



UNIVERZITET U NOVOM SADU
FAKULTET TEHNIČKIH NAUKA U
NOVOM SADU



Krtolica G. Ivana

**PROCENA EKOSTATUSA REČNIH SISTEMA NA PRIMERU
DUNAVSKOG BASENA PRIMENOM MODELA VEŠTAČKIH
NEURONSKIH MREŽA**

DOKTORSKA DISERTACIJA

Mentori:

1. Prof. emeritus dr Mirjana Vojinović – Miloradov
Univerzitet u Novom Sadu, Fakultet tehničkih nauka
2. Prof. dr Snežana Radulović, redovni profesor
Univerzitet u Novom Sadu, Prirodno – matematički fakultet

NOVI SAD, 2021.

Doktorska disertacija

Ivana Krtolica

УНИВЕРЗИТЕТ У НОВОМ САДУ

ОБРАЗАЦ – 5а

ФАКУЛТЕТ ТЕХНИЧКИХ НАУКА

КЉУЧНА ДОКУМЕНТАЦИЈСКА ИНФОРМАЦИЈА¹

Врста рада:	Докторска дисертација
Име и презиме аутора:	Кртолица Г. Ивана
Ментор (титула, име, презиме, звање, институција)	1. др Мирјана Војиновић Милорадов, професор емеритус 2. др Снежана Радуловић, редовни професор
Наслов рада:	Процена екостатуса речних система на примеру дунавског басена применом модела вештачких неуронских мрежа
Језик публикације (писмо):	Српски (латиница)
Физички опис рада:	Унети број: Страница: 147 Поглавља: 11 Референци: 233 Табела: 38 Слика: 11 Графикона: 0 Прилога: 4
Научна област:	Инжењерство заштите животне средине и заштите на раду
Ужа научна област (научна дисциплина):	Инжењерство заштите животне средине
Кључне речи / предметна одредница:	Еколошки статус акватичних речних система; дунавски басен; растворени кисеоник; нитратни анјони; ортофосфатни анјони; вештачке неуронске мреже; Капа индекс; анализа осетљивости; Mann – Whitney тест
Резиме на језику рада:	Основни циљ докторске дисертације је креирање модела за предикцију еколошког статуса речних басена на основу присуства макрофита и кључних, репрезентативних хемијских параметара на примеру Дунава применом вештачких неуронских мрежа и еко-пријатељски оријентисаних методологија. С обзиром на то да биолошки и физичко - хемијски параметри који се према Оквирној Директиви о водама користе за процену еколошког статуса водних екосистема не показују међусобну линеарну зависност модели вештачких неуронских мрежа суоптималан алат за процену екостатуса акватичних система. Основни мотив истраживања је обрада података прикупљена током последњег истраживања Дунава (енгл. Joint Danube Survey 3) у циљу процене еколошког статуса Дунава у целини. Резултати моделовања потврдили су да је креiran модел вештачких неуронских мрежа одговарајући алат за процену и предикцију еколошког статуса речних екосистема када се као улазни параметри користе вредности заступљености макрофита, а као излазни подаци класе еколошког статуса израчунате на основу измерених концентрација раствореног кисеоника, нитратних и ортофосфатних анјона. У циљу одређивања сигнификантних врста макрофита коришћених у моделовању примењена је анализа осетљивости. Приступ интеркорелације макрофита, као улазних варијабли, и селектованих репрезентативних хемијских параметара применом модела вештачких неуронских мрежа по први пут је аплициран у истраживачким активностима докторске дисертације.

¹ Аутор докторске дисертације потписао је и приложио следеће Обрасце:

5б – Изјава о ауторству;

5в – Изјава о истоветности штампане и електронске верзије и о личним подацима;

5г – Изјава о коришћењу.

Ове Изјаве се чувају на факултету у штампаном и електронском облику и не кориче се са тезом.

Doktorska disertacija

Ivana Krtolica

Датум прихватања теме од стране надлежног већа:	27.01.2021.
Датум одбране:	
Чланови комисије: (титула, име, презиме, званије, институција)	Председник: др Ивана Михајловић, ванредни професор, Факултет техничких наука, Универзитет у Новом Саду Члан: др Душанка Џвијановић, ванредни професор, Природно - математички факултет , Универзитет у Новом Саду Члан: др Драган Савић, редовни професор, Центар за водне системе, Факултет за инжењерство, математику и физику, Универзитет Екслите, Уједињено Краљевство Члан: др Срђан Ковачевић, научни сарадник, Факултет техничких наука, Универзитет у Новом Саду Члан, ментор: др Мирјана Војиновић Милорадов, професор емеритус, Факултет техничких наука, Универзитет у Новом Саду Члан, ментор: др Снежана Радуловић, редовни професор, Природно – математички факултет, Универзитет у Новом Саду
Напомена:	

Doktorska disertacija

Ivana Krtolica

UNIVERSITY OF NOVI SAD

FACULTY OF TECHNICAL SCIENCES

KEY WORD DOCUMENTATION²

Document type:	Doctoral dissertation
Author:	Ivana G. Krtolica, M.Sc.
Supervisor (title, first name, last name, position, institution)	Professor emeritus, Mirjana Vojinović Miloradov, PhD; Full professor, Snežana Radulović, PhD
Thesis title:	Prediction and assessment of Danube river basin ecostatus by applying Model of Artificial Neural Networks
Language of text (script):	Serbian language (Latin script)
Physical description:	Number of: Pages: <u>147</u> Chapters: <u>11</u> References: <u>233</u> Tables: <u>38</u> Illustrations: <u>11</u> Graphs: <u>0</u> Appendices: <u>4</u>
Scientific field:	Environmental Engineering and Occupational Safety and Health
Scientific subfield (scientific discipline):	Environmental Engineering
Subject, Key words:	Aquatic river system ecostatus; Danube basin; dissolved oxygen; nitrate anions; orthophosphate anions; Artificial Neural Networks; Kappa index; Sensitivity analysis; Mann – Whitney test
Abstract in English language:	The aim of doctoral dissertation <i>Prediction and assessment of Danube river basin ecostatus by applying model of Artificial Neural Networks</i> is creating model of artificial neural network for predicting eco status of river basins using macrophytes and key, representative chemical parameters have no linear correlation Artificial Neural Networks were shown as adequate tool for modelling river eco status. Main motive for investigation is data processing of dataset collected during Joint Danube Survey 3 expedition in aim to predict the whole Danube River basin eco status. Modelling results claimed that created model of Artificial Neural Networks is appropriate tool for prediction river eco status when inputs variables are macrophytes and outputs are classes of ecological state calculated according to measured concentrations of dissolved oxygen, nitrate and orthophosphate anions. This kind of artificial intelligence modelling for prediction and assessment of Danube River basin eco status. Modelling results claimed that model of Artificial Neural Networks is appropriate tool for prediction river eco status when inputs variables are macrophytes and outputs are classes of ecological state calculated according to measured concentrations of dissolved oxygen, nitrate and orthophosphate anions. This kind of artificial intelligence modelling for prediction and assessment of Danube river basin ecostatus for the first time was applied in PhD thesis.
Accepted on Scientific Board on:	27 th January 2021
Defended:	

² The author of doctoral dissertation has signed the following Statements:

5a – Statement on the authority,

5b – Statement that the printed and e-version of doctoral dissertation are identical and about personal data,

5c – Statement on copyright licenses.

The paper and e-versions of Statements are held at the faculty and are not included into the printed thesis.

Doktorska disertacija

Ivana Krtolica

Thesis Defend Board: (title, first name, last name, position, institution)	President: Associate professor, Ivana Mihajlović, PhD, Faculty of Technical Sciences, University of Novi Sad Member: Associate professor, Dušanka Cvijanović, PhD, Faculty of Sciences, University of Novi Sad Member: Full professor, Dragan Savić, Centar for Water Systems, Faculty for Engineering, Mathematics and Physics, University of Exeter, United Kingdom, Member: Research assistant, Srđan Kovačević, PhD Faculty of Technical Sciences, University of Novi Sad Member: Associate professor, Srđan Vukmirović, PhD Faculty of Technical Sciences, University of Novi Sad Member Mentor: Professor emeritus, Mirjana Vojinović Miloradov, PhD, Faculty of Technical Sciences, University of Novi Sad Member Mentor: Full professor, Snežana Radulović, PhD, Faculty of Sciences, University of Novi Sad
Note:	

ZAHVALNICA

Najveću zahvalnost dugujem svojim mentorkama prof. dr emeritus Mirjani Vojinović – Miloradov i prof. dr Snežani Radulović koje su verovale u mene i onda kad ni sama nisam. Provesti godine u društvu intelektualne elite, kakvoj moje dve uvažene mentorke nesumnjivo pripadaju, velika je čast i privilegija. Obeležile ste značajan deo mog života i beskrajno sam vam zahvalna na svemu što ste mi pružile.

Veliku zahvalnost dugujem doc. dr Dušanki Cvijanović, koju neizmerno cenim još iz vremena studentskih dana. Hvala na ideji, podršci i pomoći pri izradi svih dosadašnjih publikacija. Uvek je bila tu kad je najteže. Žena brilljantnog uma i zavidne energije. Čast je biti u društvu najboljih.

Za sve faze koje sam prošla na ovom trnovitom putu, sve sate priče i podrške, i za sve modele veštačkih neuronskih mreža koje je isprobavao, zahvalna sam prof. dr Đorđu Obradoviću. Uvek pun ljubavi i topline, veliki oslonac i podrška u godinama rada na ovoj tezi. Sa previše reči umanjila bih njegovu veličinu.

Neizmernu zahvalnost dugujem i prof. dr Dragunu Saviću koji je bio uz mene u svim fazama rada na tezi, pružao neprocenjivu podršku, bezrezervnu pomoć i uvek imao sjajne ideje. Veliko ime u svetu nauke! Hvala od srca!

Hvala mojim prijateljima, kolegama, svima koji su me iskreno podrili i verovali u moj uspeh. Uspeh ne bi imao težinu da nema s kim da se deli.

Za sve što jesam i verujem da mogu postati dugujem majci. Bez mnogo reči svim svojim srcem bila je uz mene. Bez tebe majko ne bih uspela.

Jedinom bratu, veliko hvala. Svaki moj uspeh deo je njegove sreće.

Bio lozi ne veruju u život posle smrti, ali mene jedan anđeo čuva, znam.

Doktorsku disertaciju posvećujem najvoljenijima, Teodori i Tijani, zbog kojih sam se borila da istrajem i kad je bilo najteže. Vredne ste borbe do poslednjeg daha.

Ivana

SADRŽAJ

1. UVODNA RAZMATRANJA	14
2. OSNOVE I MOTIV ISTRAŽIVANJA	16
3. STRUKTURA DISERTACIJE	17
4. AKTUELNO STANJE U OBLASTI	18
4.1. Primena različitih analitičkih metoda u oblasti ekologije i zaštite životne sredine	18
4.2. Metode procene ekološkog statusa reka	20
4.3. Makrofite kao bioindikatori trofičnosti vodenih ekosistema.....	24
5. PARAMETRI KOJI SE KORISTE U PROCENI EKOLOŠKOG STATUSA REKA	28
5.1. Biološki parametri u proceni ekološkog statusa reka	28
5.2. Hemijski parametri u proceni ekološkog statusa reka	29
5.2.1. Rastvoren kiseonik u površinskim vodama	31
5.2.2. Nitratni anjoni u površinskim vodama	35
5.2.3. Ortofosfatni anjoni u površinskim vodama	38
5.3. Klasifikacija ekološkog statusa reka u podunavskim zemljama.....	39
6. VEŠTAČKE NEURONSKE MREŽE KAO ALAT U MODELOVANJU EKOLOŠKOG STATUSA REČNIH EKOSISTEMA	46
6.1. Princip rada veštačkih neuronskih mreža	46
6.2. Neuronska mreža tipa višeslojni perceptron sa propagacijom signala unapred	57
6.3. Primena veštačkih neuronskih mreža	59
7. MATERIJAL I METODE	61
7.1. Osnovne karakteristike istraživanog područja	61
7.3. Internacionala komisija za zaštitu Dunava	62
7.4. Zajedničko istraživanje reke Dunav	63
7.5. Klase ekološkog statusa Dunava.....	65
7.6. Opis dataseta korišćenog u procesu modelovanja ekološkog statusa Dunava primenom veštačkih neuronskih mreža	66
7.6.1. Indeksi trofičnosti vodenih ekosistema.....	67
7.7. Definisanje modela veštačke neuronske mreže za predviđanje klase ekološkog statusa Dunava na osnovu prisustva makrofita.....	71
7.8. Određivanje signifikantnih vrsta makrofita primenom analize osetljivosti.....	75
7.9. Analiza rezultata modelovanja primenom Mann-Whitney testa	78

8. REZULTATI I DISKUSIJA.....	79
8.1. Rezultati modelovanja klase ekološkog statusa Dunava na osnovu prisustva makrofita i koncentracije rastvorenog kiseonika	81
8.2. Rezultati modelovanja klase ekološkog statusa Dunava na osnovu prisustva makrofita i koncentracija nitratnih anjona.....	90
8.3. Rezultati modelovanja ekološkog statusa Dunava na osnovu prisustva makrofita i koncentracija ortofosfatnih anjona.....	99
9. ZAKLJUČNA RAZMATRANJA.....	113
LITERATURA:.....	115
PRILOG 1.....	132
PRILOG 2.....	135
PRILOG 3.....	137
PRILOG 4.....	139

Rezime:

Određivanje i procena kvaliteta površinskih voda je izuzetno kompleksan zadatak za koji ne postoji utvrđen uniformni algoritam, te je neophodno definisati model za procenu i predikciju kvaliteta voda koji će biti pouzdan, jednostavan, ekonomski opravdan i ekološko-prijateljski orijentisan (engl. *eco-friendly oriented*).

Ekološki status vodenih ekosistema određuje se na osnovu parametara razvrstanih u biološke, hemijske, fizičko-hemijske i hidromorfološke elemente kvaliteta, i može biti kvalifikovan kao odličan, dobar ili umeren ekološki status. Ekološki status reke Dunav, kao jedinstvenog internacionalnog rečnog basena, predstavlja izuzetno važan parametar u oblasti upravljanja vodama.

Plan upravljanja za sliv reke Dunav ima za cilj da do 2027. godine dostigne postavljene ciljeve Okvirne Direktive o vodama (engl. *Water Frame Directive*). U cilju dobijanja pouzdanih i uporedivih podataka neophodnih u procesu planiranja i donošenja adekvatnih mera upravljanja, kao i da bi se pratio efekat donetih odluka, podunavske zemlje u okviru Međunarodne komisije za zaštitu reke Dunav (engl. *International Comission for the Protection of the Danube River - ICPDR*) organizuju zajednička naučna istraživanja. Od 2001. - 2013. godine, svake četvrte godine, realizovana su 3 Zajednička istraživanja reke Dunav (engl. *Joint Danube Survey*), tokom kojih je uzorkovana površinska voda Dunava sa pritokama u cilju sakupljanja svih zvaničnih parametara za procenu kvaliteta voda propisanih od strane Okvirne Direktive o vodama.

Elementi za procenu ekološkog statusa površinskih voda sakupljeni tokom trećeg Zajedničkog istraživanja reke Dunav (Joint Danube Survey 3 – JDS 3) predstavljaju vrednu bazu podataka obrađenu u okviru ove doktorske disertacije u cilju procene ekološkog statusa dunavskog basena. Realizaciju Zajedničkog istraživanja Dunava u okviru treće ekspedicije koordinira Sekretarijat Međunarodne komisije za zaštitu reke Dunav u saradnji sa podunavskim zemljama, a podaci prikupljeni tokom tog istraživanja, su još uvek najnovija dostupna baza podataka vezana za čitav tok dunavskog basena. Makrofite, kao zvanični biološki parametri u proceni ekološkog statusa vodnih ekosistema, izabrane su po prvi put kao ulazne varijable u modelovanju, dok su izlazne varijable bile klase ekološkog statusa određene na osnovu koncentracija reprezentativnih fizičko-hemijskih parametara: rastvorenog kiseonika, nitratnih i ortofosfatnih anjona.

Parametri korišćeni u modelovanju primenom modela veštačkih neuronskih mreža prikupljeni su duž čitavog toka Dunava, na 68 mapiranih lokaliteta sa obe strane rečne obale, gde je svaki lokalitet (JDS 1 – JDS 68) obuhvatao 6 km rečnog toka.

Za potrebe modelovanja klase ekološkog statusa Dunava kreirana je jedinstvena klasifikacija od 7 klasa ekološkog statusa, koje su određivane na osnovu koncentracija rastvorenog kiseonika, nitratnih i ortofosfatnih anjona.

Jedinstven i specifičan doprinos teze „*Procena ekostatusa rečnih sistema na primeru dunavskog basena primenom modela veštačkih neuronskih mreža*“ je kreiranje modela veštačkih neuronskih mreža koji uspešno predikuje klase ekološkog statusa rečnih ekosistema na osnovu sastava makrofita na određenom delu rečnog toka. Klase ekološkog statusa određene su na osnovu koncentracija rastvorenog kiseonika, nitratnih i ortofosfatnih anjona. Za sve hemijske parametre korišćene u modelovanju ekološkog statusa reke Dunav dizajniran je jedinstven model veštačke neuronske mreže. Ukupno 3 modela veštačkih neuronskih mreža su generisana, trenirana, testirana i proverena analizom osetljivosti. Za poređenje trofičnosti odabranih indikatorskih vrsta makrofita i onih vrsta makrofita koje je model odredio kao nesignifikantne primenjen je Mann – Whitney test. Podudarnost između izmerenih i prediktovanih vrednosti klase ekološkog statusa određena je izračunavanjem Kappa indeksa.

Najbolju stopu predikcije pokazao je model primenjen za modelovanje klase ekološkog statusa na osnovu izmerenih koncentracija rastvorenog kiseonika (82.93%), gde je procenat apsolutne greške iznosio 3.04%. Vrednost Kappa indeksa za ovaj model ($K_a = 0.61$) indikovao je dobru podudarnost između izmerenih i prediktovanih vrednosti klase ekološkog statusa.

Model koji je baziran na koncentracijama nitratnih anjona imao je tačnost procene 74.80%, procenat apsolutne greške iznosio je 5.42%, a Kappa indeks 0.64.

Slični rezultati dobijeni su i za model baziran na koncentracijama nivoima ortofosfatnih anjona, gde je tačnost procene iznosila 71.55%, procenat apsolutne greške 8.99%, dok je vrednost Kappa indeksa 0.17.

Na osnovu seta podataka prikupljenog tokom Joint Danube Survey 3 ekspedicije klase ekološkog statusa Dunava određene na osnovu koncentracija rastvorenog kiseonika

kreću se od I - IV klase, na osnovu koncentracija nitratnih anjona od IV - VII klase ekološkog statusa, dok su klase ekološkog statusa određene na osnovu ortofosfatnih anjona od IV - V klase. Kod modelovanja baziranog na vrednostima koncentracija rastvorenog kiseonika najčešća greška u proceni bila je jedna klasa ekološkog statusa više nego što je zapravo. Model je u nekim slučajevima pokazivao bolju procenu ekološkog statusa od realnog. To je bio slučaj sa lokalitetima koji su locirani na ušćima pritoka dunavskog basena. Na tim lokalitetima model je prediktovao nižu (bolju) klasu ekološkog statusa od one klase kojoj određeni lokalitet pripada na osnovu izmerene vrednosti određenog hemijskog parametra. Prediktovane vrednosti za klase ekološkog statusa bazirane na koncentracijama nitratnih anjona gotovo su u istom procentu odstupale od očekivanih vrednosti klase ekološkog statusa.

Model baziran na vrednostima koncentracija ortofosfatnih anjona, prediktovao je nižu klasu ekološkog statusa za 24 primera, dok je za 16 primera model prediktovao višu klasu ekološkog statusa.

Greške u proceni klase ekološkog statusa bazirane na osnovu koncentracija nitratnih i fosfatnih anjona ne pokazuju značajnu prostornu zavisnost, već se javljaju duž čitavog toka Dunava. Najveća odstupanja između izmerenih i vrednosti klase ekološkog statusa koje je veštačka neuronska mreža prediktovala za sva tri hemijska parametra (koncentracije rastvorenog kiseonika, nitratnih i ortofosfatnih anjona) bila su na pritokama Dunava, rekama Tisi i Arđeš. Na ovim primerima model neuronske mreže je uglavnom prediktovao niže (bolje) klase ekološkog statusa od one kojoj ti lokaliteti pripadaju na osnovu izmerenih vrednosti hemijskog parametra za koji je kreiran model veštačke neuronske mreže.

U istraživačkim aktivnostima doktorske teze, ekološki status dunavskog basena, po prvi put je modelovan primenom veštačkih neuronskih mreža za oblast ekoloških ispitivanja i inženjerstva zaštite životne sredine primenom makrofita kao ulaznih varijabli i klase ekološkog statusa kao izlaznih varijabli.

Razvijeni model predikcije promoviše nov način procene ekološkog statusa sveukupnih vodnih sistema u budućim istraživanjima za ekološku naučnu sferu i inženjerskih ispitivanja u oblasti zaštite životne sredine. Jedinstven rezultat istraživačkih aktivnosti doktorske disertacije je model veštačkih neuronskih mreža kao osnovna platforma istraživanja, koji će imati široku primenu za procenu i predikciju klase kvaliteta

rečnih sistema primenom makrofita kao ulaznih varijabli uz rezultat klasa akvatičnih sistema baziranih na koncentracijama selektovanih fizičko-hemijskih parametara.

Abstract:

Assessing and prediction quality of surface water is an extremely complex task for which there is no established general algorithm. The Thesis „*Prediction and assessment of Danube river basin ecostatus by applying model of Artificial Neural Networks*,“ aims to develop a model for assessment water quality that will be as simple as possible without requiring large material costs with eco-friendly oriented methodologies. The ecological status of aquatic ecosystems is determined based on parameters classified into biological, chemical, physico-chemical and hydromorphological quality elements. Those can be qualified as of excellent, good or moderate ecological status. The ecological status of the Danube River, as the most international river basin, is an important unit of information in the field of water management.

The Management Plan for the Danube River Basin aims to reach all the Water Framework Directive objectives by 2027. In order to obtain reliable and comparable data necessary for the process of planning and adoption of adequate measures, as well as to monitor the effect of the decisions made by a Danube country, the *International Commission for the Protection of the Danube River (ICPDR)* organize joint scientific research activities. From 2001 to 2013, with a period of four years between surveys, three *Joint Danube Surveys* were conducted. During those surveys, the surface water of the Danube was sampled to collect all parameters prescribed by the Water Framework Directive for water quality assessment. Data for assessing the ecological status of surface waters collected during the third Joint Danube Survey 3 (JDS 3) represent the database processed in this doctoral dissertation to assess the ecological status of the Danube. The data collected during the Joint Danube Survey 3 research are the latest available database related to the entire Danube, which is part of the comprehensive research effort coordinated by the Secretariat of the International Commission for the Protection of the Danube River in cooperation with the Danube countries. The ecological status of the Danube has been modelled using Artificial Neural Networks (ANN) and their applicability in the field of ecological research, as well as in future studies of the ecological status of aquatic ecosystems, has been confirmed. Macrophytes, as standard biological parameters in the

assessment and prediction of the ecological status of aquatic ecosystems, represent the input variables in the modelling, while the output variables were the ecological status classes determined based on dissolved oxygen, nitrate and orthophosphate anion concentrations. The parameters used in the modelling were collected at 68 sites along the entire course of the Danube, on both sides of the river bank, where each site (JDS 1 - JDS 68) covered 6 km of the river course. By the modelling classes of ecologic and environmental status of the Danube River, the unique classification of 7 ecological status classes was created, and were determined based on concentrations of dissolved oxygen, nitrate and orthophosphate anions. The main contribution and impact of the Thesis is the development of ANN models for prediction of the ecological and environmental status classes of river ecosystems founded on the composition of macrophytes in a certain part of the river. Ecological status classes were determined on concentrations of dissolved oxygen, nitrate and orthophosphate anions. The unique and specific model using an ANN was created for all chemical parameters selected in modelling the ecological status of the Danube River. A total of three ANN models were developed, trained, tested and verified by sensitivity analysis. The Mann -Whitney statistical test was applied to compare the trophicity of selected indicator macrophyte species and those identified by the model as insignificant. The agreement between the measured and predicted ecological status classes was determined by calculating the Kappa index.

The best prediction positive rate was shown by the model of the ecological status class established on the measured concentrations of dissolved oxygen (82.93%), where the mean absolute percentage error was 3.04%. The Kappa index value for this model ($K_a = 0.61$) indicated a good agreement between the measured and predicted ecological status classes.

The model based on nitrate anion concentrations had an estimation accuracy of 74.80%, an absolute error rate of 5.42% and a Kappa index of 0.64.

Similar results were obtained for the model based on orthophosphate anion concentrations, where the estimation accuracy was 71.55%, the absolute error rate was 8.99%, while the Kappa index value was 0.17.

Constructed on the data set collected during the Joint Danube Survey 3 expeditions and using dissolved oxygen concentrations, the Danube ecological status class ranges from I to

IV class. Similarly, if nitrate anion concentrations data is used the ecological status class ranges from IV to VII, while ecological status classes determined based on orthophosphate anions attained classes IV-V.

In modelling based on dissolved oxygen concentrations, the most common error in the assessment was one class of ecological status higher than it actually is. More precisely, the model in some cases estimated a better ecological status than the real one. This was the case with sites located at the mouths of tributaries. At these sites, the model predicted a lower (better) class of ecological status than that to which a particular site actually belongs based on the value of a particular chemical parameter. Predicted values for ecological status classes founded on nitrate anion concentrations deviated by almost the same percentage from expected values of ecological status classes based od concentrations of chemical variables. The model developed on orthophosphate anion concentrations indicated a lower ecological status class in 24 instances, while it predicted a higher ecological status class in 16 instances. Errors in the assessment of the ecological status class based on the concentrations of nitrate and phosphate anions do not show any spatial dependence, but occur along the entire course of the Danube. The largest deviations between the measured and predicted ecological status classes for all three chemical parameters (concentrations of dissolved oxygen, nitrate and orthophosphate anions) were on the tributaries of the Danube, the Tisza and Arges rivers. In these examples, the neural network model generally indicated lower (better) ecological status classes than the one to which they belong based on the measured values of the chemical parameters.

The research activities within the Thesis in the field of prediction and assesment of ecostatus on river basin example by artificial neural networks modelling Danube river model and the achieved dataset and results were for the first time applied in the Thesis. The unique result within the research activities presents the model of artificial neural networks as general and basic investigation platform, with wide implication for variety assesment and prediction water quality classes using the macrophytes as the input variables founded on the key physico-chemical parameters: dissolved oxygen, nitrate and ortophosphate anions.

1. UVODNA RAZMATRANJA

Usled brojnih nekontrolisanih, neodgovarajućih i devastirajućih antropogenih aktivnosti i prirodnih procesa slatkovodni akvatični resursi su vremenom transformisani u ekološki neprihvatljive vrednosti klase kvaliteta voda. Na promene kvaliteta vode utiče ekonomski razvoj, klimatski uslovi i način upotrebe zemljišta u priobalju. Ekološki status dunavskog rečnog basena, kao najvećeg i najvažnijeg međunarodnog rečnog basena u Evropi, uvek je izazovna, aktuelna i nova tematika u oblasti ekologije i zaštite životne sredine, kvaliteta površinskih voda i razvoja prediktivnih matematičkih modela za procenu kvaliteta voda, uz definisanje ključnih zavisnih varijabli fizičko-hemijskih i bioloških faktora. U okviru Internacionalne komisije za zaštitu Dunava (engl. *International Commission for the Protection of the Danube River - ICPDR*) sve podunavske zemlje organizovale su naučna istraživanja u cilju prikupljanja podataka svih zvaničnih parametara na osnovu čijih vrednosti se procenjuje ekološki status. Ukupno 3 zajednička istraživanja Dunava (engl. *Joint Danube Survey*) realizovana su u periodu od 2001. – 2013. godine. Podaci prikupljeni tokom poslednjeg, Joint Danube Survey 3 (JDS 3) istraživanja, predstavljaju poslednji set podataka koji obuhvata sve zvanične parametre za procenu ekološkog statusa Dunava propisane od strane Okvirne Direktive o vodama (engl. *Water Frame Directive*). Biološki, fizičko – hemijski i hidromorfološki parametri sakupljeni su duž čitavog toka reke Dunav, na ukupno 68 lokaliteta sa obe strane rečne obale.

Fizičko – hemijski i biološki parametri koji se koriste u proceni ekološkog statusa vodnih ekosistema ne pokazuju međusobnu linearnu zavisnost. Nelinearna povezanost nezavisnih parametara sugerira primenu veštačkih neuronskih mreža kao adekvatnog alata za modelovanje ekološkog statusa reke Dunav. U cilju pronalaženja optimalnog modela za predikciju ekološkog statusa reka na osnovu fizičko – hemijskih i bioloških parametara kreiran je model veštačke neuronske mreže za buduća naučna istraživanja u oblasti zaštite životne sredine i ekoloških studija.

Makrofite, kao zakonski biološki parametri koji se koriste u proceni ekološkog statusa reka, predstavljaju ulazne parametre u modelovanju, dok su izlazni parametri klase ekološkog statusa reke Dunav, determinisane na osnovu koncentracijonih nivoa rastvorenog kiseonika, nitratnih i ortofosfatnih anjona, a izračunate prema zvaničnim skalamama podunavskih zemalja. Za potrebe modelovanja ekološkog statusa dizajnirana je nova,

jedinstvena klasifikacija Dunava, sa 7 klasa ekološkog statusa. Jedinstvenost i specifičnost korišćenog seta podataka je u tome što predstavlja kolekciju svih zvaničnih parametara koji se prema Okvirnoj Direktivi o vodama koriste u proceni ekološkog statusa reka, i u tome što su podaci prikupljeni u istom vremenskom intervalu za čitav tok Dunava. Hipoteza, ciljevi i zadaci istraživanja definisani u doktorskoj tezi, kreiranje modela veštačke neuronske mreže za ekološki i životni status rečnih ekosistema na osnovu strukture makrofitских zajednica u funkcionalnoj vezi sa ključnim fizičko-hemijskim parametrima, su uspešno realizovani.

Razvoj modela za predikciju klasa ekološkog statusa vodnih ekosistema bio je jedan od osnovnih zadataka i motivacija predmeta istraživanja ove doktorske disertacije. Nulta hipoteza pri modelovanju ekološkog statusa Dunava bila je prepostavka o nelinearnoj, interkorelacionoj povezanosti fizičko – hemijskih i bioloških parametara, što ujedno predstavlja izazov primene modela veštačkih neuronskih mreža u modelovanju ekološkog statusa dunavskog basena. U cilju postizanja dobrog ekološkog statusa vodnih ekosistema neophodno je redovno ispitivanje kvaliteta površinskih voda, kako na lokalnom, tako i na nacionalnom i internacionalnom nivou.

2. OSNOVE I MOTIV ISTRAŽIVANJA

Osnovni cilj istraživanja je kreiranje modela za predikciju ekološkog statusa reka na osnovu prisustva makrofita i koncentracija hemijskih pokazatelja kvaliteta vodenih ekosistema, koji pre svega ne iziskuje velike finansijske izdatke i može naći primenu u budućim ekološkim istraživanjima. S obzirom da parametri koji se prema Okvirnoj Direktivi o vodama koriste za procenu ekološkog statusa vodenih ekosistema ne pokazuju međusobnu linearu zavisnost modeli veštačkih neuronskih mreža predstavljaju odgovarajući alat za procenu ekološkog statusa. Tokom Joint Danube Survey 3 (JDS 3) istraživanja sakupljena je poslednja dostupna baza podataka koja sadrži sve zvanične parametre koji se prema Okvirnoj Direktivi o vodama koriste za procenu ekološkog statusa reka. Podaci su sakupljeni za čitav tok Dunava u istom vremenskom periodu.

Osnovni motiv istraživanja za potrebe ove disertacije jeste obrada podataka sakupljenih tokom JDS 3 istraživanja u cilju procene ekološkog statusa Dunava u celini. Ovaj set podataka sadrži kako biološke, tako i fizičko-hemijske i hidromorfološke parametre sakupljene duž celog toka Dunava. Podaci su sakupljeni u letnjem periodu, te je korelacija između odabranih varijabli koja se pre svega odnosi na uticaj temperature, zastupljenost makrofita i koncentraciju rastvorenog kiseonika u vodi, specifična i karakteristična za taj period godine. Uzimajući u obzir činjenicu da između prisustva makrofita, kao bioloških parametara za procenu ekološkog statusa reka, i koncentracije rastvorenog kiseonika, nitratnih i ortofosfatnih anjona ne postoji linearna zavisnost, u cilju obrade ovih podataka primenjen je model veštačkih neuronskih mreža. Rezultati modelovanja treba da potvrde kompatibilnost primene odabranog modela veštačkih neuronskih mreža, kao i korelaciju zastupljenosti makrofita i hemijskog statusa reke.

Motiv istraživanja je razvoj modela veštačkih neuronskih mreža koji će moći da se primeni u budućim ekološkim istraživanjima, a koji ne iziskuje visoka ekonomski ulaganja i uspešno koreliše varijable koje nemaju uzajamnu linearu zavisnost.

3. STRUKTURA DISERTACIJE

Uzimajući u obzir predmet, cilj istraživanja i hipoteze, doktorska disertacija je podeljena i organizovana u 10 poglavlja.

U okviru **prvog poglavlja** navedena su uvodna razmatranja.

U **drugom poglavlju** su navedene osnove i motiv istraživanja realizovanog u okviru doktorske disertacije.

U **trećem poglavlju** je predstavljena celokupna struktura doktorske disertacije.

U **četvrtom poglavlju** opisano je aktuelno stanje u oblasti, navedena je primena različitih analitičkih metoda u oblasti ekoloških istraživanja, metode procene ekološkog statusa reka i značaj makrofita kao bioloških pokazatelja trofičnosti ekosistema.

Parametri koji se koriste u proceni ekološkog statusa reka opisani su u **petom poglavlju** doktorske disertacije. Peto poglavlje podeljeno je na 3 podpoglavlja u okviru kojih su opisani biološki i hemijski parametri koji se koriste u proceni ekološkog statusa i navedena je klasifikacija ekološkog statusa reka u podunavskim zemljama.

Veštačke neuronske mreže kao alat u modelovanju ekološkog statusa rečnih ekosistema opisane su u okviru **šestog poglavlja**, naveden je princip rada i primena veštačkih neuronskih mreža i opisan model i arhitektura veštačkih neuronskih mreža primjenjen u tezi.

Materijal i metode opisane su u **sedmom poglavlju**, i obuhvataju opis korišćenog seta podataka, osnovnih karakteristika istraživanog područja, opis rada Internacionalne komisije za zaštitu Dunava kao i Zajedničkog istraživanja Dunava (engl. *Joint Danube Survey*). U okviru *Materijala i metoda* opisani su i indeksi trofičnosti vodenih ekosistema, kao i primena analize osetljivosti i Mann - Whitney testa.

Rezultati modelovanja i diskusija, za sva tri primenjena modela veštačkih neuronskih mreža, opisani su u okviru **osmog poglavlja**.

U **devetom poglavlju** navedena su *Zaključna razmatranja*.

Korišćena literatura navedena je u **desetom poglavlju, uz Priloge**.

4. AKTUELNO STANJE U OBLASTI

4.1. Primena različitih analitičkih metoda u oblasti ekologije i zaštite životne sredine

Ekološki sistemi pokazuju veliku varijabilnost i međusobno su kompleksno, funkcionalno povezani i podstiču potrebu za različitim vidovima statističkih i geoprostornih analiza i modelovanja procene i predikcije ekostatusa akvatičnih sistema da bi se definisale ključne zavisne varijable kvaliteta stanja vodnih tela. Većina rezultata publikovanih u oblasti ekoloških istraživanja zasniva se na različitim analitičkim pristupima. Da bi došli do značajnih rezultata i zaključaka, istraživači koriste različite vrste programa i višenamenskih statističkih alata, kao i simulacione procese (Ritchie i saradnici, 1988; Stroustrup, 1997; Adams i saradnici, 2009; Schwartz i saradnici, 2011; Lutz, 2009; Hanselman & Littlefield , 2004 ; Crawley i saradnici, 2007). Razvojem ekoinformatike usavršava se i nadograđuje razvoj modela procene i predikcije ekostatusa akvatičnih sistema kroz nove pristupe dokumentovanja koje naučnici koriste kako bi došli do odgovarajućih zaključaka (Ludäscher i saradnici, 2006; De Roura i saradnici, 2009; Deelman i saradnici, 2005, Silva i saradnici, 2007; Ellison i saradnici, 2006; Deelman i saradnici, 2009).

