

Neuralne mreže i njihova primjena u vodnom gospodarstvu

Dražen Vouk, Davor Malus, Dalibor Carević

Ključne riječi

neuralne mreže, vodno gospodarstvo, podjela neuralnih mreža, povijesni razvoj, najznačajnije neuralne mreže

Key words

neural networks, water management, classification of neural networks, historic development, most significant neural networks

Mots clés

réseaux de neurones artificiels, gestion des eaux, classification des réseaux de neurones, développement historique, réseaux de neurones les plus importants

Ключевые слова

нейральные сети, водное хозяйство, распределение нейральных сетей, хронологическое развитие, важнейшие нейральные сети

Schlüsselworte

Neuronennetze, Wasserwirtschaft, Einteilung der Neuronennetze, geschichtliche Entwicklung, wichtigste Neuronennetze

D. Vouk, D. Malus, D. Carević

Pregledni rad

Neuralne mreže i njihova primjena u vodnom gospodarstvu

U radu su detaljnije opisane neuralne mreže koje su danas sve češće u primjeni pri rješavanju problema iznimno visokog stupnja složenosti. Uz definiranje neuralnih mreža, dana je njihova podjela, prikaz strukture i osobina te je izdvojen pregled povijesnog razvoja. Istaknuta je primjena neuralnih mreža unutar područja vodnog gospodarstva i to prije svega na području Hrvatske. Pri tome su ukratko opisane najznačajnije neuralne mreže koje su do danas razvijene i rabljene u praksi.

D. Vouk, D. Malus, D. Carević

Subject review

Neural networks and their application in water management

Neural networks, nowadays increasingly used for solving problems of exceptionally high level of complexity, are described in great detail. After definition of neural networks, their classification is given, and their structure and properties are presented. An overview of their historic development is also given. An emphasis is placed on the use of neural networks in water management, especially in the territory of Croatia. At that, most significant neural networks developed so far and used in current practice are briefly presented.

D. Vouk, D. Malus, D. Carević

Ouvrage de syntaxe

Réseaux de neurones artificiels et leur application dans la gestion des eaux

Les réseaux de neurones artificiels, utilisés de plus en plus pour résoudre les problèmes d'un niveau exceptionnel de complexité, sont décrites en détail. Après la définition des réseaux de neurones leur classification est fournie, et leur structure et propriétés sont présentées. Un aperçu de leur développement historique est également exposé. L'accent est mis sur l'utilisation des réseaux de neurones dans la gestion des eaux, surtout dans le territoire de Croatie. Les réseaux de neurones développés jusqu'à présent et utilisés à ce jour sont exposés en grandes lignes.

Д. Воук, Д. Малус, Д. Царевич

Обзорная работа

Нейральные сети и их применение в водном хозяйстве

В работе подробно описываются нейральные сети, которые в настоящее время все чаще применяются при решении проблем исключительно высокой степени сложности. Помимо определения нейральных сетей, приведено их распределение, показаны структура и характеристики, выделен обзор хронологического развития. Особо освещено применение нейральных сетей в области водного хозяйства, прежде всего – на территории Хорватии. При этом приведено краткое описание важнейших нейральных сетей, разработанных до настоящего времени и примененных на практике.

D. Vouk, D. Malus, D. Carević

Übersichtsarbeit

Neuronennetze und deren Anwendung in der Wasserwirtschaft

Im Artikel beschreibt man detailliert die Neuronennetze die heutzutage bei der Lösung von ausnahmsweise komplizierten Problemen immer häufiger angewendet werden. Neben dem Definieren der Neuronennetze gibt man deren Einteilung und Darstellung der Struktur und Kennzeichen. Abgesondert gibt man eine Übersicht der geschichtlichen Entwicklung. Hervorgehoben ist die Anwendung der Neuronennetze innerhalb des Gebiets der Wasserwirtschaft, vor allem im Gebiet von Kroatien. Ausserdem beschreibt man die wichtigsten Neuronennetze die bis heute entwickelt und in der Praxis angewendet sind.

Autori: Dr. sc. **Dražen Vouk**, dipl. ing. građ.; prof. dr. sc. **Davor Malus**, dipl. ing. građ.; dr. sc. **Dalibor Carević**, dipl. ing. građ., Sveučilište u Zagrebu, Građevinski fakultet, Zagreb

1 Uvod

Neuralne mreže predstavljaju novu generaciju sustava za informacijske analize (obradu), a karakterizira ih mogućnost učenja, pamćenja i generaliziranja na osnovi prethodno pripremljenih baza podataka kojima se treniraju.

Primjena neuralnih mreža, kao relativno novog alata računalne tehnologije, u današnje vrijeme sve više dobiva na značenju u svim segmentima ljudskog djelovanja. Međutim, očekivanja primjene neuralnih mreža u području građevinarstva, što uključuje i područje vodnog gospodarstva u znatno većem opsegu, do danas se nisu ostvarila, neovisno o zamjetno velikom opusu objavljenih radova i načinjenih inovativnih pokušaja [1]. Razlog tome jest slabo poznavanje neuralnih mreža, njihovih mogućnosti i načina upotrebe među užim i širim stručnim kadrom.

