

Articol original

Dezvoltarea Funcțiilor de Pedotransfer pentru Estimarea unor Proprietăți ale Solului Folosind Rețeaua Artificială Neurală și Abordările Regresiei Multivariate

A. KESHAVARZI^{1*}, F. SARMADIAN¹, M. SADEGHNEJAD², P. PEZESHKI³

¹Departamentul de Științe ale Solului, Universitatea din Teheran, Cutie Poștală: 4111, Karaj 31587-77871, Iran

²Departamentul de Adâncime de Pătrundere și de managementul Bazinelor de Recepție, Universitatea din Teheran, Cutie Poștală: 4111, Karaj 31587-77871, Iran

³Departamentul de Geologie și Științe ale Solului, Grupul de Resurse fizice ale Pământului, Universitatea Ghent, Krijgslaan 281 (S8), 9000, Ghent, Belgia

Primit 2 noiembrie 2010; recepționat și revizuit din 3 noiembrie 2010; acceptat 9 noiembrie 2010
Disponibil online 1 decembrie 2010

Rezumat

Studiul proprietăților solului ca de exemplu capacitatea câmpului (F.C.) și gradul de ofilire permanent (P.W.P) joacă un rol important în studiul umidității solului și a curbei de retenție. Deși acești parametri pot fi măsurați direct, măsurarea lor este dificilă și scumpă. Funcțiile de pedotransfer (PTF) asigură o alternativă prin estimarea parametrilor solului din date privitoare la sol care sunt mai rapid disponibile. În această investigație, 70 de probe de sol au fost colectate din orizonturi diferite a câte 15 profile localizate în regiunea Ziaran, provincia Qazvin, Iran. Datele au fost divizate în două subseturi de calibrare (80%) și testare (20%) ale modelelor și normalitatea lor a fost testată prin metoda Kolmogorov-Smirnov. Ambele regresii multivariate și tehnicile rețelei neurale artificiale (ANN) au fost utilizate pentru a dezvolta PTF-ul corespunzător pentru predicția parametrilor solului folosind caracteristici ușor măsurabile de argilă, mîl, O.C., S.P., B.D. și CaCO₃. Performanța regresiei multivariate și modelele ANN au fost evaluate folosind un set de test de date independent. Pentru a evalua modelele, eroarea de mijloc a radicalului valorii ridicate la pătrat (RMSE) și R² au fost folosite. Compararea RMSE-ului pentru cele două modele menționate a arătat că modelul ANN dă estimări mai bune ale F.C. și P.W.P. decât modelul de regresie multivariată. Valorile RMSE și R² care derivă din modelul ANN pentru F.C. și P.W.P. au fost (2,35, 0,77) și respectiv (2,83, 0,72). Valorile corespunzătoare pentru modelul de regresie multivariată au t (4,46, 0,68) și respectiv (5,21, 0,64). Rezultatele au arătat că ANN cu cinci neuroni în strat ascuns a avut performanță mai bună în previziunea proprietăților solului decât regresia multivariată.

Cuvinte cheie: rețea artificială neurală, capacitatea câmpului, gradul de ofilire permanent, funcțiile de pedotransfer, regresia multivariată

* Autorul căruia i se va adresa corespondența.
Tel./Fax: +982612231787
e-mail: alikeshavarzi@ut.ac.ir

