

Određivanje likvefakcijskog potencijala umjetnom neuronskom mrežom

Farzad Farrokhzad, Asskar Janalizadeh Choobbasti, Amin Barari

Ključne riječi

likvefakcija, likvefakcijski potencijal, neuronska mreža, regresijski model, terenska istraživanja, Babol u Iranu

Key words

liquefaction, liquefaction potential, neural network, regression model, field investigations, Babol in Iran

Mots clés

liquéfaction, potentiel de liquéfaction, réseau de neurones, modèle de régression, reconnaissances sur le terrain, Babol en Iran

Ключевые слова

ликвификация, потенциал ликвификации, нейронная сеть, регрессионная модель, изыскания на местности, Бабо́л в Иране

Schlüsselworte

Verflüssigung, Verflüssigungspotential, Neuronennetz, rückschreitendes Modell, Terrainuntersuchungen, Babol in Iran

F. Farrokhzad, A. J. Choobbasti, A. Barari

Prethodno priopćenje

Određivanje likvefakcijskog potencijala umjetnom neuronskom mrežom

Opisuje se predloženi alternativni opći regresijski model neuronske mreže, koji omogućuje analizu sumarnih podataka dobivenih istraživanjem likvefakcije uobičajenim metodama. U tu su svrhu u model uneseni podaci s ukupno trideset bušotina izvedenih terenskim istraživanjima lociranim u Babolu, u iranskoj pokrajini Mazandaran. Rezultati se slažu s rezultatima dobivenim metodom koju su uveli Seet i drugi. Predloženi je model pouzdan za ocjenjivanje likvefakcijskog potencijala.

F. Farrokhzad, A. J. Choobbasti, A. Barari

Preliminary note

Determination of liquefaction potential using artificial neural networks

The authors propose an alternative general regression model based on neural networks, which enables analysis of summary data obtained by liquefaction analysis according to usual methods. For that purpose, the data from some thirty boreholes made during field investigations in Babol, in the Iranian province of Mazandaran, were entered in the model. The results correspond well with the results obtained by the method introduced by Seet and others. The proposed model has been found reliable for prediction of liquefaction potential.

F. Farrokhzad, A. J. Choobbasti, A. Barari

Note préliminaire

Détermination du potentiel de liquéfaction à l'aide du réseau de neurones artificiels

Les auteurs proposent un modèle alternatif de régression générale basé sur réseau de neurones. Le modèle permet l'analyse des données sommaires obtenues par analyse de liquéfaction faite à l'aide des méthodes usuelles. Dans ce sens, les données d'une trentaine de forages faits au cours des reconnaissances à Babol, dans la province iranienne de Mazandaran, ont été incluses dans le modèle. Les résultats correspondent bien avec ceux obtenus par la méthode introduite par Seet et autres. Le modèle proposé s'est avéré fiable dans la prédiction du potentiel de liquéfaction.

Ф. Фаррохзад, А. Й. Чуббастии, А. Барари

Предварительное сообщение

Определение потенциала ликвификации искусственной нейронной сетью

Описывается предложенная альтернативная обобщающая регрессионная модель нейронной сети, обеспечивающая анализ суммарных данных, полученных посредством исследования ликвификации обычными методами. С этой целью в модель внесены данные с тридцати скважин, выполненных при изысканиях на местности в Баболе Мазандаранского региона Ирана. Результаты согласуются с результатами, полученными методом, введенным Сеетом (Seet) и другими. Предложенная модель является надежной для оценки потенциала ликвификации.

F. Farrokhzad, A. J. Choobbasti, A. Barari

Vorherige Mitteilung

Bestimmung des Verflüssigungspotentials mit künstlichem Neuronnetz

Beschrieben ist das vorgeschlagene alternative allgemeine rückschreitende Modell des Neuronnetzes, womit eine Analyse der summarischen Angaben, erhalten durch Forschung der Verflüssigung mit gebräuchlichen Methoden, ermöglicht ist. Zu diesem Zweck sind in das Modell Angaben von insgesamt dreissig Bohrungen von Terrainuntersuchungen eingetragen, die sich in Babol, der iranischen Provinz Mandaran befindet. Die Ergebnisse sind übereinstimmend mit den Ergebnissen erhalten durch die Methode von Seet u. a. Das vorgeschlagene Modell ist für die Bewertung des Verflüssigungspotentials zuverlässig.

Autori: **Farzad Farrokhzad**; **Asskar Janalizadeh Choobbasti**, Departments of Civil Engineering, Babol University of Technology, Babol, Mazandaran, Iran; **Amin Barari**, Departments of Civil Engineering, Aalborg University, Aalborg, Denmark

1 Uvod


Podrtavanje tla uzrokovano potresom u zoni zasićenih nanosa pijeska dovodi do porasta tlaka porne vode što uzrokuje likvefakciju, tj. potpuni pad nosivosti tla. Veliki potresi koji su zabilježeni posljednjih desetljeća, poput potresa koji je zadesio Aljasku 1964. godine, potresa iz 1964. u Niigati, potresa iz 1989. u Loma - Prietai te potresa iz 1995. u Hyogoken-Nambu, jasno upozoravaju na štetno djelovanje likvefakcije tla. Zbog toga je važno steći odgovarajuće spoznaje o efektivnim parametrima kao što su utjecaj svojstava tla i vrste potresa na stupanj likvefakcije tla.

Likvefakcija je pojava u okviru koje se otpornost i krutost tla bitno smanjuju zbog potresa ili zbog nekoga drugog dinamičkoga djelovanja. U toku likvefakcije tlak porne vode djeluje na čestice tla tj. na međusobno zbijanje čestica tla. Prije nastanka potresa, tlak vode je relativno malen [6], međutim potres može uzrokovati porast tlaka vode koji utječe na međusobni položaj čestica tla. Iako djelovanje potresa često uzrokuje takav porast tlaka vode, činjenica jest da i građevinski zahvati, poput miniranja, također mogu izazvati porast tlaka vode [21].