Uz definiranje neuralnih mreža u ovom je radu opisan i način njihova funkcioniranja. U današnje se vrijeme neuralne mreže razvijaju i rabe u sklopu gotovih računalnih programa koji ne nude razumljiv odnos važnih varijabli unutar modelske strukture, već se mogu opisati kao "crna kutija" gdje su odnosi između varijabli skriveni unutar strukture same neuralne mreže. U skladu s navedenim, u radu je izdvojen i opis osnovnih osobina neuralnih mreža s obzirom na način njihova rada u sklopu kojega su opisana osnovna četiri procesa svake neuralne mreže: priprema baze podataka, učenje (treniranje) mreže, testiranje mreže i procjena izlaznih rezultata.

U radu je opisan i povijesni razvoj neuralnih mreža, uz isticanje primjene neuralnih mreža unutar područja vodnoga gospodarstva, i to ponajprije na području Hrvatske.

2 Definicija i podjela neuralnih mreža

Neuralne mreže (engl. *Neural Networks*) zauzimaju posebnu cjelinu unutar obuhvatnog područja umjetne inteligencije. Mogu se opisati kao matematički modeli kojima se oponaša rad neurona ljudskog mozga, odnosno osobine bioloških živčanih sustava. Drugim riječima, neuralne mreže u procesu rješavanja odgovarajućeg problema oponašaju misaoni kod ljudskog mozga.

Neuralne se mreže sastoje od velikog broja međusobno povezanih elementarnih jedinica koje se nazivaju neuronima, a po svojoj funkciji oponašaju biološke neurone. Neuroni su međusobno povezani vezama koje sadrže propusne (težinske) koeficijente. Veze koje povezuju neurone u svojoj su osnovi slične sinapsama kod bioloških neuronskih mreža.

Za razliku od sustava baziranih na pravilima, rad neuralnih mreža temelji se na postojećim primjerima (prototipovima) integriranim unutar jedinstvene baze znanja.

Pri tome se neuralne mreže u postupku zaključivanja i definiranja izlaznih vrijednosti umjesto dedukcije koriste procesom analognog zaključivanja [2].

Neuralne mreže funkcioniraju na način zapažanja i učenja određenih odnosa unutar baze raspoloživih podataka. Razvojem sofisticiranih matematičkih algoritama i njihovom integracijom unutar strukture neuralnih mreža, one imaju mogućnost percipiranja izuzetno složenih odnosa unutar širokog skupa podataka. Odnosi se mogu definirati kao obrasci ili pravila koji povezuju ulazni skup podataka s vrijednostima definiranim u obliku izlaznih rezultata. Na temelju naučenih pravila neuralne mreže pružaju mogućnost naknadne ekstrapolacije procijenjenih izlaznih vrijednosti za novi skup ulaznih podataka.

Problemi pri čijem se rješavanju uspješno primjenjuju, neuralne se mreže mogu kategorizirati u dvije osnovne skupine:

- klasifikacijski problemi,
- numerički problemi.

Prvu skupinu opisuje problematika kod koje su nastojanja usmjerena na definiranje kategorije kojoj pripada nepoznata veličina, prethodno opisana skupom ulaznih podataka. Neuralne mreže izuzetno su korisni alati osobito pri rješavanju klasifikacijskih problema velike složenosti i težine, pri kojima je ostale metode poput stabla odlučivanja, metoda indukcije i sl. teško ili nemoguće primijeniti. Primjeri iz prakse obuhvaćaju postavljanje dijagnoza pri pregledu i liječenju pacijenata, procjene kreditne sposobnosti građana, procjene troškova i dr.

Numerički se problemi odnose na situacije kod kojih je u odnosu na skup ulaznih podataka potrebno načiniti procjenu izlazne vrijednosti u numeričkom obliku. U praksi se numerički problemi javljaju u gotovo svakom segmentu ljudskih djelatnosti. Međutim, primjena neuralnih mreža najčešće je vezana za analizu velikih numeričkih baza podataka (nelinearna regresija, statistička obrada, analiza vremenskih serija, analiza signala).


Klasifikacija neuralnih mreža može se provesti u odnosu prema velikom broju relevantnih parametara. Općenito se klasifikacija neuralnih mreža može provesti u odnosu na [3]:

- broj slojeva,
- vrstu veza između neurona,
- način učenja,
- smjer širenja informacija,
- vrstu podataka.

3 Struktura i osobine neuralnih mreža

Neuralne mreže u okvirima umjetne inteligencije i primijenjenoga matematičkoga modeliranja imaju sličnu strukturu kao i biološki neuronski sustavi, ali u znatno pojednostavljenom obliku (slika 1.). Neuronu su međusobno povezani vezama koje sadrže propusne (težinske) koeficijente, a po funkciji su slični sinapsama kod bioloških neurona. Pri izradi matematičkoga modela neuralne mreže brojni se faktori, čiji se utjecaji ne smatraju presudnima, zanemaruju poput:


- prostornog oblika dendrita i aksona,
- mogućih učinaka pozicije sinapse na dendrite,
- umora koji se pojavljuje kod bioloških neurona nakon odašiljanja signala,
- činjenice da biološki neuroni u odnosu na vlastitu aktivnost mogu samo imati ili pobuđene (pozitivne težine) ili nepobuđene (negativne težine) izlaze.