1. Introducere

Capacitatea câmpului este definită ca și conținutul maxim de apă din sol la două până la trei zile după ce a fost uscat și drenajul liber este neglijabil. Gradul de ofilire este definit ca și conținutul de apă din sol în urma căruia frunzele de floarea soarelui se usucă în mod continuu [7]. Conținutul de apă din sol la capacitatea câmpului și gradul de uscare sunt folosite pentru a calcula adâncimea apei care trebuie aplicată la irigații [9], și pentru a determina disponibilitatea apei, care este un factor crucial în aserțiunea convenabilității ariei de pământ pentru a produce recolta dată [36]. Dezvoltarea de modele care simulează procesele solului a crescut rapid în anii recentți. Aceste modele au fost dezvoltate pentru a îmbunătăți înțelegerea proceselor importante ale solului și pentru a folosi ca unelte pentru evaluarea problemelor de agricultură și de mediu. În consecință, simularea modelelor este în prezent folosită în mod regulat în cercetare și management [22]. F.C., P.W.P. și capacitatea de schimb de cationi (CEC) sunt printre cele mai importante proprietăți ale solului care sunt cerute în bazele de date legate de sol [18], și sunt folosite ca date de intrare în modelele de sol și mediu [1,15]. În orice caz, proprietățile solului pot fi foarte variabile spațial și temporal și măsurarea lor consumă timpul și este scump de realizat. Ca rezultat, cel mai greu și scump pas către procesul de modelare a mediului este colectarea datelor. Termenul de funcție de pedotransfer (PTF) a fost evidențiat de Bouma [5] prin translatarea datelor disponibile (cele pe care le avem) în informații folositoare (cele de care avem noi nevoie). Adeseori, în orice caz, modelele dezvoltate pentru o regiune s-ar putea să nu dea estimări adecvate pentru o altă regiune [40]. O abordare mai avansată a modelului PTF-urilor este în a folosi tehnica ANN [33]. Spre deosebire de modelele convenționale, nu este nevoie de cunoștințe anterioare, sau de constante și/sau presupuneri despre caracteristicile de deformare ale geomaterialelor. Alte atribuții ale modelelor ANN sunt flexibilitatea și adaptabilitatea, care joacă roluri importante în modelarea materialului. Când un nou set de rezultate experimentale nu pot fi reproduse prin modele convenționale, un nou model constitutiv sau un set de ecuații constitutive noi trebuie dezvoltate. În orice caz, modelele ANN antrenate pot fi mai departe antrenate cu noul set de date pentru a câștiga informațiile adiționale cerute pentru a reproduce noile rezultate experimentale. Aceste elemente conving modelul ANN în a deveni un model obiectiv care poate într-adevăr reprezenta conexiunile naturale neurale printre variabile, mai degrabă decât un model subiectiv, care admite variabile care respectă un set de relații predefinite [3]. Pe scurt, o rețea neurală este alcătuită dintr-o intrare, un ascuns, și un strat de ieșire,

toate conținând „noduri”. Numărul de noduri din intrare (ex. densitatea grămezii de sol, datele particulelor de sol și etc.) și straturile de ieșire sunt fixe, i.e., corespund numărului variabilelor de intrare și ieșire ale modelului [19]. Un tip de ANN cunoscut ca perceptor multistrat (MLP), care utilizează un algoritm de antrenare a propagării în verso, este de obicei folosit pentru generarea PTF-urilor [1,22, 23, 33]. Această rețea folosește neuroni a căror ieșire este o funcție a unei sume cântărite a intrărilor. Avantajele majore ale rețelelor neurale față de cele două gupe de PTF-uri descrise anterior este că nu necesită cunoștințe anterioare ale relațiilor dintre datele de intrare și datele de ieșire [23]. În orice caz, datorită fezabilității lor mari, modelele ANN sunt în general considerate superioare modelelor MLR [1,23,31]. Multe studii legate de modelarea diferiților parametri ai solului care folosesc diferite tipuri de PDF-uri au fost realizate. Schaap et al. [33] au dezvoltat unele funcții de estimare a diferiților parametri ale lui van Genuchten, van Genuchten-moalem și ale ecuațiilor lui Gardner prin mijloace ANN. Rezultatele lor au arătat că odată cu creșterea datelor de intrare, acuratețea funcțiilor va crește. Omid et al. [26] a adaptat ANN-ul la adâncimea de secvență a modelului și la lungimea saltului, doi parametri importanți în designul bazinelor de purificare cu salturi hidraulice. 16 configurații, fiecare cu numere diferite de straturi ascunse și/sau neuroni au fost evaluate. Modelele optime au fost capabile în a previziona adâncimea secvenței și lungimea saltului pentru o gamă largă de condiții cu radicalul erorii de mijloc (MSE) de 10%. Un studiu comparativ printre MFNN și modelele empirice a fost de asemenea realizat. Ei au găsit că modelele ANN au avut performanțe superioare modelelor de regresie. Vos. et al. [39] au folosit 12 PTF-uri și baze de date braziliene pentru predicția densității grămezii. În mod similar, Heusser et al. [10] și Kaur et al. [14] au raportat că textura solului și conținutul de materie organică au fost parametri principali pentru estimarea densității grămezii. Najafi și Givi [24] au folosit metodele ANN și PTF pentru predicția densității grămezii solului. Ei au punctat că ANN-urile sunt capabile în a previziona densitatea grămezii solului mai bine decât PTF-urile. Amini et al. [1] au estimat capacitatea de schimb de cation (CEC) în centrul Iranului folosind materie organică de sol și conținut de argilă. Ei au utilizat ANN-ul și cinci modele experimentale care au stat la baza metodelor de regresie pentru predicțiile lor. Ei au arătat că rețeaua neurală PTF cu opt neuroni ascunși a fost capabilă în a previziona CEC-ul mai bine decât regresia PTF-urilor. De asemenea modelul ANN a îmbunătățit în mod semnificativ acuratețea predicției cu până la 25%. Ei au concluzionat că modelele rețelei sunt în general mai potrivite în a captura non-