Ekoinformatika je interdisciplinarna oblast koja promoviše korišćenje naprednih kompjuterskih tehnologija u cilju prepoznavanja visoke kompleksnosti ekoloških procesa, obrazaca i novih alata procene i predikcije kroz nivoje kompleksnosti ekosistema (Deliška, 2007). Oblast ekoinformatike koja je u širokoj ekspanziji a bavi se identifikovanjem strukture kompleksnih, često nelinearnih podataka, i pronalaženjem odgovarajućih modela predikcije je mašinsko učenje (engl. *Machine learning – ML*). Veliki broj *ML* tehnika se u ekologiji pokazao kao ozbiljna konkurencija u odnosu na tradicionalne pristupe modelovanja.

Veštačke neuronske mreže koje su bazirane na nadgledanim metodama modelovanja uspešno modeluju interkorelace odnose seta podataka ulaznih i izlaznih varijabli (Lek i saradnici, 1996), kao i celularni automati (Hogeweg, 1988), fazi logika (Salski, 1992), genetski algoritmi i programiranje (Stockwell i Noble, 1992). U ekološkim istraživanjima najviše se koriste veštačke neuronske mreže i genetski algoritmi (Olden i saradnici, 2008). Keplerov naučni sistem je specijalizovan za primenu u ekološkim

istraživanjima, uključuje specifične komponente za pristup podacima opisanim na ekološkom jeziku metapodataka (engl. *EML-Ecological Metadata Language*), i omogućuje naučnicima i istraživačima da integriraju najčešće korišćene alatke za analiziranje kao što su R i Matlab (Gries i Porter, 2011; Michener i Jones, 2012). Najčešće korišćene statističke metode obrade podataka u ekologiji vegetacije su: Cocktail metod, TWINSPAN (engl. *Two-Way Indicator Species Analysis*) metod, detrendovana korespondentna analiza (DCA) (engl. *Detrended Correspondence Analysis*), korespondentna analiza (CA) (engl. *Correspondence Analysis*), kanoniska korespondentna analiza (CCA) (engl. *Canonical Correspondence Analysis*), detrendovana kanoniska korespondentna analiza (DCCA) (engl. *Detrended Canonical Correspondence Analysis*), analiza glavnih komponenti (PCA) (engl. *Principal Component Analysis*), nemetričko multidimenziono skaliranje (NMDS) (engl. *Non-metric MultiDimensional Scaling*). Iako su najzastupljenije u literaturi, navedene metode, nisu uvek matematički i ekološki najprihvatljivije (Laketić, 2013).

U cilju procene kvaliteta akvatičnih sistema u poslednje dve decenije koristi se fazi modelovanje zasnovano pre svega na lakoj lingvističkoj interpretaciji rezultata, uspešnoj obradi složenih i neizvesnih eko-fenomenoloških situacija, sposobnosti inkorporacije ekspertskega mišljenja sa podacima sa terena, uspostavljanju interkonekcije među parametrima, obezbeđuju transparentan matematički model, opisuju veliki broj nelinearnih odnosa kroz jednostavna pravila i imaju sposobnost da rešavaju problem nedostajućih podataka bez uticaja na vrednost konačnog kvaliteta vode (Kiurski – Milošević, 2015). Ekspertni sistemi, veštačke neuronske mreže, genetički algoritmi i „inteligentni agenti“ su kategorije veštačke inteligencije koje su u prošloj dekadi zabeležile nagli prodor i predstavljaju perspektivu poslovanja u istraživanju, proceni i predikciji u različitim oblastima modernog i savremenog razvoja društva u budućnosti. Postoje optimistične prognoze istraživača iz oblasti informacionih tehnologija da će veštačke neuronske mreže eventualno moći da zamene misaone procese čoveka jer su sposobne da rešavaju probleme fundirane na predikcionim pristupima (Petrović, 2011). Kao moćan alat modeli veštačke inteligencije pomažu razvoju ljudske civilizacije uopšte.

Veštačke neuronske mreže se u oblasti ekologije i inženjerstva zaštite životne sredine prvi put primenjuju 1997. godine za modelovanje podele vrsta (Mastrorillo i saradnici, 1997; Ozesmi i Ozesmi 1999), i za modelovanje diverziteta vrsta (Guegan i saradnici, 1998; Brosse i saradnici, 2001; Olden i saradnici, 2006b) i sastava zajednica.

Kolekcija veštačkih neuronskih mreža primenjenih u ekologiji nalazi se u radovima Lek & Guegan (2000), Recknagel (2003) i Ozesmi i saradnici (2006), kao i u specijalnim izdanjima časopisa *Ecological Modelling* i *Ecological Informatics* (Recknagel 2001; Park & Chon 2007). Gebler i saradnici (2013) u svom radu opisuju modelovanje nekoliko vrsta makrofita u odnosu na fizičko-hemijske parametre vode. Za svaki uzorak vode određeni su alkalitet, provodljivost, reaktiv i ukupan fosfor, nitrati, amonijak, pH i biološka potrošnja kiseonika. Kao ulazne parametre koristili su fizičko-hemijske parametre a izlazni parametri su bile makrofite.

Ovo istraživanje dokazuje da se makrofite mogu uspešno koristiti kao indikatori zagađenja vodnih ekosistema. Potvrđena je i snažna korelacija između MIR indeksa makrofita i pokazatelja zagađenja voda, a posebno koncentracije fosfora (Szoszkiewicz, 2017; Canfield i saradnici, 1983; Kuo i saradnici, 2007; Mozejko i Gniot, 2008). Najčešće korišćene veštačke neuronske mreže u ekologiji su veštačke neuronske mreže sa jednim skrivenim slojem, sa nadgledanim učenjem, obučene pomoću back – propagation algoritma (Hornik i saradnici, 1989). Danas su dostupni brojni programi za implementaciju različitih programskih jezika i modula.

4.2. Metode procene ekološkog statusa reka

Ključni dokument koji propisuje uspostavljanje okvira za delovanje Evropske unije u oblasti politike voda je Okvirna Direktiva o vodama 2000/60/EC (WFD, 2000). Postizanje i održavanje dobrog ekološkog statusa vlažnih staništa, gde je ekološki status pokazatelj kvaliteta strukture i funkcionalnosti tih ekosistema, predstavlja glavni cilj Direktive o vodama (Predojević, 2017).

Važan korak u implementaciji Okvirne Direktive Evropske unije o vodama, i monitoringu reka uopšte, predstavlja utvrđivanje bioloških, fizičko-hemijskih i hidromorfoloških parametara vodnog tela (Živković i saradnici, 2018).

Hidromorfološki parametri koji se koriste u proceni ekološkog statusa površinskih voda su hidrološki režim, kontinuitet rečnog toka i morfološki uslovi (Babić-Mladenović i Ninković, 2019).

Biološki elementi kvaliteta površinskih voda su važni indikativni parametri ekološkog statusa ili potencijala koji se odnose na pojavu i rasprostranjenost živih

organizama vodnih ekosistema. U ovu grupu bioloških parametara ubrajaju se mikroorganizmi, alge, vodene makrofite, vodeni beskičmenjaci i ihtiofauna (Kenderov i Pavlova, 2008).

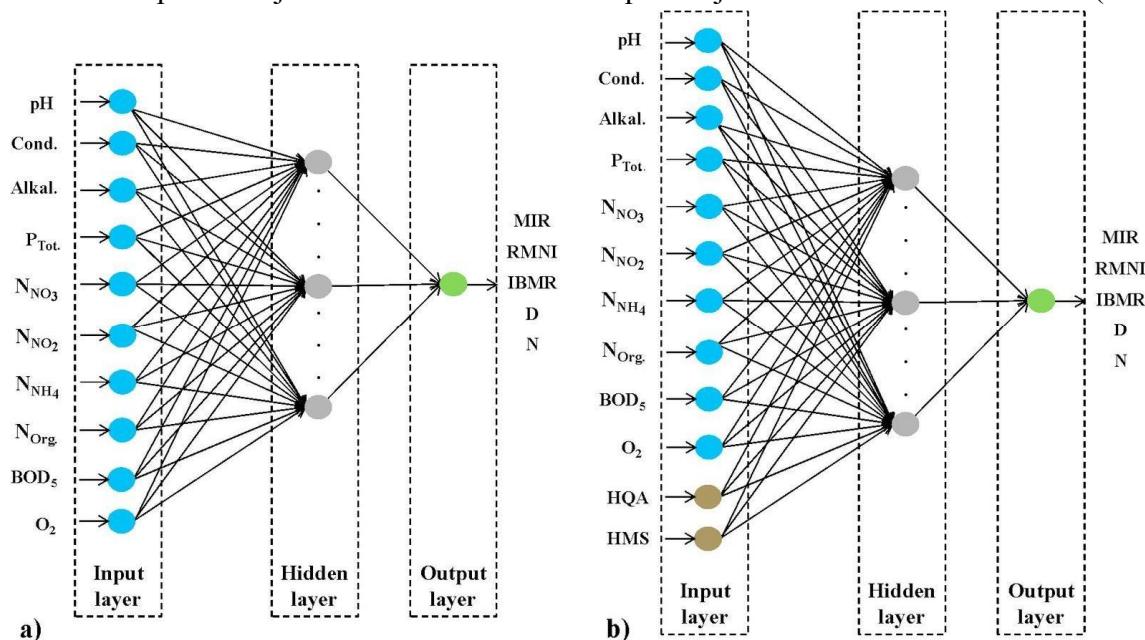
Izuzetno značajni fizičko-hemijski pokazatelji kvaliteta površinskih voda su turbiditet, temperatura, mehaničke nečistoće, protok vode, nivo stajaćih voda, nivo promene režima vode, kvalitativni i kvantitativni sastav hemijskih supstanci, kontaminanata i polutanata (del Mar Sánchez-Montoya i saradnici, 2012). Trofički status rečnog ekosistema definiše se kao svojstvo dostupnosti hranljivih materija u lancima ishrane. Definisanje stepena trofičnosti u rekama zahteva stehiometrijski pristup jer je stopa zastupljenosti ugljenika funkcionalno i interkorelaciono povezana sa unosom azota i fosfora u rečne ekosisteme. Različita jedinjenja, posebno soli, anjoni azota i fosfora su najvažniji nutrijenti koji imaju uticaj na pojavu cvetanja algi, a koja je u pozitivnoj korelaciji sa bruto primarnom produkcijom u rečnim ekosistemima (Dodds, 2007). Način eksploatacije i primena melioracionih i poljoprivrednih aktivnosti na zemljištu i priobalju reka, količina pesticida, azotnih i fosfatnih đubriva ima značajan uticaj na sadržaj nutrijenata u vodnim tokovima (Sremački i saradnici, 2020). Metod procene trofičkog statusa reka na osnovu koncentracija hranljivih materija opisan je i u radu Snelder i saradnici (2004).

Primena modela veštačke inteligencije poslednjih decenija nalazi sve veću primenu u ekološkim istraživanjima, koja svakako uključuju i procenu ekološkog statusa vodnih ekosistema. Lek i Guegan (1999) u svom radu opisuju primenu modela veštačke inteligencije kao alat u ekološkim modelovanjima. Predikcija kontaminacije podzemnih voda nitratima primenom modela veštačkih neuronskih mreža prikazana je u radovima Yesilnacar i saradnici (2008), Eslamian i saradnici (2009), Ostad-Ali-Askari (2016) i Wagh i saradnici (2018). Antanasijević i saradnici (2013) u radu opisuju primenu 3 različita modela veštačkih neuronskih mreža u cilju predikcije koncentracije rastvorenog kiseonika u Dunavu, gde su kao ulazne varijable koristili protok vode, temperaturu, pH vrednost i električnu provodljivost. Merenja su sprovedena samo na jednom lokalitetu, Bezdaru, a rezultati modelovanja su pokazali da su rekurentne neuronske mreže optimalan alat za procenu koncentracije rastvorenog kiseonika kada se kao ulazne varijable u modelovanju koriste odabrani fizičko - hemijski parametri. U radu Antanasijević i saradnici (2014) opisana je primena neuronskih mreža tipa – General regression (engl. GRNN-

General Regression Neural Networks) za predikciju koncentracija rastvorenog kiseonika u Dunavu. U radu je opisano obučavanje, validacija, testiranje i nezavisnost analize neuronskih mreža GRNN tipa. Primena modela veštačkih neuronskih mreža u cilju modelovanja indeksa makrofita na osnovu fizičko - hemijskih karakteristika vodnog tela opisana je u radu Gebler i saradnici (2013) u kom su dokazali da su veštačke neuronske mreže adekvatan alat za predikciju parametara koji determinišu kvalitet vodnih ekosistema. Najah i saradnici (2009) u svom radu potvrđili su odličan potencijal neuronskih mreža za procenu ukupnih rastvorenih materija, električne provodljivosti i turbiditeta vode.

U najvećem broju objavljenih radova na temu procene ekološkog statusa reka primenom modela veštačkih neuronskih mreža ekološki status je prediktovan na osnovu jednog izabranog fizičko-hemijskog parametra koje propisuje Okvirna Direktiva o vodama (WFD, 2000), najčešće koncentracije rastvorenog kiseonika i biološke potrošnje kiseonika (Talib i saradnici, 2009; Sarkar i Panday, 2015; Gomolka i saradnici, 2018; Antanasijević i saradnici, 2014). Talib i saradnici (2009) su u radu ocenili da su se fosfatni anjoni pokazali kao najvažniji ulazni parametri u procesu modelovanja vrednosti biološke potrošnje kiseonika u rečnom ekosistemu. U radu Milošević i saradnici (2016) u cilju procene zastupljenosti larvi hironomida, koje se ubrajaju u indikatorske taksonе u proceni ekološkog statusa, duž rečnog toka Dunava primjenjen je tip neuronskih mreža – samoorganizujuće mape. Wilson i Recknagel (2001) i Recknagel (1997) u svojim radovima opisuju primenu modela veštačke inteligencije u proceni trofičnosti vodnog ekosistema na osnovu prisustva hranljivih materija (ulazne varijable) i zastupljenosti algi koje su u modelovanju predstavljale izlazne varijable. Gebler i saradnici (2018) su u svom radu za modelovanje ekološkog statusa reka primenom modela veštačke inteligencije koristili indekse diverziteta makrofita i fizičko – hemijske parametre, i utvrdili da se procenom ekološkog statusa reka na osnovu indeksa diverziteta makrofita određuje i hidromorfološki status rečnog toka.

Na Slici 1. prikazan je model neuronske mreže primjenjen u radu Gebler i saradnici (2018).



Slika 1. Model veštačke neuronske mreže primjenjen u radu Gebler i saradnici (2018)

*Input layer – ulazni sloj; Hidden layer – skriveni sloj; Output layer – izlazni sloj

U radu Gebler i saradnici (2017) primenom modela veštačke inteligencije modelovana je veza između MIR indeksa (engl. *Macrophyte Index for Rivers*) koji opisuje stepen degradacije rečnog sistema uslovljen prisustvom polutanata u vodi, i različitih fizičko-hemijskih parametara. Wu i saradnici (2014) su model veštačkih neuronskih mreža primenili za modelovanje dnevnih vrednosti hlorofila-a i potvrdili visoku osetljivost vrednosti hlorofila-a i rastvorenog azota, nitrata, hlorida, sulfata i ukupnog fosfora u rečnom ekosistemu.

Šiljić-Tomić (2018) u svojoj doktorskoj disertaciji opisuje modelovanje kiseoničnih parametara kvaliteta površinskih voda primenom veštačkih neuronskih mreža, i u procesu modelovanja koristi neuronsku mrežu sa opštom regresijom i polinomalnu neuronsku mrežu. Podaci korišćeni u tom modelovanju vezani su za kiseonične parametre i sakupljeni su na delu rečnog toka Dunava koji protiče kroz Srbiju.

Detaljnim pregledom literaturnih referenci, fokusiranih na naučna istraživanja mogućnosti primene veštačkih neuronskih mreža kao pametnih sistema sa ulaznim parametrima makrofitama, do sada nisu opisani u naučnim radovima iz oblasti ekologije i inženjerstva zaštite životne sredine.

Izuzetna značajnost, potpuno nov način i originalnost evaluacije rezultata za procenu ekološkog statusa rečnih basena po prvi put je primenjen u istraživačkim aktivnostima doktorske teze primenom modela veštačkih neuronskih mreža sa propagacijom signala unapred koji za obučavanje koristi algoritam sa propagacijom signala unazad.

U eksperimentalnom delu doktorske disertacije, diskusionim razmatranjima kao inovirana analiza funkcionalne zavisnosti makrofita i referentnih ključnih hemijskih parametara istaknuta je posebnost doktorske disertacije, kao i razrada zvaničnih preporuka koje je propisala Okvirna Direktiva o vodama u obuhvatanju čitavog toka reke Dunav i ukupnog dunavskog basena (Krtolica i saradnici, 2021).

Istiće se da do sada nije objavljen istraživački rad na temu modelovanja ekološkog statusa reka koji je kao ulazne varijable koristio zastupljenost makrofita duž rečnog toka, iako su makrofite prihvaćeni i zakonski biološki parametri i indikatori koji se koriste u proceni ekološkog statusa površinskih voda i šire zaštite životne sredine. Model veštačkih neuronskih mreža opisan u ovoj tezi kreiran je na osnovu bioloških i fizičko – hemijskih podataka prikupljenih duž čitavog toka Dunava. Za potrebe modelovanja klase ekološkog statusa makrofite su korišćene kao ulazne varijable, dok su klase ekološkog statusa bili izlazni parametri, što čini specifičnost, jedinstvenost i značaj istraživanja sprovedenih u okviru doktorske disertacije.

4.3. Makrofite kao bioindikatori trofičnosti vodenih ekosistema

Makrofite su sve biljke koje se mogu opaziti golim okom i naseljavaju litoralne zone reka i jezera (Haslam, 2006). Litoralna vegetacija reka i jezera pomaže u sprečavanju erozija obale apsorbovanjem dela sunčeve energije određenih frekvencija, odnosno talasnih dužina, i služi kao stanište svim životinjskim vrstama (Umlauf i saradnici, 2014). Makrofite ne naseljavaju isključivo vodene površine već i obale reka i predstavljaju sklonište za mnoge beskičmenjake kao i stanište mnogim pticama pevačicama, vodozemcima, gmizavcima i sisarima.

Makrofite su izuzetno važni pokazatelji ekološkog statusa reka te su stoga izabrane kao jedan od 5 bioloških pokazatelja za procenu ekološkog statusa vodnih površina prema Okvirnoj Direktivi o vodama (WFD, 2000; Søndergaard i saradnici, 2010). Ne samo što daju informacije o kompleksnim procesima eutrofizacije, već zajedno sa vegetacijom obale

reka ukazuju na hidromorfološke pokazatelje reka i jezera, kao i na prirodnost vodnih ekosistema.

Zastupljenost makrofita zavisi od hidromorfoloških parametara koji su uslovljeni geologijom sliva i fizičkom degradacijom staništa (Živković i saradnici, 2018). Termin "makrofite" odnosi se na makroalge, vodene mahovine, vaskularne biljke, vodene paprati i skrivenosemenice. Alge se javljaju duž čitavog toka Dunava. Rod *Chara* pretežno naseljava gornji tok reke, dok se vrste iz roda *Nitellopsis* sreću na većim dubinama. Vodene mahovine preferiraju gornje tokove reke gde na obalama dominiraju stene i krupno kamenje, u nemačkom i austrijskom delu toka dunavskog basena, dok su u srednjem i donjem delu toka reke gotovo odsutne. U Dunavu su nađene samo 2 vrste vodenih paprati, i to u toplijim delovima reke. Makrofite su sa algama u kompeticiji za energetskim količinama svetlosti i nutrijentima. Dominiraju u oblastima sa sporijim tokom reke gde sprečavaju pojavu cvetanja algi. Restauracija rečnih basena u najvećem broju slučajeva imala je pozitivan efekat na diverzitet vodenih makrofita (Kail i saradnici, 2015).

Diverzitet i obilje makrofita u velikoj meri zavise od svetlosti, sadržaja hranljivih materija u vodi i sedimentu, kao i od vodnog režima (Spence, 1982; Chambers, 1987; Bornette i Puijalon, 2011). Makrofite su primarni producenti organske materije i mogu biti, kako pričvršćene za rečno dno, tako i submerzne i slobodno plutajuće vrste. Njihovo prisustvo nije ograničeno samo na vlažna staništa, već se mogu uočiti i na staništima duž rečnih obala (Haslam i saradnici, 1978; Aguair i saradnici, 2009).

Submerzne makrofite imaju značajnu ulogu u formiranju matičnih staništa nekih vodenih organizama kao što su ribe, vodeni beskičmenjaci i vodeni perifiton. Submerzna vegetacija takođe ima izuzetno pozitivan efekat na bistrinu reke (Van den Berg i saradnici, 1997).

Emerzne vrste vodenih makrofita prilagođene su na uslove smanjenog sadržaja kiseonika. Emerzne vrste su one biljke koje su jednim delom izdignute iznad vode, ali su im podzemni organi uvek u vodi, odnosno veoma vlažnoj podlozi. Emerzne makrofite predstavljaju prelazne oblike ka hidrofitama i odlikuju se visokom produktivnošću, jer koriste resurse i kopnenog i vodenog staništa (Wanke, 2011). Korenje i rizomi ovih makrofita stvaraju stalnu vezu između zemljišta i atmosfere, omogućavajući tako dostupnost kiseonika podzemnim delovima biljke (Petruzzella i saradnici, 2015). Emerzne

vrste su: *Sagittaria sagittifolia L.*, *Alisma plantago aquatica L.*, *Sium latifolium L.*, *Ranunculus lingua L.* i *Scirpus lacustris L.* (Stevanović i Janković, 2001). Različite vrste makrofita imaju različit stepen tolerancije na brzinu protoka (Riis i Biggs, 2001). Gurnell i saradnici (2006) utvrdili su da je zastupljenost emerznih vrsta makrofita, kao što je *Sparganium erectum L.*, povezano sa sporijim tokom reke i najvišim stepenom nataloženog sedimenta u blizini rečnih nasipa. Nasuprot tome, vrste *Ranunculus penicillatus sp.* i *Pseudofluitans sp.* nalaze se u najbržim delovima toka sa značajno manjom akumulacijom rečnog sedimenta.

Retencija sedimenta i morfološki uticaj vodenih biljaka nisu determinisani isključivo taloženjem sedimenta, već i raznovrsnošću postojećih biljnih vrsta koje su prilagodjene raznim ekološkim pritiscima kojima su izložene. Usporen tok reke omogućava razvoj algi epifita koje limitiraju fotosintetske procese (Flynn i saradnici, 2002). Stopa razmene podvodnih gasova, a time i akumulacija ugljenika, redukovani su u vodama sa sporijim tokom, a time je limitirana i fotosinteza (Madsen i Sand-Jansen, 2006).

Makrofite se mogu uočiti samo u određenom periodu godine i to posebno u oblastima koje karakteriše zastupljenost mediteranske klime, za koju je karakteristično sezonsko obilje padavina (Ferreira i saradnici, 2002). Neke vrste makrofita pokazale su se kao dobri indikatori zagađenosti reka katjonima teških metala. Istraživanja su pokazala da submerzne vrste makrofita sadrže veće koncentracije katjona bakra, cinka, mangana i gvožđa, dok emerzne vrste pokazuju slabiju sposobnost akumulacije jona teških metala. Vrste *Potamogeton perfoliatus L.* i *Potamogeton obtusifolius L.* pokazale su se kao vrste makrofita najadekvatnije u procesu biološkog monitoringa zagađenosti vodnih ekosistema katjonima teških metala (Aulio, 1986). Ladislas i saradnici (2012) su potvrđili sposobnost makrofita da bioakumuliraju jone teških metala. Prema rezultatima njihovog istraživanja vrsta *Typha sp.* pokazala se kao odličan bioakumulator katjona kadmijuma i nikla, dok je vrsta *Juncus sp.* dobar bioakumulator katjona cinka.

Abiotički uslovi velikih reka, kao što je glavni tok Dunava, ograničavaju rasprostranjenost makrofita na oblasti smanjene brzine protoka i dubine ispod 2m, kao i na oblasti vodenog sistema gde makrofite mogu postati dominantna biljna vrsta.

U okviru ove teze za potrebe modelovanja ekološkog statusa reke Dunav kao ulazne varijable korišćene su sledeće makrofite: *Azolla filiculoides Lam.*, *Ceratophyllum*

demersum L., Cinclidotus riparius (Host ex Brid.) Arn., Elodea nuttallii (Planch.) H.St.John, Fontinalis antipyretica Hedw., Hydrocharis morsus-ranae L., Lemna gibba L., Lemna minor L., Lemna turionifera Landolt, Myriophyllum spicatum L., Naja marina L., Naja minor All., Nuphar lutea (L.) Sm., Nymphoides peltata (S.G.Gmel.) Kuntze, Potamogeton crispus L., Potamogeton friesii Rupr., Potamogeton gramineus L., Potamogeton lucens L., Potamogeton natans L., Potamogeton nodosus Poir., Potamogeton pectinatus L., Potamogeton perfoliatus L., Potamogeton pusillus L., Potamogeton trichoides Cham. & Schleid., Ranunculus fluitans Lam., Riccia crystallina L., Salvinia natans (L.) All., Sparganium emersum Rehmann, Sparganium erectum L., Spirodela polyrhiza (L.) Schleid., Stratiotes aloides L., Trapa natans L., Vallisneria spiralis L., Zannichellia palustris L., Agrostis stolonifera L., Alopecurus geniculatus L., Ambystegium riparium (Hedw.) Schimp., Bidens frondosa L., Bidens tripartita L., Butomus umbellatus L., Carex acuta L., Carex elata All., Carex riparia Curtis, Cyperus fuscus L., Dichostylis micheliana (L.) Nees, Eleocharis acicularis (L.) Roem. & Schult., Eleocharis palustris (L.) Roem. & Schult., Equisetum fluviatile L., Glyceria fluitans (L.) R.Br., Glyceria maxima (Hartm.) Holmb., Gnaphalium uliginosum L., Iris pseudacorus L., Lythrum salicaria L., Mentha aquatica L., Mentha pulegium L., Phalaris arundinacea L., Phragmites australis (Cav.) Trin. ex Steud., Polygonum hydropiper L., Polygonum lapatifolium L., Rorippa amphibia (L.) Besser, Schoenoplectus lacustris (L.) Palla, Typha angustifolia L., Typha latifolia L.i Cladophora glomerata (Linnaeus) Kützing. Invazivne vrste makrofita izuzete su u procesu modelovanja.

Indeksi kojima se opisuje diverzitet makrofita su Shannon-Wiener-ov indeks, Simpson-ov indeks, Pielou-ov indeks kao i indeks ekološkog statusa - MIR (engl. *Macrophyte Index for Rivers*) (Shannon i Weaver, 1949; Gebler i saradnici, 2013). Procena trofičnosti vodnih ekosistema na osnovu prisustva makrofita u radovima je najčešće opisana upravo na osnovu indeksa diverziteta (Kuhar i saradnici, 2001; Szoszkiewicz i saradnici, 2006).

5. PARAMETRI KOJI SE KORISTE U PROCENI EKOLOŠKOG STATUSA REKA

Koncept "ekološkog statusa", odnosno "ekološkog potencijala" uvodi se Okvirnom Direktivom Evropske unije o vodama (engl. Water Frame Directive) (WFD, 2000/60/EC). Ekološki status predstavlja kvantitativni pokazatelj sveukupnog kvaliteta strukture i funkcije akvatičnih ekosistema.

Parametri koji se koriste u proceni ekološkog statusa vodnog ekosistema su biološki, hemijski, fizičko-hemijski i hidromorfološki parametri (Sl. glasnik RS, br. 74/2011).

5.1. Biološki parametri u proceni ekološkog statusa reka

U biološke parametre za procenu ekološkog statusa vodnih ekosistema ubrajaju se makrofite, bentsne makroinvertebrate, fitoplankton, makrozoobentos i ihtiofauna.

Bentsne makroinvertebrate su često korišćene u proceni ekološkog statusa reka jer njihova slaba pokretljivost onemogućava da izbegnu uticaj polutanata koji dospevaju u životnu sredinu. Za deskripciju longitudinalne varijabilnosti zajednice makroinvertebrata najčešće se koriste indeksi diverziteta na osnovu kojih se procenjuje kvalitet vodnog ekosistema (Wilhm i Dorris, 1968). Povećane koncentracije fosfatnih i azotnih jona u vodenom toku prouzrokuju smanjenu brojnost makroinvertebrata (Duran, 2006), a utiču i na smanjenje broja makrofita u vodnom telu.

Evropska Okvirna Direktiva o vodama (EC, 2000) prepoznala je makrofite kao značajne indikatore u proceni ekološkog statusa i kvaliteta vodnih tela (Janauer, 2001). U radu Pajević i saradnici (2005) opisana je uloga makrofita u procesu bioremedijacije i biomonitoringa. Sposobnost submerznih makrofita u procesima bioakumulacije teških metala opisali su u svom radu i Xing i saradnici (2013) i utvrdili da je vrsta *Najas marina L.* hiperakumulator arsena i kadmijuma, *Ceratophyllum demersum L.* hiperakumulator katjona kobalta, hroma i gvožđa, dok je vrsta *Vallisneria natans L.* hiperakumulator olova. Vukov i saradnici (2017) u svom radu opisuju značajan uticaj faktora spoljašnje sredine na sastav makrofita u vodenom ekosistemu.

Submerzne makrofite imaju značajnu ulogu u procesima kruženja azota i fosfora. Na procese kruženja azota, nitrifikaciju i denitrifikaciju, utiču značajno i koncentracija rastvorenog kiseonika (Hood, 2012). Na sastav makrofita u površinskim vodama utiču

trofički status i hidrološki režim rečnog toka. Kao indikatori trofičnosti vodenog ekosistema mogu se koristiti pojedinačne vrste makrofita ili zajednice makrofita (Kohler i Schneider, 2003).

Na osnovu Pravilnika o parametrima ekološkog i hemijskog statusa površinskih voda i parametrima hemijskog i kvantitativnog statusa podzemnih voda odličnim ekološkim statusom reka (I klasa), procenjenim na osnovu fitobentosa i vodenih makrofita, smatra se rečni ekosistem kod kog taksonomski sastav potpuno ili gotovo potpuno odgovara neporemećenim uslovima i ukoliko nema primetnih promena prosečne zastupljenosti makrofita i fitobentosa u odnosu na zajednicu tipičnu za dati tip voda u neporemećenim uslovima. Ukoliko se pak beleže male promene u sastavu i strukturi zajednica makrofita i fitobentosa, a da pri tom zajednica fitobentosa nije izložena negativnom uticaju porasta bakterija, nastalog kao posledica antropogene aktivnosti, ekološki status reke smatra se dobrim (II klasa). Ukoliko se sastav i struktura zajednica makrofita i fitobentosa umereno razlikuju od onih koje su tipične za neporemećene uslove, odnos osetljivih i neosetljivih taksonomske elemenata i stepen raznovrsnosti znatno su niži od tipičnih za neporemećene uslove, tada se procenjuje da rečni ekosistem pripada III klasi, odnosno umerenom ekološkom statusu (Sl. glasnik RS, 74/2011).

Vrste makrofita *Lemna minor L.* i *Spirodela polyrhiza L.* primenjuju se kao test organizmi u toksikološkim laboratorijama (Cedergreen, 2007; Teodorović i saradnici, 2012) dok su vrste iz roda *Myriophyllum sp.* našle primenu u ekološkoj proceni rizika od herbicida i kontrole kvaliteta sedimenta (Tunić, 2015). Vrste *Ranunculus fluitans L.* i *Potamogeton crispus L.* su vrste tolerantne na eutrofizaciju, te nisu adekvatni bioindikatori trofičnosti vodenog ekosistema. Primena makrofita i fitobentosa kao indikatora klase ekološkog statusa jezera u Nemačkoj opisana je u radu Schaumburg i saradnici (2004).

Generalno, makrofite jesu indikatori hemijskog statusa reka iako u nekim slučajevima usled snažnog uticaja faktora spoljašnje sredine njihovo prisustvo može izostati (Tremp i Kohler, 1995).

5.2. Hemijski parametri u proceni ekološkog statusa reka

Veza između bioloških i hemijskih parametara u proceni ekološkog statusa, i u prirodi, je reverzibilna, funkcionalna, interkorelaciona, stalna i neraskidiva. Neosporan je uticaj hemijskog statusa ekosistema na sastav živog sveta u prirodi, te se redukcijom prisustva polutanata u ekosistemu sprečava pojava eutrofizacije i poboljšava ekološki status

koji je indikator i pokazatelj kvaliteta i strukture ekosistema. Prema Okvirnoj Direktivi o vodama zvanični hemijski i fizičko-hemijski elementi koji prate biološke elemente su termički uslovi, kiseonični režim, salinitet, status zakiseljenosti (pH) i nutrijenti. Specifična zagađenja reka odnose se na zagađivanje prioritetnim supstancama i drugim štetnim supstancama koje se u značajnim količinama unose u vodno telo (WFD, 2000).

Hemijski sastav rečnog ekosistema menja se od izvora prema ušću, što uslovljava i promene u sastavu makrofitskih zajednica. Sastav makrofitskih zajednica u vodenim ekosistemima uslovljen je različitim biotičkim i abiotičkim faktorima, od kojih su najznačajniji koncentracija nutrijenata, pH vrednost, hidrološki uslovi, kinetičko – dinamički faktori kao što su brzina toka reke i tvrdoća vode (sadržaj karbonata) i drugi vrlo kompleksni klimatski uticaji.

U tekućim vodama trenutna brzina toka ima snažan uticaj na sastav vegetacije (Szoszkiewicz i saradnici, 2006; Moss, 2009). Nakon dospevanja zagađujućih materija u vodene ekosisteme dolazi do složenih oksido-redukcionih procesa organskih materija, pri čemu se troši rastvoren kiseonik iz vodotoka, te se aerobno, oksično okruženje transformiše u anoksično i na taj način se ugrožavaju sve biološke vrste kojima odgovara visoko oksična sredina.

Posledice smanjivanja koncentracije rastvorenog kiseonika ispod biološkog minimuma prouzrokuju ekološku štetu i dolazi do nagomilavanja mulja u vodotokovima (Pešić i saradnici, 2018), razvijaju se eutrofizacioni procesi, sedimentiraju toksične hemijske supstance, formiraju i evaporiraju toksične i neprijatne gasovite molekule uz istovremenu kontaminaciju sva tri osnovna abiotička kompartimenta životne sredine vode, vazduha, zemljišta, sedimentacionih taloga, i pratećih bioloških parametara.

U doktorskoj tezi Ilijević (2015) autor se bavio procenom i prognozom ekohemijskog statusa reka Srbije primenom statističkih metoda, te je u sklopu svog istraživanja poseban akcenat stavio na uticaj pritoka na ekohemijski status Dunava, koji svakako nije zanemarljiv. Rezultati istraživanja Ilijević (2015) pokazali su da se Tisa i Velika Morava po vrednostima ekohemijskih parametara značajno razlikuju od Dunava, dok se Sava razlikuje u mnogo manjoj meri. S obzirom na to da Tisa protiče kroz Panonsku niziju, na njen ekohemijski status najznačajniji uticaj ima poljoprivreda, što objašnjava povećane koncentracije ukupnog fosfora, amonijaka i organskih materija. Ilijević (2015) je utvrdio da se ekohemijski status Dunava generalno popravlja, posmatrano kako u vremenskom, tako i u prostornom okviru. U okviru procene ekohemijskog statusa Dunava

analizirane su u korelacionom odnosu makrofite i 3 kategorije hemijskih parametara, među kojima su kiseonični parametri (koncentracije rastvorenog kiseonika), fosfati i nitrati. Uočene su razlike između ekohemijskih parametara u gornjem toku reke Dunav u odnosu na donji tok.

5.2.1. Rastvoren kiseonik u površinskim vodama

Dva fizička parametra, temperatura i pritisak, su ključni za koncentraciju slobodnog rastvorenog kiseonika u akvatičnom medijumu. Dvo-istoatomni molekul kiseonika je apolarni homogeni sistem i veoma se slabo rastvara u čistoj vodi, visoko polarnom troatomnom heterogenom sistemu. Međumolekularni mehanizam dipol – indukovani dipol, dipol – voda indukovani dipol gasoviti kiseonik izaziva određeno ali vrlo ograničeno rastvaranje kiseonika u vodi. Dvoatomni molekuli istovrsnih atoma kao homogeni sistem čiste kovalentne veze (H_2 , O_2 , N_2) kao i višeatomni molekuli heterogenog sistema, ali simetrične strukture i istog vektorskog rastojanja, nemaju permanentni dipolni momenat.

Asimetrična struktura heteroatomnih molekula izaziva fenomen dipolnog momenta tipa permanentnih dipola, kakav je tipičan predstavnik molekul vode. Voda ima permanentni dipolni momenat zbog O-H veza u molekulima vode. Dipolni momenat je izuzetno važna fizičko-hemijska veličina jer je kvantitativna mera polarnosti svake molekulske specije. Dipolni momenat (μ) nepolarnog kiseonika je 0, dok molekuli vode imaju visoku vrednost dipolnog momenta $\mu = 6.1 \cdot 10^{-30} \text{ Cm}$ (engl. *Coulomb meter*).