Slika 1. Model umjetnog neurona [4]

Svaka neuralna mreža sastoji se od većeg broja strukturnih procesnih jedinica – neurona (slika 2.). Osnovna je funkcija procesnih jedinica prikupljanje informacija od susjednih jedinica, usklađivanje unutarnje razine aktivacije, proračun i prosljeđivanje izlaza daljnjim jedinicama [1]. Nad svakom procesnom jedinicom izvodi se ograničeni broj jednostavnih operacija. Strukturalno se procesne jedinice poradi jednostavnije i brže provedbe algoritamskih funkcija organiziraju u slojeve (engl. *Slab*).

Propagacija, odnosno širenje ulaznog signala odvija se preko ulaznih veza i ponderira se sukladno njegovim težinskim vrijednostima te se na taj način prikupljaju informacije od susjednih neurona. Drugim riječima, ulazno-izlazne veze između neurona koje se nazivaju težina-



Slika 2. Procesna jedinica – neuron [1]

ma (w_{ij}), mogu se prilagoditi tako da pri određenom stimulanu ulaza rezultiraju određenom vrijednosti izlaza, odnosno da izlaz mreže prepoznaje predočeni uzorak ulaznih vrijednosti i reproducira ga u poznatu vrijednost. Pri tome se stimulans ulaza (x_i) množi s pripadnim vrijednostima težina (w_{ij}) te se njihova suma procesira unutar neurona i podvrgava funkciji aktivacije [1]:

$$a = f(N_i) \quad (1)$$

$$N_i = \sum w_{ij} \cdot x_i \quad (2)$$

Funkcija aktivacije normalizira izlazne vrijednosti u intervalu (0,1) i uglavnom se nalazi u obliku:

a) linearne funkcije $f(x) = x$ (3)

b) sigmoidne funkcije $f(x) = 1/(1 + e^{(-x)})$ (4)

c) tangens hiperbolne funkcije $f(x) = \tanh(x)$ (5)

d) Gaussove funkcije $f(x) = e^{(-x^2)}$ (6)

e) komplementarno Gaussove funkcije $f(x) = 1 - e^{(-x^2)}$ (7)

f) simetrično sigmoidne funkcije $f(x) = 2/(1 + e^{(-x)}) - 1$ (8)

3.1 Priprema baze podataka

Struktura baze podataka koja se koristi za učenje (treniranje) i testiranje neuralne mreže sastoji se od skupa podataka koji sačinjavaju varijable i scenariji. Varijable su selektirane u stupcima (kolonama), gdje svaki stupac predstavlja skup vrijednosti jedne varijable karakteristične za svaki pojedini scenarij. Svaki red unutar baze podataka predstavlja jedan scenarij koji se sastoji od većeg broja nezavisnih varijabli s pripadnim vrijednostima i najčešće jedne zavisne varijable. Pritom su u prvom redu definirana imena varijabli, a ostali redovi predstavljaju različite scenarije. Vrijednost zavisne varijable može biti prethodno definirana te na temelju nje neuralna mreža provodi postupak učenja (treniranja) i testiranja. Ako je zavisna varijabla nepoznata, tada je neuralna mreža prepoznaje kao takvu i u postupku procjene definira njezinu izlaznu vrijednost.

3.2 Učenje (treniranje) neuralne mreže

Proces učenja (treniranja) jedan je od najvažnijih elemenata neuralne mreže. Učenjem neuralna mreža uočava i pamti određene zakonitosti (obrasce ili pravila) unutar velikog skupa raspoloživih podataka (scenarija). Pri tome ulazna baza podataka mora za veliki broj scenarija

imati definirane zavisne varijable na temelju čijih vrijednosti neuralna mreža pamti određene zakonitosti i donosi nove odluke u naknadnom procesu procjene izlaznih rezultata za novodefinirane scenarije. Sam proces učenja u osnovi podrazumijeva optimalizaciju težinskih faktora u vezama između neurona te je relativno spor i zahtjevan proces. Za svaku odabranu arhitekturu mreže potrebno je definirati kriterije učenja i odrediti trenutak prestanka treniranja mreže, odnosno definirati parametre prilagođavanja težinskih faktora u vezama između neurona [1]. Baza podataka raspoloživa za treniranje mreže obuhvaća veći dio (80-90 %) iz cjelokupne raspoložive baze podataka ulaznih vrijednosti. Preostali manji dio (10-20 %) koristi se kao uzorak za testiranje mreže.

Učenje je automatizirani proces unutar same strukture neuralne mreže definiran prethodnim odabirom algoritma učenja. Najčešće primjenjivani algoritam učenja je onaj s povratnom propagacijom pogreške (engl. *Back propagation*) u shematskom obliku prikazan na slici 3. Algoritam s povratnom propagacijom je temeljni algoritam učenja nadziranih neuralnih mreža i sadržan je u gotovo svakom komercijalnom obliku neuralnih mreža.