Kada nastane likvefakcija čvrstoća tla se smanjuje, a time i sposobnost naslaga tla da nose temelje raznih građevina i mostova.

Gonzalo Castro, jedan od Casagrandeovih studenata, 1960. je godine obavio značajan niz nedreniranih troosnih ispitivanja. Castro je uočio tri različite vrste odnosa naprezanje - deformacija, ovisno o stanju tla. Zbijeni se uzorci u početku se skupljaju da bi nakon toga širili s porastom tlaka i posmičnog naprezanja. Vrlo rahli uzorci deformiraju se već kod maloga posmičnog naprezanja te vrlo brzo popuštaju u slučaju znatnijih deformacija. Castro je takvo ponašanje nazvao likvefakcijom, a ta se pojava naziva i tekućom likvefakcijom. Srednje zbijeno tlo u početku se ponaša isto kao i rastresito, ali nakon početnog zbijanja to se tlo počinje širiti. Za Castra je to ograničena likvefakcija. Do sada je razvijeno nekoliko metoda za ocjenjivanje stupnja likvefakcije [17]. Prema jednoj od takvih analitičkih metoda, razina posmičnog naprezanja i broj ciklusa na terenu procjenjuju se na temelju proračunskog potresa [18]. Usporedba takvih naprezanja s onima koja dovode do likvefakcije laboratorijskih uzoraka tla pomaže nam u određivanju zona koje su podložne likvefakciji. Druga metoda koja se u ovom istraživanju rabi za ocjenu likvefakcijskog potencijala temelji se na terenskom motrenju ponašanja zabilježenih u toku prijašnjih potresa [4]. Empirijski se odnos uspostavlja kombiniranjem podataka o seizmičkim svojstvima tla sa stvarnim svojstvima naslaga tla [19].

U prošlosti su se za rješavanje nekih problema planiranja, projektiranja, dijagnosticiranja itd. rabili ekspertni




Slika 1. Statičko troosno ispitivanje naprezanja obavljeno na dva uzorka različitog stupnja gustoće

sustavi. Međutim, na taj se način nije posvećivalo dovoljno pažnje pitanjima inženjerskog projektiranja, s obzirom na činjenicu da takvu problematiku treba razmatrati integralno, uzimajući u obzir podatke iz raznih izvora i područja. Ispitivanja koja su se kontinuirano provodila u proteklih desetak godina dovela su do uvođenja novih metodologija koje će omogućiti razvoj automatiziranih integriranih sustava projektiranja, a ti će sustavi povezivati sveukupni proces projektiranja. Te metodologije uključuju sintezu projektiranja, kritičku analizu projektiranja, analizu pojedinačnih slučajeva itd., a to dovodi do istodobnih intervencija u svim potrebnim područjima. Detaljni podaci o takvim metodologijama i alatima danas su dostupni samo u obliku stručnih radova i izvješća o istraživačkim projektima koji se provode u akademskim i drugim institucijama.

Umjetne neuronske mreže (ANN – *Artificial Neural Network*) razvijaju vlastita rješenja na temelju primjera za određenu kategoriju problema. To su takozvani povezni sustavi kojima se simuliraju jednostavne radnje koje se odvijaju u središnjem živčanom sustavu čovjeka. U mozgu se manifestiraju poželjna svojstva za obradu podataka kao što su sposobnost učenja, mogućnost izvođenja, generaliziranje i definiranje dopuštenih odstupanja, a ta se svojstva usvajaju i imitiraju u umjetnim neuronskim mrežama. Umjetna neuronska mreža može se vizualizirati kao skup neurona međusobno povezanih u mrežu. Neuroni sadržani u mreži obrađuju podatke usporedno i zajednički unutar strukture mreže. Neuronske mreže mogu se podijeliti na nekoliko vrsta, ovisno o načinu povezivanja neurona, načinu djelovanja te načinu usvajanja znanja unutar mreža [1]. Odgovarajuće kombinacije tih karakteristika formiraju se ovisno o vrsti problema koji se rješava. Tipična ANN mreža prikazana je na slici 2. Tu vidimo prema naprijed usmjerenu shemu spajanja i sinkroniziranih radnji svih neurona (čvorova ili ćelija).

U ANN mreži se kao ulazna baza rabi skup primjera sadržanih u bazi podataka obučavanja. Algoritam za učenje služi za korigiranje pondera, a poticajna se funkcija upotrebljava za generiranje rezultata. Ako se promijeni ponder koji povezuje neurone, tada će se promijeniti i odnos između rezultata i ulaznih podataka [11]. Postu-

pak korekcije spojnih pondera opetovanim djelovanjem na mrežu unošenje poznatih ulaznih i izlaznih podataka naziva se obučavanjem. Najpopularnija i najuspješnija je tehnika obučavanja metoda učenja temeljena na greškama i ponavljanju. Obučavanje na ANN mreži daje rezultate u vrlo kratkom vremenu nakon unošenja ulaznih podataka, što je svakako prednost optimizacije koja se temelji na predloženom pristupu [5].



Slika 2. Troslojna struktura prema naprijed usmjerene neuronske mreže

Nedavno su obavljene opsežne studije o primjeni ANN mreža u svrhu rješavanja geotehničkih problema. Chan i drugi [2] razvili su neuronsku mrežu kao alternativno rješenje koje bi moglo zamijeniti formulu za zabijanje pilota. Nakon toga su Shahin i drugi [15] razvili slično rješenje za predviđanje slijeganja plitkih temelja u nekoherentnom tlu. Odgovarajuće metode predložili su Meyerhof [9], Schultze i Sherif [14] te Schmetmann i drugi [13]. Rezultati novijih rješenja potvrđuju rezultate koje su predložili Sivakugan i drugi [20], tj. da se ANN mrežama može dobro predvidjeti slijeganje te da su takvi rezultati bolji od onih koji se dobivaju primjenom tradicijskih metoda. U ovom se istraživanju ANN mreže upotrebljavaju za određivanje nelinearnog odnosa između likvefakcijskog potencijala i parametara, a isti se odnos može upotrijebiti za predviđanje likvefakcijskog potencijala tla.