linearitatea relațiilor între variabile. Jain și Kumar [12] au indicat că tehnicile ANN pot fi folosite cu succes pentru scopurile calibrării ecuațiilor de infiltrație. Ei au găsit de asemenea că ANN-urile sunt capabile de a avea performanțe foarte bune în situații de disponibilitate de date limitate. În contrast, Merdun et al. [20] au punctat că deși diferențele între regresii și modelele ANN au fost din punct de vedere statistic semnificative, regresia a previzionat variabilele punct și parametrice ale parametrilor hidraulici de sol mai bine decât ANN. Prezentul studiu a fost realizat cu obiectivul de a compara abilitatea ANN-urilor și a regresiei multivariate pentru estimarea F.C. și P.W.P folosind unii parametri ușor măsurabili în regiunea Ziaran a provinciei Qazvin, Iran.

2. Material și metodă

Aria de studiu

Pământul investigat în studiu este localizat în Ziaran (provincia Qazvin în Iran) care are o arie de aproximativ 5121 hectare; între latitudinea de $35^{\circ}58'$ și $36^{\circ}4'$ N și longitudinea de $50^{\circ}24'$ și $50^{\circ}27'$ E. Media, punctele de minimum și maximum ale districtului Ziaran sunt 1204, 1139 și respectiv 1269 m de la nivelul mării. Figura 1 arată aria de studiu din Iran. Umiditatea solului și regimurile de temperatură ale regiunii prin mijloacele softului Newhall sunt Slab Aride și respectiv Termice. Bazându-ne pe taxonomia solului [38], această regiune are soluri în ordinea Entisol și Aridisol.




Figura 1. Localizarea ariei de studiu

Colectarea datelor și analiza monstrelor de sol

După studii preliminare ale hărților topografice (1 : 25000), folosind GPS, localizarea studiului a fost punctată. 70 de monstre de sol au fost colectate din diferite orizonturi a câte 15 profiluri (Fig. 1).

Au fost măsurați parametrii solului inclusiv textura (determinată folosind metoda hidrometrării Bouyoucos), și carbonul organic (determinat folosind metoda Walkley-Black) [27]. Metoda bulgărelui de pământ [4] a fost folosită pentru a determina densitatea grămezii (B.D.).

Conținutul de umiditate la capacitatea câmpului și la punctul de ofilire au fost determinate cu un aparat de presiune plat la -33 și respectiv -1500 kPa [6].

Procentul de saturație al apei (SP) și conținutul de CaCO_3 au fost determinate folosind gravimetria și respectiv metodele Calcimetrice [35].

Metode care se potrivesc PTF-urilor

Regresia multivariată

Cea mai comună metodă utilizată pentru estimarea PTF-urilor este de a lucra cu regresii multiple lineare. De exemplu :

$$Y = aX_1 + bX_2 + cX_3 + \dots \quad (1)$$

unde Y denotă variabile dependente, X_i ($i=1,2,\dots,n$) este variabilă independentă și a, b, \dots sunt coeficienți necunoscuți ai modelului.

Rețeaua artificială neurală

Clasificatorii neurali se confruntă cu numeroase probleme multivariabile nonlineare, pentru care o soluție corectă analitică este dificil de obținut [30]. O rețea neurală artificială este o rețea extrem de interconectată a mai multe unități simple de procesare numite neuroni, care sunt analogi neuronilor biologici în creierul uman. Neuronii care au caracteristici similare într-un ANN sunt aranjați în grupe numite straturi. Neuronii dintr-un strat sunt conectați cu cei din straturile adiacente, dar nu cu cei din același strat. Într-o rețea de alimentare înaintată, conexiunile cântărite alimentează activările numai în direcția dinainte de la un strat de intrare la un strat de ieșire. Pe de altă parte, într-o rețea recurentă sunt utilizate conexiuni cântărite adiționale pentru a alimenta activările anterioare înapoi în rețea. Structura unui ANN alimentat înainte este arătată în figura 2. Acest ANN este o rețea neurală populară care este cunoscută drept algoritmul propagării în verso introdusă de Karaca și Ozkaya [13]. Acest ANN a avut k intrări și

un parametru de ieșire. Ei au folosit acest ANN pentru modelarea exactă a divulgării ratei de scurgere. Ei au raportat de asemenea că parametrii de intrare, numărul de neuroni la stratul ascuns și de intrare ar trebui determinați conform datelor adunate în mod curent. Chiar mai mult, un pas important în dezvoltarea modelului ANN este antrenarea matricei sale de greutate. Greutățile sunt inițializate în mod întâmplător între game potrivite, și după aceea sunt actualizate folosind anumite mecanisme de antrenare [23, 28, 33]. În rețelele de alimentare înainte,