Algoritam učenja s povratnom propagacijom pogreške rabe princip rada nazvan generalizirano delta pravilo (engl. *Generalized Delta Rule*). U ulaznom sloju odabire se slučajni niz početnih težina u vezama neurona tako da se proizvodi izlaz čiju vrijednost mreža zatim uspoređuje s vrijednosti željenog izlaza, tj. uzorkom izlazne vrijednosti pomoću kojeg se mreža uči (skup podataka za treniranje mreže). U slučaju odstupanja dobivene vrijednosti od očekivane, mreža automatski prilagođava

težine u vezama te na taj način smanjuje veličinu odstupanja izlazne vrijednosti od očekivane. Proces učenja općenito završava uspostavljanjem adekvatnih težina u vezama [2]. Kada se za svaki scenarij ulaznih vrijednosti na temelju kojih mreža uči ostvari neznatna veličina odstupanja izlaznog rezultata, proces učenja se prekida, a mreža je spremna na testiranje s novim uzorcima. Postupak učenja neuralne mreže s povratnom propagacijom pogreške slikovito je u najjednostavnijem obliku prikazan na slici 4.

3.3 Testiranje neuralne mreže

Postupak testiranja provodi se s ciljem utvrđivanja stupnja greške prethodno trenirane mreže pri definiranju izlaznih rezultata. Drugim riječima, testiranjem se provjerava u kojoj mjeri neuralna mreža rezultira zadovoljavajućim procjenama izlazne vrijednosti.


Uzorak podataka predviđen za testiranje uzima se iz ulazne baze podataka s poznatim vrijednostima zavisne varijable. Pri tome je važno da je on prethodno izdvojen iz skupa uzoraka na temelju kojih je provedeno treniranje mreže. Najčešće se veličina od 10-20 % uzoraka (scenarija) iz ulazne baze podataka rabi kao uzorak za testiranje. Postupak testiranja mreže znatno je brži od postupka treniranja. Rezultate provedenog postupka testiranja mreže moguće je, ovisno o uporabljenom računalnom programu (NeuroShell, NeuralTools i dr.), dobiti u obliku statističke analize, čime se dobiva uvid može li trenirana mreža poslužiti (i u kojoj mjeri) za procjene novih scenarija s nepoznatim veličinama zavisne varijable.



Slika 3. Shematski prikaz neuralne mreže s povratnom propagacijom pogreške [1]

3.4 Procjena izlaznih rezultata

Procjene izlaznih rezultata odnose se na definiranje nepoznatih veličina zavisne varijable za novi skup ulaznih podataka, odnosno za novodefinirane scenarije. Procjene izlaznih rezultata predstavljaju posljednji korak u primjeni opisane neuralne mreže. Procjenjuje se vrše uz odabir prethodno trenirane mreže. Moguće je odabrati različite trenirane mreže te provjeriti kako će se mijenjati izlazna vrijednost. Pritom je moguće odabrati različite načine procjene izlaznih rezultata. Osnovni se način odnosi na procjene izlaznih rezultata za skup prethodno definiranih scenarija kojima je veličina zavisne varijable nepoznata.



Slika 4. Postupak učenja neuralne mreže [5]

4 Povijesni razvoj i primjena u vodnom gospodarstvu

U nastojanjima za simulacijom rada ljudskog mozga, odnosno modeliranjem živčanog sustava, sredinom prošlog stoljeća započeo je razvoj neuralnih mreža. McCullough i sur. [6] izradili su prvi matematički model protoka obavijesti na temelju biološkog predloška funkcioniranja živčanog sustava. Model su sačinjavali višestruko povezani jednostavni neuronski sustavi. U funkcionalnom smislu binarni su mehanizmi (0,1) iskorišteni za povezivanje neurona i prijenos informacija među njima. Međutim, složenost navedenih procesa uz tadašnji nedostatak razvoja računalne tehnologije zahtijevali su ručno provođenje simulacija na modelu.

Integracija neuralnih mreža u kompjutorsko okruženje započela je krajem 50-ih godina prošlog stoljeća. Prvi model neuralne mreže razvijen uz računalnu podršku nazvan je PERCEPTRON [7] i ujedno je najjednostavniji oblik nepovratne ili jednosmjerne neuralne mreže. Perceptron se sastoji od dva sloja neurona – ulaznog i izlaznog. Perceptron je sadržavao brojne prednosti koje su se manifestirale mogućnošću simuliranja različitih logičkih odnosa. Međutim, svojstvena su mu i određena ograničenja. Dvoslojnim oblikovanjem Perceptron nije u mogućnosti povezivati ulazne i izlazne vrijednosti u slučaju primanja ulaznih signala za koje prethodno nije naučio specifičnu logičku relaciju što je slučaj kod funkcija koje nisu linearno separabilne poput *isključivo-ILI* oblika (engl. *Exclusive-OR function*).

Na temelju osnovnih funkcijskih odnosa i konceptualnog rješavanja problema u sklopu Perceptrona, razvijene su neuralne mreže ADALINE (engl. *ADaptive LINear Element*) i MADALINE (engl. *Many ADALINes*), [8]. U odnosu na Perceptron, obje mreže karakterizira složeni oblik učenja, poznatiji kao *Delta pravilo*, koji funkcionira na principu smanjenja greške, odnosno razlike između dobivene izlazne vrijednosti i unaprijed poznate vrijednosti izlaza (očekivanog rezultata).

U odnosu na početni razvoj neuralnih mreža, tijekom 60-ih i 70-ih godina prošlog stoljeća došlo je do stagnacije i gotovo potpunog napuštanja istraživanja na danom području.