Poznato je da inženjerska svojstva tla variraju od lokacije do lokacije te da uvijek postoji određena nesigurnost glede ponašanja tla, prije svega zbog složenih i teško predvidljivih fizikalnih procesa koji se odvijaju u toku formiranja naslaga. U tom se smislu tlo znatno razlikuje od većine drugih građevinskih materijala koji se odlikuju daleko većom homogenošću i izotropijom. Da bi se mogli rješavati složeno geotehničko ponašanje i prostorna varijabilnost naslaga tla, tradicijske su metode s razlogom dosta pojednostavljene.

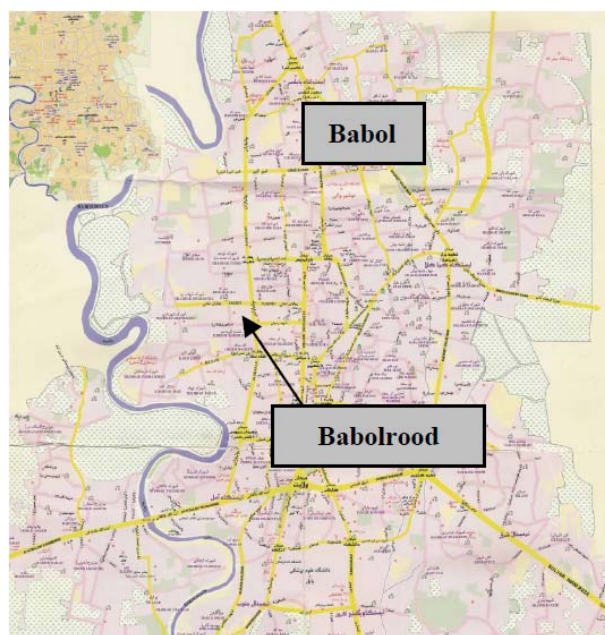

Prikupljanje podataka o tlu koje se istražuje važno je ne samo radi ocjenjivanja stupnja likvefakcije, već i radi određivanja debljine slojeva, vrste tla, razine podzemnih voda itd. [10]. Istovremeno je to dugotrajan i poprilično

skup postupak jer uključuje velik broj terenskih i laboratorijskih ispitivanja [7]. Stoga je za pouzdano predviđanje likvefakcije potrebno brižljivo planiranje metoda uzorkovanja, ispitivanja i istražnih radova [8]. Proračunima odziva tla koje se temelje na metodi konačnih elemenata postiže se točnija ocjena likvefakcije tla jer se u obzir uzima i vrsta potresa i rasipanje vrijednosti pornih tlakova. Takve su analize često skupe i dugotrajne. Osim toga, modeli koji su sastavni dio tih programa trebaju velik broj parametara za određivanje oslobađanja pornog tlaka u tlu zbog potresnog djelovanja. Zato inženjeri u praksi vrlo rado primjenjuju pojednostavljene metode za ocjenjivanje likvefakcije tla. Takvi su postupci vrlo korisni u početnim stadijima projektiranja kada se želi odrediti likvefakcijski rizik, tj. mogućnost pojave likvefakcije. Ako se ustanovi kako je mogućnost da će doći do pojave likvefakcije velika, tada se može obaviti detaljni proračun metodom konačnih elemenata da bi se dobili podaci o rasipanju vrijednosti pornog tlaka i o pomaku tla po dubini naslaga, što je potrebno u daljnjem projektiranju dubokih temelja. Drugim riječima, pouzdanije ocjenjivanje opasnosti od likvefakcije može dovesti do smanjenja troškova, a pomaže i pri planiranju poslova na projektu. U okviru ovog istraživanja, uzorci su se uzimali iz bušotina maksimalne dubine 30 m na prostoru od 7,6 kvadratnih kilometara u području Babola. Umjetne su se neuronske mreže "razrađivale" sa 60 %, a kontrolirane s 10 % podataka iz bušotina izvedenih radi predviđanja likvefakcije. Kasnije je ispitana djelotvornost čitavog sustava i u tom je smislu za ispitivanje djelotvornosti mreže rabljeno preostalih 30 % podataka iz kontrolnih bušotina nasumce odabranih unutar područja ispitivanja. Na temelju dobivenih rezultata, te uzimajući u obzir činjenicu da ispitni podaci nisu bili dostupni mreži u toku obučavanja i kontroliranja, može se zaključiti da se variranje likvefakcijskog potencijala tla može dovoljno pouzdano predvidjeti pomoću obučanih neuronskih mreža.

I na kraju, uspješnim predviđanjem likvefakcije tla temeljenom na postojećim podacima povećava se i pouzdanost podataka koji će se upotrebljavati na budućim projektima. U idućem je tekstu prikazan pristup koji uglavnom uključuje prikaz područja obuhvaćenog projektom. Nakon opisa i odabira neuronskog modela opisuje se obučavanje, poboljšavanje i razvoj konačnog modela koji će se rabiti za predviđanje likvefakcije pomoću specifične ANN mreže [3].