Figura 2. Structura de alimentare înainte a ANN

Criteriile de performanță

Performanța modelelor a fost evaluată cu un set de date de test folosind eroarea radicalului erorii de mijloc la pătrat (RMSE) și coeficientul de determinare (R^2) între valorile previzionate și măsurate. RMSE-ul este o măsură de acuratețe și de nădejde pentru calibrare și seturile de date test [41] și este definită ca:

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (z_o - z_p)^2} \quad (2)$$

unde Z_o este valoare observată, Z_p este valoare previzionată și n este numărul de mostre. Softul NeuroSolutions 5.0 a fost utilizat pentru designul și testarea modelelor ANN. Datele au fost subdivizate în două seturi: 80% pentru antrenarea rețelelor și 20% care au rămas pentru testarea scopurilor. Parametrii de sol inclusiv argila, nămolul, O.C., $CaCO_3$, SP și BD au fost date de intrare pentru predicționarea celor două date de ieșire (F.C. și P.W.P.). În acest studiu, structurile ANN au fost toate constituite dintr-un strat

minimizarea erorii poate fi obținută printr-un număr de proceduri inclusiv Gradient Descent (GD), Levenberg-Marquardt (LM) și Gradientul Conjugat (CG). BP folosește o tehnică gradient descendentă (GD) care este foarte stabilă când o rată de învățare mică este utilizată, dar are proprietăți de acoperire încete. În acest studiu, algoritmul LM, în sensul unui termen de moment este utilizat pentru a grăbi

ascuns, o funcție de activare sigmoidă în strat ascuns și o funcție de activare lineară în stratul de ieșire și un algoritm LM a fost folosit pentru a antrena rețelele datorită eficienței, simplității și vitezei mari. Pentru a dezvolta un model statistic de sunet, rețelele au fost antrenate de trei ori și cele mai bune valori au fost înregistrate pentru fiecare parametru [27]. Pentru a evita „supra-ajustarea”, subsetul MSE și CV a fost calculat după ajustarea greutăților și biasurilor. Procesul de antrenare a continuat până a fost atins minimul MSE a seturilor de validare (schema de stopare devreme). Greutățile rețelei și biasurile sunt după aceea adaptate și angajate pentru validare pentru a putea determina toată performanța modelului rețelei neurale.

3. Rezultate și discuții

Sumarul statisticilor de date

Sumarul datelor seturilor de antrenare și testare sunt prezentate în tabelul 1 și respectiv 2. Coeficienții de corelație simpli lineari (r) printre F.C., P.W.P. și variabilele independente au fost de asemenea calculați (tabelul 3).

Tabelul 3 ilustrează corelațiile între SP, argilă și F.C. și de asemenea corelațiile dintre SP, argilă și P.W.P. au fost pozitive și foarte semnificative. De exemplu corelația

de-asemena, coeficienții de corelație între B.D. și conținutul O.C. ($r = -0,58$) este mai degrabă mai

	Soil	Min	Max	Mean	Std
	parameter				
Testing set	Clay (%)	17,20	54,80	29,99	10,49
	Silt (%)	6,00	40,80	22,44	11,58
	O.C (%)	0,19	0,66	0,38	0,13
	CaCO ₃ (%)	11,00	30,20	17,32	5,01
	SP (%)	28,62	59,51	39,07	9,61
	B.D (g/cm)	1,26	1,70	1,46	0,13
	F.C (%)	14,40	29,62	19,61	4,81
	P.W.P (%)	6,81	15,20	9,96	2,63

mare decât între B.D. și S.P. ($r = -0,27$). În orice caz, legat de acești coeficienți de corelație amândoi sunt potriviți pentru dezvoltarea PTF-urilor pentru predicția F.C. și P.W.P. în solurile regiunii Ziaran.

În mod similar aceste corelații între F.C. și SP ($r = 0,95$) și de-asemena, între P.W.P. și SP ($r = 0,90$) au fost pozitive și semnificative.