Rastvorljivost kiseonika u tečnom medijumu i vodi izučava se primenom Ostvaldovog zakona rastvorljivosti i koeficijentom rastvorljivosti β koji je definisan relacijom zapremina gasa v u zapremini ratvarača V pri eksperimentalnim konstantnim uslovima pritiska i temperature. Kako se pri rastvaranju gasova u tečnom medijumu oslobađa entalpijska toplota rastvaranja ΔH , prema Le Šateljeovom principu porast temperature smanjuje i redukuje rastvorljivost gasova u rastvaraču. Uticaj temperature na rastvorljivost gasa se kvantitativno definiše sledećom matematičkom relacijom: $\frac{d\ln C_m}{dT} = \frac{\Delta H}{RT^2}$, gde je C_m koncentracija gasa u tečnoj fazi (mol/L), ΔH entalpija rastvaranja kao diferencirana toplota rastvaranja jednog mola gase u zasićenom rastvoru na konstantnoj temperaturi T. Integraljenjem matematičkog izraza rešava se zavisnost apsorpcionog koeficijenta α u funkciji od temperature T. α je apsorpcioni koeficijent prema

Avogadrovom zakonu koji definiše rastvorljivost koncentracija gasa u 1L tečnog medijuma irastvarača uz uslov da je $C_m=a$.

$$\ln = \frac{\alpha_2}{\alpha_1} = \frac{\Delta H}{R} \cdot \left(\frac{1}{T_2} - \frac{1}{T_1} \right)$$

Sniženje rastvorljivosti gasova, a posebno kiseonika, pri porastu temperature fenomenološki je česta pojava koja se dešava u prirodi i koja je devastirajuća i fatalna po akvatične ekološke sisteme. Tokom brojnih i različitih industrijskih procesa koriste se velike količine vode iz reka, akumulacija i drugih vodnih tela za rashladne procese u fazama prerade u industrijskim postrojenjima. Zagrejana voda se često ponovo vraća u prirodne recipijente i u skladu sa fizičko-hemijskim zakonitostima smanjuje rastvorljivost slobodnog rastvorenog kiseonika, što je fatalno po floru i faunu svakog vodnog sistema.

Kinetička zakonitost pokazuje porast pritiska povećava rastvorljivost gasova, što definiše Henrijev zakon. U skladu sa Henrijevim zakonom, rastvorljivost kiseonika u vodenoj sredini je obrnuto zavisna i visoko funkcionalno povezana sa temperaturom. Parametar pritisak je u direktnoj proporcionalnosti sa koncentracionim nivoom rastvorenog kiseonika. Henrijev i Arenijusov zakon u sinergiji definišu koncentracionu zavisnost slobodnog rastvorenog kiseonika i temperature. Količina gase koju tečnost može da rastvori je ograničena i zavisi od prirode gase, prirode tečnosti, temperature i parcijalnog pritiska gase u ravnoteži sa rastvorom. Rastvorljivost gase zavisi i od prirode rastvarača, te je rastvorljivost azota ili kiseonika veća u etanolu nego u vodi. U zavisnosti od visine parcijalnog pritiska i vremena ekspozicije zavisi i uticaj kiseonika na žive organizme (Rabrenović i saradnici, 2006).

Na koncentraciju rastvorenog kiseonika u vodi najznačajniji uticaj ima temperatura. Rastvor gase u tečnosti u kome ne dolazi do hemijske reakcije između komponenata, u termodinamičkom pogledu predstavlja realnu smešu, i zbog male rastvorljivosti gase može se smatrati komponentom, na koju se u ravnoteži tečne i gasovite faze može primeniti Henrijev zakon. Prema Henrijevom zakonu: „Količina gase koja se rastvara u nekoj tečnosti je direktno proporcionalna parcijalnom pritisku tog gase, na zadatoj temperaturi“.

Povećanjem pritiska povećava se i sposobnost tečnosti da rastvori neki gas, dok se sa povećanjem temperature taj kapacitet smanjuje. Henrijev zakon ne važi za gasove koji reaguju sa vodom ili nekom supstancom prisutnom u vodi. Rastvorljivost gase, izražena

njegovim molskim udelom u tečnoj smeši, x_b , računa se prema sledećoj formuli: $x_b = p_b / k$, gde je: p_b – parcijalni pritisak rastvorenog gasa, u vazduhu iznad rastvora, k –Henrijeva konstanta, koja zavisi od rastvorene materije, rastvarača i temperature. Vrednosti konstanti Henrijevog zakona prikazane su u termodinamičkim tablicama. Za rastvorljivost kiseonika u vodi na temperaturi od 25°C , konstanta Henrijevog zakona iznosi $4.40 \cdot 10^9 \text{ Pa}$. Primenom jednačine za izračunavanje rastvorljivosti gasa na temperaturi od 25°C , ako je pritisak kiseonika iznad rastvora jednak standardnom pritisku, molski ideo kiseonika u vodi iznosi $2.30 \cdot 10^{-5}$ što znači da kilogram vode pri ovim uslovima sadrži 40.9 mg kiseonika.

Ravnotežna količina kiseonika u vodi koji je u kontaktu sa atmosferom, potrebna za biljni i životinjski svet u vodi, manja je 5 puta, jer molski ideo kiseonika u vazduhu iznosi oko 0.2. Ako se pritisak kiseonika poveća za dva puta pri dovoljnom vremenu i konstantnoj temperaturi, kiseonik će se dva puta više rastvoriti nego u normalnim uslovima. Sadržaj kiseonika u vodi značajan je za metabolizam svih akvatičnih organizama (Trajković i saradnici, 2016).

Ako je više različitih gasova rastvoreno istovremeno u istom rastvaraču, kakav je slučaj u prirodnim vodama, primenjuje se i koristi Daltonov zakon prema kome je rastvorljivost svakog gasa u smeši proporcionalna parcijalnom pritisku tog gasa nezavisno od pritiska drugih gasova. Posledično i logično konstanta K , koja zavisi od prirode gase i tipa i vrste rastvarača, ima drugačiju vrednost za svaki gas, odnosno svaku gasnu hemijsku speciju. Henrijev zakon je veoma koristan za izračunavanje rastvorljivosti kiseonika u prirodnim sistemima i posebno važi za gasove male rastvorljivosti u razblaženim rastvorima. Po svojim zakonitostima je poseban oblik Raulovog zakona i kada važi Raulov zakon za gasovitu supstancu može da važi i Henrijev zakon, no relacija nije *vice-versa*.

Na višim temperaturama smanjuje se rastvorljivost kiseonika ali se povećava brzina respiracije vodenih organizama što može uslovit ozbiljan deficit kiseonika u vodenom ekosistemu. Kiseonik u vodu dospeva rastvaranjem u atmosferi i fotosintetskim delovanjem vodenih biljaka, a troši se putem respiracije akvatičnog živog sveta, procesima degradacije i dezintegracije i u različitim hemijskim reakcijama koje se odigravaju u vodenoj sredini.

Od svih parametara pokazatelja kvaliteta vode rastvoren kiseonik smatra se najosetljivijim i fragilnim, jer se sadržaj slobodnog rastvorenog kiseonika u vodi najsporije

obnavlja uzimajući u obzir da je reaeracija spor proces (Šiljić-Tomić, 2018). S obzirom da je fotosintetička aktivnost akvatičnih biljaka najveća u letnjem periodu tada je i najviši sadržaj rastvorenog kiseonika u vodi.

Pored koncentracije rastvorenog kiseonika u vodi, na količine kiseonika i stepen trofičnosti vodenog ekosistema ukazuju i kvantifikuju hemijska (HPK) i biološka potrošnja kiseonika (BPK). Viša vrednost hemijske u odnosu na biološku potrošnju kiseonika ukazuje na prisustvo supstanci koje nisu podložne biorazgradnji. Nizak sadržaj rastvorenog kiseonika u vodnom telu je u linearnoj vezi sa visokim vrednostima biološke potrošnje kiseonika. S porastom stepena organskog zagađenja smanjuje se koncentracija rastvorenog kiseonika u vodi (Šiljić-Tomić, 2018). Saturaciona vrednost kiseonika u vodnom telu opada sa porastom nadmorske visine. Koncentracije rastvorenog kiseonika u vodnim ekosistemima značajno utiču na distribuciju makrofita koje pokazuju različit stepen tolerancije na sadržaj kiseonika u vodi. Istraživanja su pokazala da se vrsta *Trapa natans L.* detektuje i u delovima rečnog toka sa ekstremno niskim vrednostima rastvorenog kiseonika, ispod 2.5 mg/L.

Delovi rečnog toka koji obiluju makrofitskom vegetacijom odlikuju se visokom primarnom produktivnošću, te su stoga i važni izvori organske materije. Vrednosti koncentracije rastvorenog kiseonika ispod 5 mg /L imaju negativan uticaj na osjetljive vrste riba i beskičmenjaka. Niske vrednosti rastvorenog kiseonika u vodi mogu usloviti oslobađanje jona metala i fosfora iz zemljišta (Caraco i Cole, 2002). Ekspanzija biljnog sveta u vodi uslovljava povišene vrednosti kiseoničnih parametara i snižene vrednosti pH, osim u slučaju da do ekspanzije biljnog sveta dolazi užvodno ili dominantan udeo ima terestrijalno poreklo. U tom slučaju kiseonični parametri imaju snižene vrednosti, jer se kiseonik troši na razlaganje organske supstance (Ilijević, 2015).

Rezultati istraživanja Ilijević (2015) pokazali su da se Tisa i Velika Morava po vrednostima ekohemijskih parametara značajno razlikuju od Dunava, dok se Sava razlikuje u mnogo manjoj meri. S obzirom na to da Tisa protiče kroz Panonsku niziju na ekohemijski status tog rečnog sistema najznačajniji uticaj imaju poljoprivredne aktivnosti, primena mineralnih đubriva i melioracija, što objašnjava povećane koncentracije ukupnog fosfora, amonijaka i organskih materija.

Granične vrednosti koncentracije rastvorenog kiseonika u jedinici mg/L i klasifikacija vodenih ekosistema za sve podunavske zemlje prikazane su u Tabelama 1. - 12., dok je jedinstvena klasifikacija ekološkog statusa kreirana za potrebe teze prikazana u Tabeli 13.

5.2.2. Nitratni anjoni u površinskim vodama

Azot je jedan od 6 hemijskih, biogenih elemenata koji se ubrajaju u makroelemente, jer u velikom procentu ulazi u sastav svake žive materije. Azot je element koji ima 10 različitih oksidacionih stanja, od - 3 u amonijaku, preko nultog za gasoviti azot, do +5 oksidacionog stanja u nitratima. Većina izotopa azota je nestabilna i radioaktivna, sa najdužim vremenom poluraspada za ^{13}N od 10 minuta (Perović, 2019).

Azot gradi brojna, različita organska i neorganska jedinjenja sa 9 mogućih oksidacionih brojeva (- 3, - 2, - 1/3, 0, +1, +2, +3, +4, +5). Soli azotne kiseline – neorganski nitrati ubrajaju se u biogene anjonske specije, nutrijente, koji su kao izvor azota pored velike grupe organskih supstanci, monomolekularnih amino i purinskih i pirimidinskih baza i polimerizacionih visoko molekularnih proteina, DNK i RNK, neophodne za život i razvoj biljaka.

Azotne materije u vodi vode poreklo iz atmosfere, leguminoznih biljaka, biljnog otpada, životinjskih ekskremenata, kanalizacije, azotnih đubriva ili industrijskih otpadnih voda. U akvatične ekosisteme azot dospeva razgradnjom organske materije ili spiranjem zemljišta na kom je korišćeno mineralno veštačko đubrivo (kalijum – nitrat, KAN, amonijum – nitrat) ili prirodno đubrivo koje u sebi sadrži azot. Procesom mineralizacije u zemljištu se stvaraju amonijum joni. Određeni deo amonijum jona nastalih procesom mineralizacije se u oksičnim uslovima mogu transformisati u soli azotne kiseline – nitrati, dvostepenim procesom oksidacije posredstvom hemolitotrofnih bakterija, koje oksidišu amonijak i nitrite (Perović, 2019).

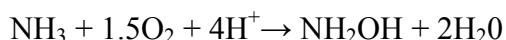
Biološko uklanjanje azota iz otpadnih voda odvija se procesima nitrifikacije i denitrifikacije. Procesom nitrifikacije azot se iz amonijaka (u kom azot ima negativan oksidacioni broj - 3) enzimatskim, redoks procesima transformiše najpre na niže +3 oksidaciono stanje, nitrite, a zatim na +5 oksidaciono stanje – nitrati. Nitrifikacija je dvostepeni proces koji obuhvata oksidaciju amonijum katjona do nitritnih anjona, a zatim oksidaciju nitritnih do nitratnih anjona. Kiseonik potreban za nitrifikaciju može poticati iz

vode ili iz atmosferskog vazduha. Energiju oslobođenu prilikom procesa nitrifikacije koriste mikroorganizmi (Perović, 2019).

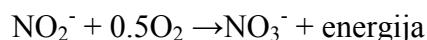


Nakon nitrifikacije redukcijom se nitrati prevode u gasoviti elementarni azot, nultog stanja, koji se iz živog sistema i akvatičnog sistema transportuje u atmosferu. Neophodni parametri potrebni za postizanje slabe parcijalne nitrifikacije su niske koncentracije rastvorenog kiseonika, visoka temperatura, vreme zadržavanja mulja, visoka koncentracija supstrata, dok su inhibirajući faktori slobodan amonijak i nitritna kiselina. U procesu nitrifikacije učestvuju autotrofne, strogo aerobne bakterije *Nitrosomonas*, *Nitrosocystis*, *Nitrosopira* i *Nitrobacter*. Procesi nitrifikacije i denitrifikacije mogu se odigravati u kombinaciji (Maričić, 2013; Cvetković i Despotović, 2011).

Oksidacioni proces nitrifikacije opisan je sledećim jonskim stehiometrijskim jednačinama:



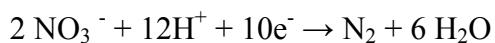
$\text{NH}_2\text{OH} + 2\text{H}_2\text{O} \rightarrow \text{NO}_2^- + 5\text{H}^+ + 4\text{e}^-$ pa se zbirna reakcija nastajanja nitrita može prikazati sledećim jednačinama:



Oksidacija amonijum jona se odvija preko intermedijnog jedinjenja hidroksilamina (NH_2OH) uz enzim amonijum - monooksigenazu (AMO), a oksidacija hidroksilamina do nitrita uz enzim hidroksilamin oksidoreduktazu (HAO), prema navedenim jednačinama (Drljača i saradnici, 2016).

Proces redukcije nitrata do gasovitog azota predstavlja denitrifikaciju. U procesu denitrifikacije se pored oksida azota oslobođaju i CO_2 i H_2 . Denitrifikacija je proces karakterističan za suboksične uslove i predstavlja anaeroban proces "disanja" koji sprovode anaerobne i aerobne bakterije i određene vrste gljivica. Redukcija nitrata može se

predstaviti elektronsko-jonskom polureakcijom, koja ilustruje samo ulogu transfera elektrona (e^-) u procesu denitrifikacije, nezavisno od izvora elektrona:



Denitrifikacija se odvija dejstvom fakultativnih heterotrofnih bakterija: *Pseudomonas*, *Achromobacter*, *Bacillus* i *Micrococcus*. Pored koliformnih bakterija sa denitrifikacijom su asocirani i: *Bacillus*, *Mycobacterium*, *Pseudomonas*, *Proteus*, *Thiobacillus*, *Clostridium*, *Alcaligenes*, *Micrococcus*, *Nocardia*, *Leptothrix*, *Serratia*, i dr. Hidroksidni anjoni oslobođeni tokom procesa denitrifikacije indukuju porast pH vrednosti u vodenoj sredini. Prema rezultatima redukcija nitrata se ne odvija ukoliko je količina kiseonika iznad 0.4 mg/L. Perović (2019) u svojoj doktorskoj disertaciji navodi da su povoljni uslovi za denitrifikaciju pH vrednost u opsegu od 7.0 – 8.0, koncentracija rastvorenog kiseonika < 2 mg/L, vrednost elektrodnog potencijala Eh < 250 mV i temperaturni opseg od 25 - 35°C. U kiseloj sredini, pH<5, denitrifikacija se zaustavlja na nivou formiranja N₂O.

Prema izveštajnim rezultatima i podacima Evropske agencije za zaštitu životne sredine u periodu od 1992. - 2007. godine koncentracija nitratnih anjona u evropskim rekama opadala je za 0.02 mg/L azota godišnje, a od 2010. godine se stabilizovala, što se pripisuje redukovanoj upotrebi nitrata u poljoprivrednoj proizvodnji (www.eea.europa.eu/data-and-maps/indicators/nutrients-in-freshwater).

U cilju smanjivanja kontaminacije vodenih ekosistema nitratima koji potiču iz poljoprivrede 1991. godine je doneta, propisana i usvojena Nitratna Direktiva (91/676/EEC) koja propisuje maksimalnu koncentraciju nitratnih anjona od 50 mg NO₃⁻/dm³. Nitratna Direktiva implementirana je u svim zemljama Evropske unije.

Svi biološki procesi uključeni u proces kruženja azota (nitrifikacija, denitrifikacija i usvajanje azota od strane biljaka) zavise od temperature (Zweimüller i saradnika, 2008). U ljudskom organizmu nitrati se vezuju za hemoglobin te se dospevanjem nitratnih anjona u organizam čoveka, direktno ili putem lanaca ishrane, redukuje sposobnost krvi da prenosi kiseonik što može usloviti pojavu methemoglobinemije kod novorođenčadi. Methemoglobin (Fe³⁺) ometa vezivanje i prenos kiseonika (Wagh i saradnici, 2018). Nizak aciditet želudačnog sadržaja kod novorođenčadi pogoduje razvoju bakterija koje redukuju nitrate u nitrite, te su u dečijoj patologiji methemoglobinemije najčešće prouzrokovane

upravo visokim vrednostima nitrata u vodi koju dete u toku dana ingestira (Santo i saradnici, 2017).

Vrednosti koncentracija nitratnih anjona na osnovu kojih se određuju klase ekološkog statusa površinskih voda za sve podunavske zemlje prikazane su u Tabelama 1. – 12.

5.2.3. Ortofosfatni anjoni u površinskim vodama

Fosfor je neophodan bioelement za razvoj biljaka, no kada se fosfatni anjoni u vodi prisutni u koncentracijama iznad 0.8 mg/L znatno se ubrzava proces eutrofizacije. Ortofosfati su soli ortofosforne kiseline, dok su estri fosforne kiseline izuzetno važni u biohemiji, kao energetski faktori, biogeohemiji i ekologiji.

Ortofosforna (fosforna kiselina), kao troprotična neorganska kiselina, elektrolitičkom disocijacijom formira tri tipa fosfatnih anjona u vodenoj sredini (PO_4^{3-} , HPO_4^{2-} ili H_2PO_4^-). Zbog osobine da ortofosforna kiselina može proći tri disocijacije, ima i tri konstante disocijacije, K_1-K_3 , $7.5 \cdot 10^{-3}$, $6.2 \cdot 10^{-8}$, $2.2 \cdot 10^{-13}$ respektivno. U kojoj od 3 moguće disocijabilne forme će se fosfatni anjoni javiti u vodenoj sredini zavisi od pH vrednosti sredine. U prvom stepenu disocijacije (K_1) fosforna kiselina, H_2PO_4^- , pripada relativno jakim kiselinama, dok se na osnovu druga dva stepena disocijacije (K_2 , K_3), anjonske specije (HPO_4^{2-} , PO_4^{3-}), ubraja u slabe kiseline (Cherif i saradnici, 2000).

Osnovni izvor zagađenja akvatičnih sredina i vodnih tela fosfatima su veštačka đubriva, alkalni deterdženti i pražnjenja sanitarnih instalacija. U delovima rečnog toka u neposrednoj blizini obradivih površina očekivano je da koncentracije anjona fosfata budu više u odnosu na druge delove rečnog toka. Vrednost emisije fosfora u Srbiji koja potiče od poljoprivrede je iznad 75 kg/km^2 godišnje, što predstavlja najveću vrednost emisije fosfora duž čitavog toka sliva Dunava.

Pojava eutrofizacije uzrokovanu povišenim koncentracijama ortofosfatnih anjona ima negativan uticaj na nivo rastvorenog kiseonika u vodi (Šiljić-Tomić, 2018). U poslednje 3 decenije prosečne koncentracije fosfatnih anjona u evropskim rekama opadale su za 0.002 mg/L fosfora godišnje, što je posledica unapređivanja tretmana otpadnih voda i redukcija sadržaja fosfata u deterdžentima. Poslednjih godina usled intenzivne urbanizacije

i poljoprivredne proizvodnje registruje se dramatičan porast sadržaja fosfora u površinskim vodama koje su sve više izložene složenim i kompleksnim procesima eutrofizacije.

Upravljanje procesima koji za posledice imaju povećanje koncentracije fosfatnih anjona u vodama od ključnog je značaja za redukovanje esencijalnih procesa eutrofizacije (Feijoó i Ferreiro, 2011). Prema istraživanju Ensign i Doyle (2006) na usvajanje nutrijenata utiču biohemski faktori, pre svega usvajanje nutrijenata od strane bakterija, algi, gljiva i makrofita, i geomorfološki faktori koji se odnose na veličinu plovног puta i vreme zadržavanja rastvorenih materija u delovima reke sa sporijim tokom. Visok sadržaj fosfatnih anjona u vodama indikacija je i zagađenja animalnog porekla, što se posebno odnosi na razvoj mikrobne flore (Balaban i Constantinescu, 2009). U deterdžentima fosfati imaju ulogu da disperguju nečistoće na sitne čestice i sprečavaju njihovo ponovno taloženje, a u sinergiji sa surfaktantima omekšavaju vodu čime se povećava moć pranja.

U cilju smanjenja eutrofizacije vodenih resursa kao zamena za fosfate u deterdžentima može da se koristi sintetički zeolit ili neke druge hemijske supstance, ali je u tom slučaju efikasnost deterdženta manja. Primenom nekih hemijskih supstanci koje u deterdžentima mogu zameniti fosfatne anjone povećava se hemijska potrošnja kiseonika i nije rešeno pitanje povećane koncentracije teških metala u vodama, te se time ne mogu zadovoljiti svi aspekti zaštite voda od zagađenja. Adekvatna zamena za fosfate u deterdžentima nije ni do danas pronađena (Grbavčić, 2014).

Klasifikacija površinskih voda na osnovu koncentracija fosfatnih anjona u Dunavu za sve podunavske zemlje prikazana je u Tabelama 1. - 12. Koncentracije su izražene u jedinici mg/L.

5.3. Klasifikacija ekološkog statusa reka u podunavskim zemljama

Na osnovu brojnih podataka različitih ekoloških statusa akvatičnih sistema, selektovane su reprezentativne zemlje podunavskog basena i kreirana je jedinstvena klasifikacija ekološkog statusa Dunava na osnovu prikupljenih podataka. Klasifikacija ekološkog statusa reka u Bugarskoj podeljena je na osnovu toga da li je reka ravničarskog, planinskog ili poluplaninskog tipa (Tabela 1.- 3.).

Prema bugarskoj klasifikaciji klase ekološkog statusa reka razlikuju se kod planinskih, poluplaninskih i ravničarskih tipova reke. Razlike u klasifikaciji reka u Bugarskoj odnose se pre svega na koncentracije nitratnih anjona i ukupnog azota kod planinskih i poluplaninskih tipova reka, dok se kod ravničarskog tipa reka ne navode referentne vrednosti koncentracija rastvorenog kiseonika za odličan i umeren ekološki status. Referentne vrednosti za koncentracije nitritnih anjona razlikuju se kod ravničarskog tipa reka u odnosu na planinske i poluplaninske tipove reka.

Tabela 1. Klasifikacija ekološkog statusa planinskih tipova reka u Bugarskoj

Ekološki status	[DO]	$[\text{NH}_4^+]$	$[\text{NO}_3^-]$	$[\text{NO}_2^-]$	Ukupan azot	$[\text{PO}_4^{3-}]$
ODLIČAN	10.5 – 8	<0.04	<0.2	<0.01	<0.2	<0.01
DOBAR	8 – 6	0.04 – 0.4	0.2 – 0.5	0.01 – 0.025	0.2 – 0.8	0.01 – 0.02
UMEREN	<6	>0.4	>0.5	>0.025	>0.8	>0.02

Tabela 2. Klasifikacija ekološkog statusa poluplaninskih tipova reka u Bugarskoj

Ekološki status	[DO]	$[\text{NH}_4^+]$	$[\text{NO}_3^-]$	$[\text{NO}_2^-]$	Ukupan azot	$[\text{PO}_4^{3-}]$
ODLIČAN	10.5 – 8	<0.04	<0.5	<0.01	<0.5	<0.02
DOBAR	8 – 6	0.04 – 0.4	0.5 – 1.5	0.01 – 0.03	0.5 – 1.5	0.02 – 0.04
UMEREN	<6	>0.4	>1.5	>0.03	>1.5	>0.04

Tabela 3. Klasifikacija ekološkog statusa ravničarskih tipova reka u Bugarskoj

Ekološki status	[DO]	$[\text{NH}_4^+]$	$[\text{NO}_3^-]$	$[\text{NO}_2^-]$	Ukupan azot	$[\text{PO}_4^{3-}]$
ODLIČAN	–	<0.1	<0.7	<0.03	<0.7	<0.07
DOBAR	6.5 – 8.5	0.1 – 0.3	0.7 – 2	0.03 – 0.06	0.7 – 2.5	0.07 – 0.15
UMEREN	–	>0.3	>2	>0.06	>2.5	>0.15

Ukrajinska klasifikacija ekološkog statusa reka se razlikuje od klasifikacije u Bugarskoj, i obuhvata 4 klase ekološkog statusa prikazane u Tabeli 4. (Ukrainy, 2015; Safranov i saradnici, 2016).

Tabela 4. Klasifikacija ekološkog statusa reka u Ukrajini

Klasa ekološkog statusa	[DO]	[NH ₄ ⁺]	[NO ₃ ⁻]	[NO ₂ ⁻]	[PO ₄ ³⁻]
I	>8	<0.1	<0.002	<0.2	<0.15
II	8 – 7.1	0.1 – 0.3	0.002 – 0.01	0.2 – 0.5	0.015 – 0.05
III	7 – 5	0.3 – 1.30	0.01 – 0.05	0.51 – 1	0.51 – 0.20
IV	<5	>1	>0.05	>1	>0.20

U Hrvatskoj i Moldaviji klasifikacija kvaliteta površinskih voda određuje se na osnovu petostepene skale klasa ekološkog statusa. Referentne vrednosti parametara na osnovu kojih su klasifikacije kreirane prikazane su u Tabelama 5. i 6.

Tabela 5. Klasifikacija ekološkog statusa Dunava u Hrvatskoj

Klasa ekološkog statusa	[DO]	[NH ₄ ⁺]	[NO ₃ ⁻]	[NO ₂ ⁻]	Ukupan fosfor
I	>7	<0.1	>1	<0.01	<0.01
II	7 – 6	0.1 – 0.2	1 – 5	0.01 – 0.03	0.01 – 0.03
III	6 – 4	0.2 – 0.4	5 – 10	0.03 – 0.05	0.03 – 0.05
IV	4 – 3	0.4 – 1	10 – 25	0.05 – 0.2	0.05 – 0.1
V	<3	>1	>25	>0.2	>0.1

Tabela 6. Klasifikacija ekološkog statusa Dunava u Moldaviji

Klasa ekološkog statusa	[DO]	[NH ₄ ⁺]	[NO ₃ ⁻]	[NO ₂ ⁻]	[PO ₄ ³⁻]	Ukupan fosfor
I	> 7	0.2	1	0.01	0.05	0.1
II	> 7	0.4	3	0.06	0.1	0.2
III	> 5	0.8	5.6	0.12	0.2	0.4
IV	> 4	3.1	11.3	0.3	0.5	1
V	<4	>3.1	>11.3	>0.3	>0.5	>1

Klasifikacija ekološkog statusa Dunava u Nemačkoj obuhvata 4 osnovne i 3 prelazne klase ekološkog statusa, u zavisnosti od vrednosti koncentracije hemijskih parametara (Tabela 7.).

Tabela 7. Klasifikacija ekološkog statusa Dunava u Nemačkoj

Klasa ekološkog statusa	[DO]	[NH ₄ ⁺]	[NO ₃ ⁻]	[NO ₂ ⁻]	[PO ₄ ³⁻]	Ukupan fosfor
I	>8	<0.04	<1	<0.01	<0.02	<0.05
I – II	>8	<0.1	<1.5	<0.05	<0.04	<0.08
II	>6	<0.3	<2.5	<0.1	<0.1	<0.15
II – III	>5	<0.6	<5	<0.2	<0.2	<0.3
III	>4	<1.2	<10	<0.4	<0.4	<0.6
III – IV	>2	<2.4	<20	<0.8	<0.8	<1.2
IV	<2	>2.4	>20	>0.8	>0.8	>1.2

Klasifikacija ekološkog statusa Dunava u Slovačkoj zasnovana je na preporučenim i najvišim dozvoljenim vrednostima koncentracija rastvorenog kiseonika, amonijum, nitratnih, nitritnih i ortofosfornih anjona. Referentne vrednosti navedenih parametara razlikuju se na osnovu ihtiološke strukture rečnog toka, odnosno u zavisnosti od toga da li u određenom delu rečnog ekosistema dominiraju salmonide ili ciprinide (Tabela 8).

Tabela 8. Klasifikacija ekološkog statusa Dunava u Slovačkoj

	Zona vode sa salmonidama		Zona vode sa ciprinidama	
Hemijski parametar	Preporučena granična vrednost	Najviša dozvoljena vrednost	Preporučena granična vrednost	Najviša dozvoljena vrednost
[DO]	9	7	8	5
[NH ₄ ⁺]	0.03	0.8	0.15	0.8
[NO ₂ ⁻]	0.003	-	0.01	-
[PO ₄ ³⁻]	0.2	-	0.4	-

Prema slovačkoj klasifikaciji vrednosti parametara koji su pokazatelji klase ekološkog statusa Dunava razlikuju se u delovima rečnog toka u zavisnosti od načina dezinfekcije i fizičkog, odnosno hemijskog tretmana vodnog tela, što je prikazano u Tabeli 9.

Tabela 9. Klasifikacija ekološkog statusa Dunava u Slovačkoj

	*A1		**A2		***A3	
	Preporučena granična vrednost	Najviša dozvoljena vrednost	Preporučena granična vrednost	Najviša dozvoljena vrednost	Preporučena granična vrednost	Najviša dozvoljena vrednost
Zasićenost kiseonikom (%)	> 80		> 70		> 60	
[NH ₄ ⁺] (mg/L)	0.04	0.4	0.4	0.8	0.8	2.3
[NO ₃ ⁻] (mg/L)	1		7		7	
[PO ₄ ³⁻] (mg/L)	0.4		0.7	0.7		

* jednostavni fizički tretmani dezinfekcije

** fizički i hemijski tretmani dezinfekcije

*** intenzivni fizički i hemijski tretmani dezinfekcije

U Mađarskoj se primenjuje klasifikacija od 9 klasa ekološkog statusa Dunava, s tim što se referentne vrednosti za IV i V klasu ekološkog statusa razlikuju samo po vrednostima koncentracije amonijum jona (Tabela 10.) (www.okologia.ta.hu).

Tabela 10. Klase ekološkog statusa Dunava u Mađarskoj

Klasa ekološkog statusa	[DO]	[NH ₄ ⁺]	[PO ₄ ³⁻]	[NO ₂ ⁻]	[NO ₃ ⁻]
I	9	0.02	15	< 0.01	0.04
II	9	0.03	20	< 0.01	0.08
III	9	0.05	30	-	-
IV	8.5	0.05	40	0.01	0.08
V	8.5	0.1	40	0.01	0.08
VI	7	0.1	40	< 0.01	< 0.1
VII	8	0.1	40	< 0.01	0.1
VIII	8.5	0.05	40	< 0.01	0.18
IX	8.5	0.05	40	< 0.02	< 0.20

U klasifikaciji dela toka Dunava koji prolazi kroz Rumuniju izdvojena su 3 segmenta rečnog toka na osnovu geografskog položaja, odnosno specifičnog dela rečnog toka. Određeni deo rečnog toka na osnovu vrednosti odabranih hemijskih parametara može pripadati visokom ili dobrom ekološkom statusu (H/G), odnosno dobrom ili umerenom ekološkom statusu (G/M). Vrednosti koncentracija hemijskih parametara na osnovu kojih se klasificuje ekološki status Dunava u Rumuniji prikazane su u Tabeli 11.

Tabela 11. Klasifikacija dela toka Dunava koji prolazi kroz Rumuniju

	[DO]		[NH ₄ ⁺]		[NO ₃ ⁻]		[NO ₂ ⁻]		[PO ₄ ³⁻]	
KATEGORIJA VODA	H/G	G/M	H/G	G/M	H/G	G/M	H/G	G/M	H/G	G/M
RO 13	8	6	0.36	0.76	1.7	3.5	-	0.35	0.13	0.27
RO 14	8	6	0.66	1.40	2.6	5.5	-	0.35	0.09	0.20
RO 15	8	6	0.62	1.30	2.4	5.1	-	0.35	0.1	0.21

*RO13 - (Ostrov-Chiciu; 863 - 375.5 km;),

*RO14 – Chiciu – Issaccea (375.5 - 100 km)

*RO15 - Delta Dunava

*H/G – high/good (odličan/dobar ekološki status)

*G/M – good/moderate (dobar/umeren ekološki status)

Na osnovu svih navedenih klasifikacija kreirana je jedinstvena klasifikacija ekološkog statusa Dunava.

6. VEŠTAČKE NEURONSKE MREŽE KAO ALAT U MODELOVANJU EKOLOŠKOG STATUSA REČNIH EKOSISTEMA

U cilju procene klase ekološkog statusa Dunava korišćen je obiman set podataka koji sadrži sve zvanične parametre koji se prema Okvirnoj Direktivi o vodama koriste u proceni ekostatusa. Parametri su prikupljeni na 68 lokaliteta sa obe strane obale reke. S obzirom na to da biološki i hemijski parametri ne pokazuju međusobnu linearnu zavisnost, standardne statističke metode nisu pogodan alat za modelovanje ekološkog statusa na osnovu prisustva makrofita, kao bioloških pokazatelja kvaliteta, i koncentracija odabralih hemijskih parametara.

Obiman set podataka sa parametrima koji ne pokazuju međusobnu linearnu zavisnost indikuje primenu modela veštačkih neuronskih mreža kao alata za modelovanje klase ekološkog statusa rečnog sliva Dunava.

6.1. Princip rada veštačkih neuronskih mreža

Razvoj veštačkih neuronskih mreža inspirisan je biološkim nervnim sistemom. Iako veza prirodnih i veštačkih neurona nema naročitog značaja, funkcije neuronske mreže mogu se, u određenoj meri, porediti sa funkcijom biološkog nervnog sistema. Početak neuro-računarstva datira još iz 1943. godine kada su kibernetičar Norbert Winer i matematičar John von Neumann došli do zaključka da bi istraživanja na polju računarstva, inspirisana radom ljudskog mozga, mogla biti izuzetno zanimljiva (Petrović, 2011).

Danas neuronske mreže nalaze širok spektar primena u različitim oblastima. S obzirom na to da je veliki broj faktora koji utiču na kvalitet voda u međusobnim nelinearnim zavisnostima, korelacije između indikatora kvaliteta vodnih ekosistema ne mogu se matematički prikazati niti jednostavno objasniti.

Primena modela veštačkih neuronskih mreža u ekološkim istraživanjima umnogome je doprinela kvalitetu predikcije ekološkog statusa na osnovu varijabli koje su međusobno nelinearne. Statistički programi koji su bazirani na veštačkim neuronskim mrežama se u ekologiji koriste onda kada tradicionalne metode analize podataka ne daju zadovoljavajuće rezultate (Lencioni i saradnici, 2007; Palialexis i saradnici, 2011).

Prednost upotrebe veštačkih neuronskih mreža je u tome što mreže mogu da imaju različite strukture i uključuju različite interaktivne algoritme u zavinosti od problema koji se ispituje. To znatno proširuje njihovu primenu u rešavanju kompleksnih problema s kojima se srećemo u analiziranju ekosistema (Lek i Guegan, 1999; Lek i saradnici 2000; Ozesmi i saradnici, 2006).

Veštačke neuronske mreže (VNM) su mreže veštačkih neurona i predstavljaju grubu aproksimaciju bioloških neuronskih mreža. Sličnost veštačkih sa biološkim neuronskim mrežama zasniva se u tome da oba tipa neuronskih mreža uče na osnovu iskustva. Biološkim sistemom upravlja hormoni (humoralna regulacija) i nervni sistem (neuralna regulacija). Prenošenje draži iz spoljašnje sredine putem nerava do organa efektora osnova je upravljanja biološkim sistemom putem nervnog sistema, odnosno neuralne regulacije.

