法推估臺灣杉立木材積，在實務應用上的優缺點如下：

優點：功能靈活，在預測能力上常可獲得較佳的結果。

缺點：分析耗時，且不可解釋獨立變數與應變數之間的關係。其結果必須先將模式內隱藏層、神經元、以及權數值儲存成一個資料集，於應用時需要使用與開發者相同軟體

(例如，R軟體與套件)才能應用。對於發展森林生長模擬器(Simulator)較為不方便。

本研究結果證實深度學習模型在預測能力上比迴歸模型優越，但在模型結果的解釋上之方便性不如迴歸模型。本文之主要貢獻是在顯示深度學習模型在單木材積資源預測上優於傳統之迴歸模型，但在應用上應視使用之目的、個人的設備與喜好來選擇適當之模型。

結論

本研究顯示DLA方法在估計單株樹幹材積方面優於迴歸模式。在決定模式的最合適結構來預測樹幹材積之前，應測試DLA方法中其不同層數和神經元組合之網路結構。由於DLA方法有不需要事先設定統計函數型態、高度強力處理資料間非線性關係能力、和不需任何統計假設之優點，加上持續之研究，因此DLA方法能期待成為未來在處理森林生長模式預測相關議題中之重要工具。

引用文獻

- Arturo AA, Francisco JZ, Karen ID. 2020.** A Procedure for Choosing Tree-Stem Volume Equations Previously Fitted in a Forest, *J. Sustain. For.* 39:595-607, DOI:10.1080/10549811.2020.1711776
- Baskerville GL. 1972.** Use of logarithmic regression in the estimation of plant biomass. *Can J For Res.* 2:49-53.
- Diamantopoulou MJ, Milios E. 2010.** Modeling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural network models. *Biosyst. Eng.* 105:306-15.
- Ercanli I. 2020.** Innovative deep learning artificial intelligence applications for predicting relationships between individual tree height and diameter at breast height. *For.*

- Ecosyst. 7:1-18.
- Fassnacht FE, Latifi H, Ghosh A, Joshi PK, Koch B. 2014.** Assessing the potential of hyperspectral imagery to map bark beetle-induced tree mortality. *Remote Sens. Environ.* 140:533-48.
- Haykin, SS. 2001.** *Neural networks: a comprehensive foundation.* Tsinghua University Press, Beijing.
- Hlásny T, Křístek Š, Holusa J, Trombik J, and Urbaňcová N. 2011.** Snow disturbances in secondary Norway spruce forests in Central Europe: Regression modeling and its implications for forest management. *For. Ecol. Manage.* 262: 2151-161. doi: 10.1016/j.foreco.2011.08.005
- Honer TG. 1965.** A new total cubic foot volume function. *Forest Chron.*41:476-93.
- Lee D, Seo Y, Choi J. 2017.** Estimation and validation of stem volume equations for *Pinus densiflora*, *Pinus koraiensis*, and *Larix kaempferi* in South Korea, *For. Sci. Technol.* 13:77-82, DOI: 10.1080/21580103.2017.1315963
- Lin ZR. 2022.** Quantifying Individual Tree Growth and Stand Structure for a Konishii Fir (*Cunninghamia konishii*) Plantation at Huisun Experimental Forest Station. Doctoral dissertation. National Chung Hsing University. R.O.C.
- Liu Z, Peng C, Work T, Candau JN, DesRochers A, Kneeshaw D. 2018.** Application of machine-learning methods in forest ecology: recent progress and future challenges. *Environ. Rev.* DOI: 10.11139/er-2018-0034
- Nunes NH, Gorgens EB. 2016.** Artificial intelligence procedure for tree taper estimation within a complex vegetation mosaic in Brazil. *PloS One.* 11:0154738.
- Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, et al. 2011.** Scikit-learn: machine learning in python. *J Mach Learn Res.* (12)2825-30.
- Poudel KP, Cao QV. 2013.** Evaluation of methods to predict Weibull parameters for characterizing diameter distributions. *For Sci* 59:243-52.
- Pouteau R, Meyer JY, Taputuarai R, Stoll B. 2012.** Support vector map rear and endangered native plants in Pacific islands forest. *Ecol. Inf.* 9:37-46.
- R Development Core Team. 2018.** R: A language and environment for statistical computing, R Foundation for Statistical Computing, Vienna, Austria.
- Robinson AP, Duursma RA, Marshall JD. 2005.** A regression-based equivalence test for model validation: shifting the burden of proof. *Tree Physiol* 25: 903-13.
- Robinson AP, Froese RE. 2004.** Model validation using equivalence tests *Ecol model* 176:349-58.
- Ruder S. 2017.** An overview of multi-task learning in deep neural networks. arXiv preprint, arXiv: 1706.05098.
- Sarker IH. 2021a.** Machine learning: algorithms, real world applications and research directions. *SN Computer Science* (2021)2:160.
- Sarker IH. 2021b.** Deep cybersecurity: a comprehensive overview from neural network and deep learning perspective. *SN Computer Sc.*
- Sarker IH, Kayes ASM, Badsha S, Alqahtani H, Watters P, Ng A. 2020.** Cybersecurity data science: an overview from machine learning perspective. *J Big Data.* 7:1-29.
- Sharma, M. 2021.** Total and Merchantable Volume Equations for 25 Commercial Tree Species Grown in Canada and the

Northeastern United States. *Forests* 2021, 12, 1270. <https://doi.org/10.3390/f12091270>

Schumacher FX, Hall FDS. 1933. Logarithmic expression of timber-tree volume. *J Agric Res.* 47:719-34.

Valverde JC, Rubilar R, Medina A, Mardones O, Emhart V, Bozo, et al. 2022. Generalized Tree Volume Equations for Eucalyptus Genotypes under Contrasting Irrigation. *Environ. Sci. Proc.* 22:70. <https://doi.org/10.3390/IECF2022-13074>

Xin Y, Kong L, Liu Z, Chen Y, Li Y, Zhu H, et al. 2018. Machine learning and deep learning methods for cyber-security. *IEEE Access.* 2018:6:35365-81.

Yen TM, Lee JS, Huang KL. 2008. Growth and yield models for thinning demonstration zones of Taiwan Red Cypress (*Chamaecyparis formosensis* Matsum.) and Japanese Cedar (*Cryptomeria japonica* D. Don) plantations in central Taiwan. *Q. J. For. Res.* 30:31-40.