2 Materijali i metode

Područje istraživanja je Babol, grad smješten u pokrajini Mazandaran na sjeverozapadu Irana. Grad se nalazi otprilike 20 kilometara južno od Kaspijskog mora, na zapadnoj obali rijeke Babolrood (slika 3.). Godišnje obo-



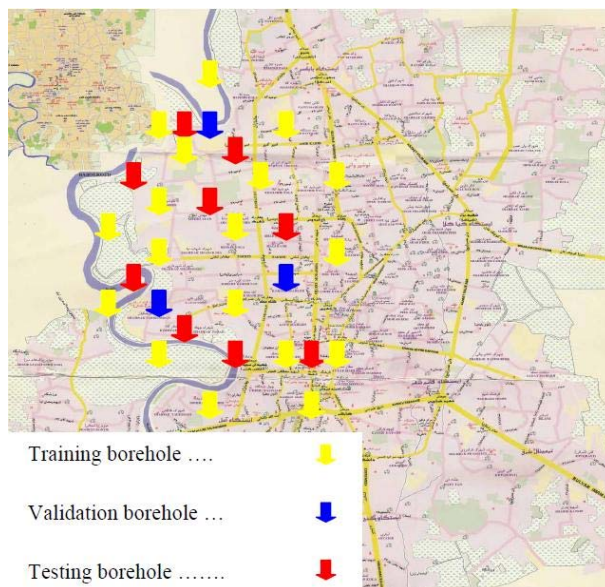
Slika 3. Karta područja istraživanja (lijevo) i područje rijeke Babolrood (desno)

rine koje se bilježe u tom gradu prilično su obilne. Babolrood ima dvije skupine riječnih terasa, a označene su kao H_1 i H_2 . Znak H_1 označava riječne terase s visinskom razlikom od 1 do 2,5 m, dok im širina varira od nula do 150 m. To je granica aktivne (godišnje) naplavne ravnice u nekim dijelovima rijeke, a ponekad i alternativna naplavna ravnica. Sastoji se od sitnozrnatih nekonsolidiranih aluvijalnih sedimenata. Znak H_2 označava riječne terase koje po visini variraju od 4 do 6 m. Površinska vegetacija na terasi je kompaktna; sastoji se od materijala eolskog podrijetla (npr. prapor). Većina značajnijih potresa pogađa granična područja tektonskih ploča poput onih koje se nalaze na sjevernom dijelu Irana.

U geotehnici često nailazimo na probleme koji su izuzetno složeni i ne mogu se u potpunosti razjasniti. Matematički modeli kojima se takvi problemi pokušavaju riješiti ne mogu obuhvatiti sve fizikalne aspekte procesa, pa stoga model valja ili pojednostavniti ili se pak trebaju usvojiti neke pretpostavke. U matematičkom se modeliranju također pretpostavlja prethodno poznavanje strukture modela, a to nije uvijek ispunjeno. Stoga se u mnogim matematičkim modelima ne može simulirati stvarna složenost nekih geotehničkih problema. S druge strane, ANN mreže uglavnom se temelje na strukturi ulaznih podataka, pri čemu se pretpostavlja da je takva struktura i interakcija podataka dostatna za opisivanje prognostičkog modela. U ovom slučaju problem ne treba pojednostavljivati niti treba uvoditi bilo kakve pretpostavke (osim podataka koje odabire korisnik na temelju nekih logičnih povezanosti). Osim toga, već definirani neuron-

ski model uvijek se može ponovno doradivati, tj. "obučavati" primjenom dodatnih ili novijih podataka iz istog područja, a sve radi postizanja što boljih rezultata.

U ovom se istraživanju rabe podaci iz istraživanih bušotina u području istraživanja (slika 4.), a podatke su prikupile raznovrsne institucije za razne istraživačke projekte. Podaci se temelje na analizi više od četrdeset izvještaja o bušenju na prostoru većem od 7,6 kvadratnih kilometara u području Babola. Zbog velikih varijacija slojeva tla, ovo je područje podijeljeno na šest dijelova (slika 4.).



Slika 4. Šest zona u području Babola

Od ukupno četrdeset bušotina samo je njih trideset dubine od 10 do 30 m zadovoljavalo uvjete za primjenu u ANN mreži. Na uzorcima su obavljena uobičajena ispitivanja.

Dostupni su podaci slučajnim odabirom podijeljeni u tri niza: niz za obučavanje, kontrolni niz i ispitni niz što omogućuje bolje ispitivanje valjanosti modela. U modelima ANN mreže 60 % podataka odabrano je za obučavanje, 30 % za ispitivanje konačne ocjene, a preostalih 10 % za kontrolu ili praćenje učinkovitosti modela u fazi obučavanja (tablica 1.).

Tablica 1. Učinkovitost raznih nizova podataka primijenjenih u ANN mreži

Parametri	Niz za obučavanje	Kontrolni i niz	Ispitni niz
Broj bušotina	18	3	9
Broj podataka (parovi podataka U/I)	1500	2350	750

Kada se želi riješiti problem s nekoliko varijabli, tj. s više raspona i dimenzija, može se rabiti i nekoliko mreža. Neuronske su mreže djelotvorni alati kada se koriste kao sredstva za klasifikaciju trendova. Važno je dobro odabrati ulazne varijable za proces obučavanja (učenja) unutar ANN mreže, isto kao i metodu za određivanje veza između ulaznih i izlaznih varijabli. Niz poznatih ulaznih i izlaznih vrijednosti nazivamo ulazno-izlaznim parom. Svi su takvi parovi obično podijeljeni u tri niza. Prvi i drugi niz su niz za obučavanje i kontrolni niz, a rabe se za određivanje pondera veze ili koeficijenta za ponderiranje (kao u metodama za interpoliranje), a obično se označavaju sa w_{ij} . Također treba napomenuti da se nizovi za obučavanje i kontrolu upotrebljavaju u toku postupka obučavanja, dok se niz za ispitivanje (ispitni niz) upotrebljava za ocjenjivanje. Svi modeli unutar ANN mreže obučavaju se pomoću algoritma s automatskim reguliranjem da bi generalizacija bila što realnija. Kontrolni se niz rabi kao ograničenje pri obučavanju da bi se preklapanje svelo na minimum.

U ovoj je studiji prikazana korisnost primjene neuronske mreže za izradu modela sličnosti. Ulazni podaci mreže su podaci o nizu faktora potrebnih za definiranje tla. Izlazni su podaci mreže niz vrijednosti sličnosti u odnosu na niz zadanih kategorija tla podijeljenih prema veličini zrna, debljini slojeva i razini podzemne vode. Iz trideset bušotina smještenih na području obuhvata projekta generiran je niz od 2500 uzoraka. Podaci su prikupljeni u okviru geotehničkih istražnih radova. Svaki se uzorak brižljivo kontrolirao da bi se osiguralo precizno definiranje modela ANN mreže, a u svrhu generiranja pouzdanih nizova za obučavanje, kontrolu i ispitivanje.