Kod veštačkih neuronskih mreža informacija se obrađuje od ulaznih, preko skrivenih, do izlaznih neurona gde, po analogiji neuronskih elemenata u refleksnom luku, ulazni neuroni imaju ulogu receptora, a neuroni u izlaznom sloju imaju ulogu efektora. Sa praktičnog stanovišta, veštačke neuronske mreže predstavljaju sistem za paralelno računanje koji se sastoji od mnogo procesnih elemenata – neurona, međusobno povezanih na način koji omogućuje da reše određeni zadatak. Procesna sposobnost veštačkih neuronskih mreža data je u vidu jačina veza između procesnih elemenata koje se nazivaju težine. Težine se dobijaju procesom prilagođavanja, ili učenja iz skupa obučavajućih podataka.

Jedna od najmoćnijih osobina neuronskih mreža je njihova sposobnost da uče i uopštavaju na osnovu skupa obučavajućih podataka. Određivanje vrednosti težinskih koeficijenata veza između neurona predstavlja zapravo proces obučavanja veštačke neuronske mreže. S obzirom na to da se veštačke neuronske mreže obučavaju na osnovu iskustva, ne postoji potreba za njihovim eksplisitnim programiranjem.

Osnovne razlike između prirodnih i veštačkih neuronskih mreža zasnivaju se na različitoj brzini obrade podataka, različitom broju neurona i načinu rada (Antanasijević, 2014). Veštačke neuronske mreže imaju sposobnost da nakon uspešnog obučavanja pronađu rešenje za slične probleme, iz iste klase problema, za koje nisu eksplisitno obučene, što zauzvrat dovodi do visokog stepena tolerancije na otkaze (Kaplar, 2015).

Neuronska mreža često uspešno rešava probleme koji su previše kompleksni za konvencionalne tehnologije (na primer, problem koji nema algoritamsko rešenje ili za koji je algoritam previše komplikovan da bi bio pronađen) i one su često dobra pratnja problemima koje ljudi rešavaju.

Gotovo da ne postoji naučno – istraživačka oblast u kojoj veštačke neuronske mreže ne mogu naći svoju primenu. U hemiji se koriste umesto klasičnih spektrofotometrijskih metoda za determinaciju određenih hemijskih supstanci (Musa i saradnici, 2016), za predikciju produkcije bioetanola iz međuproizvoda prerade šećerne repe (Grahovac i saradnici, 2016), u ekonomiji za predviđanje cene akcija na određeni dan (White, 1988). Da bi se proces obučavanja neuronskih mreža adekvatno odvijao, neophodno je da se definišu ulazne i izlazne varijable, kao i da se izvrši grupisanje podataka na tri skupa: skup podataka za treniranje, testiranje i konačnu proveru - validaciju.

U doktorskoj disertaciji Šiljić–Tomić (2018) čitav proces modelovanja predstavljen je u 8 koraka. Prvi korak je promišljen odabir ulaznih, odnosno izlaznih parametara. Zatim sledi prikupljanje podataka, kreiranje skupa podataka za obučavanje, preprocesiranje podataka, kreiranje mreže kroz odabir algoritma i odgovarajuće arhitekture, obučavanje modela sa odabranim ulaznim promenljivima. Završne faze modelovanja čine testiranje modela, odnosno predviđanje izlaza sa ulaznim vrednostima koje su do tad mreži bile nepoznate, i optimizacija modela uz ispitivanje performansi. Preporuka je da se najveći deo podataka iskoristi za potrebe treniranja mreže (oko 70%), dok je ostatak namenjen za potrebe testiranja i validacije. Odabir podataka je slučajan, osim kada se radi o vremenskim serijama podataka (Popčević i saradnici, 2012).

Korišćen algoritam, odnosno tip učenja u okviru neuronskih mreža može biti:

1. Učenje koje se nadgleda - nadgledano učenje (engl. *supervised learning*) kod kojeg su poznate sve vrednosti izlaznih varijabli u okviru skupa za treniranje. Razlika između dobijenih i realnih vrednosti se koristi za podešavanje težinskih faktora u mreži. Smanjivanjem razlike između željene i izračunate vrednosti (konvergencija greške), povećava se uspešnost učenja (Zhu & Goldberg, 2009);

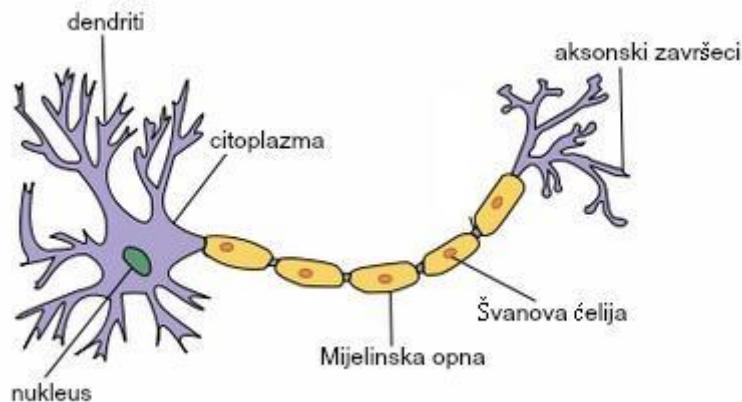
2. Učenje koje se ne nadgleda - nenadgledano učenje (engl. *unsupervised learning*) - gde vrednosti izlaznih varijabli iz skupa za učenje nisu poznate. Ova vrsta učenja je samoorganizujućeg tipa, odnosno mreži se predstavljaju samo stimulativni ulazi, na osnovu

kojih se mreža interno organizuje i daje izlaze čiji kvalitet i korisnost određuje osoba koja trenira mrežu (Barlow, 1989).

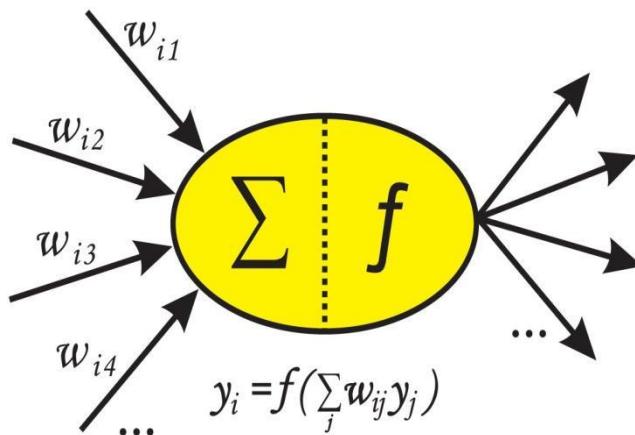
Podešavanje težinskih faktora u mreži, odnosno faza učenja se odvija kroz više iteracija, odnosno prolaza kroz mrežu. Pod iteracijom se podrazumeva podešavanje jednog izlaznog vektora u odnosu na ulazni, pri čemu se često tokom jedne iteracije obrađuje i više paralelnih podešavanja, što se onda naziva epoha (Lojanica, 2001; Bašić i saradnici, 2008; Barlow, 1989).

Mreže se obično treniraju u nekoliko hiljada iteracija, uz napomenu da mreža može i da se „pretrenira“ (engl. *overfitting*), odnosno da izgubi sposobnost obrade onih podataka koji se nalaze izvan grupe podataka za učenje. Da bi se izbegla pojava overfitting-a u literaturi se predlaže da se broj iteracija, broj skrivenih slojeva i broj neurona u skrivenom sloju određuju metodom probe i greške (Dogan i saradnici, 2009). Ljudski mozak i biološku neuronsku mrežu čini oko 10^{11} nervnih ćelija, neurona, raspoređenih prema definisanom rasporedu u skladu sa funkcijom koju obavljaju, pri čemu je u proseku svaki neuron povezan sa 10^4 drugih neurona, čineći na taj način ukupno oko 10^{15} konekcija (Kriesel, 2007; Bašić i saradnici, 2008).

Veštačka neuronska mreža je zapravo model koji imitira biološke neuronske mreže te se stoga može uspostaviti paralela sa terminima iz neurobiologije kako bi se označili odgovarajući koncepti i/ili softverske komponente. Veliki potencijal neuronskih mreža se nalazi u mogućnosti paralelne obrade podataka, tokom izračunavanja komponenti koje su nezavisne jedne od drugih (Martindale, 1991; Lawrence i saradnici, 1997). Telo neurona u biološkoj neuronskoj mreži analogno je čvoru u veštačkoj neuronskoj mreži. Dendriti neurona analogni su ulazima u veštačkim neuronskim mrežama, osa izlazima, sinapsa težinama, a čitav neuron analog je veštačkom neuronu. Na Slici 2. prikazan je prirodni, a na Slici 3. veštački neuron.



Slika 2. Prirodni neuron



Slika 3. Šematski prikaz veštačkog neurona

Elementi veštačke neuronske mreže prikazani na Slici 3. su težinski koeficijenti (w_{i1-4}), sumator aktivacione funkcije (Σ) i izlazi neuronske mreže.

Osnovna sličnost veštačkih neuronskih mreža sa ljudskim mozgom korespondira u tome da mreža stiče znanje kroz proces učenja, a na osnovu podataka dobijenih iz njenog okruženja (učenje na osnovu iskustva), te da se sinaptičke težine koriste za čuvanje stečenog znanja.

Ključni elementi ovog modela jesu težine (w) koje predstavljaju relativnu značajnost svakog ulaza za posmatrani neuron. Menjanjem težina, kroz odgovarajući algoritam, neuronska mreža uči. Veštački neuron prihvata ulaze (analogno dendritima, koji prima elektro-hemijske impulse), i generiše izlaz (signalom koji se šalje kroz osu neurona), koji se formira u zavisnosti od težina, tj. na osnovu promena u sinapsama. Matematički

opisano, ukoliko su ulazne vrednosti u neuronu predstavljene realnim brojevima x_i ($i = 1, 2, \dots, m$) i ako se svaka ulazna vrednost množi sa odgovarajućim težinskim koeficijentom w_{ki} ($i = 1, 2, \dots, m$), tada se zbirna vrednost u_k , dobijena sabiranjem ponderisanih ulaza može predstaviti sledećim matematičkim izrazom:

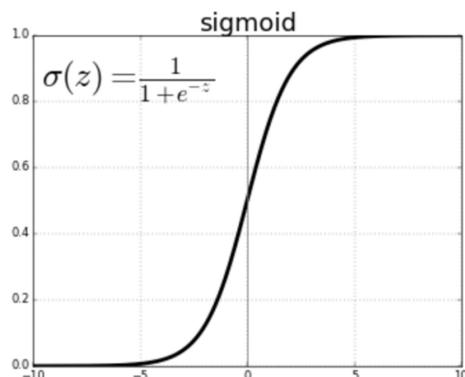
$$u_k = \sum W_{ki} X_i.$$

Ovako dobijena suma u_k obrađuje se pomoću funkcije prenosa (a), tj. aktivacione funkcije $f(u_k)$.

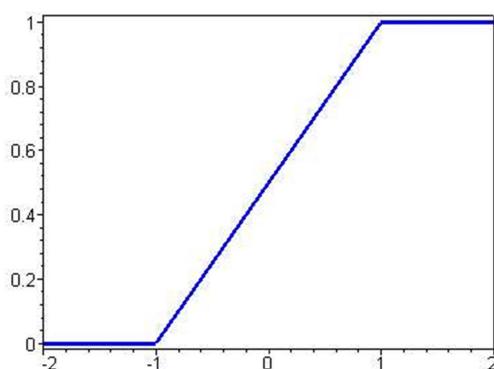
Vrednost izlaza y_k , dobija se oduzimanjem vrednosti praga aktivacije θ_k od vrednosti u_k , odnosno:

$$y_k = a(u_k - \theta_k).$$

Najčešće korištene aktivacione funkcije su sigmoidna – sgn (Slika 4.) i semilinearna aktivaciona funkcija (Slika 5.).

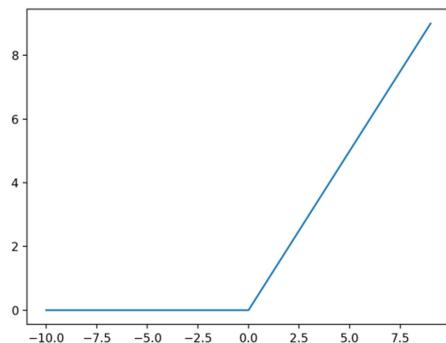


Slika 4. Sigmoidna aktivaciona funkcija



Slika 5. Semilinearna aktivaciona funkcija

Za potrebe modelovanja ekološkog statusa Dunava u istraživačkim aktivnostima doktorske disertacije primenjena je ReLu (engl. *Rectified linear unit*) aktivaciona funkcija (Slika 6.) opisana u 6. poglavlju teze (Agarap, 2018).



Slika 6. ReLu aktivaciona funkcija

Kod veštačke neuronske mreže, neuroni su obično raspoređeni po grupama ili slojevima u kojima se paralelno obrađuju informacije.

Klasična neuronska mreža se najčešće sastoji od nekoliko slojeva, pri čemu je prvi uvek ulazni, a poslednji izlazni sloj, dok se jedan ili više međuslojeva nazivaju skriveni slojevi (Wang, 2003). Ulazni sloj služi za učitavanje podataka iz okoline, izlazni sloj prikazuje rezultat mreže za zadani ulaz, dok se unutar skrivenih slojeva definiše odgovarajuća prenosna funkcija.

Funkcije prenosa ili aktivacione funkcije mogu biti linearne, ali i nelinearne, što je od posebnog značaja ako se ima u vidu da je kod većine realnih problema koji se izučavaju, priroda veze između posmatranih ulaza i izlaza nelinearna (Kriesel, 2007; Popčević i saradnici, 2012).

Najjednostavnija aktivaciona funkcija je linearna funkcija, kod koje je izlaz iz posmatranog neurona jednak težinskoj sumi njegovih ulaza. Korišćena funkcija može biti i linearna po delovima, odnosno kada su zadate vrednosti u okviru određenog intervala predstavljane linearnom funkcijom, dok se svim preostalim vrednostima (iznad i ispod tog intervala) dodeljuje maksimalna, odnosno minimalna vrednost. Za ulazne vrednosti pri kojima se funkcija ponaša linearno se uglavnom uzima interval od -0,5 do +0,5, dok se za sve preostale ulazne vrednosti iznad i ispod pomenutog intervala dodeljuje 1, odnosno 0.

Kod funkcije skoka ili praga, se svim vrednostima koje pređu određenu granicu (prag) dodeljuje neka fiksna vrednost, dok se sve vrednosti koje se nalaze ispod zadate granice preslikavaju u nulu. Najčešće se za vrednost praga uzima 0, dok se svim vrednostima iznad definisanog praga dodeljuje broj 1, čime se dobija binarni izlaz iz neurona.

Kada je izlaz funkcije određen intervalom od -1 do 1, tada je reč o bipolarnoj aktivacionoj funkciji.

Sigmoidna ili logistička funkcija spada u grupu najčešće korišćenih aktivacionih funkcija, pre svega zbog činjenice da je derivabilna, odnosno uključuje i parametar „ b “ kojim se određuje nagib funkcije. Sigmoidna funkcija u stvari ima slične karakteristike kao i funkcija praga, uz postojanje područja nesigurnosti unutar određenog intervala što je čini najčešće korišćenom aktivacionom funkcijom.

Pored različitih tipova aktivacionih funkcija, neuronske mreže mogu se razlikovati i po načinu na koji su neuroni povezani u mreži, odnosno od načina na koji su neuroni grupisani u slojeve posmatrane mreže. Najjednostavnije mreže mogu biti predstavljene samo sa dva osnovna sloja, ali se svaka složenija funkcija realizuje sa najmanje jednim skrivenim slojem.

Arhitekturu, odnosno topologiju neuronske mreže, određuje broj slojeva i način na koji su slojevi organizovani, tj. povezani, unutar neuronske mreže (Batinić, 2015). Na osnovu broja slojeva neuronske mreže se dele na jednoslojne i višeslojne. Iako pored izlaznog sloja neurona, jednoslojna mreža sadrži i ulazni sloj, on se suštinski ne računa jer unutar njega nema matematičkih operacija. Ulazi u mrežu predstavljaju ujedno i ulaze neurona izlaznog sloja, a izlazi neurona predstavljaju i izlaz mreže. Takođe, ne postoje povratne veze s izlaza na ulaz.

Višeslojne neuronske mreže, imaju jedan ili više skrivenih slojeva, pri čemu se upravo u ovim slojevima obrađuju informacije i krajnji rezultat prosleđuje neuronima izlaznog sloja (Ponce i saradnici, 2004; Kriesel, 2007). Izlazi neurona iz posmatranog skrivenog sloja predstavljaju istovremeno izlaze narednog skrivenog sloja. Po istom principu se posmatra svaki naredni skriveni sloj, sve dok se ne dođe do krajnjeg, tj. izlaznog sloja.

U zavisnosti od korišćene veze među neuronima različitih slojeva, u opštem smislu neuronske mreže se dele na aciklične i ciklične, analogno podeli ugljovodonika u organskoj hemiji, odnosno potpuno i delimično povezane neuronske mreže.

Za razliku od acikličnih, ciklične mreže sadrže povratne veze između neurona susednih slojeva. Ako je svaki neuron prethodnog sloja povezan sa svakim neuronom narednog sloja, reč je o potpuno povezanoj neuronskoj mreži, a kada to nije nužno pravilo radi se o delimično povezanoj neuronskoj mreži (Popčević i saradnici, 2016).

Prema smeru prostiranja informacija kroz neuronsku mrežu, one se mogu podeliti na nepovratne i povratne mreže. Kod nepovratne ili nerekurzivne mreže (engl. *Feedforward*) prostiranje informacija se prostire samo u jednom smeru, odnosno od ulaza ka izlazu. Ovo znači da posmatrani neuron prenosi informaciju, tj. utiče isključivo na neuron koji se nalazi u narednom sloju bliže izlazu. Nepovratne mreže obično za zadati ulaz daju brz odgovor na izlazu i pogodne su za prepoznavanje oblika.

Tabela 12. Podela neuronskih mreža

Kriterijum podele neuronskih mreža	Tip neuronske mreže	Karakteristike	Tip učenja neuronske mreže	Karakteristike
Na osnovu broju slojeva	Jednoslojne Višeslojne	Određuju arhitekturu neuronske mreže	Nadgledano učenje	Razlika između dobijenih i realnih vrednosti se koristi za podešavanje težinskih faktora u mreži
Na osnovu korišćene veze među neuronima	Aciklične Ciklične	Potpuno ili delimično povezane	Nenadgledano učenje	Mreži se predstavljaju samo stimulativni ulazi, na bazi kojih se mreža obučava
Na osnovu smera prostiranja informacija	Povratne Nepovratne	Informacija se prostire u jednom smeru ili se vraća sa viših slojeva u niže		

Povratne ili rekurzivne mreže (engl. *Feedback*) dozvoljavaju mogućnost da se informacije sa viših slojeva vraćaju u niže slojeve ili isti sloj. Povratne mreže imaju mnogo veće procesne sposobnosti od nerekurzivnih mreža, zbog čega se koriste za rešavanje dinamičkih problema, ali im je zbog svoje kompleksnosti potrebno više vremena da generišu izlaz.

Dve osnovne faze na kojima je baziran princip rada neuronskih mreža se odnose na fazu učenja i fazu testiranja. Poznavanje izlaznih informacija kao funkcije ulaza, sadržane su u sklopu težinskih koeficijenata koji se kroz proces učenja postepeno prilagođavaju sve dok izlaz iz neuronske mreže koji se proverava u okviru grupe podataka odabralih za testiranje, ne da zadovoljavajuću vrednost.

Proces učenja kod neuronskih mreža, predstavlja proces menjanja težinskih faktora u mreži, koji nastaje kao posledica upoređivanja dobijene vrednosti sa željenom, sve dok se podešavanjem težina i vraćanjem na prvi korak ne dobiju odgovarajuće izlazne vrednosti (Ponce i saradnici, 2004; Bašić i saradnici, 2008). Posmatranjem izlaza koje mreža daje za odgovarajuće ulazne vrednosti iz skupa za testiranje, može se odrediti iteracija u kojoj izlazna veličina ima najmanje odstupanje u odnosu na željenu vrednost. Konačna provera tačnosti i preciznosti obrade podataka vrši se u okviru skupa za validaciju.

Drugu ključnu fazu u radu neuronske mreže predstavlja njen testiranje, odnosno ocenjivanje performansi posmatrane mreže. Za razliku od faze treniranja, u fazi testiranja posmatraju se konačni težinski koeficijenti dobijeni kao krajnji rezultat prethodne faze.

Proces testiranja sprovodi se tako što se mreži predstavljaju nove ulazne varijable koje nisu učestvovale u procesu učenja, nakon čega se posmatra kakav izlaz je dala mreža na zadati ulaz u odnosu na stvarnu izlaznu vrednost. Na osnovu izračunate greške, ocenjuju se neuronske mreže. Mogućnost primene neuronske mreže u domenu predviđanja budućih podataka, određuje se na osnovu izračunate greške koju daje mreža u okviru skupa podataka odabralih za validaciju (Suzuki, 2011; Kriesel, 2007).

Najčešće vrste grešaka koje se koriste u cilju evaluacije uspešnosti određene neuronske mreže su koren srednje kvadratne greške (RMSE) i srednja apsolutna greška (MAE), kao i koeficijent korelacije (r), odnosno koeficijent determinacije (r^2) (Batinić, 2015).

Koren srednje kvadratne greške (engl. *Root Mean Squared Error* - RMSE) koristi se kao mera razlike vrednosti prognoziranih modelom i realnih vrednosti. Definiše se kao kvadratni koren srednje kvadratne greške (engl. *Mean Squared Error* - MSE), pri čemu u okviru n posmatranih vrednosti, f predstavljaju prognozirane, dok y_i predstavljaju izmerene vrednosti. RMSE se izražava u jedinicama promenljive, što omogućava lakšu interpretaciju, dobijenih rezultata odnosno karakteristika modela. Što je koren srednje kvadratne greške manji, to je preciznost modela veća.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (Y_i - Y_i')^2$$

Srednja apsolutna greška (engl. *Mean Absolute Error* - MAE) odnosi se na srednju vrednost apsolutnih razlika vrednosti prognoziranih modelom i realnih vrednosti. Srednja apsolutna greška je praktična za evaluaciju modela, s obzirom na to da prati intuiciju korisnika izražavajući vrednost greške u istim jedinicama kao i promenljiva koja je predmet modelovanja. Srednja apsolutna greška - MAE teži ka nuli, što se dešava u idealnom slučaju kada ne postoji razlika između modelovanih i realnih vrednosti.

Srednja apsolutna procentualna greška (engl. *Mean Absolute Percentage Error* - MAPE) predstavlja meru tačnosti predviđenih vrednosti u odnosu na izmerene, izraženu u procentima. Za razliku od prethodna dva tipa greške, MAPE se ne izražava u jedinicama promenljive, već se posmatra srednja vrednost procentualne razlike između svih realnih i modelovanih vrednosti (Mathews & Diamantopoulos, 1994). Srednja apsolutna procentualna greška teži da ima vrednost nula kada su predviđene vrednosti bliže izmerenim vrednostima.

Koeficijent korelacijske (r) - predstavlja statističku meru povezanosti prognoziranih vrednosti dobijenih modelom i realnih vrednosti, odnosno reflektuje stepen linearne korelacijske između izmerene i prediktovane vrednosti (Willmott & Matsuura, 2005). Koeficijent korelacijske se kreće u intervalu od 1 (idealna pozitivna linearna korelacija promenljivih), do -1 (idealna negativna linearna korelacija promenljivih). U slučajevima kada se želi izraziti u kojoj meri promene vrednosti jedne promenljive utiču na promenu vrednosti druge promenljive, koristi se koeficijent determinacije (r^2).

Koeficijent determinacije označava u kom procentu se varijacija zavisne promenjive može objasniti linearnom vezom sa nezavisnom promenjivom. Model veštačke neuronske mreže primenjen u okviru ove teze specifičan je po skupu podataka za obučavanje, primenjenoj aktivacionoj funkciji (ReLU) i Leave - one out modelu validacije.

6.2. Neuronska mreža tipa višeslojni perceptron sa propagacijom signala unapred

Tip neuronske mreže višeslojni perceptron sa propagacijom signala unapred (engl. *Feedforward neural network*) kao algoritam za obučavanje koristi algoritam sa propagacijom greške unazad (engl. Backpropagation - BP). Ovaj tip neuronske mreže razvijen je sa ciljem da se problem nelinearnog preslikavanja iz ulaznog u izlazni prostor uspešno reši, pri čemu se ostvaruje modifikacija težinskih odnosa između ulaznog i skrivenih slojeva neurona. Neuronska mreža koja koristi Backpropagation algoritam za obučavanje realizuje supervizorski vid učenja, sa različitim aktivacionim funkcijama i algoritmima učenja (Hecht-Nielsen, 1992).

Neuronska mreža sa propagacijom greške unazad koristi gradijentni postupak pri obučavanju, koji je analogan procesu minimizacije greške. To znači da uči preslikavanja iz ulaznog prostora uzorka u izlazni prostor, kroz proces minimizacije greške između aktuelnog izlaza koji je ostvarila mreža i zahtevanog izlaza, na osnovu skupa obučavajućih parova, odnosno primera.

Proces učenja počinje sa prezentacijom ulaznog oblika uzorka Backpropagation mreži, koji prostiranjem kroz mrežu ostvaruje izlazni oblik. Backpropagation mreža zatim primenjuje generalisano delta pravilo da bi se utvrdila greška na izlazu, koju prostiranjem unazad preko skrivenog sloja, koristi za modifikovanje svakog težinskog odnosa između neurona. Taj postupak se ponavlja za svaki novi uzorak.

Konvergenciju procesa učenja do zadatog nivoa tačnosti obezbeđuje generalisano delta pravilo kroz iterativni proces adaptacije težinskih odnosa (Miljković, 2007).

Koraci *Backpropagation* algoritma su sledeći:

1. Inicijalizacija težinskih vrednosti na slučajne male vrednosti;
2. Postavljanje ulaznih vektora na ulaz neuronske mreže;
3. Izračunavanje izlaza iz neuronske mreže;

4. Izračunavanje greške u izlaznom sloju;
5. Izračunavanje uticaja grešaka u skrivenim slojevima;
6. Korekcija težina;
7. Uzimanje sledećeg ulaznog vektora iz obučavajućeg skupa i ponavljanje postupka od 2. koraka;
8. Ponavljati korake od 2. do 7., dok se ne iskoriste svi uzorci iz obučavajućeg skupa;
9. Izračunati ukupnu grešku.

Greška predstavlja razliku između predikcije i očekivane vrednosti i propagira se od izlaznog ka skrivenim slojevima prema ulazu.

Ako je izračunata greška manja od maksimalne dozvoljene greške mreža je obučena, u suprotnom na ulaz mreže treba dovesti prvi uzorak iz obučavajućeg skupa i nastaviti od koraka 2 (Kaplar, 2015).

Propagacija greške odvija se od izlaznog ka skrivenim slojevima, zatim prema ulazu, i izračunava se koliko je koji neuron učestvovao u konačnoj grešci.

Postoje varijacije osnovnog tipa algoritma zasnovanih na standardnim numeričkim tehnikama optimizacije, ali najčešće primenu u praksi ima Backpropagation algoritam sa opadajućim gradijentom stope učenja (engl. *gradient descent*). Kod ovog tipa algoritma podešavanje težinskih koeficijenata vrši se u smeru najbržeg opadanja greške, tj. povećanja preciznosti modela, što je opisano sledećom formulom: $x_{k+1} = x_k - \alpha_k g_k$, gde je x_k vektor trenutnih težinskih koeficijenata i korektivnih faktora, g_k trenutni gradijent greške, a α_k stopa učenja (engl. *learning rate*), koja se može menjati tokom procesa obučavanja (Ehret i saradnici, 2015; Šiljić - Tomić, 2018).

Ovaj tip neuronskih mreža sa propagacijom greške unazad (engl. *Back Propagation Neural Network – BPNN*) najčešće se sastoji od 3 ili više slojeva. Pre puštanja BPNN mreže u rad potrebno je podesiti početne težinske koeficijente i stopu učenja. Stopa učenja (engl. *learning rate*) predstavlja promenu težinskih koeficijenata u odnosu na vrednost dobijene greške kao i indeks kojom se odreduje udeo prethodne u novoj vrednosti težinskog koeficijenta.

Momentum član u procesu obučavanja ima ulogu da "priguši" učestale promene težine što doprinosi dostizanju ukupne stabilnosti algoritma (Onkal - Engin i saradnici, 2005).

6.3. Primena veštačkih neuronskih mreža

U početku razvoja modela veštačke inteligencije naučnici su u oblasti računarskih i kognitivnih nauka pokušavali da modeliraju čulni sistem živih organizama. Danas su neuronske mreže veoma atraktivna i izazovna oblast istraživanja, i brojna naučno – istraživačka i praktična polja koriste modele veštačkih neuronskih mreža kao alate u evaluaciji dobijenih rezultata. Primenjuju se u procesu donošenja odluke organa saobraćajne podrške (Dragan, 2010), prepoznavanju rukopisa, modelovanju procesa alkoholne fermentacije (Jokić i saradnici, 2012), prepoznavanje govora (Zuber & Ličen, 2011), finansijsko i ekonomsko modelovanje (Thawornwong i Enke, 2004), za predviđanje kretanja cena na tržištu (Szkuta i Dillon, 1999), psihijatrijske procene (Linstrom i Boye, 2005), u analizi medicinskih testova (Forsström i Dalton, 1995), za ispitivanje EEG i EKG signala (Jiang i saradnici, 2015), u kriminološkim istraživanjima (Stathopoulou i Tsirhrintzis, 2011), za vremensku prognozu (Baboo i Shereef, 2010), u bioračunarskim sistemima (Lancashir i Ball, 2009), za analiziranje podataka pri spektroskopiji (Long & Gemperline, 1990), pronalaženje optimalnog rešenja (Hill i saradnici, 1994), upravljanje robotima (Zhong i N-Nagy, 1996), naftna istraživanja (Ochoa-Estopier i saradnici, 2013), analizi električnih kola (Aggarwal i Song, 1998), u upravljanju proizvodnim procesima, u ekologiji (Zhang, 2010) i raznim drugim oblastima.

Primenu neuronskih mreža je moguće podeliti na tri karakteristične oblasti:

- procesiranje senzorskih informacija,
- analiza podataka i
- kontrola upravljanja.

Primena modela veštačke inteligencije može zameniti mnoge do danas korišćene metode analize, i to sasvim uspešno. Danas se neuronske mreže primenjuju za rešavanje sve većeg broja praktičnih problema koje karakteriše složenost i kompleksnost iznalaženja optimalnih rešenja. Nalaze primenu u oblasti interdisciplinarnih istraživanja inženjerstva i zaštite životne sredine, upravljanja i održivog razvoja, mitigacije mikroplastičnih materijala, monitoringu kvaliteta vazduha, zemljišta i klimatskih promena. U programiranju se mogu koristiti kao "generator" i snaga iniciranja, prepoznavanja i

klasifikacije za generalizaciju prilikom odlučivanja primenom nepotpunih ulaznih podataka.

Neuronske mreže tolerišu nepotpune i neprecizne podatke, a pogodne su za brzu obradu velike količine podataka (Sarkar i Pandey, 2015). Neuronske mreže nude idealno i optimalno rešenje za raznovrsno klasifikovanje problema, kao što je prevođenje teksta u govor, prepoznavanje slova, i uopšte za rešavanje problema za koje ne postoji algoritamsko rešenje. Pokazuju dobre rezultate prilikom predviđanja i modelovanja sistema gde fizički procesi nisu jasni ili su veoma kompleksni.

Prednost neuronskih mreža leži u visokoj elastičnosti prema poremećajima u ulaznim podacima i u sposobnosti da uči. Veštačke neuronske mreže se koriste u gotovo svim oblastima istraživanja, tačnije predviđanja, i to, na primer umesto klasičnih spektrofotometrijskih metoda za determinaciju određenih hemijskih supstanci (Musa i saradnici, 2016), za predikciju produkcije bioetanola iz međuproizvoda prerade šećerne repe (Grahovac i saradnici, 2016), u ekonomiji za predviđanje cene akcija na određeni dan (Mihajlović i saradnici, 2009).

7. MATERIJAL I METODE

7.1. Osnovne karakteristike istraživanog područja

Dunav je, posle Volge, druga najduža i druga vodom najbogatija reka u Evropi, te najduža reka u Evropskoj uniji. Dunav izvire u Schwarzwaldu, u pokrajini Baden – Virtemberg (Baden – Württemberg) spajanjem rečica Breg i Brigah, kod grada Donauešingena, a uliva se u Crno more u Rumuniji. Sliv reke Dunav iznosi 801.463 km² na području 19 zemalja i smatra se najvećim, visoko međunarodnim rečnim basenom na svetu (ICPDR, 2014).

Dunav teče prema istoku, kroz nekoliko glavnih gradova u srednjoj i istočnoj Evropi (Beč, Bratislavu, Budimpeštu i Beograd). Reka Dunav danas protiče kroz, ili čini granicu, deset država, a to su redom od izvora prema ušću: Nemačka (7,5 %), Austrija (10,3 %), Slovačka (5,8 %), Mađarska (11,7 %), Hrvatska (4,5 %), Srbija (10,3 %), Bugarska (5,2 %), Rumunija (28,9 %), Moldavija (1,7 %) i Ukrajina (3,8 %). Dunav iz Baden – Virtemberga, gde prolazi kroz Sigmaringen i Ulm, ulazi preko Bavarske u severnu Austriju (teče kroz Linc i Beč), pa kroz Bratislavu, na jugu Slovačke, prelazi preko Mađarske (kroz Budimpeštu) od severa prema jugu i ulazi u istočnu Hrvatsku (prolazeći pored Vukovara) i severnu Srbiju, kroz Beograd. Dužina Dunava kroz Srbiju iznosi 588 km.

Dunav formira granicu između Srbije i Rumunije, a kasnije između Rumunije i Bugarske, nakon čega se uliva u Crno more, stvarajući veliku deltu na granici s Ukrajinom.

Delta Dunava je visoko diverzitetna, jedna od najvećih močvara na svetu i najveća preostala prirodna močvara u Evropi, sa 30 različitih tipova ekosistema, naseljenih različitim vrstama flore i faune (Šiljić – Tomić, 2018). Deltu Dunava je 1991. godine UNESCO markirao kao svetsku baštinu (Giosan i saradnici, 2005).

Najveće pritoke Dunava i njihove prosečne vrednosti brzine protoka su: Iller sa 70 m³/s, Lehsa 200 m³/s, Nab sa 49 m³/s, Altmil sa 17 m³/s, Izar sa 174 m³/s, In sa 163 m³/s, Traun sa 150 m³/s, Ens sa 195 m³/s, Morava sa 108 m³/s, Raba sa 63 m³/s, Vah sa 152 m³/s, Hron sa 55 m³/s, Ipelj sa 22 m³/s, Šio, iz Balatona, Drava sa 577 m³/s, Tisa sa 794 m³/s, Sava sa 47 m³/s, Velika Morava sa 232 m³/s, Timok sa 31 m³/s, Žiu sa 86 m³/s, Isnar sa 54 m³/s, Olt sa 174 m³/s, Jantra sa 47 m³/s, Arđeš sa 73 m³/s, Jalomice sa 45 m³/s, Siret sa 240 m³/s, Prut sa 110 m³/s.

Dunav sa pritokama ima izuzetan ekonomski, društveni, industrijski, kulturni i socijalni, zdravstveni i prosperitetni značaj jer predstavlja važan resurs reni bunara u snabdevanju i proizvodnji pijaće vode; u poljoprivredi, industriji, ribarstvu, turizmu i rekreaciji, energetici, rečnom transportu. No, ekološki negativan i visoko kontaminirajući aspekt je što se ujedno koristi i kao recipijent sve većih količina zagađenih, neprečišćenih otpadnih voda (Vukov i saradnici, 2008).

Na listi dugačkih reka, Dunav se nalazi na 40. mestu, i jedna je od najbolje istraženih reka na svetu o čijem je kvalitetu objavljen veliki broj naučno–istraživačkih radova (Janauer i saradnici, 2006). Ubraja se medju prvih 10 najugroženijih reka na svetu (Wong i saradnici, 2007). Basen reke Dunav obuhvata 9 ekoregiona (Illies, 1978) i oko 81 miliona ljudi je povezano ovim hidrološkim linkom i kompleksom (Sommenwerk i saradnici, 2010). Republici Srbiji pripada samo 10.2 % Dunavskog sliva, ali je čak 92.3% državne teritorije potpada pod sliv Dunava (Šiljić – Tomić, 2019).