Corelațiile între CaCO₃ și conținutul de argilă ($r = 0,59$) și între CaCO₃ și SP ($r = 0,49$) au fost relativ mari. În aditie, legat de acest tabel este clar că B.D. este corelat în mod negativ cu F.C. ($r = -0,29$) și P.W.P. ($r = -0,23$). Referitor la tabelul 3, ecuațiile de regresie multivariată au fost dezvoltate pentru studiul parametrilor folosind softul SPSS 15.

Am selectat numai un model de regresie care a avut un coeficient de determinare (R^2), mai mare decât 0,5 [1,17].

După determinarea Ec. (3) și (4), performanța regresiei multivariate a fost dezvoltată pentru setul de date test.

Coeficientul de determinare (R^2) și RMSE pentru F.C. și P.W.P. au obținut 0,68, 4,46 și respectiv 0,64, 5,21.

Sarmadian et al. [31] a observat de-asemena corelații similare între coeficienți în rezultatele lor pentru F.C. ($r = 0,75$) și P.W.P. ($r = 0,66$).

Dezvoltarea PTF-urilor folosind rețeaua artificială neurală

Pentru dezvoltarea F.C.-ului și P.W.P.-ului prin mijloace ANN, caracteristica vectorului de intrare a fost similară celor folosite pentru regresia multivariată lineară. În prezentul studiu pentru a preziona proprietățile solului nu am crescut datele de intrare pentru construcția ANN, deoarece conform descoperirilor lui Lake et al. [17] și Amini et al. [1] creșterea numărului de intrări va scădea acuratețea estimărilor.

De exemplu, pentru predicționarea caracteristicilor solului dacă doar un tip de date de

intrare au coeficienți scăzuți la datele de ieșire, acuratețea modelului va scădea automat. Ca urmare,

	Soil	Min	Max	Mean	Std
	parameter				
Training set	Clay (%)	4,40	55,60	22,30	11,83
	Silt (%)	2,80	62,80	30,10	12,86
	O.C (%)	0,04	1,10	0,35	0,23
	CaCO ₃ (%)	2,86	25,4	10,63	5,92
	SP (%)	21,18	65,67	34,76	9,26
	B.D (g/cm)	1,20	1,71	1,50	0,11
	F.C (%)	10,80	32,50	17,38	4,65
	P.W.P (%)	5,72	16,40	9,02	2,36

stratul de intrare ANN constă din șase date în acest model în care există variabile exploratorii, anume, argilă, nămol, O.C., CaCO₃, SP și B.D. După randomizarea și împărțirea setului de date în date de antrenare și testare, variate structuri ANN ale topologiei 6-k-2, de exemplu, rețelele având șase neuroni în stratul de intrare, unul ascuns cu un număr diferit de neuroni ($k = 1,2, \dots, 10$) și doi neuroni (F.C. și P.W.P.) ca strat de ieșire au fost concepuți. Structura optimă a rețelei a fost decisă prin mijloace R^2 și criterii RMSE. Valorile RMSE pentru variații k (număr de neuroni în strat ascuns) corelate de parametrii solului studiați sunt prezentate în figura 3 și 4. Este arătat în această figură că nivelul minim al RMSE pentru F.C. și P.W.P. este legat de rețea având cinci neuroni în stratul ascuns. De-asemena, legat de această figură se poate realiza că odată cu creșterea numărului de neuroni, eficiența totală a modelelor va scădea, cea mai mare performanță legată de rețele care au număr optim de neuroni de exemplu este 6-5-2-MLP. Nivelurile RMSE și R^2 pentru F.C. și P.W.P. au fost 2,35, 0,77 și respectiv 2,83, 0,72. În aditie, nivelurile R^2 (și RMSE) derivate din ANN pentru parametrii solului studiați au avut valori mai ridicate (și mai scăzute) decât cele derivate din regresia multivariată lineară (tabelul 4) care este în linie cu lucrul înfăptuit de Sarmadian et al. [31], Amini et al. [1], Tamari et al. [37], Minasny și McBratney [22] și Schaap et al. [33].




Figura 3. Valorile RMSE pentru 1-10 neuroni în strat ascuns




Figura 4. Valorile RMSE pentru 1-10 neuroni în strat ascuns (P.W.P.)