Naknadno su početni nedostaci Perceptrona riješeni prelaskom u trodimenzijsko područje uz dodavanje trećeg skrivenog sloja i povratnih informacija pri učenju, gdje problem *isključivo-ILI* oblika postaje linearno razdjelni [9]. Time je otvoren put značajnijem širenju interesa i daljnjem razvoju unutar područja tehnologije neuralnih mreža. Treći skriveni sloj i širenje informacija s povratnim tokom omogućavaju prepoznavanje različitih pravila i zakonitosti unutar bilo kakve grupe uzoraka u specifičnoj domeni.

Sredinom 80-ih godina prošlog stoljeća na tržištu su se počele pojavljivati prve komercijalne neuralne mreže u obliku gotovih ljuski koje su se rabile za integraciju različitih znanja i iskustava za rješavanje različitih problema unutar različitih znanstvenih i strukovnih područja. Time su se neuralne mreže u dodatnoj mjeri približile širim masama korisnika te njihov razvoj sve više napreduje. Navedenoj činjenici dodatno je pogodovao ubrzani razvoj računalne tehnologije i dostupnost visokosofisticiranih hardverskih i softverskih komponenata.

Kohonen [10] razvija neuralnu mrežu koja ima sposobnost razumijevanja finskog jezika, uz dodatnu mogućnost njegove pismene interpretacije. Nadalje, razvijaju se brojni oblici neuralnih mreža među kojima se izdvajaju NETtalk [11] koja čita, piše i govori (na nižoj razini poput osmogodišnjeg djeteta), zatim DEEP BLUE neuralna mreža koja igra šah s vrhunskim igračima, a razvio ju je IBM 1997. godine [12], ALVINN kao samostalno vozilo naučeno voziti na primjerima kod kojih je izlazni sloj linearni prikaz smjera kojim se vozilo treba kretati da bi ostalo na cesti. Također se pojavljuju i brojni primjeri razvoja i primjene neuralnih mreža u različitim područjima - od financijskog menadžmenta (predviđanja burzovnih i drugih ekonomskih kretanja), medicinskih znanosti (postavljanje dijagnoza i preporuka liječenja) pa sve do primjene u području građevinarstva. U nastavku će se opisati do danas razvijene neuralne mreže unutar područja vodnoga gospodarstva.

S obzirom na primjenu neuralnih mreža unutar područja vodnoga gospodarstva uočava se rastući interes i to prvenstveno u analizi hidroloških i hidrauličkih vremenskih serija [13], [14], [15], [16], [17], [18]; modeliranju otjecanja oborinskog dotoka [19], [20], [21], [22], [23], [24], [25], [26], [27]; prognoziranju potrošnje vode i dotjecanja otpadnih voda [28], [29]; dimenzioniranju kanalske mreže kod sustava odvodnje [30]; analizi otpadnih voda [31], [32], [33], [34], [35], [36], [37]; dimenzioniranja i upravljanja uređaja za pročišćavanje [38], [39], [40], [41]; ponovne uporabe pročišćenih voda [42]; predviđanja hidromorfoloških parametara [43], [44], [45], [46], [47]; upravljanju vodoprivrednim sustavima [48], [49], [50]; prostornoj interpolaciji podataka [51] i sličnim primjenama.

U Hrvatskoj se u području vodnoga gospodarstva neuralne mreže, prema spoznajama autora, primjenjuju i u praksi. U skladu s navedenim, zabilježeni su pozitivni pomaci vezani uz njihov razvoj i nastojanja za daljnjom primjenom.

Deduš [52] postavlja osnove važnosti primjene neuralnih mreža pri upravljanju sustavima odvodnje, osobito onih sustava s većim stupnjem složenosti (veći broj crpnih stanica, preljevnih građevina i sl.). Naglašena je važnost upravljanja sustavima odvodnje u realnom vremenu, radi pravodobnog donošenja racionalnih odluka i primjene odgovarajućih rješenja. Konstantnim praćenjem pojedinih parametara (intenziteta i količina pale oborine, dubine vode na uzvodnim dionicama kanalskog sustava i sl.), uloga neuralnih mreža bila bi istovremeno predviđanje veličina ostalih relevantnih parametara (protoka, dubine vode na nizvodnim dionicama, kvalitete vode). Neuralna se mreža može pritom rabiti samostalno, isključivo u funkciji predviđanja pojedinih parametara, a može se i integrirati u sklopu ekspertnog sustava koji bi na temelju rezultata neuralne mreže predlagao optimalne postupke daljnjeg upravljanja sustavom.

Barbalić i sur. [53] opisali su mogućnost utvrđivanja obuhvata vodenih površina sa satelitske snimke primjenom neuralne mreže. Konvencionalne metode klasifikacije satelitskih snimaka zasnivaju se na složenim matematičkim algoritmima, pa je u radu definirana neuralna mreža koja ima mogućnost klasifikacije multispektralne satelitske snimke radi prepoznavanja i izdvajanja površinskih vodnih sustava. Klasifikacija satelitskih snimaka, primjenom sofisticirane metode integrirane u neuralnoj mreži, omogućava jednostavno, brzo i jeftino vođenje postupka daljinskog motrenja površinskih vodnih sustava. Navedeno se može ocijeniti važnim prvenstveno s aspekta potreba vodnogospodarskog planiranja, praćenja dinamike poplava, praćenja promjena na vodnim dobrima (npr. regulacijske mjere, iskop šljunka) i sl.