7.3. Internacionalna komisija za zaštitu Dunava

U cilju dobijanja pouzdanih i uporedivih podataka neophodnih za proces modelovanja na bazi hidromorfoloških, hemijskih i bioloških parametara podunavske zemlje organizovale su naučna istraživanja u okviru Internacionalne komisije za zaštitu Dunava (engl. *International Comission for the Protection of the Danube River - ICPDR*) (ICPDR, 2005).

Rad Internacionalne komisije zasnovan je na Konvenciji o zaštiti reke Dunav, najvećem legalnom instrumentu za upravljanje vodama Dunavskog sliva, sa ciljem i zadatkom da obezbedi održivu upotrebu vodnih resursa iz Dunavskog sliva (Todić, 2016).

Konvencija postavlja i definiše principe i pravila za zaštitu i održivo upravljanje rekom Dunav. Ciljevi Konvencije usmereni su ka obezbeđivanju održivog korišćenja i adekvatnog, zakonskog upravljanja vodnim resursima u slivu, uključujući mere za održanje i unapređenje zaštite životne sredine, ekosistema, poboljšanje i racionalnu upotrebu površinskih i podzemnih voda u celokupnom slivu dunavskog basena.

Promovisanjem i koordinacijom održivog i ravnomernog upravljanja vodama, uključujući zaštitu, unapređenje i racionalno korišćenje voda u okviru Dunavskog sliva, ICPDR realizuje ekološku misiju usvajanjem preporuka za poboljšanje kvaliteta voda,

razvojem mehanizama za kontrolu poplava i poplavnih talasa i akcidenata, dogovaranjem standarda u oblasti emisija zagađujućih supstanci i materija, otpadnih rezidualnih polutanata, kao i obezbeđivanjem implementacije preporuka u nacionalnom zakonodavstvu i njegovoj primeni, ali i u kratkoročnim i dugoročnim strategijama razvoja politike održivog upravljanja vodama zemalja dunavskog sliva.

Plan upravljanja za sliv reke Dunav sa Zajedničkim programom mera usvojen je 10. decembra 2009. godine sa ciljem postizanja misije i zadataka Okvirne Direktive o vodama u prvom periodu do 2015. godine (WFD, 2000). Prvi ciklus se nadopunjuje inoviranjem Plana za period do 2021. godine, i kasnije do 2027. godine, kada bi trebalo da svi postavljeni ciljevi budu dostignuti i realizovani. Države članice Međunarodne komisije za zaštitu reke Dunav su decembra 2014. godine u Beču usvojile nacrt noveliranog Plana upravljanja slivom reke Dunav i Nacrt Plana upravljanja rizicima od poplava za period od 2015. - 2021.godine. Plan upravljanja slivom reke Dunav i Plan upravljanja rizicima od poplava imaju za cilj da poboljšaju zaštitu i unaprede status svih voda, kao i da obezbede održivo i dugoročno korišćenje vodnih resursa i održivo upravljanje rizicima od poplava.

Prema poslednjem izveštaju ICPDR-a, koji se odnosi na period do 2021. godine, 69% toka Dunava, što obuhvata 1.976 kilometara toka reke, je klasifikованo kao izuzetno izmenjeno (Šiljić – Tomić, 2019). Poglavlje ažuriranog plana o sprezi sa klimatskim promenama ukazuje na hitno donošenje i usvajanje novih mera koje su neophodne slivu reke Dunav usled očekivanih značajnih negativnih uticaja na kvalitet i kvantitet vodnih resursa (ICPDR, 2012).

7.4. Zajedničko istraživanje reke Dunav

U cilju dobijanja pouzdanih i uporedivih podataka, neophodnih u procesu praćenja efekata donetih odluka, podunavske zemlje u okviru Međunarodne komisije za zaštitu reke Dunav (engl. *International Commission for the protection of the Danube River – ICPDR*) organizovala i naučna istraživanja (<https://www.icpdr.org/main>).

Prvo zajedničko istraživanje Dunava (engl. *Joint Danube Survey 1 - JDS1*) sprovedeno je 2001. godine, drugo istraživanje (engl. *Joint Danube Survey 2 – JDS 2*) realizovano je 2007. godine, a treća naučna ekspedicija ispitivanja reke Dunav (engl. *Joint Danube Survey 3 – JDS3*) sprovedena je 2013. godine. Realizaciju JDS istraživanja

koordinira Sekretarijat ICPDR-a u saradnji sa podunavskim zemljama (Literathy, 2006; Tomović i saradnici, 2014; Kolarević i saradnici, 2016).

Prvo zajedničko istraživanje Dunava, Joint Danube Survey 1, trajalo je od 12. avgusta do 20. septembra 2001. godine. Zadatak ovog istraživanja bilo je dobijanje uporedivih rezultata kvaliteta voda duž čitavog toka reke. Uzorkovanje je izvršeno na 74 lokacije na glavnom toku Dunava, i na 24 lokacije na najvećim pritokama. Akvatične makrofite predstavljale su jedan od aspekata istraživanja (<https://www.icpdr.org/main>).

Šest godina kasnije, 2007. godine, sprovedeno je drugo zajedničko istraživanje Dunava - Joint Danube Survey 2 (JDS2), koje je dugoročno izuzetno važno i još uvek najveće autentično sprovedeno naučno istraživanje jednog rečnog sistema. U odnosu na Joint Danube Survey 1, povećan je broj ispitivanih parametara i broj istraživanih lokaliteta. Makrofite su uzorkovane po Evropskom Standardu EN 14184 – 2003 i modifikovanoj Kohlerovoj metodi (Kohler, 1978; Englomer, 2012). Poslednje u nizu istraživačkih aktivnosti sprovedeno je JDS 3 istraživanje 2013. godine, na deonici dugoj 2375 km. Makrofite su ispitivane duž čitavog toka Dunava, kao i na ušćima nekih pritoka, na ukupno 68 lokaliteta, na isti način kao u okviru Joint Danube Survey 2 istraživanja (Slika 7.).

Podaci prikupljeni tokom Joint Danube Survey 3 istraživanja (biološki i hemijski pokazatelji kvaliteta površinskih voda) po prvi put su korišćeni za potrebe modelovanja ekološkog statusa Dunava, što je opisano u okviru ove teze. Joint Danube Survey 3 ekspedicija imala je za cilj da prikupi informacije o parametrima koji nisu obuhvaćeni tekućim monitoringom, izradi baze setova podataka koje su uporedive, jer su rađeni za ceo tok reke Dunav, i promoviše rad Međunarodne komisije za zaštitu reke Dunav u cilju podizanja znanja, informisanosti i značajnosti upravljanja vodama kod građanstva (www.rdvode.gov.rs/lat/medjunarodna-saradnja-dunav.php).

Uzorkovanje na JDS lokalitetima obuhvatalo je 5 različitih tipova uzoraka, i to: površinske vode i sediment, suspendovane rastvorene čestice, biota i biološki parametri koji se zvanično koriste u proceni ekološkog statusa vodnih ekosistema. Uzorkovanje je sprovedeno sa obe strane obale reke, na udaljenosti od po 6 km između svakog ispitivanog JDS lokaliteta.

U okviru zvaničnih bioloških parametara za procenu ekostatusa vodnog ekosistema korišćene su makrofite i fitobentos. Makrofite su sakupljane ručno ili pomoću grablji, osim

u slučajevima kada je bilo neophodno da se prikupe ronjenjem (Vogel i saradnici, 2004). Vegetacijska baza podataka za sliv reke Dunav kreirana je na osnovu podataka prikupljenih tokom Joint Danube Survey 3 istraživanja (Novković, 2014).

Evropska komisija za zaštitu voda (EC, 2000) svrstava akvatične makrofite u biološke pokazatelje kvaliteta neophodne za postizanje dobrog ekološkog statusa površinskih voda (Janauer i saradnici, 2010).



Slika 7. Lokaliteti na kojima su uzorkovani parametri za procenu ekološkog statusa Dunava tokom JDS 3 istraživanja

7.5. Klase ekološkog statusa Dunava

Ekološki status površinskih voda obuhvata biološke, hidromorfološke i fizičko – hemijske elemente kvaliteta sa posebnim akcentom na specifične polutante. Na osnovu Pravilnika o parametrima ekološkog i hemijskog statusa površinskih voda i parametrima hemijskog i kvantitativnog statusa podzemnih voda (Sl. Glasnik RS, broj 74/2011) ekološki status i ekološki potencijal određuju se na osnovu bioloških, fizičko - hemijskih i hidromorfoloških parametara (Khalil i saradnici, 2010).

Zbog nedostatka jedinstvene klasifikacije u proceni ekološkog statusa reka Dunavskog sliva za potrebe modelovanja klase ekološkog statusa Dunava u okviru teze, kreirana je jedinstvena klasifikacija na osnovu podataka o klasama ekološkog statusa prikupljenih od strane podunavskih zemalja (Europea, C., 2000; Sommerwerk i saradnici, 2010; Who, G., 2011; Novine, N., 1998; Directive, E. U. W., 1991; DIN 38 410, 1990; DIN 38 410, 1990; Gonta, 2014) prikazano u Tabeli 13.

Tabela 13. Klase ekološkog statusa Dunava na osnovu parametara koji se koriste u proceni ekološkog statusa reka prema Okvirnoj Direktivi o vodama

Klase ekološkog statusa	[DO]	[NH ₄ ⁺]	[NO ₃ ⁻]	[NO ₂ ⁻]	[PO ₄ ³⁻]
I	>9	0 – 0.029	0 – 0.019	0 – 0.009	0 – 0.019
II	78.9	0.03 – 0.09	0.02 – 0.9	0.01 – 0.029	0.02 – 0.039
III	5 – 6.9	0.1 – 0.29	1 – 2.9	0.03 – 0.049	0.04 – 0.09
IV	4 – 4.9	0.3 – 0.59	3 – 4.9	0.05 – 0.09	0.1 – 0.19
V	3 – 3.9	0.6 – 1.19	5 – 6.9	0.1 – 0.39	0.2 – 0.49
VI	2 – 2.9	1.2 – 2.4	7 – 10	0.4 – 0.8	0.5 – 0.8
VII	<2	>2.4	>10	>0.8	>0.8

7.6. Opis dataseta korišćenog u procesu modelovanja ekološkog statusa Dunava primenom veštačkih neuronskih mreža

Za potrebe modelovanja ekološkog statusa Dunava, na osnovu podataka sakupljenih tokom Joint Danube Survey 3 (JDS 3) istraživanja kreirana je matrica koja sadrži sve parametre koji se prema Okvirnoj Direktivi o vodama zvanično koriste za procenu ekološkog statusa rečnih ekosistema (WFD, 2000).

U okviru prikupljenih zvaničnih parametara za procenu ekostatusa popisane su koncentracije svih fizičko - hemijskih parametara izmerenih tokom Joint Danube Survey 3 istraživanja, kao i zastupljenost makrofita izražena Kolerovom petostepenom skalom (Kohler, 1978). Matricu čini 69 kolona i 123 reda. Redovi u matrici predstavljaju JDS lokalitete (JDS 1 - JDS 68) na kojima su realizovana merenja, obuhvatajući obe strane rečne obale. U kolonama matrice navedeni su svi parametri koje je Okvirna Direktiva o vodama uvrstila kao zvanične parametre u proceni ekološkog statusa rečnih ekosistema, uključujući biološke, hemijske i hidromorfološke parametre.

Makrofite, kao biološki pokazatelji kvaliteta vodnih ekosistema korišćene su kao ulazne varijable u modelovanju klase ekološkog statusa, dok su klase ekološkog statusa bazirane na odabranim hemijskim parametrima predstavljale izlazne varijable.

Za potrebe modelovanja ekološkog statusa Dunava, definisani su hemijski parametri koncentracija rastvorenog kiseonika, nitratnih i ortofosfatnih anjona kao signifikantni pokazatelji prisustva određenih vrsta makrofita. Zastupljenost makrofita na određenom delu rečnog toka, JDS lokalitetu, prikazana je pomoću Kolerove petostepene skale (Kohler, 1978). Usled nemogućnosti pristupa nekim lokalitetima određeni delovi rečnog toka su izostavljeni u modelovanju. Na lokalitetu JDS 14 merenja su sprovedena samo na desnoj strani obale reke. Lokaliteti JDS 12, JDS 23, JDS 28, JDS 29, JDS 30 i JDS 56 su izostavljeni u merenjima, dok su na lokalitetima JDS 28 i JDS 48 merenja sprovedena samo na levoj strani obale reke (Slika 7.).

Za potrebe modelovanja klase ekološkog statusa izostavljene su invazivne i semiakvatične vrste makrofita, zbog visoke tolerancije na promenu uslova sredine, te time i potencijalnog uticaja na tačnost procene neuronske mreže. U procesu modelovanja klase ekološkog statusa korišćeno je 64 vrste makrofita.

Podaci korišćeni u modelovanju prikupljeni su na ukupno 123 lokaliteta. Prisustvo određenih vrsta makrofita detektovanih na određenom JDS lokalitetu treba da bude pokazatelj one klase ekološkog statusa kojoj dati lokalitet pripada na osnovu izmerenih vrednosti koncentracija rastvorenog kiseonika, nitratnih ili ortofosfatnih anjona. Za potrebe ovog istraživanja na osnovu podataka prikupljenih od strane svih podunavskih zemalja: Nemačke (Arle i saradnici, 2013), Slovačke (Pekarova i saradnici, 2009; Slobodik i saradnici, 2012), Austrije (BGBI, 2006), Bugarske (Sommerwerk i saradnici, 2010), Ukrajine (WHO, 2011), Hrvatske (Vlada Republike Hrvatske, 2019), Srbije (National Assembly of the Republic of Serbia, 2011), Mađarske (Varga i saradnici, 1990; Schiemer i saradnici, 2004; Szilagy i saradnici, 2008), Rumunije (Apele Romane, 2019) i Moldavije (Duca i saradnici, 2014) kreirana je klasifikacija koja obuhvata 7 klase ekološkog statusa (Tabela 14.).

7.6.1. Indeksi trofičnosti vodenih ekosistema

U proceni trofičnosti vodnih ekosistema i zagađenja uzrokovanih organskim materijama koriste se sledeći indeksi: TIM indeks (engl. *Trophic Index of Macrophytes*)

(Schneider, & Melzer, 2003), IBMR index (engl. *Macrophyte Biological Index for Rivers*) (Haury i saradnici, 2006), STR (engl. *Species Trophic Rank*) i MIR indeks (engl. *Macrophyte Index for Rivers*) (Schneider, 2007).

TIM indeks predstavlja relativne vrednosti fosfora koje makrofite usvajaju na određenom delu rečnog toka (Schneider i saradnici, 2000; Schneider & Melzer, 2003). TIM indeks razvijen je u Nemačkoj i zasnovan na vrednostima koncentracija fosfata u vodenom ekosistemu.

TIM indeks se izračunava prema sledećoj formuli:

$$TIM = \frac{\sum_{n=1}^n IVa Wa Qa}{\sum_{n=1}^n Wa Qa}$$

gde IVa predstavlja indikatorsku vrednost vrste, Wa je težinski faktor vrste dok je Qa ukupan broj vrsta na delu rečnog toka.

Kao indikator tačnosti koristi se vrednost brzine rasipanja (SC - engl. *Rate of scatter*) koja se određuje prema sledećoj formuli:

$$SC = \sqrt{\frac{\sum_{n=1}^n (IVa - TIM)^2 Wa Qa}{(n - 1) \sum_{n=1}^n Wa Qa}}$$

U navedenoj formuli n pokazuje ukupan broj indikatorskih vrsta makrofita koje se javljaju u odgovarajućem delu rečnog toka. Vrednost brzine rasipanja mora biti manja ili jednaka 0.2, u protivnom računanje TIM indeksa nije moguće (Schneider & Melzer, 2003).

IBMR indeks razvijen je u Francuskoj u cilju definisanja stepena trofičnosti i organskog zagađenja vodnih ekosistema. Vrednosti IBMR indeksa zasnovane su na stepenu zastupljenosti makrofita (Haury i saradnici, 2006). Poređenjem različitih ekoregionala utvrđeno je da u zavisnosti od pH vodnog sistema, kiselosti/alkalnosti vodnog ekosistema, različite vrste ili zajednice makrofita mogu reagovati na različite koncentracije azota i fosfora (Robach i saradnici, 1996).

Dva kriterijuma se uzimaju u obzir za svaku pojedinačnu vrstu makrofita, a to su Csi i Ei koeficijenti. Vrednosti Csi (engl. Scores) variraju od 0 (visok stepen organskog zagađenja) do 20 za oligotrofna područja i determinišu kvalitet vodnog ekosistema na

osnovu vrednosti koncentracija anjona ortofosfata i amonijum katjona. Vrednosti Ei koeficijenta (engl. *coefficient of ecological amplitude*) opisuju opseg zastupljenosti vrsta preko 4 klase trofičnosti staništa (oligotrofno, mezotrofno, eutrofno i hipertrofno). Vrednost koeficijenta 1 označava široku amplitudu koja pokriva 3 klase trofičnosti, dok vrednost koeficijenta 3 predstavlja amplitudu ograničenu na samo jednu klasu trofičnosti.

Procentualna zastupljenost se pocenjuje za sve vrste makrofita i klasificuje se na osnovu skale zastupljenosti Ki koja se kreće od 1 do 5 što omogućava zastupljenost vrednosti K_i u formuli za izračunavanje IBMR indeksa (Haury i saradnici, 2006).

IBMR indeks se računa prema sledećoj formuli:

$$IBMR = \frac{\sum Ei \cdot Ki \cdot Csi}{\sum Ei \cdot Ki}$$

Poređenjem sa prethodnim Francuskim indeksom (Haury i saradnici, 1996), koeficijenti zastupljenosti makrofita (skorovi) odgovaraju petostepenoj skali trofičkog statusa, od oligotrofnog do hipertrofnog (Tabela 14.).

Tabela 14. Procena trofičkog statusa reka na osnovu vrednosti IBMR indeksa
(Haury i saradnici, 2006)

Vrednosti IBMR indeksa	Trofički status
>14	Veoma dobar
14 > IBMR > 12	Dobar
12 > IBMR > 10	Umeren
10 > IBMR > 8	Loš
8 > IBMR	Veoma loš

MTR (engl. *Mean Trophic Rank*) indeks (Holmes i saradnici, 1999) je razvijen u Velikoj Britaniji u skladu sa odredbama Direktive o tretmanu gradskih, komunalnih otpadnih voda (UWWTD, 91/271/EEC). Vrednosti MTR indeksa zasnovane su na prisustvu i zastupljenosti vodenih makrofita. Makrofite su uključene u proces procene

ekološkog statusa jer se s porastom koncentracija hranljivih materija u vodi menja sastav makrofita. Promene u sastavu zajednica makrofita su lako uočljive, jer su makrofite vidljive golim okom, što je svakako jedna od ključnih pogodnosti primene zastupljenosti makrofita u proceni trofičnosti vodenih ekosistema.

Uzimajući u obzir činjenicu da je većina bioloških indeksa kvaliteta zasnovana na zastupljenosti makroinvertebrata, makrofitama je dodeljen specijski indeks STR (engl. *Species Trophic Rank*) čije se vrednosti kreću od 1-10 u zavisnosti od stepena tolerancije na eutrofizaciju (Holmes, 2010). Vrednosti MTR indeksa se, za razliku od STR indeksa, kreću u rasponu od 10 do 100, pri čemu niže MTR vrednosti korespondiraju sa porastom eutrofikacije. Niže vrednosti MTR indeksa ukazuju na biljke tolerantne na eutrofizaciju ili na to da su vrste kosmopolitske.

Shodno navedenom, MTR indeks se izračunava preko formule:

$$MTR = \frac{\sum CVS}{\sum SCV} \cdot 10$$

SCV (Species Cover Value) – učestalost (abundanca) za indikatorske vrste; CVS - (Cover Value Score) – proizvod SCV i vrednosti STR indeksa za indikatorske vrste.

Vrednosti MTR indeksa veće od 65 ukazuju na staništa koja nisu eutrofna, dok vrednosti ispod 25 odgovaraju izuzetno eutrofnim staništima. U rasponu vrednosti MTR indeksa između 25 i 65 postoji veći ili manji rizik za eutrofikaciju staništa (Holmes i saradnici, 1999).

MIR indeks (engl. *Macrophyte Index for Rivers*) razvijen je 2007. godine u Poljskoj i jedan je od prvih bioloških metoda za procenu ekološkog statusa tekućih voda koja odgovara zahtevima Okvirne Direktive o vodama (Szoszkiewicz i saradnici, 2020). Metod procene ekološkog statusa reka na osnovu vrednosti MIR indeksa zasnovan je na kvalitativnoj i kvantitativnoj evaluaciji vodenih biljaka. U proceni ekološkog statusa reka na osnovu MIR indeksa uključene su sve submerzne, slobodnoplutajuće, amfibijске i emerzne monokotiledone i dikotiledone biljne vrste, kao i filamentozne alge, mahovine i biljke koje više od 85% godine žive kao submerzne vrste. MIR indeks se računa prema sledećoj formuli:

$$MIR = \sum_{i=1}^N \frac{I_i \cdot W_i \cdot P_i}{W_i \cdot P_i}$$

gde je N broj vrsta makrofita na mestu uzorkovanja, I_i je indikatorska vrednost za i -ti takson, Wi je težinski faktor za i-ti takson, a p_i predstavlja pokrovnu vrednost i-tog taksona na osnovu devetostepene skale (Holmes i saradnici, 1999).

Vrednost MIR indeksa zavisi od prisustva vrsta u reci i njihovih indikatorskih vrednosti. Metod procene ekološkog statusa na osnovu MIR indeksa zasnovan je na 153 vrste, od kojih su: 106 vaskularne biljke (uključujući 55 monokotiledonih, 48 dikotiledonih, i 3 pteridofite), 30 vrsta mahovina i 17 vrsta algi. Po dve ekološke vrednosti razvijene su za svaku indikatorsku vrstu ponaosob. Prva vrednost (I), varira od 1 do 10 i pokazuje prosečnu vrednost trofičke degradacije reke. Drugi parametar je težinski faktor (w), čija vrednost varira od 1 do 3 i pokazuje stepen tolerancije na uslove životne sredine. Najniže vrednosti ovih parametara ukazuju na najveću tolerantnost biljke.

Vrednosti MIR indeksa ukazuju na ekološki status reke, pokazuju stepen degradacije reka, posebno stepen eutrofizacije, i kreću se u opsegu od 10, za najviše degradirane rečne tokove, do 100, za najkvalitetnije. Topologija reka zasnovana na kvalitativnoj i kvantitativnoj evaluaciji makrofita, to jest vrednostima MIR indeksa, preporučena je u radu Jusik i saradnici, 2015.

7.7. Definisanje modela veštačke neuronske mreže za predviđanje klase ekološkog statusa Dunava na osnovu prisustva makrofita

Na osnovu koncentracija rastvorenog kiseonika, nitratnih i ortofosfatnih anjona, izvedena je sedmostepena klasifikacija ekološkog statusa (Tabela 14).

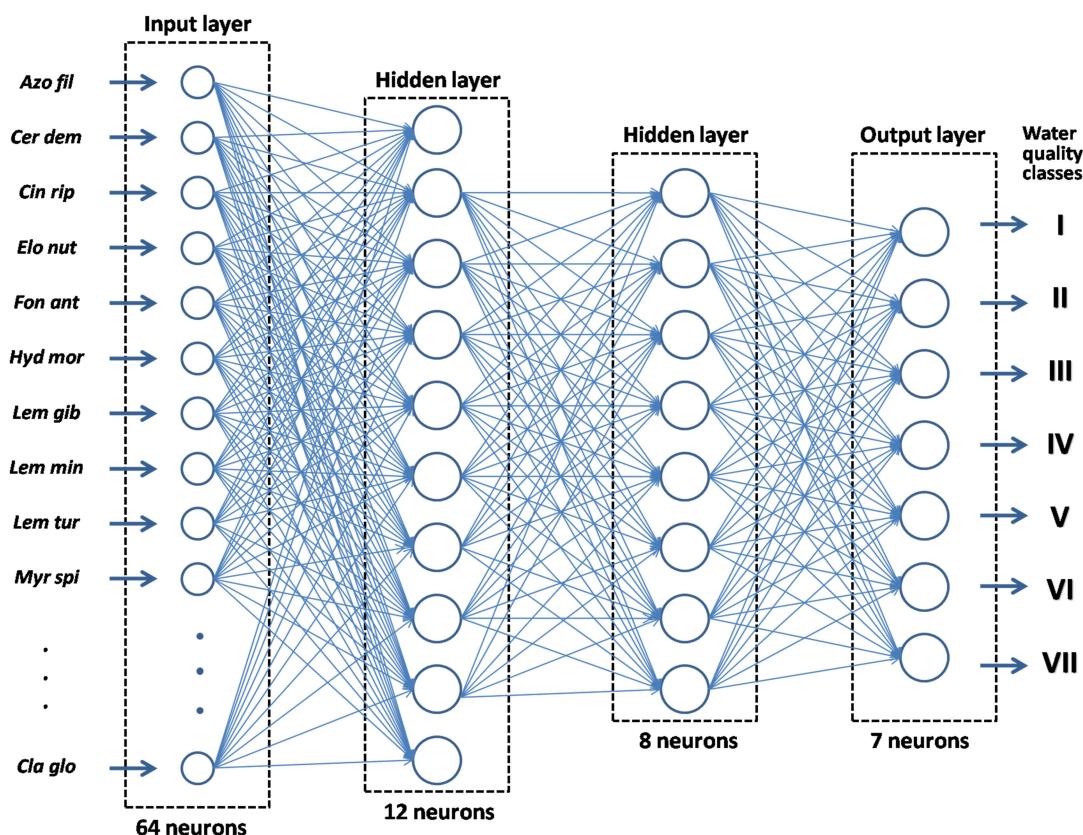
U cilju procene klase ekološkog statusa Dunava na osnovu sastava makrofita i koncentracija odabralih hemijskih parametara kreirana je veštačka neuronska mreža sa propagacijom signala unapred (engl. *Feed forward*).

Za obučavanje neuronske mreže korišćen je algoritam tipa Back propagation (BP). Makrofite, čije je prisustvo prikazano Kohler-ovom petostepenom skalom (Kohler, 1978), predstavljale su ulazne varijable u modelovanju, dok su izlazne varijable predstavljale klase ekološkog statusa izvedene na osnovu vrednosti odabralih hemijskih parametara.

Primenjeni modeli veštačkih neuronskih mreža sastojali su se od 4 sloja. Ulazni sloj činilo je 64 neurona, što je analogno broju vrsta makrofita koje su korišćene u procesu

modelovanja. U dva skrivena sloja bilo je 12 u jednom, odnosno 8 neurona u drugom skrivenom sloju, dok se izlazni sloj sastojao od 7 neurona, što odgovara broju klasa ekološkog statusa (Slika 8.). U radu Sheela & Deepa (2013) preporučeni su metodi odabira optimalnog broja neurona u skrivenim slojevima. Broj neurona u skrivenim slojevima uslovjen je brojem ulaznih i izlaznih varijabli, arhitekturom neuronske mreže, aktivacionim funkcijama i algoritmima. Odabir broja skrivenih slojeva i broja neurona u skrivenim slojevima korišćenih u ovom modelu neuronske mreže opisan je u radu Keene i saradnici (1999).

Propagacija signala, s obzirom na odabranu arhitekturu neuronske mreže, odvija se od ulaznog, preko skrivenih do izlaznog sloja. Za potrebe modelovanja kreirane su 3 neuronske mreže, po jedna za svaki od korišćenih hemijskih parametara, sve sa istom arhitekturom. Za sva 3 odabrana hemijska parametra, (koncentracije rastvorenog kiseonika, nitratnih i ortofosfatnih anjona), kreirana je neuronska mreža jednake arhitekture (Slika 8.).



Slika 8. Šematski prikaz arhitekture veštačke neuronske mreže primenjene u modelovanju klasa ekološkog statusa Dunava

*Input layer – ulazni sloj; Hidden layer – skriveni sloj; Output layer – izlazni sloj; Water quality classes – klase ekološkog statusa vodnog tela

Odabrani model neuronske mreže je model duboke neuronske mreže (engl. *Deep learning - DL*) model mašinskog učenja, sa ReLu (engl. *Rectified Linear Unit*) aktivacionom funkcijom (Slika 5.), baziran na učenju reprezentacije podataka (Nielsen, 2015).

Za duboke neuronske mreže karakteristično je prisustvo nekoliko skrivenih slojeva (Relić, 2019). Duboke neuronske mreže sastoje se od slojeva neurona koje konstruišu nove reprezentacije ulaza, a na izlazu predviđaju ciljnu promenljivu. Svaki sloj neuronske mreže sadrži određeni broj neurona koji pomoću težina transformišu ulazne podatke i određuju izlaz. Duboko učenje odnosi se na broj slojeva kroz koje ulazni podaci prolaze i transformišu se. Svaki nivo učenja kod ovog tipa neuronskih mreža uči da transformiše ulazne podatke u složeniju i apstraktniju reprezentaciju.

Pogodan izbor aktivacione funkcije u značajnoj meri može poboljšati performanse veštačke neuronske mreže koja se primenjuje u modelovanju (Dabović i Tartalja, 2017). U procesu modelovanja ekološkog statusa Dunava primjenjenog u okviru ove teze korišćene su ReLu (Agarap, 2018) i Binary Cross Entropy aktivacione funkcije (Saxe & Berlin, 2015).

Dubina, odnosno broj slojeva u arhitekturi neuronske mreže ima značajnu ulogu za ReLu aktivacionu funkciju (Schmidt-Hieber, 2020).

ReLu aktivaciona funkcija je klasifikaciona funkcija dubokih neuronskih mreža (Agarap, 2018). Prednost korišćenja ReLu aktivacione funkcije ispoljava se u tome što za razliku od ostalih funkcija nema deo sa zasićenjem aktivacione funkcije.

Aktivacija neurona m, koja se označava kao a_m , objašnjava se sledećom jednačinom:

$$a_m = \sum_{n=1}^L w_{mi} x_i + b_m$$

gde je b_m korektivni faktor koji dozvoljava pozitivnu aktivaciju a_m kada je x_i jednak nuli. L je broj ulaznih promenljivih predstavljenih neuronskoj mreži. Numerička izlazna vrednost signala neurona m, koja se naziva i odgovor neurona, a obeležava kao s_m , zasniva se na težinskom zbiru svih ulaznih promenljivih i rezultata proračuna funkcije aktivacije $f(a_m)$.

Proces utvrđivanja nepoznatih koeficijenata w_{mi} i b_m neophodnih za aproksimaciju propisane funkcije zapravo predstavlja proces obučavanja, a skup ulaznih podataka – skup podataka za obuku (Šiljić-Tomić, 2018).

Za validaciju odabranog modela neuronske mreže primenjena je unakrsna validacija (engl. *Cross validation*), Leave – one out metod. Leave – one out metod se koristio prvenstveno zbog nedovoljno obimnog seta podataka za potrebe modelovanja modelima veštačke inteligencije (Park i saradnici, 2015). Modelovanje je obuhvatalo 123 iteracije. Po jedna iteracija realizovana je za svaki primer, odnosno za svaki JDS lokalitet na kom su odabrani parametri uzorkovani.

Skup podataka za treniranje neuronske mreže podeljen je u podskupove za obučavanje i validaciju. Obučavajući skup sadrži sve parametre osim jednog koji se koristi za validaciju, što je odlika Leave - one out metoda validacije. Skup podataka za validaciju čini samo jedan parametar, onaj koji je izostavljen u procesu obučavanja.

Zou i saradnici (2019) u svom radu bavili su se proučavanjem problematike obučavanja potpuno povezanih dubokih neuronskih mreža sa ReLu i Binary Cross Entropy aktivacionim funkcijama primenom gradijentnog spusta (engl. *gradient descent*). Gradijentni spust se primenjuje u cilju ubrzavanja obučavanja neuronske mreže (www.neuralnetworksanddeeplearning.com/chap1.html).

Za optimizaciju funkcije korišćen je Adam optimizator (Kingma i Ba, 2014), koji je i najčešće primenjivan optimizator kod dubokih neuronskih mreža. Klasa ekološkog statusa određivana je na osnovu toga koji je neuron „najviše pobuđen” u izlaznom sloju. Shodno tome u istraživačkim aktivnostima Teze se za procenu tačnosti predikcije odabranog modela neuronske mreže nije mogla primeniti srednja kvadratna greška. S obzirom na to da je neuronska mreža u modelovanju procenjivala jednu od 7 mogućih klasa ekološkog statusa, pogrešna procena neuronske mreže za jednu klasu, više ili niže od realne, ne može se smatrati istim procentom greške kao da je pogrešila za 2 ili više klasa ekološkog statusa. Stopa predikcije (*Pr*) neuronske mreže određuje se obično kao količnik broja primera za koje je neuronska mreža tačno odredila klasu ekološkog statusa i ukupog broja primera, pomnoženo sa 100%.

$$Pr = \frac{Np}{N} \cdot 100\%$$

Pr (engl. *prediction rate*) u ovoj formuli predstavlja stopu predikcije neuronske mreže, Np broj primera za koje je neuronska mreža tačno procenila klasu ekološkog statusa, a N je ukupan broj primera korišćen u procesu modelovanja.

Stopa predikcije neuronske mreže pokazuje uspešnost modela u proceni odgovarajuće klase ekološkog statusa. Što je veći procenat "poklapanja" očekivane klase ekološkog statusa dobijene na osnovu vrednosti hemijskih parametara i onih klasa koje je mreža odredila, veća je i stopa tačnosti predikcije odabranog modela veštačke neuronske mreže. Najveća greška u proceni klase ekološkog statusa može biti da mreža pogrešno odredi I klasu umesto VII klase, i obrnuto, to jest da pogreši u proceni za 6 klase. Uzimajući u obzir opseg potencijalne greške procene veštačke neuronske mreže za potrebe procene procenta greške na osnovu distance između prediktovane i stvarne vrednosti klase ekološkog statusa primenjena je sledeća formula:

$$Pa = \frac{\sum_{i=1}^N |t_i^e - t_i^p|}{6N} \cdot 100\%$$

gde Pa predstavlja procenat absolutne greške, t_i^p je klasa ekološkog statusa koju je mreža odredila, a t_i^e je očekivana klasa ekološkog statusa na osnovu kreirane klasifikacije od 7 klasa ekološkog statusa. Što je vrednost procenta absolutne greške (Pa) manja to je veća tačnost procene modela.

Za određivanje stepena podudarnosti između izmerenih i vrednosti klasa ekološkog statusa koje je neuronska mreža odredila primenjen je Kappa indeks (Cohen, 1960). Landis i Koch (1977) u naučnom radu opisuju da vrednosti Kappa indeksa iznad 0.75 ukazuju na savršenu podudarnost između izmerenih i prediktovanih klasa ekološkog statusa. Vrednosti Kappa indeksa između 0.40 i 0.75 predstavljaju vrednosti od slabe do dobre podudarnosti između izmerenih i prediktovanih klasa ekološkog statusa, dok vrednosti Kappa indeksa ispod 0.40 ukazuju na slabu podudarnost te dve vrednosti (Cook, 2005).

7.8. Određivanje signifikantnih vrsta makrofita primenom analize osetljivosti

Najčešće korišćen model veštačke neuronske mreže u modelovanjima u oblasti ekologije je višeslojni perceptron (engl. *Multilayer perceptron –MLP*). U najvećem broju objavljenih radova na temu modelovanja ekološkog statusa metode koje se koriste za analizu parametara uključenih u proces modelovanja su analiza osetljivosti (engl. *Sensitivity analysis*) i Pruning metoda analize podataka (Pastor-Barcenas i saradnici, 2004).

U cilju procene signifikantnosti odabralih vrsta makrofita u modelovanju primenjena je metoda analize osetljivosti (Saltelli i saradnici, 2008). Primenom analize

osetljivosti određuje se uticaj uzajamne zavisnosti ulaznih/izlaznih varijabli tako što se procenjuje greška obučavanja nakon izostavljanja neke ulazne varijable. U literaturi se ova mera naziva delta greškom (engl. *delta error*) (Kittler i saradnici, 2018).

Cilj primene analize osetljivosti je da odredi sve parametre koji su manje značajni u predikciji ekološkog statusa, odnosno definiše ulazne varijable (makrofite) koje nisu signifikantne u proceni klase ekološkog statusa reke Dunav. Izbacivanjem signifikantih ulaznih varijabli raste procenat greške procene neuronske mreže. Na ovaj način redukuje se broj ulaznih podataka čime se preciznije određuje koje vrste makrofita su signifikantni ulazni parametri u budućim modelovanjima.