Schaap et al. [33] au confirmat aplicabilitatea ANN-urilor și au concluzionat că

Tabelul 4. Parametrii calculați statistic în stadiul de test pentru diferite metode bazate pe funcțiile de pedotransfer

	Multivariate linear regression (F.C)	Multivariate linear regression (P.W.P)	Artificial neural network (F.C)	Artificial neural network (P.W.P)
RMSE	4,46	5,21	2,35	2,83
R ²	0,68	0,64	0,77	0,72




Figura 5. Lotul împrăștiat al măsurătorilor versus F.C.-ul previzionat




Figura 6. Lotul împrăștiat al măsurătorilor versus P.W.P.-ul previzionat

Motivul pentru această eficiență superioară a modelelor ANN comparate cu ecuațiile regresiei de bază sunt probabil pentru că PTF-urile care derivă din variate arii au eficiențe diferite. Pe de altă

acuratețea acestor modele depind de numărul de intrări. Amini et al. [1] a găsit că modelele de rețea neurale au furnizat predicții pe care te poți baza față de PTF-urile în regresie. Koekkoek și Booltink [16] au găsit că ANN a avut performanțe ușor mai bune, dar diferențele nu au fost semnificative. Modelele de rețea pentru F.C. și P.W.P. au fost mai potrivite în a captura non-linearitatea relațiilor între variabile.

Așadar, conform acestor diagrame, cea mai bine potrivită linie are unghiul aproape de 45° care arată cea mai mare acuratețe a estimării prin modelul ANN.

parte, conform ipotezei lui Schaap et al. [33], pentru crearea unei rețele neurale nu avem nevoie de o ecuație specială.

În orice caz, ei cred că odată cu crearea unei ecuații potrivite între datele de intrare și ieșire noi suntem capabili în a realiza cele mai bune rezultate. De-asemena, datorită nonlinearității moștenite între variabilele exploratorii și variabilele previzionate, rețelele neurale au o eficiență mai bună comparate cu ecuațiile de regresie de bază. Pachepsky et al. [28] au investigat acuratețea ANN-urilor și au analizat metoda de regresie folosind un coeficient de corelație și RMSE. Ei au raportat ca rețeaua neurală este capabilă în a previziona parametrii de sol ușor măsurabili cu o acuratețe mai mare și o eroare mai mică. Analiza parametrilor ANN a sugerat că mai multe variabile de intrare au fost necesare pentru a îmbunătăți predicția parametrilor de sol [21,37].

Diferențele între determinările de câmp și laborator a datelor referitoare la retenția apei ar putea fi asociate cu reprezentarea insuficientă a porilor mari în laborator, tulburări monștră și variații spațiale, hysteresis și efecte de scară legate de monștra dimensională [8,21,34]. Pachepsky și Rawls [29] au găsit diferențe semnificative între conținuturile de apă volumetrică de câmp și laborator pentru orizonturi de sol grosiere, intermediare și fine. Ca urmare, erori de măsurare ar putea cauza o predicție slabă a parametrilor.

4. Concluzii

În acest studiu, regresia multivariată lineară și modelul rețelei neurale (rețea de propagare în verso alimentată în față) au fost angajate pentru a dezvolta o funcție de pedotransfer pentru a predicționa F.C.-ul și P.W.P.-ul solului folosind proprietăți ale solului disponibile. Pentru a predicționa proprietățile solului prin mijloace PTF, datele de intrare au fost considerate argilă, nămol, O.C., CaCO₃, SP și B.D. pentru F.C. și P.W.P.. Performanța regresiei multivariat lineare și modelul rețelei neurale au fost evaluate folosind un set de date test. Rezultatele au arătat că ANN cu cinci

neuronii în strat ascuns a avut o performanță mai bună în predicția F.C.-ului și P.W.P.-ului de sol decât regresia multivariată. Modelul rețelei pentru acești parametri a fost mai potrivit în a captura non-linearitatea relațiilor între variabile. ANN poate modela funcții non-lineare și a arătat că există performanță mai bună decât regresia lineară. Referitor la criteriile evaluate, rezultatele acestui studiu au pus în evidență că ANN-urile au avut superioritate ecuațiilor de regresie de bază pentru a prezice parametrii de sol menționați. Acesta este un rezultat crucial, având în vedere că ANN-PTF-urile au format din produsul de date locale predicții mai exacte decât acelea construite din date răspândite dintr-o arie mai largă, conceptul de conservare a datelor devine un factor critic în construcția ANN-PTF [2]. În orice caz, datorită dificultăților de măsurare directă a parametrilor de sol, noi recomandăm folosirea modelelor neuro-vagi cum ar fi ANFIS în studiile viitoare pentru a obține ecuații logice ale altor parametrii de sol, în special proprietățile hidraulice ale solului, în fiecare arie. Prin supraproformarea tehnicilor de modelare empirice, ANN are un mare dezavantaj – este greu să desenezi orice informație fizică din el, de exemplu nici o informație de la greutatea neuronilor și a biasurilor nu poate fi desenată cu privire la greutatea fiecărui predictor la scorul final [27]. Nu în ultimul rând, datorită rezultatelor mai bune ANN-urile au fost des folosite în ultimii 10 ani pentru a rezolva problemele non-lineare ale complexității ridicate.