Imajući na umu dostupnost podataka i njihovu kakvoću, u ovoj je analizi primijenjen program neuronske mreže napisan u algoritmu povratnog prostiranja. Osam parametara tla i seizmičkih parametara odabrano je kao ulaz za razne modele, a ti su parametri podijeljeni u skupine podataka. Svaka skupina podataka uvedena je u mrežu pojedinačno te je istražena učinkovitost mreže kao sredstva za određivanje likvefakcijskog potencijala. Mrežna su predviđanja uspoređena s konvencionalnom metodom za određivanje likvefakcije koju predlažu Seed i drugi.

Kao algoritam za obučavanje neuronske mreže odabrano je povratno prostiranje (tablica 2.). To je najpoznatiji obrazovni algoritam za višeslojne perceptronske (MLP – *Multilayer Perception*) neuronske mreže, a još uvijek se smatra najkorisnijim, osobito zbog kasnijih poboljšanja u obliku RProp-a. Algoritam povratnog prostiranja znači da obučavanje u okviru mreže uključuje i određivanje razlike između točnih i poželjnih odziva, tj. proračun greške koja je uključena u neuronsku mrežu radi optimaliziranja procesa obučavanja [16]. Taj algoritam ima manje memorijske zahtjeve u usporedbi s većinom ostalih algoritama i obično brzo postiže prihvatljivu razinu greške u procesu predviđanja (u relativno malom broju ponavljanja ili razdoblja).

Tablica 2. Rezultati istraživanja redosljeda pri odabiru algoritma za učenje/obučavanje

Algoritmi za kontrolirano obučavanje	Povratno prostiranje	Udruženo podizanje/spuštanje	Levenberg--Marquardt	Brzo prostiranje	Delta-bar--Delta
RMSE (%)	6,3*	12,1	8,7	10	9,2
*minimalna greška					

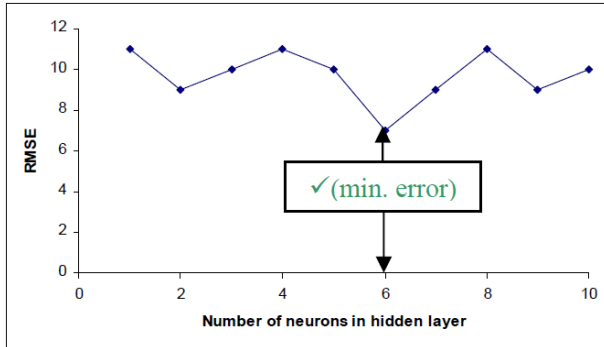
Za potrebe ove studije, model ANN mreže je razvijen, obučan, kontroliran i ispitan u okviru proračunskog paketa STATISTICA, a uz primjenu alata neuronske mreže. Preciznost modela ANN mreže ocijenjena je pomoću vrijednosti RMSE u rasponu između izmjerenih i predviđenih vrijednosti:

$$RMSE = \sqrt{\frac{\sum_{k=1}^n (z_s - z_0)^2}{n}} \quad (1)$$

gdje je z_s promatrana vrijednost, z_0 predviđena vrijednost, a n je broj uzoraka. Vrijednost RMSE za razne neurone u skrivenom sloju iskazana je na slici 5. Arhitek-

tura ANN mreže za predviđanje klasifikacije tla i debljine slojeva u promatranom području bila je prema naprijed usmjerena, kontrolirana, višeslojna perceptronska (MLP) mreža s jednim skrivenim slojem i jednim izlaznim slojem. Najprikladniji niz podataka dobiven obučavanjem ostvaren je sa šest neurona u skrivenom sloju za predviđanje likvefakcije.

Pri odabiru algoritma za učenje/obučavanje uporabljeni su: broj neurona u raznim slojevima (ulazni, skriveni, izlazni), broj epoha, brzina učenja i moment.



Slika 5. Vrijednost RMSE raznih neurona u skrivenom sloju za predviđanje likvefakcijskog potencijala tla

U svakom se razdoblju kompletan niz za obučavanje provodi kroz mrežu i rabi za korigiranje mrežnih pondera. Brojevi razdoblja zadaju se na samom početku, ali se može zadati i alternativan kriterij za zaustavljanje. U slučaju pretjeranog obučavanja može se usvojiti najbolja mreža koja je uočena u toku obučavanja. U ovoj je analizi broj razdoblja varirao od 100 do 500.

Skupna i prema naprijed usmjerena MLP mreža s pravilima učenja temeljenim na povratnom prostiranju primijenjena je pri definiranju ANN modela spomenutim računalnim programom. Osim toga, primijenjena je i prilagodna stopa učenja tako da u razdoblju stabilnog obučavanja koraci učenja budu što veći. Arhitektura modela uključuje jedan skriveni sloj, stopu učenja od 0,1 ažuriranu s koeficijentom 1,1 nakon svakog razdoblja i moment od 0,9 ažuriran s koeficijentom od 0,95 za svako razdoblje. Ulazni je vektor potpuno povezan sa skrivenim neuronima pomoću tan-sigmoidne prijenosne funkcije, dok su neuroni skrivenog sloja potpuno povezani s izlaznim slojem linearnom funkcijom. Eksperimentalna je studija provedena s jednim skrivenim neuronom da bi se dobio optimalni broj skrivenih neurona i postigla tražena točnost. Ulazni vektor sadrži početne parametre tla, a izlaz (ciljni vektor) je likvefakcijski potencijal. Da bi postupak obučavanja bio što djelotvorniji, ulaz i izlaz su standardizirani na takav način da imaju nultu, srednje i jedinično standardno odstupanje. Unakrsna kontrola, ili primjena drugog niza podataka u daljnjem testiranju, može se rabiti da bi se povećala

generalizacijska sposobnost modela u budućim predviđanjima. U ovoj je studiji deset posto bušotinskih podataka upotrijebljeno kao kontrolni niz. Zapravo, za izradu modela definirano je nekoliko ANN modela s ispitnim podacima elemenata. Od tih je modela odabran model s boljom učinkovitošću (viši koeficijent determinacije i manja vrijednost RMSE-a) za kontrolni niz podataka. Drugim riječima, istodobno su se razvijali ANN modeli koji su najučinkovitiji za obučavanje, ispitivanje i kontroliranje nizova podataka. Razvijena su tri ANN modela s raznim kombinacijama ulaznih parametara (tablica 3.).