U radu [2] su opisane mogućnosti upravljanja sustavima javne odvodnje pomoću analiza optimalizacije u realnom vremenu uz primjenu neuralne mreže. Definirana je neuralna mreža za simulaciju modela otjecanja oborinskog dotoka i praćenja promjena unutar sustava javne odvodnje, kao osnovne podloge za upravljanje urbanim sustavima. Neuralna se mreža temelji na skupu ulaznih podataka vezanih uz zabilježene kišne događaje (vremenski zapis kiše). Izlazni rezultati iz neuralne mreže opisuju osnovne parametre otjecanja (dubine vode i veličine protoka) unutar zatvorenog cijevnog sustava javne odvodnje. Rezultati rada upućuju da je uz primjenu neuralnih mreža u upravljanju u realnom vremenu omogućeno postizanje visokog stupnja pouzdanosti kratkoročnih predviđanja budućih stanja unutar sustava odvodnje. Time je omogućeno pravovremeno poduzimanje odgovarajućih mjera radi ostvarivanja optimalnih hidrauličko-pogonskih uvjeta tečenja unutar kanalske mreže i maksimalne zaštite prijavnika.

Primjena neuralnih mreža za predviđanje vodostaja razmatrana je u radu [54]. Definirana neuralna mreža bazira se na praćenju vodostaja na mjernim postajama na uzvodnim dionicama vodnoga toka, te prognoziranja vodostaja na nizvodnim dionicama. Na taj je način primjenom neuralne mreže moguće pravovremeno predvidjeti vodostaje koji onemogućavaju plovidbu nizvodnim dionicama te poduzeti odgovarajuće mjere. Isto tako, moguće je predvidjeti i nailazak poplavnih valova te pravodobno poduzeti odgovarajuće mjere zaštite.

U radu [55] analizirana je mogućnost primjene neuralnih mreža u ekonomskim analizama sustava odvodnje. Kre-

irana je neuralna mreža NEMATSO (Neuralna mreža za aproksimativnu procjenu troškova sustava odvodnje) koja omogućava jednostavnu, brzu i dovoljno točnu procjenu ukupnih ili jediničnih troškova izgradnje, pogona i održavanja sustava odvodnje, bez potrebe za njihovim prethodnim dimenzioniranjem i izradom pripadnih troškovnika. Time je omogućena jednostavna i učinkovita ekonomska usporedba većeg broja varijantnih rješenja. Predviđenim postupkom korisnici na jednostavan i brz način dobivaju okvirni uvid u ekonomsku isplativost pojedinog rješenja na temelju čega je iz velikog skupa potencijalnih kombinacija sustava odvodnje i pročišćavanja otpadnih voda omogućeno provođenje eliminacije onih rješenja za koja je jasno uočljivo da s ekonomskog aspekta odstupaju od ostalih. Ograničenja neuralne mreže NEMATSO ogledaju se u mogućnosti aproksimativnih procjena isključivo za manja ruralna naselja veličine do 500 ES.

5 Zaključak

Ovim je radom uz sažeti opis neuralnih mreža također potvrđena početna pretpostavka da su mogućnosti njihove primjene izuzetno velike u svim segmentima ljudskog djelovanja, uključivo i vodno gospodarstvo. Uporaba neuralnih mreža unutar područja vodnoga gospodarstva u znatnoj bi mjeri pojednostavila i ubrzala provođenje različitih analiza i ekspertiza te bi rezultiralo donošenjem kvalitetnih zaključaka. Premda je do danas razvijen manji broj kvalitetnijih neuralnih mreža i na području Hrvatske, nameće se potreba za poticanjem njihova daljnjeg razvoja.