Mulumiri

Srijinul financiar furnizat de Universitatea din Teheran, Iran, este recunoscut în grație.

References

- [1] Amini M., K.C. Abbaspour, H. Khademi, N. Fathianpour, M. Afyuni, R. Schulin, 2005, Neural network models to predict cation exchange capacity in arid regions of Iran. *European Journal of Soil Science*, 53, 748 - 757
- [2] Baker L., D. Ellison, 2008, Optimisation of pedotransfer functions using an artificial neural network ensemble method. *Geoderma*, 144, 212 - 224
- [3] Banimahd M., S.S. Yasrobi, P.K. Woodward, 2005, Artificial neural network for stress-strain behavior of sandy soils: Knowledge based verification. *Comput. Geotech*, 32, 377 - 386
- [4] Blake G.R., K.H. Hartge, 1986, Particle density. In: Klute A., (eds.) *Methods of soil analysis. Part 1, Agron Monogr 9, ASA, Madison*, 377 - 382
- [5] Bouma, J., 1989, Using soil survey data for quantitative land evaluation. *Advances in Soil Science*, 9, 177 - 213
- [6] Cassel D.K., D.R. Nielsen, 1986, Field capacity and available water capacity. In: Klute A., (eds.) *Methods of Soil Analysis. Part 1, 2nd edition, Agron Monogr 9, ASA and SSSA, Madison*, 901 - 926
- [7] Cavazza L., A. Patruno, E. Cirillo, 2007, Field capacity in soils with a yearly oscillating water table. *Biosystems Engineering*, 98, 364 - 370
- [8] Field J.A., J.C. Parker, N.L. Powell, 1984, Comparison of field- and laboratory measured and predicted hydraulic properties of a soil with macropores. *Soil Science*, 138, 385 - 396
- [9] Givi J., S.O. Prasher, R.M. Patel, 2004, Evaluation of pedotransfer functions in predicting the soil water contents at field capacity and wilting point. *Agricultural Water Management*, 70, 83 - 96
- [10] Heuser S.A., C.C. Brandt, P.M. Jardin, 2005, Using soil physical and chemical properties to estimate bulk density. *Soil Sci Soc Am J*, 69, 51 - 56
- [11] Hillel D., 1998, *Environmental Soil Physics*. Academic Press, New York, USA
- [12] Jain A., A. Kumar, 2006, An evaluation of artificial neural network technique for the determination of infiltration model parameters. *Appl Soft Comput*, 6, 272 - 282
- [13] Karaca F., B. Ozkaya, 2006, NN-LEAP: A neural network-based model for controlling leachate flow-rate in a municipal solid waste landfill site. *Environ Modell Software*, 21, 1190 - 1197
- [14] Kaur R., S. Kumar, H.P. Gurung, 2002, A pedotransfer function soil data and its comparison with existing PTFs. *Aust J Soil Res*, 40, 847 - 857
- [15] Keller A., B. Von Steiger, S.T. Vander Zee, R. Schulin, 2001, A stochastic empirical model for regional heavy metal balances in agroecosystems. *Journal of Environmental Quality*, 30, 1976 - 1989
- [16] Koekkoek E.J.W., H. Booltink, 1999, Neural network models to predict soil water retention. *Eur J Soil Sci*, 50, 489 - 495
- [17] Lake H.R., A. Akbarzadeh, R. Taghizadeh Mehrjardi, 2009, Development of pedotransfer functions (PTFs) to predict soil physico-chemical and hydrological characteristics in southern coastal zones of the Caspian Sea. *Journal of Ecology and the Natural Environment*, 1(7), 160 - 172
- [18] Manrique L.A., C.A. Jones, P.T. Dyke, 1991, Predicting cation exchange capacity from soil physical and chemical properties. *Soil Sci Soc Am J*, 50, 787 - 794