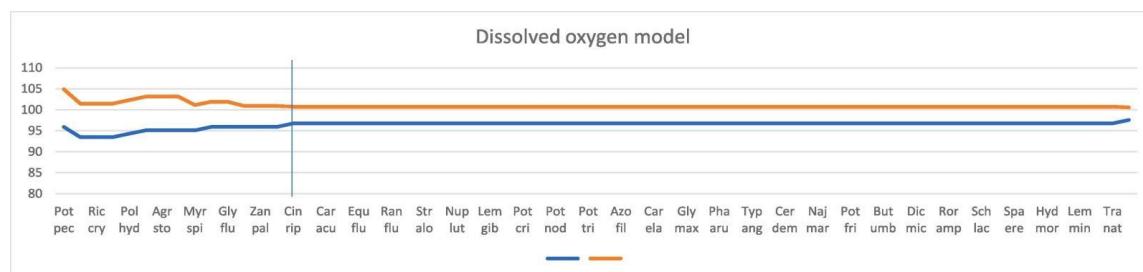
Analizom osetljivosti se određuje uticaj svake pojedinačne vrste makrofita na rezultat modelovanja. Postupak primene analize osetljivosti zasniva se na kreiranju modela veštačkih neuronskih mreža ekvivalentnog modelima primjenjenim za određivanje klase ekološkog statusa tako što se u slučaju primene analize osetljivosti izostavlja po jedna vrsta makrofita, kao ulaznog parametra, u odnosu na originalnu verziju modela. Vrste čije izostavljanje prouzrokuje najveću grešku u tačnosti procene modela smatra se ključnom indikatorskom vrstom (KIV) za određeni parametar.

Opadanje vrednosti tačnosti procene (*Pr*) i rast vrednosti procenta absolutne greške (*Pa*) ukazuje na vrstu koja je najznačajnija za određeni model neuronske mreže. Na osnovu ovih podataka kreirana je lista ključnih indikatorskih vrsta za sva tri parametra korišćena u modelovanju. Za ključne indikatorske vrste makrofita vrednosti tačnosti procene (*Pr*) opadale su najmanje za 1.5% za sva tri hemijska parametra. Vrednost procenta absolutne greške (*Pa*) za ključne indikatorske vrste je veća za 1.45% za model baziran na koncentracijama ortofosfatnih anjona, i 0.66% za modele bazirane na koncentracijama rastvorenog kiseonika i nitratnih anjona.

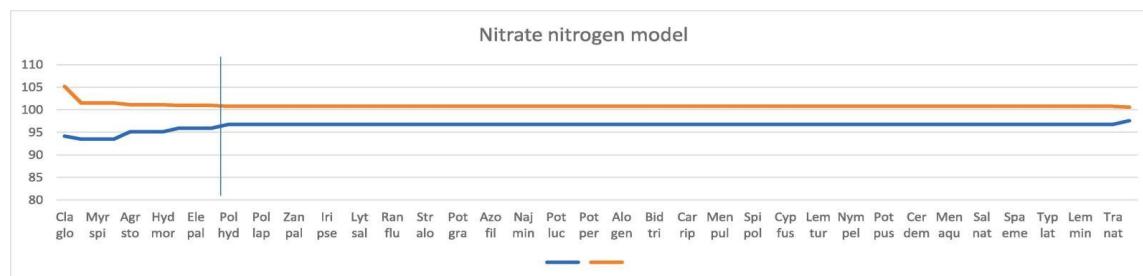
Analiza osetljivosti primenjena u ovoj tezi determinisala je da su 28 od 64 vrste makrofita signifikantne u proceni kvaliteta rečnog ekosistema (Slike 6., 7. i 8). Rezultati analize osetljivosti i vrednosti indeksa trofičnosti prikazani su u tabeli koja se nalazi u Prilogu 1. Doprinos pojedinačnih vrsta makrofita modelu neuronskih mreža baziranom na koncentracijama rastvorenog kiseonika prikazan je grafički na Slici 9., odnosno na Slici 10 za model baziran na koncentracijama nitratnih anjona, i na Slici 11. za model baziran na

konzentracijama ortofosfatnih anjona. Vertikalno na grafiku prikazane su vrednosti Pr i Pa . Akronimi makrofita prikazani su na horizontalnoj osi.

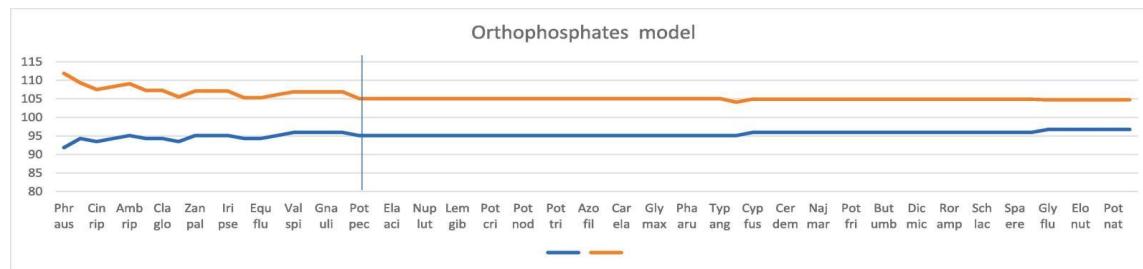
Za modele neuronskih mreža bazirane na koncentracijama rastvorenog kiseonika, odnosno nitratnih anjona, ključnim indikatorskim vrstama smatraju se one vrste koje su pokazale opadanje vrednosti tačnosti procene (Pr) za najmanje 1.50% i najmanje 0.66% rast vrednosti procenta absolutne greške (Pa). Vertikalno na grafiku prikazane su vrednosti Pr i Pa . Akronimi makrofita prikazani su na horizontalnoj osi



Slika 9. Doprinos pojedinačnih vrsta makrofita modelu neuronskih mreža baziranom na koncentracijama rastvorenog kiseonika



Slika 10. Doprinos pojedinačnih vrsta makrofita modelu neuronskih mreža baziranom na koncentracijama nitratnih anjona



Slika 11. Doprinos pojedinačnih vrsta makrofita modelu neuronskih mreža baziranom na koncentracijama ortofosfatnih anjona

Za model baziran na koncentracijama ortofosfatnih anjona ključnim indikatorskim vrstama smatraju se vrste makrofita koje su pokazale opadanje vrednosti tačnosti procene (Pr) za najmanje 1.50% i najmanje 1.45% rast vrednosti procenta apsolutne greške (Pa).

7.9. Analiza rezultata modelovanja primenom Mann-Whitney testa

Mann-Whitney test je neparametarski test za 2 nezavisna uzorka, te je stoga i našao primenu u analizi rezultata modelovanja ekološkog statusa površinske vode u kom su ulazne varijable biološki, a izlazne varijable hemijski parametri koji se zvanično koriste za procenu kvaliteta voda. Cilj primene Mann-Whitney testa je određivanje verovatnoće da dva uzorka, odnosno grupe podataka, pripadaju statistički istoj populaciji.

Mann-Whitney test nalazi primenu kada se nezavisna promenljiva sastoji od 2 kategorički nezavisne grupe i kada je nepoznata raspodela obeležja. U procesu modelovanja klasa ekološkog statusa, primjenjenog u okviru ove doktorske disertacije, Mann-Whitney test koristio se za poređenje trofičnosti odabranih indikatorskih vrsta makrofita i onih vrsta makrofita koje je model odredio kao nesignifikantne. Tako su upoređene vrste koje je analiza osetljivosti odredila kao indikatore prisustva rastvorenog kiseonika, anjona nitrata i ortofosfata u vodi i neindikatorskih vrsta za sva tri navedena parametra. Analizirane su Ellenberg – ove indikatorske vrednosti, IBMR, MIR, MTR/STR i TIM indeksi trofičnosti.

Sve indikatorske vrste makrofita koje su pokazale osetljivost na bar jedan od odabranih parametara imale su značajno više vrednosti MIR indeksa u poređenju sa neindikatorskim vrstama.

Četiri vrste makrofita, *Amblystegium riparium L.*, *Agrostis stolonifera L.*, *Phragmites communis L.* i *Myriophyllum spicatum L.*, pokazale su se kao indikatorske vrste za sva 3 primenjena hemijska parametra.

8. REZULTATI I DISKUSIJA

Modelovanje ekološkog statusa Dunava realizovano je primenom modela veštačkih neuronskih mreža. Parametri korišćeni za modelovanje su makrofite i klase ekološkog statusa Dunava izračunate na osnovu koncentracija rastvorenog kiseonika, nitratnih i ortofosfatnih anjona. Hemijski i biološki parametri određivani su u uzorcima prikupljenim na istim lokalitetima, u isto vreme, i pripadaju setu podataka prikupljenih u okviru Joint Danube Survey 3 (JDS 3) istraživanja.

Makrofite su predstavljale ulazne varijable, dok su klase ekološkog statusa izlazne varijable u procesu modelovanja klase ekološkog statusa.

Rezultati modelovanja interpretirani su na osnovu matrice grešaka (engl. *Confusion Matrix, CM*) (Tabele 16., 23. i 31.) u kojima je prikazano na koliko lokaliteta je neuronska mreža tačno, odnosno netačno, odredila klasu ekološkog statusa. Na osnovu rezultata modelovanja predstavljenih u *CM* računao se procenat tačnosti procene применjenog modela veštačke neuronske mreže. Za tumačenje rezultata korišćena je formula za izračunavanje vrednosti Pa , izvedena za potrebe analiziranja применjenog modela veštačke inteligencije. Što je veće odstupanje rezultata od glavne dijagonale u *CM*-u, prepoznavanje klase ekološkog statusa pomoću odabranog modela neuronske mreže je lošije.

Kolone u matrici su klase ekološkog statusa kojoj određeni lokalitet pripada na osnovu izmerenih vrednosti hemijskog parametra korišćenog u modelovanju.

U vrstama matrice predstavljene su one klase ekološkog statusa koje je neuronska mreža odredila modelovanjem podataka. Dijagonalno u matrici prikazan je broj lokaliteta na kojima je neuronska mreža tačno odredila klasu ekološkog statusa, što je ključan podatak u proceni tačnosti predikcije neuronske mreže. Što su manja odstupanja rezultata modelovanja od glavne dijagonale u matrici veća je tačnost procene neuronske mreže (Pr).

Za sve parametre korišćene u modelovanju klasa ekološkog statusa kreiran je jedinstven model neuronske mreže, te je stoga i tumačenje rezultata realizovano na osnovu podataka iz tri *CM*. Ukupno 3 modela veštačkih neuronskih mreža su generisana, obučena, testirana i proverena analizom osetljivosti.

Najbolji procentualni nivo tačnosti predikcije imao je model primjenjen za modelovanje klase ekološkog statusa baziran na koncentracijama rastvorenog kiseonika (82.93%), gde je procenat apsolutne greške iznosio 3.04%. Vrednost Kappa indeksa,

$Ka = 0.61$, za ovaj model indikovao je dobru podudarnost između izmerenih i prediktovanih vrednosti klase ekološkog statusa.

Tačnost procene modela kreiranog na osnovu koncentracija nitratnih anjona iznosi 74.80%, dok je za model baziran na koncentracijama ortofosfatnih anjona 71.55%. Procenat apsolutne greške za model baziran na koncentracijama nitratnih anjona je 5.42%, a Kappa indeks 0.64, dok je vrednost procenta apsolutne greške modela baziranog na koncentracijama ortofosfatnih anjona 8.99%, a Kappa indeks 0.17.

Na osnovu seta podataka prikupljenih tokom Joint Danube Survey 3 istraživanja klase ekološkog statusa Dunava baziranih na izmerenim koncentracijama rastvorenog kiseonika kreću se od I-IV klase, na bazi koncentracija nitratnih anjona od IV-VII klase, a prema vrednostima koncentracija ortofosfatnih anjona procenjene su IV ili V klasa ekološkog statusa.

Kod modelovanja fundiranog na koncentracijama rastvorenog kiseonika neuronska mreža je najčešće grešila u proceni za jednu klasu ekološkog statusa, procenjivala je lošiju klasu ekološkog statusa od realne. Izuzetke su predstavljali lokaliteti koji se nalaze na ušćima pritoka. Na tim lokalitetima model je prediktovao nižu, bolju klasu ekološkog statusa od one klase kojoj određeni lokalitet pripada. Prediktovane vrednosti klase ekološkog statusa bazirane na koncentracijama nitratnih anjona gotovo da su jednakodistupale od očekivanih vrednosti.

Model baziran na koncentracijama ortofosfatnih anjona prediktovao je nižu klasu ekološkog statusa na 24 primera, dok je na 16 primera procenjena viša klasa ekološkog statusa od realne.

Greške u proceni klase ekološkog statusa zasnovane na koncentracijama nitratnih i ortofosfatnih anjona ne pokazuju prostornu zavisnost, već su zastupljene duž čitavog toka Dunava.

Najviša odstupanja između izmerenih i prediktovanih vrednosti klase ekološkog statusa za sva 3 hemijska parametra dobijena su za lokalitete koji se nalaze na ušćima

pritoka Dunava, rekama Tisi i Ardeš. Na ovim lokalitetima model je uglavnom procenio nižu (bolju) klasu ekološkog statusa u odnosu na klasu ekološkog statusa kojoj određeni lokalitet pripada na osnovu koncentracije odabranog hemijskog parametra.

8.1. Rezultati modelovanja klase ekološkog statusa Dunava na osnovu prisustva makrofita i koncentracije rastvorenog kiseonika

Analizom Confusion matrice (Tabela 15.) koja je kreirana na osnovu podataka dobijenih modelovanjem klasa ekološkog statusa dobijenih na osnovu vrednosti koncentracija rastvorenog kiseonika neuronska mreža je u najvećem broju primera tačno odredila II klasu ekološkog statusa (84 primera), dok je na svega 6 lokaliteta mreža pogrešila u predikciji II klase ekološkog statusa.

Tabela 15. Confusion matrica (*CM*) za klase ekološkog statusa koje je neuronska mreža odredila na osnovu izmerenih koncentracija rastvorenog kiseonika

[DO]	I	II	III	IV	V	VI	VII
I	4	2	0	0	0	0	0
II	6	84	6	1	0	0	0
III	0	5	14	0	0	0	0
IV	0	0	0	1	0	0	0
V	0	0	0	0	0	0	0
VI	0	0	0	0	0	0	0
VII	0	0	0	0	0	0	0

Na 6 lokaliteta mreža je umesto I klase odredila II klasu ekološkog statusa, na 5 lokaliteta je umesto III klase ekološkog statusa odredila II klasu, dok je na samo jednom lokalitetu umesto IV klase ekološkog statusa odredila II klasu ekološkog statusa. Najveće odstupanje u proceni klase ekološkog statusa na osnovu izmerenih koncentracija rastvorenog kiseonika je upravo na lokalitetu na kom je neuronska mreža umesto IV klase ekološkog statusa odredila II klasu. Na sva 84 lokaliteta na kojima je mreža tačno odredila II klasu ekološkog statusa detektovana je vrsta *Phragmites australis L.* koju je analiza osetljivosti izdvojila kao jednu od 4 signifikantne vrste makrofita u proceni klase ekološkog statusa na osnovu koncentracija rastvorenog kiseonika. Jedini lokalitet na kom

je neuronska mreža tačno odredila IV klasu ekološkog statusa je lokalitet JDS 41, leva obala reke. Popis makrofita na tom lokalitetu je sledeći: *Cladophora glomerata L.*, *Phalaris arundinacea L.*, *Phragmites australis L.*, *Polygonum lapatifolium L.*, *Iris pseudacorus L.*, *Lythrum salicarium L.*, *Glyceria maxima L.*, *Dichostylis micheliana (L.) Nees*, *Bidens frondosa L.* i *Ceratophyllum demersum L.*

Na desnoj obali reke (D) na lokalitetu JDS 41 neuronska mreža je umesto IV klase ekološkog statusa prepoznaла II klasu ekološkog statusa. Na istom lokalitetu na suprotnoj strani obale reke neuronska mreža je tačno odredila IV klasu ekološkog statusa. Na lokalitetu JDS 41, leva obala reke – (L), na kom je IV klasa ekološkog statusa tačno procenjena, izostaju vrste makrofita *Iris pseudacorus L.* i *Glyceria maxima L.* Ovakav rezultat modelovanja ukazuje na to da mreža na osnovu iskustva prisustvo vrsta *Glyceria maxima L.* i *Iris pseudacorus L.* vezuje za bolju klasu ekološkog statusa od IV klase ekološkog statusa, te se prisustvo tih vrsta makrofita može smatrati indikatorima II klase ekološkog statusa. Na desnoj obali (D) reke na lokalitetima JDS 8, JDS 9, JDS 10 i JDS 13 mreža je na osnovu izmerenih vrednosti koncentracija rastvorenog kiseonika tačno odredila I klasu ekološkog statusa. Lokaliteti JDS 8 – JDS 10 pripadaju delu toka Dunava koji protiče kroz Austriju, dok se lokalitet JDS 13 nalazi u Bratislavi.

Na sva 4 navedena lokaliteta detektovane su vrste *Cinclidotus riparius (Host ex Brid.) Arn.* i *Phalaris arundinacea L.* Vrsta *Phalaris arundinacea L.* zastupljena je i na delu rečnog toka koji na osnovu izmerenih koncentracija rastvorenog kiseonika pripada IV klasi ekološkog statusa, te se zbog svoje široke ekološke valence ne može smatrati indikatorskom vrstom za pripadnost određenog dela rečnog toka visokoj klasi ekološkog statusa. Vrsta *Lythrum salicarium L.*, nije uočena na lokalitetu JDS 13, dok je na ostala 3 lokaliteta bila prisutna. Vrsta *Phragmites australis L.* izostala je na lokalitetu JDS 9, dok je na ostala 3 navedena lokaliteta bila prisutna.

Izmerene koncentracije rastvorenog kiseonika na lokalitetima na kojima je mreža tačno odredila I klasu ekološkog statusa kretale su se u opsegu od 9.3 - 10 mg/L. Izmerene koncentracije nitratnih anjona na navednim lokalitetima su od 7 - 7.3 mg/L, što odgovara VI klasi ekološkog statusa, dok su koncentracije ortofosfatnih anjona varirale od 0 - 0.12 mg/L, što pripada opsegu od I do IV klase ekološkog statusa.

Tabela 16. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža tačno odredila I klasu ekološkog statusa na osnovu koncentracija rastvorenog kiseonika

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 8 (D)	9.4 mg/L	7 mg/L	0.1 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis L.;</i> <i>Lythrum salicaria L.</i>
JDS 9 (D)	10 mg/L	7.2 mg/L	0 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Phalaris arundinacea L.</i> <i>Lythrum salicaria L.;</i> <i>Polygonum lapatifolium L.</i>
JDS 10 (D)	9.4 mg/L	7.3 mg/L	0 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis;</i> <i>Lythrum salicaria L.</i>
JDS 13 (D)	9.3 mg/L	7.3 mg/L	0.12 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis L.</i>

Iz navedenih vrednosti izmerenih koncentracija hemijskih parametara može se zaključiti da vrste koje su indikatori I klase ekološkog statusa na osnovu vrednosti rastvorenog kiseonika u vodi tolerišu vrednosti nitratnih anjona koje odgovaraju VI klasi ekološkog statusa, odnosno koncentracije fosfatnih anjona koje odgovaraju IV klasi ekološkog statusa.

Na lokalitetima JDS 8, JDS 9, JDS 10 i JDS 13 na levoj obali reke (L), i JDS 31, na obe strane rečne obale, neuronska mreža je umesto I klase ekološkog statusa odredila II klasu ekološkog statusa (Tabela 17.) Nijedna vrsta makrofita nije zastupljena na svim navedenim lokalitetima. Vrste *Phalaris arundinacea L.* i *Cinclidotus riparius (Host ex Brid.) Arn.* detektovane su na svim navedenim lokalitetima osim na lokalitetu JDS 31. Na lokalitetima na kojima je mreža tačno odredila I klasu ekološkog statusa na osnovu izmerenih koncentracija rastvorenog kiseonika pored vrsta *Phalaris arundinacea L.* i *Cinclidotus riparius (Host ex Brid.) Arn.* detektovana je i vrsta *Phragmites australis L.* Vrsta *Cinclidotus riparius (Host ex Brid.) Arn.* detektovana je isključivo na lokalitetima na kojima je vrednost izmerene koncentracije rastvorenog kiseonika iznad 7.3 mg/L, te se može smatrati indikatorском vrstom za pripadnost najmanje II klasi ekološkog statusa određenog dela obeležja i prirode rečnog toka.

Tabela 17. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto I klase ekološkog statusa odredila II klasu ekološkog statusa na osnovu koncentracija rastvorenog kiseonika

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 8 (L)	9.4 mg/L	7 mg/L	0.1 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Phalaris arundinacea</i> L.; <i>Phragmites australis</i> L.; <i>Lythrum salicaria</i> L.
JDS 9 (L)	10 mg/L	7.2 mg/L	0 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn., <i>Phalaris arundinacea</i> L..
JDS 10 (L)	9.4 mg/L	7.3 mg/L	0 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Phalaris arundinacea</i> L.,
JDS 13 (D)	9.3 mg/L	7.3 mg/L	0.12 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Phalaris arundinacea</i> L.;
JDS 31 (L)	9.3 mg/L	6.2 mg/L	0.14 mg/L	<i>Bidens frondosa</i> L.; <i>Carex acuta</i> L.; <i>Dichostylis micheliana</i> (L.) Nees; <i>Lythrum salicaria</i> L.; <i>Polygonum lapatifolium</i> L.
JDS 31 (D)	9.3 mg/L	6.2 mg/L	0.14 mg/L	<i>Bidens frondosa</i> L.; <i>Carex acuta</i> L.; <i>Dichostylis micheliana</i> (L.) Nees; <i>Lythrum salicaria</i> L.; <i>Polygonum lapatifolium</i> L.; <i>Salvinia natans</i> (L.) All.; <i>Spirodela polyrhiza</i> (L.) Schleid.

U radu Janauer i saradnici (2010) vrsta *Cinclidotus riparius* (Host ex Brid.) Arn. se navodi kao jedna od 3 vrste makrofita čije je prisustvo karakteristično za delove rečnog toka najveće brzine, što potvrđuje i činjenicu da su to ujedno i delovi toka sa visokim sadržajem rastvorenog kiseonika.

Na ukupno 14 lokaliteta neuronska mreža je tačno odredila III klasu ekološkog statusa, i to na levoj obali reke na lokalitetima JDS 35, JDS 38 i JDS 58, na lokalitetima JDS 40, JDS 42, JDS 43 i JDS 46, na obe strane rečne obale, i na desnoj obali reke na lokalitetima JDS 44, JDS 47 i JDS 49 (Prilog 2.). Na svim navedenim lokalitetima na kojima je mreža tačno odredila III klasu ekološkog statusa na osnovu koncentracija rastvorenog kiseonika detektovana je vrsta *Ceratophyllum demersum* L. Vrsta *Lemna gibba*

L. izostala je jedino na lokalitetu JDS 58, na levoj obali reke, dok je vrsta *Lemna minor L.* izostala na lokalitetima JDS 49, na desnoj obali reke i JDS 58, na levoj obali reke. Vrsta *Polygonum lapatifolium L.* izostala je na lokalitetima JDS 40, na desnoj obali reke, kao i na lokalitetu JDS 58, na levoj obali reke. Na lokalitetu JDS 58, koji na osnovu izmerene koncentracije ortofosfatnih anjona pripada VII klasi ekološkog statusa zastupljena je jedino vrsta *Ceratophyllum demersum L.*, što potvrđuje njen kosmopolitski karakter i tolerantnost na povišene koncentracije ortofosfatnih anjona u vodnom ekosistemu. Vrsta *Lemna gibba L.* sreće se na svim lokalitetima koji na osnovu koncentracije rastvorenog kiseonika pripadaju III klasi ekološkog statusa a da na osnovu izmerenih koncentracija ortofosfatnih anjona lokalitet pripada najviše V klasi ekološkog statusa.

Prisustvo vrste *Lemna gibba L.* isključuje osobinu pripadnosti određenog dela rečnog toka VI, odnosno VII klasi ekološkog statusa na osnovu izmerenih koncentracija ortofosfatnih anjona. Vrste *Lemna gibba L.* i *Ceratophyllum demersum L.* izostaju na lokalitetima koji na osnovu koncentracije rastvorenog kiseonika pripadaju I klasi ekološkog statusa. Na svim lokalitetima na kojima je mreža tačno odredila III klasu ekološkog statusa na osnovu izmerenih koncentracija rastvorenog kiseonika odredila je i IV klasu ekološkog statusa na osnovu izmerenih vrednosti koncentracije ortofosfatnih anjona, te se prisustvo vrste *Ceratophyllum demersum L.* može smatrati sigurnim pokazateljem III klase ekološkog statusa na osnovu vrednosti koncentracije rastvorenog kiseonika, kao i IV klase ekološkog statusa na osnovu vrednosti koncentracija ortofosfatnih anjona.

Na lokalitetima JDS 11 i JDS 15, na levoj obali reke, neuronska mreža je umesto II klase ekološkog statusa odredila I klasu ekološkog statusa (Tabela 18). Makrofite koje se zastupljene na oba navedena lokaliteta su: *Cinclidotus riparius (Host ex Brid.) Arn.*, *L.*, *Phalaris arundinacea L.* i *Phragmites australis (Cav.) Trin. ex Steud.* Vrste *Cinclidotus riparius (Host ex Brid.) Arn.* i *Phalaris arundinacea L.* nalaze se na svim lokalitetima koji na osnovu vrednosti koncentracija rastvorenog kiseonika pripadaju I klasi ekološkog statusa. Vrsta *Phragmites australis (Cav.) Trin. ex Steud.* izostaje jedino na lokalitetu JDS 9, na desnoj obali reke, na kom je izmerena koncentracija rastvorenog kiseonika 10 mg/L. Na svim ostalim lokalitetima na kojima je neuronska mreža tačno odredila I klasu ekološkog statusa na osnovu koncentracije rastvorenog kiseonika izmerene vrednosti rastvorenog kiseonika su ispod 10 mg/L, što objašnjava fenomen da neuronska mreža

prisustvo vrste *Phragmites australis* (Cav.) Trin. ex Steud. vezuje za I klasu ekološkog statusa.

Tabela 18. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto II klase ekološkog statusa odredila I klasu ekološkog statusa na osnovu izmerenih vrednosti koncentracije rastvorenog kiseonika

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 11 (L)	8.8 mg/L	7.3 mg/L	0 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Lythrum salicaria</i> L.; <i>Phalaris arundinacea</i> L.; <i>Phragmites australis</i> (Cav.) Trin. ex Steud.
JDS 15 (L)	8.4 mg/L	6.6 mg/L	0.1 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Phalaris arundinacea</i> L.; <i>Phragmites australis</i> (Cav.) Trin. ex Steud.; <i>Polygonum lapatifolium</i> L.

Na lokalitetima JDS 37 i JDS 54, na levoj obali reke, JDS 39, desna obala reke, kao i na lokalitetu JDS 36, na obe strane rečne obale, neuronska mreža je umesto II klase ekološkog statusa prepoznala III klasu ekološkog statusa. Na svim navedenim lokalitetima nalaze se vrste *Ceratophyllum demersum* L., *Bidens frondosa* L. i *Polygonum lapatifolium* L. Vrsta *Ceratophyllum demersum* L. se nalazi na svim lokalitetima na kojima je neuronska mreža tačno odredila III klasu ekološkog statusa na osnovu izmerenih vrednosti koncentracija rastvorenog kiseonika, a toleriše i povišene koncentracije ortofosfatnih anjona koje odgovaraju eutrofnim delovima rečnog toka koji na osnovu koncentracija ortofosfatnih anjona pripadaju VII klasi ekološkog statusa. Na lokalitetima na kojima je neuronska mreža na osnovu koncentracija rastvorenog kiseonika umesto II klase odredila III klasu ekološkog statusa, koncentracije nitratnih anjona variraju od vrednosti koje odgovaraju od III do V klase ekološkog statusa, te se vrsta *Ceratophyllum demersum* L. ne može smatrati indikatorskom vrstom za neku određenu klasu ekološkog statusa procenjivanu na osnovu koncentracije nitratnih anjona (Tabela 19).

Tabela 19. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto II klase prepoznala III klasu ekološkog statusa

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 36 (L)	7 mg/L	6.1 mg/L	0.13 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Hydrocharis morsus-ranae L.;</i> <i>Lemna gibba L.; Lemna minor L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Bidens frondosa L.; Carex acuta L.;</i> <i>Cyperus fuscus L.;</i> <i>Dichostylis micheliana (L.) Nees;</i> <i>Lythrum salicaria L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 36 (D)	7 mg/L	6.1 mg/L	0.13 mg/L	<i>Lemna gibba L.; Lemna minor L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Bidens frondosa L.;</i> <i>Butomus umbellatus L.;</i> <i>Cyperus fuscus L.;</i> <i>Dichostylis micheliana (L.) Nees;</i> <i>Eleocharis palustris (L.) Roem. & Schult.;</i> <i>Lythrum salicaria L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.;</i> <i>Polygonum lapatifolium L.;</i> <i>Typha angustifolia L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 37 (L)	7.6 mg/L	2.7 mg/L	0.15 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Bidens frondosa L.;</i> <i>Dichostylis micheliana (L.) Nees;</i> <i>Lythrum salicaria L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Rorippa amphibia (L.) Besser</i>
JDS 39 (D)	7.3 mg/L	5.5 mg/L	0.14 mg/L	<i>Azolla filiculoides Lam.;</i> <i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Potamogeton pectinatus L.;</i> <i>Potamogeton perfoliatus L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Bidens frondosa L.;</i> <i>Butomus umbellatus L.;</i> <i>Lythrum salicaria L.;</i> <i>Rorippa amphibia (L.) Besser;</i> <i>Typha latifolia L.</i>
JDS 54 (L)	7.3 mg/L	4.2 mg/L	0.22 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Bidens frondosa L.;</i> <i>Butomus umbellatus L.;</i> <i>Polygonum lapatifolium L.</i>

Na levoj obali Dunava za lokalitete JDS 35, JDS 44, JDS 47 i JDS 49, i na desnoj obali reke za lokalitete JDS 38 i JDS 58 neuronska mreža je umesto III klase ekološkog statusa prepoznala II klasu ekološkog statusa. Vrsta makrofita koja je detektovana na svim navedenim lokalitetima je *Ceratophyllum demersum L.* što potvrđuje da je indikator III

klase ekološkog statusa na osnovu koncentracija rastvorenog kiseonika. Prisustvo drugih vrsta makrofita na navedenim lokalitetima dovelo je do greške u proceni klase ekološkog statusa primjenjenim modelom veštačkih neuronskih mreža (Tabela 20.).

Tabela 20. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto III klase ekološkog statusa prepoznala II klasu ekološkog statusa

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 35 (L)	5.2 mg/L	1.4 mg/L	0.25 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Hydrocharis morsus-ranae L.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Zannichellia palustris L.;</i> <i>Glyceria maxima (Hartm.) Holmb.;</i> <i>Polygonum lapatifolium L.</i>
JDS 38 (D)	5.2 mg/L	1.4 mg/L	0.25 mg/L	<i>Hydrocharis morsus-ranae L.;</i> <i>Lemna gibba L.;</i> <i>Lemna gibba L.;</i> <i>Myriophyllum spicatum L.;</i> <i>Potamogeton gramineus L.;</i> <i>Potamogeton nodosus Poir.;</i> <i>Potamogeton pectinatus L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Bidens frondosa L.;</i> <i>Carex acuta L.;</i> <i>Carex riparia Curtis.;</i> <i>Cyperus fuscus L.;</i> <i>Dichotylis micheliana (L.) Nees;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 44 (L)	6.5 mg/L	5.8 mg/L	0.16 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Lemna turionifera Landolt;</i> <i>Nymphaoides peltata (S.G.Gmel.) Kuntze;</i> <i>Potamogeton natans L.;</i> <i>Potamogeton nodosus Poir.;</i> <i>Potamogeton pectinatus L.;</i> <i>Potamogeton perfoliatus L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Glyceria maxima (Hartm.) Holmb.;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 47 (L)	6.5 mg/L	4.4 mg/L	0.33 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Myriophyllum spicatum L.;</i> <i>Potamogeton crispus L.;</i> <i>Potamogeton lucens L.;</i> <i>Potamogeton pectinatus L.;</i> <i>Potamogeton perfoliatus L.;</i> <i>Vallisneria spiralis L.;</i> <i>Butomus umbellatus L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 58 (D)	6.7 mg/L	6.1 mg/L	1.5 mg/L	<i>Ceratophyllum demersum L.</i>

Analizom svih rezultata modelovanja klasa ekološkog statusa na osnovu izmerenih vrednosti koncentracije rastvorenog kiseonika prikazanih u *CM* (Tabela 15.) neuronska mreža je na ukupno 103 lokaliteta tačno odredila klasu ekološkog statusa (glavna dijagonala), dok je na 19 lokaliteta odstupanje u proceni neuronske mreže za jednu klasu ekološkog statusa. Odstupanje u proceni neuronske mreže za jednu klasu ekološkog statusa, bez obzira na to da li je procenjena viša ili niža klasa ekološkog statusa od realne, znači da je rastojanje između očekivane i dobijene klase ekološkog statusa 1. Na jednom lokalitetu rastojanje između očekivane i modelovanjem dobijene klase ekološkog statusa je 2, što determiniše da je mreža pogrešila u proceni za 2 klase ekološkog statusa. Rastojanje predstavlja apsolutnu vrednost razlike determinisane klase i klase ekološkog statusa koja je očekivana, i kojoj određeni lokalitet pripada na osnovu klasifikacije.

Na osnovu rezultata modelovanja klasa ekološkog statusa prikazanih u *CM* (Tabela 15.) srednja apsolutna greška (*Pa*) modela neuronske mreže baziranog na koncentracijama rastvorenog kiseonika određuje se prema sledećoj formuli:

$$Pa = \frac{103 \cdot 0 + 19 \cdot 1 + 1 \cdot 2}{123 \cdot 7} = \frac{21}{8 \ 6 \ 1} = 0.024$$

Tačnost procene neuronske mreže izračunava se na osnovu razlike maksimalne vrednosti tačnosti procene od 100% i vrednosti srednje apsolutne greške.

Tačnost procene modela neuronske mreže kreiranog na osnovu vrednosti koncentracija rastvorenog kiseonika iznosi :

$$(100 - Pa)\% = (100 - 0.024)\% = 99.976\%.$$

Neuronska mreža je na 103 od ukupno 123 lokaliteta tačno procenila klasu ekološkog statusa, te se stopa predikcije (*Pr*) neuronske mreže u slučaju procene klase ekološkog statusa na osnovu koncentracija rastvorenog kiseonika računa prema sledećoj formuli:

$$Pr = \frac{103}{123} \cdot 100\% = 83.74\%.$$

Stopa predikcije neuronske mreže predstavlja količnik broja lokaliteta na kojima je neuronska mreža tačno odredila klasu ekološkog statusa i ukupnog broja lokaliteta pomnoženo sa 100.

8.2. Rezultati modelovanja klase ekološkog statusa Dunava na osnovu prisustva makrofita i koncentracija nitratnih anjona

Na ukupno 93 lokaliteta neuronska mreža je na osnovu vrednosti koncentracija nitratnih anjona tačno odredila klasu ekološkog statusa, i to na 32 lokaliteta IV klasu ekološkog statusa, na 44 lokaliteta V klasu ekološkog statusa, na 7 lokaliteta VI klasu ekološkog statusa, i na 10 lokaliteta VII klasu ekološkog statusa (glavna dijagonala matrice) Rezultati modelovanja prikazani su u Tabeli 21.

Tabela 21. Confusion matrica (*CM*) za klase ekološkog statusa koje je neuronska mreža odredila na osnovu izmerenih vrednosti koncentracija nitratnih anjona

[NO ₃ ⁻]	I	II	III	IV	V	VI	VII
I	0	0	0	0	0	0	0
II	0	0	0	0	0	0	0
III	0	0	0	0	1	0	0
IV	0	0	1	32	8	0	1
V	0	0	3	8	44	5	0
VI	0	0	0	0	3	7	0
VII	0	0	0	0	0	0	10

VII klasa ekološkog statusa na osnovu koncentracije nitratnih anjona tačno je procenjena na prvih 5 JDS lokaliteta, s obe strane rečne obale (JDS1 - JDS5) (Prilog 3.). Na lokalitetima na kojima je neuronska mreža tačno odredila VII klasu ekološkog statusa vrednosti koncentracije nitratnih anjona varirale su od 11-15 mg/L. Jedina vrsta makrofita koja je detektovana na svim lokalitetima od JDS 1 – JDS 5 je *Phalaris arundinacea L.*, te se može smatrati vrstom makrofita za koju se sa sigurnošću može tvrditi da toleriše povišene koncentracije nitratnih anjona u površinskim vodama. *Phalaris arundinacea L.* je autohtona vrsta vlažnih staništa na području Sjedinjenih Američkih Država čije invazivne forme, koje su produkt genetskog ukrštanja nativnih vrsta i vrsta zastupljenih na evropskom podneblju, usled povećanih koncentracija nitratnih anjona u medijumu brže rastu i dostižu veću biomasu. Mehanizam agresivnijeg rasprostiranja vrste *Phalaris arundinacea L.* u staništima bogatijim nitratnim anjonima objašnjen je u radu Martina i Von Ende (2013). Male količine svetlosti imaju inhibirajuće dejstvo na rast vrste *Phalaris arundinacea L.*

(Martina i Von Ende, 2012). Vrsta *Lythrum salicaria L.* izostala je jedino na lokalitetu JDS 2, na desnoj obali reke. Vrste *Cinclidotus riparius (Host ex Brid.) Arn.* i *Fontinalis antipyretica Hedw.* detektovane su na svim lokalitetima koji na osnovu koncentracije nitratnih anjona pripadaju VII klasi ekološkog statusa, osim na lokalitetu JDS 4 na kom je izmerena najniža koncentracija jona rastvorenog kiseonika (7 mg/L) na delu toka između lokaliteta JDS 1 i JDS 5.