LITERATURA

- [1] Rajčić, V., (2003), *Ekspertni sustavi* (skripta predavanja), Poslijediplomski studij, Građevinski fakultet Sveučilišta u Zagrebu, Zagreb.
- [2] Šperac, M., (2004), *Upotrebljivost neuralnih mreža za određivanje otjecanja u sustavu urbane odvodnje*, doktorska disertacija, Građevinski fakultet, Sveučilište u Zagrebu.
- [3] URL_1, <http://solair.eunet.rs/~ilicv/ocr.html>
- [4] URL_2, http://www.tsrb.hr/meha/index.php?option=com_content&task=view&id=14&Itemid=1
- [5] Bigus, J.P., (1996), *Data Mining with Neural Networks – Solving Business Problems from Application Development to Decision Support*, McGraw-Hill Companies, SAD.
- [6] McCullough, W.W., Pitts, W., (1943), *A logical calculus of the ideas immanent in nervous activity*, Bulletin of Mathematical Biophysics, Vol. 5, pp. 115-133.
- [7] Rosenblatt, F., (1958), *The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain*, Cornell Aeronautical Laboratory, Psychological Review, v65, No. 6, pp. 386-408.
- [8] Widrow, B., Hoff, M.E., (1960), Adaptive switching circuits, IRE WESCON Convention Record, Vol. 4, pp. 96-104, New York: Institute of Radio Engineers.
- [9] Hopfield, J.J., (1982), *Neural networks and physical systems with emergent collective computational abilities*, Proceedings of the National Academy of Sciences of the USA, Vol. 79, No. 8, pp. 2554-2558.
- [10] Kohonen, T., (1984), *Self-Organization and Associative Memory*, Springer, Berlin.
- [11] Sejnowski, T., Rosenberg, C., (1986), *NETtalk: a Parallel Network that Learns to Read Aloud*, The John Hopkins University Electrical Engineering and Computer Science Technical Report, JHU/EECS-86/01.
- [12] URL_3, [http://en.wikipedia.org/wiki/Deep_Blue_\(chess_computer\)](http://en.wikipedia.org/wiki/Deep_Blue_(chess_computer))
- [13] French, M.N., Krajewski, W.F., Cuykendall, R.R., (1992), *Rainfall forecasting in space and time using a neural network*, Journal of Hydrology, Vol. 137, pp.1-31.
- [14] Raman, H., Sunilkumar, N., (1995), *Multivariate modeling of water resources time series using artificial neural network*, Journal of Hydrology, Vol. 40, pp. 145-163.
- [15] Govindaraju, R.S., Ruo, A.R., (2000), *Artificial Neural Networks in Hydrology*, Kluwer Academic Publishers, Dordrecht.
- [16] Elshorbagy, A., Simonovic, S.P., Panu, U.S., (2000), *Performance evaluation of artificial neural networks for runoff prediction*, Journal of Hydrologic Engineering ASCE 5 (4), pp. 424-427.