- [19] Manyame C., C.L. Morgan, J.L. Heilman, D. Fatondji, B. Gerard, W.A. Payne, 2007, Modeling hydraulic properties of sandy soils of Niger using pedotransfer functions. *Geoderma*, 141, 407 - 415
- [20] Merdun H., O. Cinar, R. Meral, M. Apan, 2006, Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil Till Res*, 90, 108 - 116
- [21] Mermoud A., D. Xu, 2006, Comparative analysis of three methods to generate soil hydraulic functions. *Soil Till Res*, 87, 89 - 100
- [22] Minasny B., A.B. McBratney, 2002, The neuro-m methods for fitting neural network parametric pedotransfer functions. *Soil Sci Soc Am J*, 66, 352-361
- [23] Minasny B., A.B. McBratney, K.L. Bristow, 1999, Comparison of different approaches to the development of pedotransfer functions for water retention curves. *Geoderma*, 93, 225 - 253
- [24] Najafi M., J. Givi, 2006, Evaluation of prediction of bulk density by artificial neural network and PTFs. 10th Iranian Soil Science Congress, Karaj. 680 - 681
- [25] Nelson D.W., L.E. Sommers, 1982, Total carbon, organic carbon, and organic matter. In: Page A.L., Miller R.H., Keeney D.R., (eds.), *Methods of Soil Analysis. Part II*, 2nd edn. American Society of Agronomy, Madison, WI, USA, 539 - 580
- [26] Omid M.H., M. Omid, M.E. Varaki, 2005, Modeling hydraulic jumps with artificial neural networks. *Proceedings of ICE-Water Management*, 158(2), 65 - 70
- [27] Omid M., A. Baharlooei, H. Ahmadi, 2009, Modeling drying kinetics of pistachio nuts with multilayer feed-forward neural network. *Drying Tech*, 27, 1069 - 1077
- [28] Pachepsky Y.A., D. Timlin, G. Varallyay, 1996, Artificial neural networks to estimate soil water retention from easily measurable data. *Soil Sci Soc Am J*, 60, 727 - 733
- [29] Pachepsky Y.A., W.J. Rawls, 2003, Soil structure and pedotransfer functions. *Eur J Soil Sci*, 54: 443-451
- [30] Park B.J., W. Pedrycz, S.K. Oh, 2010, Polynomial-based radial basis function neural networks (P-RBFNNs) and their application to pattern classification. *Applied Intelligence*, 32, 27 - 46
- [31] Sarmadian F., R. Taghizadeh Mehrjardi, A. Akbarzadeh, 2009, Modeling of some soil properties using artificial neural network and multivariate regression in Gorgan province, north of Iran. *Australian J of Basic and Applied Sci*, 3(1), 323 - 329
- [32] Schaap M.G., F.J. Leij, 1998, Using neural networks to predict soil water retention and soil hydraulic conductivity. *Soil Till Res*, 47, 37 - 42
- [33] Schaap M.G., F.J. Leij, M.Th. Van Genuchten, 1998, Neural network analysis for hierarchical prediction of soil hydraulic properties. *Soil Sci Soc Am J*, 62, 847 - 855
- [34] Shuh W.M., R.D. Cline, M.D. Sweeney, 1988, Comparison of a laboratory procedure and a textural model for predicting in situ water retention. *Soil Sci Soc Am J*, 52, 1218 - 1227
- [35] Sparks D.L., A.L. Page, P.A. Helmke, R.H. Leppert, P.N. Soltanpour, M.A. Tabatabai, G.T. Johnston, M.E. Summer, 1996, *Methods of soil analysis*, Soil Science Society of America Journal, Madison, Wisconsin
- [36] Sys Ir.C., E. Van Ranst, Ir.J. Debaveye, 1991, Land evaluation. Part I. Principal Land evaluation and Crop production calculation general administration for development, Cooperation agric Pub, 1(7), 247
- [37] Tamari S., J.H.M. Wosten, J.C. Ruiz-Suarez, 1996, Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Sci Soc Am J*, 60, 1732-1741
- [38] USDA., Soil Survey Staff, 2006, *Keys to Soil Taxonomy*, 10th edition
- [39] Vos B.D., M.V. Meirvenne, P. Quataert, J. Deckers, B. Muys, 2005, Predictive quality of pedotransfer functions for estimating bulk density of forest soils. *Soil Sci Soc Am J*, 69, 500 - 510
- [40] Wagner B., V.R. Tarnawski, V. Hennings, U. Muller, G. Wessolek, R. Plagge, 2001, Evaluation of pedo-transfer functions for unsaturated soil hydraulic conductivity using an independent data set. *Geoderma*, 102, 275 - 279
- [41] Wösten, J.H.M., A. Lilly, A. Nemes, C. Le Bas, 1999, Development and use of a database of hydraulic properties of European soils. *Geoderma*, 90, 169 - 185