Činjenica da se vrsta *Cinclidotus riparius (Host ex Brid.) Arn.* sreće na lokalitetima koji se na osnovu koncentracija nitratnih anjona svrstavaju u VII klasu ekološkog statusa, a na osnovu vrednosti koncentracije rastvorenog kiseonika u II klasu ekološkog statusa, ukazuje na nelinearnu zavisnost između koncentracija nitratnih anjona i koncentracija rastvorenog kiseonika. S obzirom na to da vrsta *Cinclidotus riparius (Host ex Brid.) Arn.* nije zastupljena na delovima rečnog toka na kojima je izmerena koncentracija rastvorenog kiseonika ispod 7 mg/L, njeno prisustvo u vodenom ekosistemu indikuje pripadnost određenog dela rečnog toka najmanje II klasi ekološkog statusa na osnovu vrednosti koncentracije rastvorenog kiseonika.

Vrste *Cinclidotus riparius (Host ex Brid.) Arn.*, *Fontinalis antipyretica Hedw* i *Amblystegium riparium (Hedw.) Schimp.* pripadaju razdelu Bryophyta, te na sličan način reaguju na dejstvo pojedinačnih ekoloških faktora, čime se objašnjava činjenica da na određenim delovima toka izostaju istovremeno. Vrsta *Fontinalis antipyretica Hedw* je indikator prisustva teških metala, posebno katjona kadmijuma, i pogodna je u biomonitoringu teških metala u vodenim staništima (Bleuel i saradnici, 2005).

Cinclidotus riparius (Host ex Brid.) Arn. i *Fontinalis antipyretica Hedw* su vrste makrofita sa širokom ekološkom valencijom na viši stepen trofičnosti ekosistema, i češće su zastupljene u eutrofnim delovima rečnog toka (Vanderpoorten i Stieperaere, 1999).

Na desnoj obali reke, na lokalitetu JDS 37 neuronska mreža je umesto III klase ekološkog statusa odredila IV klasu ekološkog statusa. Makrofite popisane na tom lokalitetu prikazane su u Tabeli 22. Vrste *Ceratophyllum demersum L.*, *Potamogeton sp.*, *Bidens frondosa L.* i *Polygonum lapatifolium L.* zastupljene su na JDS lokalitetima koji na osnovu koncentracija nitratnih anjona pripadaju IV klasi ekološkog statusa, te je izvesno da neuronska mreža na osnovu iskustva prisustvo navedenih vrsta makrofita, koje su

zastupljene i na lokalitetu JDS 37, desna obala reke, vezuje za IV klasu ekološkog statusa na osnovu koncentracija nitratnih anjona.

Tabela 22. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetu na kom je neuronska mreža umesto III klase ekološkog statusa odredila IV klasu na osnovu izmerenih vrednosti koncentracija nitratnih anjona

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 37 (D)	7.6 mg/L	2.7 mg/L	0.15 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Najas marina L.;</i> <i>Potamogeton crispus L.;</i> <i>Potamogeton nodosus Poir.;</i> <i>Potamogeton pectinatus L.;</i> <i>Potamogeton perfoliatus L.;</i> <i>Sparganium erectum L.;</i> <i>Bidens frondosa L.;</i> <i>Butomus umbellatus L.;</i> <i>Dichostylis micheliana (L.) Nees;</i> <i>Lythrum salicaria L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Rorippa amphibia (L.) Besser</i>

Na lokalitetima JDS 35, na obe strane rečne obale, i na lokalitetu JDS 37, na levoj obali reke, neuronska mreža je umesto III klase ekološkog statusa odredila V klasu (Tabela 23.).

Tabela 23. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto III klase ekološkog statusa odredila V klasu na osnovu vrednosti koncentracija nitratnih anjona

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 35 (L)	5.2 mg/L	1.4 mg/L	0.25 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Bidens frondosa L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Rorippa amphibia (L.) Besser</i>
JDS 35 (D)	5.2 mg/L	1.4 mg/L	0.25 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Hydrocharis morsus-ranae L.;</i> <i>Lemna minor L.; Lemna gibba L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Dichostylis micheliana (L.) Nees;</i> <i>Glyceria maxima (Hartm.) Holmb.;</i> <i>Polygonum lapatifolium L.</i>
JDS 37 (L)	7.6 mg/L	2.7 mg/L	0.15 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Bidens frondosa L.;</i> <i>Dichostylis micheliana (L.) Nees;</i> <i>Lythrum salicaria L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Rorippa amphibia (L.) Besser</i>

Na lokalitetu JDS 37 popisan je različit sastav makrofita, i neuronska mreža je na tom lokalitetu pogrešila u proceni klase ekološkog statusa za obe strane obale reke. Na desnoj obali reke na lokalitetu JDS 37 sastav makrofita je „bogatiji“ za vrste *Butomus umbellatus L.*, *Sparganium erectum L.*, *Potamogeton perfoliatus L.*, *Potamogeton pectinatus L.*, *Potamogeton nodosus Poir.*, *Potamogeton lucens L.*, *Potamogeton crispus L.* i *Najas marina L.* što objašnjava činjenicu zašto je neuronska mreža za navedeni lokalitet odredila lošiju klasu ekološkog statusa od realne. Bogatiji popis makrofita vezuje se za eutrofnu staništa.

Na svim lokalitetima na kojima je neuronska mreža na osnovu koncentracije nitratnih anjona umesto III klase ekološkog statusa odredila V klasu ekološkog statusa, uočena je vrsta *Polygonum lapatifolium L.* Na lokalitetu JDS 35 izmerena koncentracija rastvorenog kiseonika odgovara III klasi ekološkog statusa, dok se na osnovu koncentracije fosfatnih anjona isti lokalitet svrstava u V klasu ekološkog statusa. Na obe strane rečne obale na lokalitetu JDS 35 detektovane su sledeće vrste makrofita: *Ceratophyllum demersum L.*, *Lemna gibba L.*, *Lemna minor L.*, *Salvinia natans (L.) All.*, *Spirodela polyrhiza (L.) Schleid.* i *Polygonum lapatifolium L.*

Tabela 24. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto V klase ekološkog statusa odredila III klasu na osnovu izmerenih vrednosti koncentracija nitratnih anjona

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 39 (L)	7.3 mg/L	5.5 mg/L	0.14 mg/L	<i>Polygonum lapatifolium L.;</i> <i>Rorippa amphibia (L.) Besser;</i> <i>Glyceria maxima;</i> <i>Bidens frondosa L.;</i> <i>Trapa natans L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Potamogeton nodosus Poir.;</i> <i>Potamogeton pectinatus L.;</i> <i>Potamogeton perfoliatus L.;</i> <i>Potamogeton lucens L.;</i> <i>Potamogeton friesii Rupr.;</i> <i>Myriophyllum spicatum L.;</i> <i>Hydrocharis morsus-ranae L.;</i> <i>Lemna gibba;</i> <i>Lemna minor;</i> <i>Azolla filiculoides Lam;</i> <i>Ceratophyllum demersum L.</i>

Na lokalitetu JDS 39, na levoj obali reke, mreža je umesto V klase ekološkog statusa odredila III klasu ekološkog statusa. Makrofite zastupljene na tom lokalitetu popisane su u Tabeli 24.

Vrste *Polygonum lapatifolium L.* i *Ceratophyllum demersum L.* nalaze se na svim lokalitetima na kojima je neuronska mreža pogrešila u proceni klase ekološkog statusa i umesto III klase ekološkog statusa odredila V klasu, i obrnuto, te se prisustvo ovih vrsta makrofita ne može eksplicitno vezati za pripadnost dela rečnog toka određenoj klasi ekološkog statusa na osnovu koncentracijonih nivoa nitratnih anjona.

Na osnovu izmerenih koncentracija nitratnih anjona neuronska mreža ni za jedan lokalitet nije tačno procenila III klasu ekološkog statusa.

Na 44 JDS lokaliteta neuronska mreža je tačno odredila V klasu ekološkog statusa na osnovu izmerenih koncentracija nitratnih anjona. Na najvećem broju lokaliteta na kojima je neuronska mreža tačno odredila V klasu ekološkog statusa na osnovu koncentracije nitratnih anjona (41 od 44) zastupljena je vrsta *Polygonum lapatifolium L.*, što ukazuje da je vrsta tolerantna na povišene koncentracije nitratnih anjona u vodenom ekosistemu. Vrsta *Polygonum lapatifolium L.* je indikator V ili više klase ekološkog statusa na osnovu koncentracija nitratnih anjona što potvrđuje i detekcija na svim lokalitetima na kojima je neuronska mreža umesto III klase ekološkog statusa odredila V klasu ekološkog statusa. U radu Rawat i saradnici (2012) vrstu *Polygonum lapatifolium L.* deklarišu kao vrstu tolerantnu na povišene koncentracije nitratnih anjona u vodnim telima koja ima značajnu ulogu u remedijaciji nitratima kontaminiranih delova vodenih površina. Na lokalitetu JDS 48, na levoj obali reke, mreža je umesto VII odredila IV klasu ekološkog statusa, što predstavlja najveće odstupanje u proceni klase ekološkog statusa u modelovanju zasnovanom na koncentracijama nitratnih anjona. Sastav makrofita zastupljenih na delu rečnog toka koji odgovara VII klasi ekološkog statusa na osnovu koncentracija nitratnih anjona odstupa od sastava makrofita popisanog na lokalitetu JDS 48, na levoj obali reke (Tabela 25.).

Na lokalitetu JDS 48, leva obala reke, koncentracija nitratnih anjona je ekstremno povišena u odnosu na sve okolne JDS lokalitete koji na osnovu izmerenih koncentracija nitratnih anjona pripadaju IV klasi ekološkog statusa, što objašnjava grešku u proceni neuronske mreže koja uči na osnovu iskustva. Navedeni lokalitet nalazi se u Srbiji, na 845.

rečnom kilometru Dunava, mesto gde se reka Timok uliva u Dunav. Ušće Timoka u Dunav predstavlja najnižu tačku u Srbiji, na 28 m nadmorske visine.

Tabela 25. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto VII odredila IV klasu ekološkog statusa na osnovu vrednosti koncentracija nitratnih anjona

JDS Lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 48 (L)	8.9 mg/L	16 mg/L	0 mg/L	<i>Potamogeton pusillus L.;</i> <i>Potamogeton trichoides Cham. & Schltdl.;</i> <i>Alopecurus geniculatus L.;</i> <i>Bidens frondosa;</i> <i>Cyperus fuscus L.;</i> <i>Dichostylis micheliana (L.) Nees;</i> <i>Eleocharis acicularis (L.) Roem. & Schult.;</i> <i>Polygonum lapatifolium L.</i>

Na lokalitetima JDS 9, na obe strane rečne obale, JDS 7 i JDS 11, desna obala reke, odnosno JDS 10, leva obala reke, neuronska mreža je umesto VI klase ekološkog statusa odredila V klasu ekološkog statusa (Tabela 26.). Na 4 od 5 navedenih JDS lokaliteta popisana je vrsta *Lythrum salicaria L.*, dok je na 3 lokaliteta zastupljena vrsta *Cinclidotus riparius (Host ex Brid.)*.

Tabela 26. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto VI klase ekološkog statusa odredila V klasu na osnovu izmerenih vrednosti koncentracija nitratnih anjona

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 7 (D)	8.7 mg/L	7.3 mg/L	0.11 mg/L	<i>Bidens frondosa L.;</i> <i>Iris pseudacorus L.;</i> <i>Lythrum salicaria L.;</i> <i>Mentha aquatica L.;</i> <i>Phalaris arundinacea L.</i>
JDS 9 (L)	10 mg/L	7.2 mg/L	0 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.;</i> <i>Polygonum lapatifolium L.</i>
JDS 9 (D)	10 mg/L	7.2 mg/L	0 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Glyceria maxima (Hartm.) Holmb.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.;</i> <i>Polygonum lapatifolium L.</i>
JDS 10 (L)	9.4 mg/L	7.3 mg/L	0 mg/L	<i>Phragmites australis (Cav.) Trin. ex Steud.;</i> <i>Lythrum salicaria L.</i>
JDS 11 (D)	8.8 mg/L	7.3 mg/L	0 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.;</i> <i>Polygonum hydropiper L.;</i> <i>Polygonum lapatifolium L.</i>

Na 3 JDS lokaliteta, JDS 8, desna obala reke, JDS 15 i JDS 18, leva strana obale reke, neuronska mreža je umesto V klase ekološkog statusa odredila VI klasu. Makrofite zastupljene na tim lokalitetima navedene su u Tabeli 27.

Tabela 27. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto V klase ekološkog statusa odredila VI klasu na osnovu izmerenih vrednosti koncentracija nitratnih anjona

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 8 (D)	9.4 mg/L	7 mg/L	0.1 mg/L	<i>Lythrum salicaria L.</i> ; <i>Cinclidotus riparius</i> (<i>Host ex Brid.</i>) Arn.; <i>Phalaris arundinacea L.</i> ; <i>Phragmites australis</i> (<i>Cav.</i>) Trin. ex Steud.
JDS 15 (L)	8.4 mg/L	6.6 mg/L	0.1 mg/L	<i>Lythrum salicaria L.</i> ; <i>Phalaris arundinacea L.</i> ; <i>Phragmites australis</i> (<i>Cav.</i>) Trin. ex Steud.; <i>Polygonum lapatifolium L.</i>
JDS 18 (L)	8.8 mg/L	5.3 mg/L	0.17 mg/L	<i>Lythrum salicaria L.</i>

Vrsta *Lythrum salicaria L.* zastupljena je na sva 3 JDS lokaliteta na kojima je neuronska mreža umesto V klase ekološkog statusa odredila VI klasu. Sva 3 navedena JDS lokaliteta na osnovu koncentracije fosfatnih anjona pripadaju IV klasi ekološkog statusa. Lokalitet JDS 8 (D) na osnovu koncentracije rastvorenog kiseonika pripada I klasi ekološkog statusa, dok se lokaliteti JDS 15 (L) i JDS 18 (L) na osnovu izmerene koncentracije rastvorenog kiseonika svrstavaju u II klasu ekološkog statusa. Rezultati modelovanja potvrdili su da je vrsta *Lythrum salicaria L.* tolerantna na koncentracije nitratnih anjona koje determinišu pripadnost određenog dela rečnog toka V, odnosno VI klasi ekološkog statusa. Na ukupno 7 lokaliteta, JDS 41, JDS 45, JDS 51 i JDS 54, na levoj obali reke, i JDS 46, JDS 64 i JDS 66, na desnoj obali reke, neuronska mreža je umesto IV klase ekološkog statusa odredila V klasu ekološkog statusa. Vrste makrofita detektovane na navedenim lokalitetima popisane su u Tabeli 28.

Tabela 28. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto IV klase ekološkog statusa odredila V klasu ekološkog statusa na osnovu izmerenih vrednosti koncentracija nitratnih anjona

JDS Lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 41 (L)	4.3 mg/L	4.9 mg/L	0.2 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Bidens frondosa L.;</i> <i>Dichotylis micheliana (L.) Nees;</i> <i>Glyceria maxima (Hartm.) Holmb.;</i> <i>Iris pseudacorus L.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 45 (L)	7 mg/L	4.6 mg/L	0.14 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna minor L.;</i> <i>Lemna turionifera Landolt;</i> <i>Nymphoides peltata (S.G.Gmel.) Kuntze;</i> <i>Potamogeton lucens L.;</i> <i>Potamogeton natans L.;</i> <i>Potamogeton nodosus Poir.;</i> <i>Potamogeton pectinatus L.;</i> <i>Potamogeton perfoliatus L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Butomus umbellatus L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 46 (D)	5.9 mg/L	4.7 mg/L	0.13 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Azolla filiculoides Lam.;</i> <i>Elodea nuttallii (Planch.) H.St.John;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Lemna turionifera Landolt;</i> <i>Myriophyllum spicatum L.;</i> <i>Potamogeton lucens L.;</i> <i>Potamogeton natans L.;</i> <i>Potamogeton perfoliatus L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Trapa natans L.;</i> <i>Vallisneria spiralis L.;</i> <i>Bidens frondosa L.;</i> <i>Butomus umbellatus L.;</i> <i>Glyceria fluitans (L.) R.Br.;</i> <i>Lythrum salicaria L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.;</i> <i>Polygonum lapatifolium L.;</i> <i>Schoenoplectus lacustris (L.) Palla;</i> <i>Typha angustifolia L.;</i> <i>Typha latifolia L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 51 (L)	8.2 mg/L	4.6 mg/L	0.28 mg/L	<i>Myriophyllum spicatum L.;</i> <i>Bidens frondosa L.;</i> <i>Polygonum lapatifolium L.</i>
JDS 54 (L)	7.3 mg/L	4.2 mg/L	0.22 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Bidens frondosa L.;</i> <i>Butomus umbellatus L.;</i> <i>Polygonum lapatifolium L.</i>
JDS 64 (D)	8.1 mg/L	4.5 mg/L	0.17 mg/L	<i>Lemna minor L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Alopecurus geniculatus L.;</i> <i>Bidens frondosa L.;</i> <i>Gnaphalium uliginosum L.;</i> <i>Lythrum salicaria L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.;</i> <i>Polygonum lapatifolium L.</i>

JDS lokalitet	[DO]	[NO ₃] ⁻	[PO ₄ ³⁻]	Detektovane makrofite
JDS 66 (D)	8 mg/L	4 mg/L	0.15 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Myriophyllum spicatum L.;</i> <i>Nuphar lutea (L.) Sm.;</i> <i>Potamogeton nodosus Poir.;</i> <i>Potamogeton perfoliatus L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Sparaganium erectum L.;</i> <i>Stratiotes aloides L.;</i> <i>Trapa natans L.;</i> <i>Bidens frondosa L.;</i> <i>Butomus umbellatus L.;</i> <i>Dichostylis micheliana (L.) Nees; Gnaphalium uliginosum L.;</i> <i>Lythrum salicaria L.;</i> <i>Mentha aquatica L.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.; Typha angustifolia L.</i>

Najveće odstupanje u proceni klase ekološkog statusa zasnovane na koncentracijama nitratnih anjona je na lokalitetu JDS 48, za koji je neuronska mreža odredila IV klasu ekološkog statusa umesto VII klase. Na tom lokalitetu je rastojanje između očekivane i izračunate klase ekološkog statusa 3. Makrofite zastupljene na tom lokalitetu su: *Potamogeton pusillus L.*, *Potamogeton trichoides Cham. & Schltl.*, *Alopecurus geniculatus L.*, *Bidens frondosa L.*, *Cyperus fuscus L.*, *Dichostylis micheliana (L.) Nees*, *Eleocharis acicularis (L.) Roem. & Schult.* i *Polygonum lapatifolium L.* Lokalitet JDS 48 nalazi se na 845. km rečnog toka, na mestu gde se Timok uliva u Dunav. Svi okolni lokaliteti pripadaju IV klasi ekološkog statusa, i uzimajući u obzir zakonitost da mreža uči na osnovu iskustva objašnjava da je uzrok većeg odstupanja u proceni klase ekološkog statusa. Koncentracija nitratnih anjona na ovom lokalitetu iznosi 16 mg/L, dok je na susednim lokalitetima od 4.4 – 4.7 mg/L.

Srednja apsolutna greška (*Pa*) modela zasnovanog na proceni klasa ekološkog statusa na osnovu izmerenih koncentracija nitratnih anjona računa se prema sledećoj formuli:

$$Pa = \frac{93 \cdot 0 + 25 \cdot 1 + 4 \cdot 2 + 1 \cdot 3}{7 \cdot 123} = \frac{36}{8 \ 6 \ 1} = 0.0418$$

Tačnost procene neuronske mreže u slučaju klasifikacije na osnovu vrednosti koncentracija nitratnih anjona je 99.95%.

$$\text{Tačnost procene} = (100 - Pa)\% = (100 - 0.0418)\% = 99.96\%$$

Neuronska mreža je na 93 od ukupno 123 lokaliteta tačno procenila klasu ekološkog statusa te se stopa predikcije (Pr) neuronske mreže za model zasnovan na koncentracijama nitratnih anjona računa prema sledećoj formuli:

$$Pr = \frac{93}{123} \cdot 100\% = 75.6\%$$

8.3. Rezultati modelovanja ekološkog statusa Dunava na osnovu prisustva makrofita i koncentracija ortofosfatnih anjona

Na osnovu koncentracije ortofosfatnih anjona neuronska mreža je na 87 lokaliteta tačno odredila klasu ekološkog statusa, i to: na 5 lokaliteta I klasu ekološkog statusa, na 81 lokalitetu IV klasu ekološkog statusa i na 1 lokalitetu V klasu ekološkog statusa (Tabela 29.)

Tabela 29. Confusion matrica (CM) za klase ekološkog statusa koje je neuronska mreža odredila na osnovu izmerenih vrednosti koncentracija ortofosfatnih anjona

[PO ₄ ³⁻]	I	II	III	IV	V	VI	VII
I	5	0	0	11	1	0	0
II	0	0	0	0	0	0	0
III	0	0	0	0	0	0	0
IV	7	0	0	81	10	0	1
V	1	0	0	4	1	0	1
VI	0	0	0	0	0	0	0
VII	0	0	0	0	0	0	0

Za najveći broj primera mreža je odredila IV klasu ekološkog statusa, i to za 81 lokalitet tačno, dok je za 15 lokaliteta došlo do odstupanja u proceni IV klase ekološkog statusa.

Na lokalitetu JDS 9, na desnoj obali reke, neuronska mreža je odredila V klasu ekološkog statusa umesto I klase ekološkog statusa. Na tom lokalitetu zastupljene su sledeće vrste makrofita: *Polygonum lapatifolium L.*, *Phalaris arundinacea L.*, *Lythrum salicaria L.*, *Glyceria maxima (Hartm.) Holmb.* i *Cinclidotus riparius (Host ex Brid.) Arn.*

Tabela 30. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto I klase ekološkog statusa odredila IV klasu ekološkog statusa na osnovu izmerenih koncentracija ortofosfatnih anjona

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 6 (D)	8.7 mg/L	6.7 mg/L	0 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Fontinalis antipyretica</i> Hedw.; <i>Potamogeton pectinatus</i> L.; <i>Iris pseudacorus</i> L.; <i>Lythrum salicaria</i> L.; <i>Phalaris arundinacea</i> L.
DS 9 (L)	10 mg/L	7.2 mg/L	0 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Lythrum salicaria</i> L.; <i>Phalaris arundinacea</i> L.; <i>Polygonum lapatifolium</i> L.
JDS 21 (L)	8.4 mg/L	6.1 mg/L	0 mg/L	<i>Lemna gibba</i> L.; <i>Lemna minor</i> L.; <i>Salvinia natans</i> (L.) All.; <i>Spirodela polyrhiza</i> (L.) Schleid.; <i>Bidens frondosa</i> L.; <i>Phragmites australis</i> (Cav.) Trin. ex Steud.; <i>Polygonum hydroppiper</i> L.; <i>Polygonum lapatifolium</i> L.
JDS 21 (D)	8.4 mg/L	6.1 mg/L	0 mg/L	<i>Lemna gibba</i> L.; <i>Lemna minor</i> L.; <i>Salvinia natans</i> (L.) All.; <i>Bidens frondosa</i> L.; <i>Dichostylis micheliana</i> (L.) Nees; <i>Iris pseudacorus</i> L.; <i>Lythrum salicaria</i> L.; <i>Phalaris arundinacea</i> L.; <i>Phragmites australis</i> (Cav.) Trin. ex Steud.; <i>Polygonum hydroppiper</i> L.; <i>Polygonum lapatifolium</i> L.
JDS 48	8 mg/L	3.9 mg/L	0 mg/L	<i>Potamogeton pusillus</i> L.; <i>Potamogeton trichoides</i> Cham. & Schldl.; <i>Alopecurus geniculatus</i> L.; <i>Bidens frondosa</i> L.; <i>Cyperus fuscus</i> L.; <i>Dichostylis micheliana</i> (L.) Nees; <i>Eleocharis acicularis</i> (L.) Roem. & Schult.; <i>Polygonum lapatifolium</i> L.
JDS 55 (L)	8 mg/L	3.9 mg/L	0 mg/L	<i>Alopecurus geniculatus</i> L.; <i>Butomus umbellatus</i> L.; <i>Lythrum salicaria</i> L.; <i>Polygonum lapatifolium</i> L.
JDS 55 (D)	8 mg/L	3.9 mg/L	0 mg/L	<i>Myriophyllum spicatum</i> L.; <i>Potamogeton crispus</i> L.; <i>Potamogeton pectinatus</i> L.; <i>Potamogeton perfoliatus</i> L.; <i>Alopecurus geniculatus</i> L.; <i>Bidens frondosa</i> L.; <i>Butomus umbellatus</i> L.; <i>Cyperus fuscus</i> L.; <i>Dichostylis micheliana</i> (L.) Nees; <i>Lythrum salicaria</i> L.; <i>Polygonum lapatifolium</i> L.

Na lokalitetima JDS 6, desna obala reke, JDS 9, leva obala reke, JDS 21, obe strane rečne obale, JDS 48 i JDS 55 neuronska mreža je pogrešila u proceni za 3 klase ekološkog statusa i umesto I klase ekološkog statusa odredila IV klasu (Tabela 30). Vrsta *Polygonum*

lapatifolium L. je zastupljena na 6 od 7 navedenih lokaliteta, a vrsta *Lythrum salicaria L.* na 5 od 7 navedenih JDS lokaliteta. Vrsta *Lythrum salicaria L.* je zastupljena i na svim JDS lokalitetima na kojima je neuronska mreža tačno odredila I klasu ekološkog statusa na osnovu izmerenih koncentracija ortofosfatnih anjona, te se ne može smatraati indikatorskom vrstom za procenu klase ekološkog statusa na osnovu vrednosti koncentracije ortofosfatnih anjona.

Na 11 lokaliteta neuronska mreža je umesto IV klase ekološkog statusa odredila I klasu ekološkog statusa (Tabela 31.).

Tabela 31. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto IV klase ekološkog statusa odredila I klasu ekološkog statusa na osnovu izmerenih vrednosti koncentracija ortofosfatnih anjona

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 7 (L)	8.7 mg/L	7.3 mg/L	0.11 mg/L	<i>Iris pseudacorus L.;</i> <i>Lythrum salicaria L.;</i> <i>Mentha aquatica L.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.</i>
JDS 8 (L)	9.4 mg/L	7 mg/L	0.1 mg/L	<i>Fontinalis antipyretica Hedw.;</i> <i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Phalaris arundinacea L.</i>
JDS 8 (D)	9.4 mg/L	7 mg/L	0.1 mg/L	<i>Phragmites australis (Cav.) Trin. ex Steud.;</i> <i>Lythrum salicaria L.;</i> <i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Phalaris arundinacea L.</i>
JDS 13 (L)	9.3 mg/L	7.3 mg/L	0.12 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.;</i> <i>Bidens frondosa L.;</i> <i>Lythrum salicaria L.</i>
JDS 13 (D)	9.3 mg/L	7.3 mg/L	0.12 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.</i>
JDS 17 (L)	8.8 mg/L	6.8 mg/L	0.14 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.;</i> <i>Polygonum hydropiper L.;</i> <i>Polygonum lapatifolium L.</i>
JDS 18 (L)	8.8 mg/l	5.2 mg/L	0.17 mg/L	<i>Lythrum salicaria L.</i>
JDS 18 (D)	8.8 mg/l	5.2 mg/L	0.17 mg/L	<i>Lemna minor L.;</i> <i>Iris pseudacorus L.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.;</i> <i>Polygonum hydropiper L.;</i> <i>Polygonum lapatifolium L.</i>

JDS lokalitet	[DO]	[NO ₃ ⁻]	[PO ₄ ³⁻]	Detektovane makrofite
JDS 50 (D)	8.1 mg/L	4.4 mg/L	0.13 mg/L	<i>Myriophyllum spicatum L.;</i> <i>Potamogeton crispus L.;</i> <i>Potamogeton pectinatus L.;</i> <i>Potamogeton perfoliatus L.;</i> <i>Alopecurus geniculatus L.;</i> <i>Butomus umbellatus L.;</i> <i>Cyperus fuscus L.;</i> <i>Lythrum salicaria L.;</i> <i>Polygonum lapatifolium L.</i>
JDS 53 (L)	8.9 mg/L	4.2 mg/L	0.14 mg/L	<i>Elodea nuttallii (Planch.) H.St.John;</i> <i>Potamogeton pectinatus L.;</i> <i>Potamogeton pusillus L.;</i> <i>Potamogeton trichoides Cham. & Schldl.;</i> <i>Alopecurus geniculatus L.;</i> <i>Butomus umbellatus L.;</i> <i>Polygonum lapatifolium L.</i>
JDS 60 (D)	8.2 mg/L	4.3 mg/L	0.14 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Potamogeton perfoliatus L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Bidens frondosa L.;</i> <i>Butomus umbellatus L.;</i> <i>Lythrum salicaria L.;</i> <i>Polygonum lapatifolium L.</i>

Na svim lokalitetima koji se na osnovu vrednosti koncentracija jona rastvorenog kiseonika ubrajaju u I klasu ekološkog statusa, a na osnovu koncentracije ortofosfatnih anjona u IV klasu ekološkog statusa (JDS 8 i JDS 13) zastupljene su vrste *Cinclidotus riparius (Host ex Brid.) Arn.* i *Phalaris arundinacea L.*

Na lokalitetu JDS 8 neuronska mreža je umesto III klase ekološkog statusa odredila I klasu ekološkog statusa. Svi okolni lokaliteti na osnovu koncentracije ortofosfatnih anjona pripadaju I klasi ekološkog statusa što je uzrok pogrešne procene neuronske mreže koja uči na osnovu iskustva. Makrofite zastupljene na lokalitetu JDS 8 pobrojane su u Tabeli 32.

Tabela 32. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO₃⁻) i ortofosfatnih anjona (PO₄³⁻) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto III klase ekološkog statusa odredila I klasu na osnovu izmerenih vrednosti koncentracija ortofosfatnih anjona

JDS lokalitet	[DO]	[NO ₃ ⁻]	[PO ₄ ³⁻]	Detektovane makrofite
JDS 8 (L)	9.4 mg/L	7 mg/L	0.1 mg/L	<i>Phalaris arundinacea L.;</i> <i>Cinclidotus riparius (Host ex Brid.) Arn. ;</i> <i>Fontinalis antipyretica Hedw.</i>
JDS 8 (D)	9.4 mg/L	7 mg/L	0.1 mg/L	<i>Phalaris arundinacea L.;</i> <i>Cinclidotus riparius (Host ex Brid.) Arn. ;</i> <i>Lythrum salicaria L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.</i>

Na lokalitetu JDS 4, leva obala reke, neuronska mreža je umesto V klase ekološkog statusa odredila I klasu ekološkog statusa na osnovu izmerenih koncentracija ortofosfatnih anjona. Na tom lokalitetu zastupljene su sledeće vrste makrofita: *Phalaris arundinacea L.*, *Lythrum salicaria L.*, *Butomus umbellatus L.*, *Sparganium emersum Rehmann*, *Potamogeton pectinatus L.*, *Nuphar lutea (L.) Sm.*, i *Myriophyllum spicatum L.*. Izmerena koncentracija rastvorenog kiseonika na ovom lokalitetu odgovara II klasi ekološkog statusa, dok izmerena koncentracija nitratnih anjona odgovara najlošijoj, VII klasi ekološkog statusa. Na desnoj obali reke lokaliteta JDS 4, za koji je neuronska mreža odredila da pripada IV umesto V klasi ekološkog statusa, zastupljene su sledeće vrste makrofita: *Typha latifolia L.*, *Cladophora glomerata L.* i *Polygonum lapatifolium L.*

Na 5 lokaliteta neuronska mreža je tačno odredila I klasu ekološkog statusa. Listing lokaliteta i makrofite koje su zastupljene prikazane su u Tabeli 33.

Tabela 33. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža tačno odredila I klasu ekološkog statusa na osnovu izmerenih vrednosti koncentracija ortofosfatnih anjona

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 6 (L)	8.7 mg/L	6.7 mg/L	0 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Potamogeton pectinatus</i> L.; <i>Iris pseudacorus</i> L.; <i>Lythrum salicaria</i> L.; <i>Phalaris arundinacea</i> L.
JDS 10 (L)	9.4 mg/L	7.3 mg/L	0 mg/L	<i>Lythrum salicaria</i> L.; <i>Phragmites australis</i> (Cav.) Trin. ex Steud.
JDS 10 (D)	9.4 mg/L	7.3 mg/L	0 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Lythrum salicaria</i> L.; <i>Phragmites australis</i> (Cav.) Trin. ex Steud.
JDS 11 (L)	8.8 mg/l	7.3 mg/L	0 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Lythrum salicaria</i> L.; <i>Phalaris arundinacea</i> L. <i>Phragmites australis</i> (Cav.) Trin. ex Steud.;
JDS 11 (D)	8.8 mg/l	7.3 mg/L	0 mg/L	<i>Polygonum hydroppiper</i> L.; <i>Polygonum lapatifolium</i> L.; <i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Lythrum salicaria</i> L.; <i>Phalaris arundinacea</i> L.; <i>Phragmites australis</i> (Cav.) Trin. ex Steud.

Na svim JDS lokalitetima na kojima je neuronska mreža tačno odredila I klasu ekološkog statusa zastupljena je vrsta *Lythrum salicaria* L., dok je vrsta *Phragmites australis* (Cav.) Trin. ex Steud. zastupljena na 4 od 5 lokaliteta na kojima je tačno prediktovana I klasa ekološkog statusa. Vrsta *Phragmites australis* (Cav.) Trin. ex Steud izostaje na lokalitetu JDS 6, leva obala reke.

V klasa ekološkog statusa tačno je procenjena na lokalitetu JDS 51, desna obala reke, i na tom JDS lokalitetu zastupljene su sledeće vrste makrofita: *Ceratophyllum demersum* L., *Myriophyllum spicatum* L., *Bidens frondosa* L. i *Polygonum lapatifolium* L. Izmerena koncentracija rastvorenog kiseonika na tom lokalitetu odgovara II klasi ekološkog statusa, dok na osnovu koncentracije nitratnih anjona pripada IV klasi ekološkog statusa.

Na lokalitetu JDS 58, neuronska mreža je umesto VII klase ekološkog statusa odredila IV klasu, za lokalitet na levoj obali reke, odnosno V klasu ekološkog statusa za lokalitet na desnoj obali reke. Vrednost izmerene koncentracije ortofosfatnih anjona na lokalitetu JDS 58 znatno odstupa od vrednosti ortofosfatnih anjona izmerenih na okolnim JDS lokalitetima koja iznosi 0.14 mg/L, što odgovara IV klasi ekološkog statusa.

Vrsta *Ceratophyllum demersum L.* nalazi se na obe strane rečne obale lokaliteta JDS 58 (Tabela 34).

Tabela 34. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto VII klase ekološkog statusa odredila IV, odnosno V klasu ekološkog statusa na osnovu izmerenih vrednosti koncentracija ortofosfatnih anjona.

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 58 (L)	6.7 mg/L	6.1 mg/L	1.5 mg/L	<i>Ceratophyllum demersum L.</i>
JDS 58 (D)	6.7 mg/L	6.1 mg/L	1.5 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Bidens frondosa L. i Butomus umbellatus L.</i>

Listing makrofita na lokalitetima na kojima je neuronska mreža umesto IV klase ekološkog statusa odredila V klasu ekološkog statusa prikazan je u Tabeli 35.