Tablica 3. Razne kombinacije ulaznih parametara

Model #	1	2	3
Ulaz	M, A, σ , σ' , C_D , D_r	M, $\frac{\tau}{\sigma'}$, V_s , C_D , σ	V, $\frac{\tau}{\sigma'}$, C_D , σ , A
RMSE	13 %	17 %	16 %


U tablici 3. vrijednost M je magnituda potresa, A je klasifikacija tla, σ je ukupno naprezanje, σ' je stvarno naprezanje, C_D je faktor smanjenja posmičnog naprezanja, a D_r je relativna gustoća.

3 Rezultati i diskusija

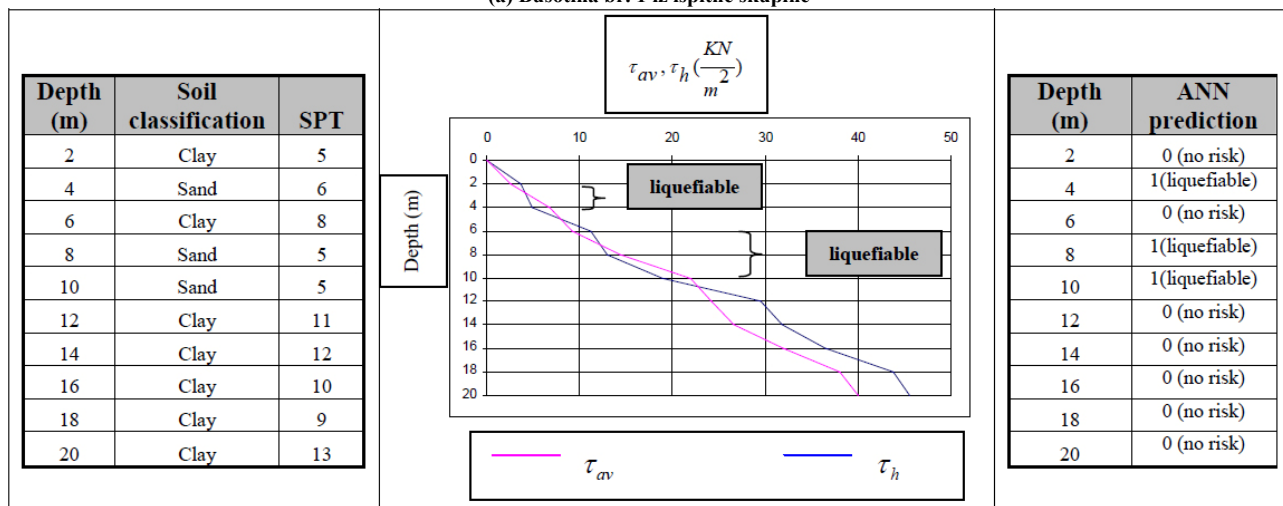
U prethodnom je poglavlju objašnjena upotreba niza podataka za učenje ili obučavanje u svrhu određivanja pondera. Zatim je drugi kontrolni niz rabljeni za praćenje učinkovitosti modela u fazi obučavanja i za minimiziranje pretjeranog usklađivanja, dok su u konačnici upotrebljavani ispitni nizovi za ocjenjivanje obučene neuronske mreže. Nizovi ispitnih podataka pokazuju da se eksperimentalna ANN mreža može uspješno rabiti za predviđanje likvefakcijskog potencijala.

Za ocjenjivanje mreže odabrani su podaci iz triju bušotina koje nisu upotrebljavane za obučavanje neuronske mreže, a predviđanje likvefakcijskog potencijala za svaku od te tri bušotine, temeljeno na ANN modelu, uspoređeno je sa Seedovom metodom. Na slici 6. prikazana je preciznost ANN modela u tri spomenute bušotine. U prvom su stupcu klasifikacija tla i broj standardnih penetracijskih pokusa (SPT) provedenih u toku terenskih istraživanja na svim dubinama, a u drugom je stupcu Seedova analitička metoda za određivanje likvefakcijskog potencijala. Očito je da do likvefakcije dolazi ako je $\tau_{av} \geq \tau_h$. U trećem su stupcu prikazani rezultati ANN za svaku dubinu. Prema [18] vrijednost τ_{av} može se preuzeti iz jednadžbe (2), a vrijednost τ_h iz slike 6.:

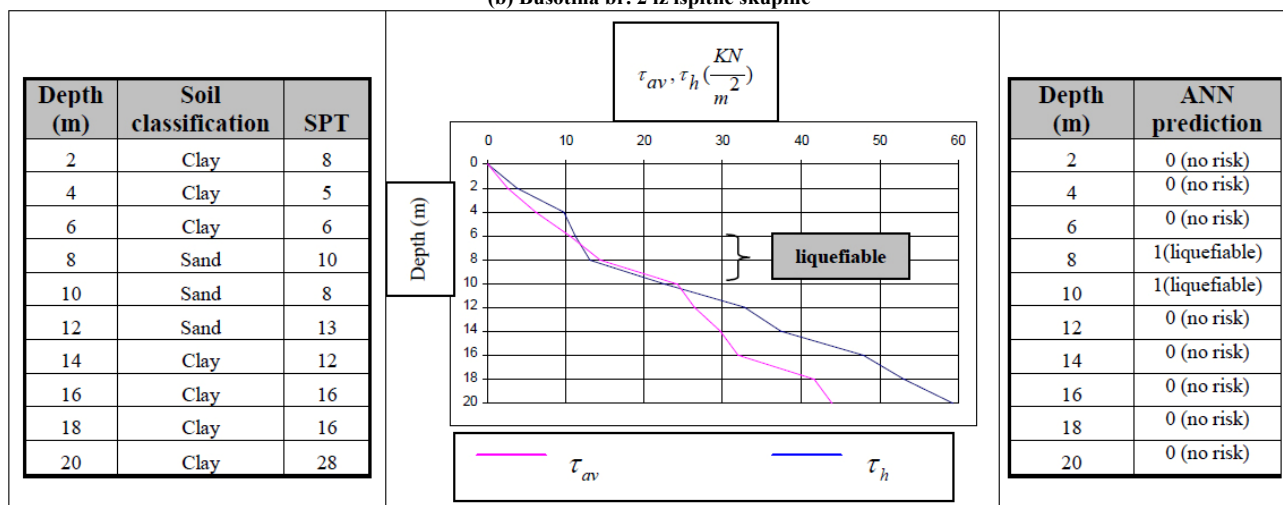
$$\tau_{av} = 0,65\tau_{max} = 0,65C_D \left[\left(\frac{yh}{g} \right) a_{max} \right] \quad (2)$$



(a) Bušotina br. 1 iz ispitne skupine

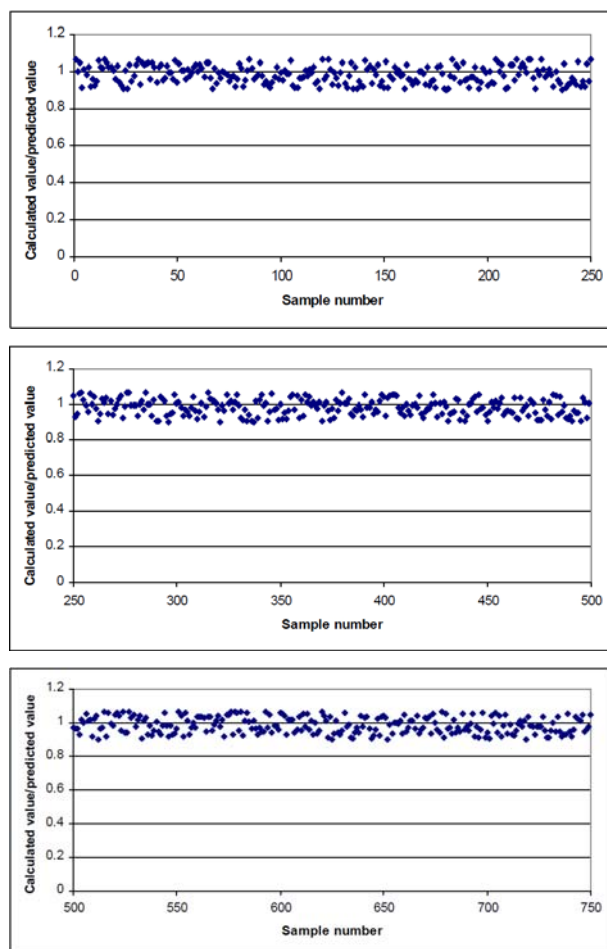


(b) Bušotina br. 2 iz ispitne skupine



(c) Bušotina br. 3 iz ispitne skupine

Slika 6. Usporedba predviđanja likvefakcijskog potencijala pomoću modela ANN i Seedove metode za tri nasumce odabrane bušotine iz ispitne skupine



Slika 7. Preciznost modela ANN u predviđanju likvefakcijskog potencijala na bazi 750 uzoraka iz ispitne skupine

Konačno, da bi se ocijenila preciznost ANN modela obavljena je korelacija svih uzoraka iz ispitne skupine prema broju uzoraka i preciznosti (usporedba predviđanja metodom ANN i Seedovom metodom) svakog uzor

ka (slika 7.). Na tim je prikazima iskazan koeficijent proračunane vrijednosti likvefakcijskog potencijala prema Seedovoj metodi i predviđene vrijednosti prema ANN-u (na osi Y), dok je na osi X iskazan broj uzoraka tla iz ispitnih bušotina. Jasno je da bi, ako su predviđene i stvarne vrijednosti jednake, takva točka trebala biti

LITERATURA

- [1] Bochereau, L.; Bourcier, D.; Bourguine, P.: (1991). *Extracting legal knowledge by means of a multilayer neural network application to municipal jurisprudence*, Proc. Third Int. Conf. Artificial Intelligence and Law, 288–296.
- [2] Chan, W. T.; Chow, Y. K.; Liu, L. F.: (1995). *Neural network: An alternative to pile driving formulas*, J.Computers and Geotechnics, 17, 135-156.
- [3] Choobbasti, A. J.; Farrokhzad, F.; Barari, A.: (2009). *Prediction of slop stability using artificial neural network*, Arab J Geosci; 10.1007/s12517-009-0035-3.
- [4] Idriss, I. M.; Seed, H.B.: (1986). *Seismic Response of Horizontal Soil Layers*, Journal of the Soil Mechanics and Foundations Division, ASCE, Vol.94, No. SM4, July, pp.1003 – 1031.
- [5] Kartam, N.; Flood, I.; Tongthong, T.: (1995). *Integrating knowledge-based systems and artificial neural networks for*

smještena na liniji $y = 1$. Rasipanje rezultata pokazuje razlike. Jasno je da prosječna korelacija ANN modela i stvarnih podataka iznosi više od 87 % u svim slučajevima. Stoga se može zaključiti da je predviđanje likvefakcijskog potencijala podudarno s izračunanim vrijednostima dobivenima iz bušotina.