- [17] Dawson, C.W., Wilby, R.L., (2001), *Hydrological modeling using artificial neural networks*, Progress in Physical Geography 25 (1), pp. 80–108.
- [18] Ashu, J., Avadhnam, M.K., (2007), Hybrid neural network models for hydrologic time series forecasting, Applied Soft Computing, Vol. 7, Issue 2, pp. 585-592.
- [19] Hsu, K.L., Gupta, H.V., Sorooshian, S., (1995), *Artificial neural network modeling of the rainfall-runoff process*, Water Resources Research, Vol. 31, Issue 10, pp. 2517–2530.
- [20] Minns, A.W., Hall, M.J., (1996), *Artificial neural networks as rainfall-runoff models*, Hydrological Sciences, Vol. 41, Issue 3, pp. 399–417.
- [21] Smith, J., Eli, R.N., (1997), *Neural-network models of rainfall-runoff processes*, Journal of water resources planning and management, Vol. 121, Issue 6, pp.499-508.
- [22] Jacq, F., Savic, D.A., (1997), *Rainfall-Runoff Modelling Using Neural Networks*, Centre For Systems And Control Engineering, Report No. 97/02, School of Engineering, University of Exeter, Exeter, United Kingdom, pp.66.
- [23] Shamseldin, A.Y., (1997), *Application of a neural network technique to rainfall-runoff modeling*, Journal of Hydrology, Vol. 199, pp. 272–294.
- [24] Tokar, A.S., Johnson, P.A., (1999), *Rainfall-runoff modeling using artificial neural networks*, Journal of Hydrologic Engineering, Vol. 4, Issue 3, pp. 232–239.
- [25] Sajikumar, N., Thandaveswara, B.S., (1999), *A non-linear rainfall-runoff model using an artificial neural network*, Journal of Hydrology, Vol. 216, pp. 32–55.
- [26] de Vos, N. J., Rientjes, T. H. M., (2008), *Multiobjective training of artificial neural networks for rainfall-runoff modeling*, Water Resources Research, Vol. 44.
- [27] Modarres, R., (2008), *Multi-criteria validation of artificial neural network rainfall-runoff modeling*, Hydrology and Earth System Sciences, Discuss., Vol. 5, pp. 3449-3477.
- [28] Dandy, G.C., Loukas, B., Davies, C.M., (1998), *Modelling residential water demand in Adelaide using artificial neural networks*, Research Report No. R160, Department of Civil and Environmental Engineering, University of Adelaide, Australia.
- [29] El-Din, A.G., Smith, D.W., (2002), *A neural network model to predict the wastewater inflow incorporating rainfall events*, Water Resources, Vol. 36, Issue 5, pp. 1115-1126.
- [30] Shukla, M.B., Kok, R., Prasher, S.O., Clark, G., Lacroix, R., (1996), *Use of artificial neural networks in transient drainage design*, Trans. ASAE, Vol. 39, pp. 119–124.
- [31] Maier, H.R., Dandy, G.C., (2001), *Neural network based modelling of environmental variables: a systematic approach*, Mathematical and Computer Modelling, 33 (6), pp. 669-682.
- [32] Lek, S., Guiresse, M., Giraudel, J-L., (1999), *Predicting stream nitrogen concentration from watershed features using neural networks*, Water Research, Vol. 33, Issue 16, pp. 3469-3478.
- [33] Bowers, J.A., Shedrow, C.B., (2000), *Predicting stream water quality using Artificial Neural Networks (ANN)*, Environmental Studies Journal, Vol.4, pp. 89-97.
- [34] Bowden, G.J., Nixon, J.B., Maier, H.M., Dandy, G.C., Holmes, M., (2003), *Forecasting Chlorine Residuals in a Water Distribution System using a Generalised Regression Neural Network*, Proceedings, Proceedings of MODSIM 2003, Townsville, Australia.
- [35] May, R.J., Maier, H.R., Dandy, G.C., Nixon, J.B., (2004), *General Regression Neural Networks for Modeling Disinfection Residual in Water Distribution Systems*, Proceedings of the 6th World Water and Environmental Resources Congress, Salt Lake City, SAD.
- [36] Holmes, M., Chow, C.W.K., May, R.J., Badalyan, A., Fitzgerald, F., Nixon, J.B., Dandy, G.C., Maier, H.R., (2005), *Disinfection residual control tool: Developing tools for improved disinfection control within water distribution systems*, Proceedings of Disinfection 2005-Sharing Disinfection Technologies: Water, Wastewater, Water Reuse and Biosolids, Mesa, SAD.
- [37] Kunwar P. S., Ankita B., Amrita M., Gunja J., (2009), *Artificial neural network modeling of the river water quality - A case study*, Ecological Modelling, Vol. 220, Issue 6, pp. 888-895.
- [38] Woinaroschy, A., Vidrighin, M., (1999), *Neural networks simulation and optimization of waste water treatment*, ECCE 2, Montpellier, Francuska.
- [39] Baruch, I.S., Georgieva, P., Barrera-Cortes, J., de Azevedo, S.F., (2005), *Adaptive recurrent neural network control of biological wastewater treatment: Research Articles*, International Journal of Intelligent Systems, Volume 20 , Issue 2, pp.173 – 193.
- [40] Benelmir, O., Filali, S., (2007), *Modelling and Neural Networks of Bioreactors in Wastewater Treatment Process*, Int. Journal on Sciences and Techniques of Automatic control, Vol. 1, Issue 1, pp. 109-119.
- [41] Borowa, A., Brdys, M.A., Mazur, K., (2007), *Modelling of Wastewater Treatment Plant for Monitoring and Control*, International Journal of Computers, Communications & Control, Vol. II, No. 2, pp. 121-131.
- [42] Chen, J.C., Chang, N.B., Shieh, W.K., (2003), *Assessing wastewater reclamation potential by neural network model*, Engineering Application of Artificial Intelligence, Vol. 16, pp. 149–157.
- [43] Dibike, Y.B., Abbott, M.B., (1999a), *Application of artificial neural networks to the simulation of a two dimensional flow*, Journal of Hydraulic Research, Vol. 37, No. 4, pp. 435-446.
- [44] Dibike, Y.B., Minns, A.W., Abbott, M.B., (1999b), *Application of artificial neural networks to the generation of wave equations from hydraulic data*, Journal of Hydraulic Research, Vol.37, No.1, pp. 81-97.
- [45] Dibike, Y.B., (2002), *Developing generic hydrodynamic models using artificial neural networks*, Journal of Hydraulic Research, Vol.40, No.2., pp. 183-190.
- [46] Cigizoglu, H.K., Alp, M., (2006), *Generalized regression neural network in modelling river sediment yield*, Advances in Engineering Software, Vol. 37, Issue 2, pp. 63 – 68.
- [47] Zhang, Q., Zhang, X., Wu, J., (2009), *Research on Dynamic Response of Riverbed Deformation Based on Theory of BP Neural Network*, Advances in Soft Computing, Springer Berlin/Heidelberg, Vol. 56, pp. 865-873.
- [48] Ames, D.P., (2002), *Bayesian Decision Networks for Watershed Management*, Doctor of Philosophy thesis, Civil and Environmental Engineering, Logan, Utah State University, SAD.
- [49] Schuize, F.H., Wolf, H., Jansen, H.W., van der Veer, P., (2005), *Applications of artificial neural networks in integrated water management : fiction or future?*, Water science and technology, vol. 52, n°9, pp. 21-31.
- [50] Khalil, A. F., McKee, M., Kemblowski, M., Asefa, T., (2006), *Basin scale water management and forecasting using artificial neural networks*, Journal of the American Water Resources Association, Vol. 41, Issue 1, pp.195-208.
- [51] Kapelan, Z., Savic, D.A., Walters, G.A., (2005), *Decision-Support Tools for Sustainable Urban Development*, Proceedings of the Institution of Civil Engineers, Engineering Sustainability 158, issue ES3, pp. 135-142.
- [52] Deduš, B., (1994), *Neuralni modeli upravljanja kanalskim sustavima*, www.proning-dhi.hr.
- [53] Barbalčić, D., Rajčić, V., (2003), *Identifikacija vodenih površina na satelitskim snimcima neuralnom mrežom*, Građevinar, br.55, str.513-518.
- [54] Carević, D., Bekić, D., Vouk, D., (2008), *Primjena neuralnih mreža za predviđanje vodostaja*, Hrvatske vode, vol.16, no.62, pp.1-5.
- [55] Vouk, D., (2009), *Ekspertni sustav podrške pri odabiru optimalnog sustava odvodnje u ruralnim naseljima*, doktorska disertacija, Građevinski fakultet Sveučilišta u Zagrebu, Zagreb.