4 Zaključak

Ovom se studijom želi prikazati razvoj nove pojednostavljene metode za ocjenjivanje likvefakcije tla koja se temelji na umjetnoj neuronskoj mreži. U toku potresa, likvefakcijski potencijal mase tla ovisi i o seizmičkim parametrima i o parametrima tla. U ovom su istraživanju podaci rabljeni za obučavanje ANN modela uzeti na površini od 7,6 kvadratnih kilometara u području Babola u sjevernom dijelu Irana. Niz podataka obuhvaća 2500 uzoraka koji potječu iz trideset bušotina. Uporabljjen je model povratnog prostiranja neuronske mreže, a učinkovitost modela mreže analizirana je mijenjanjem varijabli tla i seizmičkih varijabli, uključujući između ostalog i magnitudu potresa, ukupno naprezanje, stvarno naprezanje, seizmički koeficijent, relativnu gustoću, faktor smanjenja posmika i brzinu posmičnih valova. Ukratko su prikazani najdjelotvorniji i opći model za ocjenjivanje likvefakcijskog potencijala i najznačajniji ulazni parametri koji utječu na likvefakciju. Studija predviđanja obavljena je za grad Babol u Iranu.

Predloženi pojednostavljeni postupak ilustriran je konkretnim primjerima. Na temelju rezultata dobivenih usporednom analizom, ustanovljeno je da je novoizrađeni ANN model vrlo jednostavan i precizan te da se njegovom primjenom u ocjenjivanju likvefakcijskog potencijala postiže stopa uspješnosti od gotovo 90 %.

Predviđanje likvefakcijskog potencijala smatra se složenim područjem istraživanja u okviru kojeg treba provoditi i detaljna istraživanja pomoću drugih metoda, terenska istraživanja i laboratorijska ispitivanja. U toku budućih istraživanja u ovom području, bilo bi vrlo korisno obaviti odgovarajuće korekcije ovog postupka da bi se koncept umjetne neuronske mreže što bolje prilagodio potrebama predviđanja likvefakcijskog potencijala.

- engineering, *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, 9, 13–22.
- [6] Kayen, R. E.; Mitchell, J. K.: (1997). *Assessment of liquefaction potential during earthquakes by Arias intensity*, *J Geotech Geoenviron Eng, ASCE*; 123(12):1162–74.
- [7] Kryl, V.; Hudeček, V.; Fröhlich, E.: (2000), *The problem of liquidating the buildings of former underground brown coal mines in the Podkrušnohoří area in connection with the decree of the czech bureau of mines no. 52/1997, collection of laws, and problems of open cast mines in places of their occurrences*, *Acta Montanistica Slovaca* Volume 5 Number 4.
- [8] Macuda, J.; and Zawisza L.: (2006), *Environmental hazard accompanying the liquid waste storage in the mass*, *Acta Montanistica Slovaca* Special Issue 1/2006.
- [9] Meyrehof, G. G.: (1976). *Bearing capacity and settlement of pile foundations*, *J. Geotech. Engrg., ASCE*, 102(3), 196-228.
- [10] Kaszowska, O.; Kalisz, P.; Mika, W.: (2007), *Examples of development of the postindustrial objects from the liquidated mines* *Acta Montanistica Slovaca*, Special Special Issue 3/2007.
- [11] Sakthivel, T. S.; Kalyanaraman, V.: (1991). *Standards processing in an integrated engineering system*, in *Artificial Intelligence and Structural Engineering*, Topping, B. H. V (Ed.), Civilcomp Press, Edinburgh, UK, 247–255.
- [12] Schmertmann, J. H. (1970). "Static cone to compute static settlement over sand." *J. Soil Mech. & Found. Div., ASCE*, 96(SM3), 7302-1043.
- [13] Schmertmann, J. H.; Hartman, J. P.; Brown, P. B.: (1978). *Improved strain influence factor diagrams*, *J. Geotech. Engrg., ASCE*, 104(GT8), 1131-1135.
- [14] Schultze, E.; Sherif, G.: (1973). *Prediction of settlements from evaluated settlement observations for sand*. Proc., 8th Int. Conf. Soil Mech. & Found. Engrg., 1(3), 225-230.
- [15] Shahin, M. A.; Jaksa, M. B.; Maier, H. R.: (2000). *Predicting the settlement of shallow foundations on cohesionless Soils using back-propagation neural networks*, Research Report No. R 167, The University of Adelaide, Adelaide.
- [16] Shiva Kumar, H.; Krishnamoorthy, C. S.; Rajagopalan, N.: (1995). *A process model for knowledge-based concrete bridge design*, *Engineering Application of Artificial Intelligence*, 8(4), 435–447, 1995.
- [17] Seed, H. B.; Tokimatsu, H.; Harder, L. F.; Chung, R. M.: (1985). *Influence of SPT procedure in seismic liquefaction resistance evaluations*, *J. Geotech. Engrg., ASCE*, 111(12), 1425-1445.
- [18] Seed, H. B.; Idriss, I. M.: (1971), *Simplified Procedure for Evaluating Soil Liquefaction Potential*, *Journal of the Soil mechanics and Foundations Division, ASCE*, Vol.97, No SM9, Proc. Paper 8371, september 1971, pp. 1249 – 1273.
- [19] Seed, R. B.; Cetin, K. O. et al.: (2003), *Recent Advances in Soil Liquefaction Engineering: A Unified and Consistent Framework*, 26 th Annual ASCE Los Angeles Geotechnical Spring Seminar
- [20] Sivakugan, N.; Eckersley, J. D.; Li, H.: (1998). *Settlement predictions using neural networks*, *Australian Civil Engineering Transactions*, CE40, 49-52.
- [21] Towhata, I.; Park, J. K.; Orense, R.P.; Kanoh, H.: (1996), *Use of spectrum intensity for immediate detection of subsoil liquefaction*, *Soils Found*; 36(2):29–44.