Tabela 35. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto IV klase ekološkog statusa odredila V klasu ekološkog statusa na osnovu izmerenih vrednosti koncentracija ortofosfatnih anjona

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 1 (D)	8.1 mg/L	15 mg/L	0.11 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Fontinalis antipyretica Hedw.;</i> <i>Amblystegium riparium (Hedw.) Schimp.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.</i>
JDS 2 (D)	7.8 mg/L	11 mg/L	0.12 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Fontinalis antipyretica Hedw.;</i> <i>Agrostis stolonifera L.;</i> <i>Phalaris arundinacea L.</i>
JDS 3 (L)	7.4 mg/L	12 mg/L	0.17 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Eloea nuttallii (Planch.) H.St.John;</i> <i>Fontinalis antipyretica Hedw.;</i> <i>Myriophyllum spicatum L.;</i> <i>Najas marina L.;</i> <i>Nuphar lutea (L.) Sm.;</i> <i>Potamogeton crispus L.;</i> <i>Potamogeton lucens L.;</i> <i>Potamogeton nodosus Poir.;</i> <i>Potamogeton pectinatus L.;</i> <i>Potamogeton perfoliatus L.;</i> <i>Potamogeton trichoides Cham. & Schldl.;</i> <i>Sparganium emersum Rehmann.;</i> <i>Sparganium erectum L.;</i> <i>Butomus umbellatus L.;</i> <i>Iris pseudacorus L.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.;</i> <i>Typha latifolia L.</i>

JDS lokalitet	[DO]	[NO ₃ ⁻]	[PO ₄ ³⁻]	Detektovane makrofite
JDS 38 (L)	6.7 mg/L	5.3 mg/L	0.14 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Myriophyllum spicatum L.;</i> <i>Potamogeton lucens L.;</i> <i>Potamogeton pectinatus L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Bidens frondosa L.;</i> <i>Bidens tripartita L.;</i> <i>Butomus umbellatus L.;</i> <i>Cyperus fuscus L.;</i> <i>Dichostylis micheliana (L.) Nees;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>

Na suprotnim stranama obale reke lokaliteta navedenih u Tabeli 38. neuronska mreža je tačno odredila klasu ekološkog statusa. Sastav makrofita se razlikuje na levoj u odnosu na desnu obalu reke, što je prouzrokovalo grešku u proceni neuronske mreže.

Na 10 lokaliteta mreža je umesto V klase ekološkog statusa odredila IV klasu. Vrsta *Polygonum lapatifolium L.* zastupljena je na svih 10 lokaliteta (Prilog 4.).

Tabela 36. Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO₃⁻) i ortofosfatnih anjona (NO₃⁻) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto I klase ekološkog statusa odredila IV klasu ekološkog statusa na osnovu izmerenih vrednosti koncentracija ortofosfatnih anjona

JDS lokalitet	[DO]	[NO ₃ ⁻]	[PO ₄ ³⁻]	Detektovane makrofite
JDS 21 (L)	8.4 mg/L	6.1 mg/L	0 mg/L	<i>Polygonum hydroppiper L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Bidens frondosa L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Spirodela polyrhiza (L.) Schleid.</i>
JDS 21 (D)	8.4 mg/L	6.1 mg/L	0 mg/L	<i>Polygonum hydroppiper L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Bidens frondosa L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Dichostylis micheliana (L.) Nees;</i> <i>Iris pseudacorus L.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.</i>
JDS 9 (D)	10 mg/L	7.2 mg/L	0 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Glyceria maxima (Hartm.) Holmb.;</i> <i>Phalaris arundinacea L.;</i> <i>Lythrum salicaria L.;</i>

Na lokalitetima JDS 21, obe strane rečne obale, i JDS 9, desna obala reke, mreža je umesto I klase ekološkog statusa odredila IV klasu ekološkog statusa (Tabela 36.).

Lokaliteti JDS 20 i JDS 22 na osnovu izmerenih koncentracija ortofosfatnih anjona pripadaju IV klasi ekološkog statusa, te se pogrešna procena neuronske mreže objašnjava činjenicom da neuronske mreže uče na osnovu iskustva.

Popis makrofita na lokalitetu JDS 9, na desnoj obali reke u odnosu na suprotnu stranu obale reke za koji je neuronska mreža odredila V klasu ekološkog statusa, razlikuje se samo po prisustvu vrste *Glyceria maxima (Hartm.) Holmb.*

Za lokalitete JDS 7 i JDS 8 neuronska mreža je tačno odredila da pripadaju IV klasi ekološkog statusa na osnovu izmerenih vrednosti ortofosfatnih anjona, čime je potvrđena činjenica da neuronska mreža greši u proceni za više od 1 klase ekološkog statusa isključivo zbog osobine da uči na osnovu iskustva.

Nijedna vrsta makrofita nije uočena na sva 3 lokaliteta za koje je neuronska mreža umesto I klase ekološkog statusa odredila IV klasu ekološkog statusa na osnovu izmerenih vrednosti koncentracija ortofosfatnih anjona.

Srednja apsolutna greška (Pa) za model baziran na koncentracijama ortofosfatnih anjona računa se prema sledećoj formuli:

$$Pa = \frac{8 \cdot 70 + 16 \cdot 1 + 4 \cdot 2 + 17 \cdot 3 + 3 \cdot 4}{7 \cdot 123} = \frac{8 \cdot 7}{8 \cdot 6 \cdot 1} = 0.1$$

Tačnost procene = $(100 - Pa)\% = (100 - 0.1)\% = 99.99\%$

Neuronska mreža je na 87 od ukupno 123 lokaliteta tačno procenila klasu ekološkog statusa. Stopa predikcije (Pr) neuronske mreže za model zasnovan na koncentracijama nitratnih anjona računa se prema sledećoj formuli:

$$Pr = \frac{8 \cdot 7}{123} \cdot 100\% = 70.73\%$$

Tačnost procene neuronske mreže u slučaju klasifikacije na osnovu vrednosti koncentracija ortofosfatnih anjona je 99.89%, što je najveći procenat tačnosti za sva tri odabrana hemijska parametra. U slučaju modelovanja klasa ekološkog statusa na osnovu koncentracija ortofosfatnih anjona neuronska mreža je imala najmanje odstupanja.

Tabela 37. Broj lokaliteta na kojima je neuronska mreža tačno/sa odstupanjima odredila klase ekološkog statusa na osnovu odabralih hemijskih parametara uz redosled $O_2 > PO_4^{3-} > NO_3^-$

Hemijski parametar	A	B	C	D
[DO]	103	19	2	0
[NO ₃ ⁻]	93	25	4	1
[PO ₄ ³⁻]	94	24	4	1

A - broj lokaliteta na kojima je neuronska mreža tačno odredila klasu ekološkog statusa

B - broj lokaliteta na kojima je rastojanje između klase ekološkog statusa koje je neuronska mreža odredila i realne klase ekološkog statusa 1

C - broj lokaliteta na kojima je rastojanje između klase ekološkog statusa koje je neuronska mreža odredila i realne klase ekološkog statusa 2

D - broj lokaliteta na kojima je rastojanje između klase ekološkog statusa koje je neuronska mreža odredila i realne klase ekološkog statusa 3

Vrednosti stope predikcije, srednje apsolutne greške i tačnosti procene neuronske mreže (%) za sva tri hemijska parametra koja su korišćena u modelovanju kao ulazne varijable, prikazane su u Tabeli 38.

Tabela 38. Vrednosti stope predikcije, srednje apsolutne greške i tačnosti procene neuronske mreže (%) za sva tri hemijska parametra korišćena u modelovanju kao ulazne varijable

Ulagne varijable	Stopa predikcije modela (%)	Srednja apsolutna greška (%)	Tačnost procene modela neuronske mreže (%)
[DO]	83.74	0.024	99.98
[NO ₃ ⁻]	75.60	0.0418	99.96
[PO ₄ ³⁻]	67.47	0.0406	99.99

Za sva tri odabrana hemijska parametra vrednosti tačnosti procene su izuzetno visoke i potvrđuju primenu modela veštačkih neuronskih mreža kao adekvatnog i

optimalnog alata u modelovanju klase ekološkog statusa na osnovu koncentracija rastvorenog kiseonika, nitratnih i ortofosfatnih anjona.

Modelovanje uslova staništa na osnovu prisustva, odnosno odsustva indikatorskih vrsta je osnovni i izuzetno važan zadatak bioindikacije detaljno opisan u radu Schleiter i saradnici, 2006. Modelovanje klase ekološkog statusa primenjeno u istraživanjima sprovedenim u okviru doktorske teze zasnovano je na zastupljenosti makrofita, kao bioloških pokazatelja trofičnosti vodenog ekosistema. Prisustvo bioloških pokazatelja kvaliteta životne sredine se u jedinici vremena ne menja brzo, te stoga makrofite predstavljaju adekvatne pokazatelje kvaliteta životne sredine.

Vrednosti zastupljenosti makrofita primenjene u doktorskoj disertaciji bazirane su na podacima prikupljenim tokom Joint Danube Survey 3 istraživanja (Liska i saradnici, 2015). Udaljenost između svakog JDS lokaliteta je 3 rečna kilometra što se projektuje na tačnost procene i može „maskirati“ uslove staništa. Bolja sposobnost predikcije odabranog modela očekuje se analiziranjem manjih površina rečnog toka i korišćenjem većeg broja podataka za modelovanje (Jusik i saradnici, 2015).

Prikupljanje podataka o zastupljenosti makrofita ne iziskuje visoke materijalne troškove te se može realizovati frekventnije od Joint Danube Survey istraživanja. Iako se makrofite lako uočavaju na terenu, način modelovanja ekološkog statusa primenjen u ovom radu je relativno brza metodologija, što je jedna od važnih prednosti primene u modelovanju ekološkog statusa rečnih ekosistema.

Primenom podataka o zastupljenosti makrofita eliminiše se statistički šum (engl. *statistical noise*) brzine rečnog toka koji je važan faktor pri formiranju zajednica makrofita u Dunavu, i lotičkim sistemima uopšte (Janauer i saradnici, 2010). Brzina rečnog toka utiče na zastupljenost vodenih biljaka fizičkim pomeranjem vrsta, pri čemu se sastav vrsta menja (Franklin i saradnici, 2008). Pri brzini rečnog toka od 1m/s makrofite su zastupljene u zanemarljivoj količini, ili su potpuno odsutne (Franklin i saradnici, 2008). Birk i saradnici (2012) su u radu pokušali da dokažu zavisnost kvaliteta vodenog ekosistema i degradacije staništa duž rečnog toka Dunava primenom zastupljenosti makrofita. Za svoje istraživanje koristili su podatke prikupljene tokom Joint Danube Survey 2 istraživanja (Liska i saradnici, 2008) i utvrdili povezanost velikog broja makrofita sa njihovom tolerantnošću na prosece eutrofizacije (Birk i saradnici, 2012).

Vrste makrofita koje je analiza osetljivosti u ovom radu prepoznala kao indikatorske vrste uglavnom su i vrste tolerantne na eutrofizaciju sa širokom ekološkom valencom. Vrednosti ekološke valence za ključne indikatorske vrste za nitratne anjone znatno su šire u poređenju ekološkim valencama ostalih vrsta.

Na osnovu vrednosti MIR indeksa (engl. *Macrophyte Index for Rivers*) sve ključne indikatorske vrste svrstane su u vrste tolerantne na nivoje eutrofnosti. U radu Szoszkiewicz i saradnici (2020) MIR indeks se pokazao kao dobar pokazatelj različitih hemijskih nutrijentnih specija, uključujući i nitratne i ortofosfatne anjone. Sa druge strane, ključne indikatorske vrste za ortofosphate imale su blago povišene vrednosti STR indeksa (engl. *Species Trophic Rank*) u poređenju sa drugim vrstama.

Vrednosti STR indeksa su ukazivale na mezo-eutrofan kvalitet voda što ukazuje da se prisustvo ortofosfata bolje prediktuje pomoću vrsta tolerantnih na eutrofikacione procese.

U radovima (Gebler i saradnici, 2017; 2018) se navodi da se makrofite mogu smatrati indikatorima ekološke degradacije reka prouzrokovane kompleksom faktora trofičnosti koji nisu neophodno međusobno zavisni. Osim manjeg broja izuzetaka, u indikatorske vrste ubrajaju se submerzne vrste kao što su *Potamogeton crispus L.*, *Potamogeton lucens L.* i višegodišnje emerzne vrste kao što su *Amblystegium riparium L.*, *Glyceria fluitans L.*, *Glyceria maxima L.*, *Mentha aquatica L.* i *Typha angustifolia L.* Szoszkiewicz i saradnici (2017) prikazuju da su u nizijskim rekama u Poljskoj vrste sa širokom stopom trofičnosti uglavnom emerzne (amfibijiske) vrste. Slični rezultati objavljeni su i u radu Birk i saradnici (2012) za vrste *Potamogeton sp.* čije prisustvo ukazuje na delove rečnog toka sa boljim ekološkim statusom. Submerzne vrste makrofita generalno imaju sposobnost apsorpcije fosfora (Zhang i saradnici, 2011; Christiansen i saradnici, 2016) i njihovo prisustvo je zavisno od koncentracije fosfora (PO_4^{3-}) u vodi (Sondergaard i saradnici, 2010). Procentualna zastupljenost ovih funkcionalnih grupa u litoralnim zonama jezera prepoznata je kao dobar i pouzdan pokazatelj indikatora kvaliteta voda (Kolada, 2014). Prisustvo emerznih vrsta makrofita vezuje se za vode sa povećanim sadržajem hranljivih materija i hlorofila-a, i dobri su pokazatelji mezotrofnih uslova staništa (Kolada, 2014).

Najviše vrednosti tačnosti procene modela, koje ukazuju na sposobnost modela da tačno odredi klasu ekološkog statusa rečnog ekosistema, izračunate su za model baziran na koncentracijama rastvorenog kiseonika. Na osnovu izmerenih koncentracija rastvorenog kiseonika neuronska mreža je u najvećem broju slučajeva tačno odredila II klasu ekološkog statusa.

Na svim lokalitetima na kojima je tačno procenjena II klasa ekološkog statusa detektovana je vrsta *Phragmites australis L.*, koju je analiza osetljivosti odredila kao jednu od 4 signifikantne vrste makrofita. Najveće odstupanje u proceni klase ekološkog statusa na osnovu koncentracije rastvorenog kiseonika zabeleženo je na lokalitetu JDS 41, na desnoj obali reke. Lokalitet JDS 41 nalazi se na 1103. km rečnog toka i pripada delu toka Dunava koji protiče kroz Srbiju, i mesto na kom se Velika Morava uliva u Dunav.

Na svim delovima rečnog toka na kojima je neuronska mreža tačno odredila III klasu ekološkog statusa na osnovu izmerenih koncentracija rastvorenog kiseonika i IV klasu ekološkog statusa na osnovu izmerenih koncentracija ortofosfatnih anjona, detektovana je vrsta *Ceratophyllum demersum L.*, te se može smatrati indikatorskom vrstom za navedene klase ekološkog statusa. Prisustvo vrste *Ceratophyllum demersum L.* ne ukazuje na određenu klasu ekološkog statusa na osnovu izmerenih koncentracija nitratnih anjona.

Na osnovu koncentracija rastvorenog kiseonika neuronska mreža je pokazala visok procenat tačnosti od čak 99.976%. Na osnovu vrednosti srednje apsolutne greške sva tri modela pokazala su dobre performanse. Za glavni deo rečnog toka model je uglavnom pokazivao jednaku distribuciju ili greške vezane za vrednosti ispitivanih varijabli. Izuzetak su predstavljali primeri uzorkovanja na pritokama reka ili nizvodno od ušća pritoka. Na tim lokalitetima model je češće prediktovao nižu (bolju) klasu ekološkog statusa. Ova činjenica se posebno odnosi na vrednosti ortofosfatnih anjona na ušćima pritoka reka Tise i Ardeš, što je ujedno i potencijalan uzrok nižih vrednosti Kappa indeksa za model baziran na koncentracijama ortofosfatnih anjona u poređenju sa modelima baziranim na koncentracijama rastvorenog kiseonika i nitratnih anjona.

Rezultati i diskusiona analiza primene modela veštačkih neuronskih mreža, i procene ekološkog statusa akvatičnih sistema otvaraju nova polja istraživačkih aktivnosti na širok spektar upravljanja i procene kvaliteta zaštite životne sredine, vodnih resursa,

fenomenom održivosti. Ovakav kompleksan, interdisciplinarni tip istraživanja osnov je strategije razvoja zaštite i unapređenja životne sredine, kako za kratkoročne, a posebno dugoročne mere, u okviru nove metodologije klastera životne sredine u pristupu Republike Srbije Evropskoj Uniji.

9. ZAKLJUČNA RAZMATRANJA

Na osnovu evaluacionih analiza rezultata prediktovanih klasa ekološkog statusa rečnog basena Dunava, prisustva makrofita, selektovanih fizičko hemijskih parametara, primenom modela veštačkih neuronskih mreža sa propagacijom signala unapred definisana su sledeća zaključna razmatranja.

Modelovanje klasa ekološkog statusa po prvi put je primenjeno u istraživanju doktorske disertacije bazirano na zastupljenosti makrofita, kao indikatora trofičnosti vodnog ekosistema u funkcionalnoj interkorelaciji sa koncentracijom nivoima slobodnog rastvorenog kiseonika i anjonima nitrata i ortofosfata.

Poseban izazov je bio da se u uslovima malog broja primera za trening mreže obuče tako da zadrže osobinu generalizacije i dobre predikcije u test primerima. Zato je proces treniranja ponavljan tako da se svaki primer iz trening skupa jednom koristi za validaciju a svi ostali za treniranje. Primenjeni prediktivni model neuronskih mreža za procenu kvaliteta površinskih voda, pokazao je vrlo dobre performanse za ceo tok Dunava.

Od 64 analiziranih vrsta makrofita, 28 su selektovane analizom osetljivosti kao signifikantni indikatori kvaliteta voda za najmanje jednu od izlaznih ekoloških varijabli. Indikatorske vrste makrofita dominantno pripadaju eutrofno-tolerantnim, submerznim ili emerznim vrstama sa širokom ekološkom valencijom, odnosno amplitudom.

Indikatorske vrste makrofita dominantno pripadaju eutrofno-tolerantnim, submerznim ili emerznim vrstama sa širokom ekološkom valencijom, odnosno amplitudom. Razvijeni model veštačkih neuronskih mreža ima izuzetno važan ekološki, praktičan i upravljački značaj u proceni ekološkog statusa svih rečnih ekosistema podložnim zagađenju različitim nutrijentima, uz ograničenja na delove rečnog toka na kojima je brzina rečnog toka pogodna za razvoj makrofita.

Ovaj tip visoko interdisciplinarnih istraživanja biološkog i hemijskog statusa kvaliteta voda i primene veštačkih neuronskih mreža po prvi put je primenjen u istraživačkim aktivnostima realizovanim u okviru doktorske disertacije.

Postavljene hipoteze, definisani zadaci i ciljevi u okviru doktorske disertacije u potpunosti su i uspešno realizovani.

Jedinstveni specifičan doprinos doktorske teze *Procena ekostatusa rečnih sistema na primeru dunavskog basena primenom modela veštačkih neuronskih mreža* je kreiranje modela veštačkih neuronskih mreža koji uspešno prediktuje klase ekološkog statusa rečnih sistema na osnovu sastava makrofita na mapiranom lokalitetu dela rečnog toka, definisanih selektovanim ključnim fizičko-hemijskim parametrima (koncentracioni nivoi kiseonika, nitratni i ortofosfatni anjoni).

Razvijeni model veštačkih neuronskih mreža je fundamentalna platforma budućih istraživanja i imaće široku primenu za procenu i predikciju klasa kvaliteta rečnih sistema. Rezultati, analiza i diskusija primene modela veštačkih neuronskih mreža i procene ekološkog statusa akvatičnih sistema otvaraju nova polja istraživačkih aktivnosti na širok spektar upravljanja i procene kvaliteta zaštite životne sredine i vodnih resursa, kao i fenomena održivosti. Visoko interdisciplinarni tip istraživanja osnov je strategije razvoja zaštite i unapređenja životne sredine, kako za kratkoročne, a posebno dugoročne mere, u okviru nove metodologije klastera životne sredine u pristupu Republike Srbije Evropskoj Uniji.

LITERATURA:

1. Agarap, A. F. (2018). Deep learning using rectified linear units (relu). *arXiv preprint arXiv:1803.08375*.
2. Alagić, S. Č., Maluckov, B. S., & Riznić, D. T. (2013). Phytoremediation as an environmental friendly method for POPs removal from contaminated soils. In *International Scientific conference on impact of climate change on the environment and the economy, Belgrade, April* (Vol. 2224, p. 218).
3. Antanasićević, D. (2014). Modelovanje indikatora kvaliteta životne sredine primenom veštačkih neuronskih mreža. *Univerzitet u Beogradu*
4. Antonijević, M. M., Dimitrijević, M. D., Milić, S. M., & Nujkić, M. M. (2012). Metal concentrations in the soils and native plants surrounding the old flotation tailings pond of the Copper Mining and Smelting Complex Bor (Serbia). *Journal of Environmental Monitoring*, 14(3), 866-877.
5. Appenroth, K. J., Krech, K., Keresztes, A., Fischer, W., & Koloczek, H. (2010). Effects of nickel on the chloroplasts of the duckweeds Spirodela polyrhiza and Lemna minor and their possible use in biomonitoring and phytoremediation *Chemosphere*, 78(3), 216-223.
6. Arsić, S., Nikolić, D., Mihajlović, I., Fedajev, A., & Živković, Ž. (2018). A new approach within ANP-SWOT framework for prioritization of ecosystem management and case study of National Park Djerdap, Serbia. *Ecological Economics*, 146, 85-95.
7. Arle, J., Blondzik, K., Claussen, U., Duffek, A., Grimm, S., Hilliges, F., ... & Wolter, R. (2014). Water Resource Management in Germany-Part 2-Water Quality. *Federal environmental agency*, 135.
8. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000). Artificial neural networks in hydrology. I: Preliminary concepts. *Journal of Hydrologic Engineering*, 5(2), 115-123.
9. Aulio, K. (1986). Aquatic macrophytes as indicators of heavy metal pollution. *Publications of the Water Research Institute*, 68, 171-174.
10. Babić-Mladenović, M., & Ninković, D. (2009). Hidromorfološke promene i upravljanje vodama/Hydromorphological alterations within water management. *Vodoprivreda*.
11. Baboo, S. S., & Shereef, I. K. (2010). An efficient weather forecasting system using artificial neural network. *International journal of environmental science and development*, 1(4), 321
12. Balaban, A., & Constantinescu, E. (2009). Physico-chemical Studies on the Pollution with Phenols and Phosphates of the Danube Waters in Braila. *Rev. Chim.(Bucharest)*, 60, 316.
13. Barlow, H. B. (1989). Unsupervised learning. *Neural computation*, 1(3), 295-311.
14. Batinić, B. (2015). Model za predviđanje količine ambalažnog i biorazgradivog otpada primenom neuronskih mreža, Doktorska disertacija, *Univerzitet u Novom Sadu*.

15. Birk, S., Van Kouwen, L., & Willby, N. (2012). Harmonising the bioassessment of large rivers in the absence of near-natural reference conditions—a case study of the Danube River. *Freshwater Biology*, 57(8), 1716-1732.
16. Block, H. D. (1962). The perceptron: A model for brain functioning. i. *Reviews of Modern Physics*, 34(1), 123.
17. Bornette, G., & Puijalon, S. (2011). Response of aquatic plants to abiotic factors: a review. *Aquatic Sciences*, 73(1), 1-14.
18. Campos, V. M., Merino, I., Casado, R., Pacios, L. F., & Gómez, L. (2008). Phytoremediation of organic pollutants. *Spanish Journal of Agricultural Research*, (1), 38-47.
19. Canfield Jr, D. E., Langeland, K. A., Maceina, M. J., Haller, W. T., Shireman, J. V., & Jones, J. R. (1983). Trophic state classification of lakes with aquatic macrophytes. *Canadian Journal of Fisheries and Aquatic Sciences*, 40(10), 1713-1718.
20. Caraco, N. F., & Cole, J. J. (2002). Contrasting impacts of a native and alien macrophyte on dissolved oxygen in a large river. *Ecological Applications*, 12(5), 1496-1509.
21. Cedergreen, N., Spliid, N. H., & Streibig, J. C. (2004). Species-specific sensitivity of aquatic macrophytes towards two herbicide. *Ecotoxicology and Environmental Safety*, 58(3), 314-323.
22. Cedergreen, N., Abbaspoor, M., Sørensen, H., & Streibig, J. C. (2007). Is mixture toxicity measured on a biomarker indicative of what happens on a population level? A study with *Lemna minor*. *Ecotoxicology and Environmental Safety*, 67(3), 323-332.
23. Chambers, P. A., & Kalff, J. (1987). Light and nutrients in the control of aquatic plant community structure. I. In situ experiments. *The Journal of Ecology*, 611-619.
24. Chambers, P. A., Lacoul, P., Murphy, K. J., & Thomaz, S. M. (2007). Global diversity of aquatic macrophytes in freshwater. In *Freshwater Animal Diversity Assessment* (pp. 9-26). Springer, Dordrecht.
25. Cherif, M., Mgaidi, A., Ammar, N., Vallée, G., & Fürst, W. (2000). A new investigation of aqueous orthophosphoric acid speciation using Raman spectroscopy. *Journal of solution chemistry*, 29(3), 255-269.
26. Chon, T. S., Park, Y. S., Moon, K. H., & Cha, E. Y. (1996). Patternizing communities by using an artificial neural network. *Ecological modelling*, 90(1), 69-78.
27. Choi, J. W., Han, J. H., Park, C. S., Ko, D. G., Kang, H. I., Kim, J. Y., ... & An, K. G. (2015). Nutrients and sestonic chlorophyll dynamics in Asian lotic ecosystems and ecological stream health in relation to land-use patterns and water chemistry. *Ecological Engineering*, 79, 15-31.
28. Christiansen, N. H., Andersen, F. Ø., & Jensen, H. S. (2016). Phosphate uptake kinetics for four species of submerged freshwater macrophytes measured by a ³³P phosphate radioisotope technique. *Aquatic botany*, 128, 58-67.
29. Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and psychological measurement*, 20(1), 37-46.

30. Crawley, J., Farnsworth, T., Flynn, C., & White, C. (2007). *U.S. Patent Application No. 11/193,090*.
31. Cunningham, S. D., Shann, J. R., Crowley, D. E., & Anderson, T. A. (1997). Phytoremediation of contaminated water and soil.
32. Cvetković, D., & Despotović, M. (2011). Application of SBR systems for the treatment of municipal wastewater with parametric model of plant. *Vodoprivreda (Serbia)*.
33. Dabović, M. M., & Tartalja, I. I. (2017). Duboke konvolucijske neuronske mreže—koncepti i aktuelna istraživanja.
34. Davies, B. R., & Walker, K. F. (1986). River systems as ecological units. An introduction to the ecology of river systems. In *The ecology of river systems* (pp. 1-8). Springer, Dordrecht.
35. Dawson, C.W., Wilby, R.L., (2001) Hydrological modelling using artificial neural networks *Progress in Physical Geography*, 25 (1) , 80–10
36. Deelman, E., Singh, G., Su, M. H., Blythe, J., Gil, Y., Kesselman, C., ... & Laity, A. (2005). Pegasus: A framework for mapping complex scientific workflows onto distributed systems. *Scientific Programming*, 13(3), 219-237.
37. Deelman, E., Gannon, D., Shields, M., & Taylor, I. (2009). Workflows and e-Science: An overview of workflow system features and capabilities. *Future generation computer systems*, 25(5), 528-540.
38. De Roure, D., Goble, C., & Stevens, R. (2009). The design and realisation of the Experimentmy Virtual Research Environment for social sharing of workflows. *Future Generation Computer Systems*, 25(5), 561-567.
39. Directive, W. F. (2000). Water Framework Directive. *Journal reference OJL*, 327, 1-73.
40. Directive, E. U. W. (1991). Council Directive of 21. May 1991 concerning urban waste water treatment (91/271/EEC). *J. Eur. Commun*, 34, 40.
41. Dodds, W. K. (2007). Trophic state, eutrophication and nutrient criteria in streams. *Trends in ecology & evolution*, 22(12), 669-676.
42. Dogan, E., Sengorur, B., & Koklu, R. (2009). Modeling biological oxygen demand of the Melen River in Turkey using an artificial neural network technique. *Journal of Environmental Management*, 90(2), 1229-1235.
43. Dragan, P. D. (2010). Primena fuzzy logike i veštačkih neuronskih mreža u procesu donošenja odluke organa saobraćajne podrške. *Vojnotehnički glasnik*, 58(3).
44. Drliča, D., Dalmacija, B., Vukić, L., & Zorić, S. (2016). Biološko uklanjanje amonijum jona iz vode za piće. *Glasnik hemičara, tehnologa i ekologa Republike Srpske*, 8(12).
45. Duran, M. (2006). Monitoring Water Quality Using Benthic Macroinvertebrates and Physicochemical Parameters of Behzat Stream in Turkey. *Polish Journal of Environmental Studies*, 15(5).
46. Dzigurski, D. Nikolic, Lj, Ljevnaic-Masic, B. (2016), Vegetation of the Hydrochari-Lemnetae and Potametea classes in the Danube-Tisza-Danube hydrosystem (Serbia), Contemporary problems of ecology, Volume: 9, Issue: 3, 329-341

47. Đorđević, S. Đ., & Dražić, V. J. (2005). *Fizička hemija*. Tehnološko-metalurški fakultet Univerziteta.
48. Ehret, A., Hochstuhl, D., Gianola, D., & Thaller, G. (2015). Application of neural networks with back-propagation to genome-enabled prediction of complex traits in Holstein-Friesian and German Fleckvieh cattle. *Genetics Selection Evolution*, 47(1), 1-9.
49. Ellison, A. M., Osterweil, L. J., Clarke, L., Hadley, J. L., Wise, A., Boose, E., ... & Riseman, E. (2006). Analytic webs support the synthesis of ecological data sets. *Ecology*, 87(6), 1345-1358.
50. Engloner, A. I. (2012). Alternative ways to use and evaluate Kohler's ordinal scale to assess aquatic macrophyte abundance. *Ecological Indicators*, 20, 238-243.
51. Ensign, S. H., & Doyle, M. W. (2006). Nutrient spiraling in streams and river networks. *Journal of Geophysical Research: Biogeosciences*, 111(G4).
52. Eslamian, S., & Lavaei, N. (2009). Modelling nitrate pollution of groundwater using artificial neural network and genetic algorithm in an arid zone. *International journal of water*, 5(2), 194-203.
53. Feijoó, C., Giorgi, A., & Ferreiro, N. (2011). Phosphate uptake in a macrophyte-rich Pampean stream. *Limnologica*, 41(4), 285-289.
54. Ferreira, M. T., Albuquerque, A., Aguiar, F. C., & Catarino, L. F. (2001). Seasonal and yearly variations of macrophytes in a Southern Iberian River. *Internationale Vereinigung für theoretische und angewandte Limnologie: Verhandlungen*, 27(7), 3833-3837.
55. Fomin, A. (1989). *Untersuchungen zur Schwermetallbelastung höherer Pflanzen: physiologische und ultrastrukturelle Studien zur Wirkung von Quecksilber und Spirodela polyrhiza*, Doktorska disertacija.
56. Forsström, J. J., & Dalton, K. J. (1995). Artificial neural networks for decision support in clinical medicine. *Annals of medicine*, 27(5), 509-517.
57. Franklin, P., Dunbar, M., & Whitehead, P. (2008). Flow controls on lowland river macrophytes: a review. *Science of the Total Environment*, 400(1-3), 369-378.
58. Fressl, J. (2010). *Utjecaj emergne vegetacije na sastav zooplanktona i epifitona u rukavcima rijeke Krapine* (Doctoral dissertation, University of Zagreb. Faculty of Science. Department of Biology).
59. Gebler, D., Kayzer, D., Szoszkiewicz, K., & Budka, A. (2014). Artificial neural network modelling of macrophyte indices based on physico-chemical characteristics of water. *Hydrobiologia*, 737(1), 215-224.
60. Giosan, L., Donnelly, J. P., Vespremeanu, E., Bhattacharya, J. P., Olariu, C., & Buonaiuto, F. S. (2005). River delta morphodynamics: Examples from the Danube delta. *Water*, 10(1), 4.
61. Gomolka, Z., Twarog, B., Zeslawska, E., Lewicki, A., & Kwater, T. (2018). Using Artificial Neural Networks to Solve the Problem Represented by BOD and DO Indicators. *Water*, 10(1), 4.
62. Gonta, M., Duca, G., Matveevici, V., Iambartv, V., & Mocanu, L. (2014). Textile waste water treatment of dyes by combining the coagulation and catalytic oxidation

- with hydrogen peroxide methods. In *Management of Water Quality in Moldova* (pp. 197-208). Springer, Cham.
63. Grbavčić, S. Ž. (2014). *Proizvodnja mikrobnih lipaza i proteaza kao aditiva u formulacijama detergenata*, Doktorska disertacija, Univerzitet u Beogradu, Tehnološko-metalurški fakultet).
64. Gries, C., & Porter, J. H. (2011). Moving from custom scripts with extensive instructions to a workflow system: use of the Kepler workflow engine in environmental information management. In *Proceedings of the Environmental Information Management Conference 2011 (EIM 2011)*, 70-75. University of California.
65. Guégan, J.F., Lek, S., Oberdorff, T. (1998),, Energy availability and habitat heterogeneity predict global riverine fish diversity Nature, 391, 382–38
66. Hall, Robert O., Tank, Jennifer L.. Baker, Michelle A, Marshall, Emma J..Hotchkiss, Erin R.) (2016), Metabolism, Gas Exchange, and Carbon Spiraling in Rivers ECOSYSTEMS Volume: 19 Issue: 1, 73-86
67. Hanselman. (2004). D, Littlefield B. *Mastering MATLAB7*.
68. Haury, J., Peltre, M. C., Trémolières, M., Barbe, J., Thiébaut, G., Bernez, I., & Dutartre, A. (2006). A new method to assess water trophy and organic pollution—the Macrophyte Biological Index for Rivers (IBMR): its application to different types of river and pollution. In *Macrophytes in aquatic ecosystems: From biology to management* , 153-158. Springer, Dordrecht.
69. Haykin, S., (1999) Neural Networks: A Comprehensive Foundation Prentice Hall Upper Saddle River, New Jersey
70. Hecht-Nielsen, R. (1992). Theory of the backpropagation neural network. In *Neural networks for perception*, 65-93. Academic Press.
71. Hogeweg, P. (1988). Cellular automata as a paradigm for ecological modeling. *Applied mathematics and computation*, 27(1), 81-100.
72. Holmes N. (2010) The Development and Application of Mean Trophic Rank (MTR). In: Hurford C., Schneider M., Cowx I. (eds) Conservation Monitoring in Freshwater Habitats. Springer, Dordrecht
73. Hood, J. L. A. (2012). The role of submersed macrophytes in river eutrophication and biogeochemical nutrient cycling.
74. ICPDR. (2005). Danube basin analysis (EU Water Framework Directive roof report 2004).
75. Ilijević, K. (2015). Procena i prognoza ekohemijskog statusa reka Srbije uz optimizaciju i evaluaciju metoda za statističku obradu baza podataka dugoročnog monitoringa, Doktorska disertacija, Univerzitet u Beogradu-Hemski fakultet).
76. Janauer, G.A. (2001), Is what has been measured of any direct relevance to the success of the macrophyte in its particular environment? Scientific and legal aspects of biological monitoring in freshwater. O. Ravera (Ed.), J.Limnol. 60(1), 33-38
77. Janauer, G. A., Schmidt-Mumm, U., & Schmidt, B. (2010). Aquatic macrophytes and water current velocity in the Danube River. *Ecological Engineering*, 36(9), 1138-1145.

78. Janauer, G. A., Schmidt, B., & Schmidt-Mumm, U. (2014). Macrophytes in the Danube River. In *The Danube River Basin*, 341-358. Springer, Berlin, Heidelberg.
79. Jiang, G. J., Fan, S. Z., Abbod, M. F., Huang, H. H., Lan, J. Y., Tsai, F. F., ... & Jen, K. K. (2015). Sample entropy analysis of EEG signals via artificial neural networks to model patients' consciousness level based on anesthesiologists experience. *BioMed research international*, 2015.
80. Jokić, A. I., Grahovac, J. A., Dodić, J. M., Dodić, S. N., Popov, S. D., Zavargo, Z. Z., & Vučurović, D. G. (2012). Modelovanje alkoholne fermentacije gustog soka šećerne repe primenom veštačkih neuronskih mreža. *Hemisika industrija*, 66, 211-221.
81. Johnson, B. L., Richardson, W. B., & Naimo, T. J. (1995). Past, present, and future concepts in large river ecology. *BioScience*, 45(3), 134-141.
82. Jones, R. C., & Adams, M. S. (1982). Seasonal variations in photosynthetic response of algae epiphytic on *Myriophyllum spicatum* L. *Aquatic Botany*, 13, 317-330.
83. Jusik, S., Szoszkiewicz, K., Kupiec, J. M., Lewin, I., & Samecka-Cymerman, A. (2015). Development of comprehensive river typology based on macrophytes in the mountain-lowland gradient of different Central European ecoregions. *Hydrobiologia*, 745(1), 241-262.
84. Kail, J., Brabec, K., Poppe, M., & Januschke, K. (2015). The effect of river restoration on fish, macroinvertebrates and aquatic macrophytes: a meta-analysis. *Ecological Indicators*, 58, 311-321.
85. Kaisarevic, S., Lübecke-von Varel, U., Orcic, D., Streck, G., Schulze, T., Pogrmic, K., & Kovacevic, R. (2009). Effect-directed analysis of contaminated sediment from the wastewater canal in Pancevo industrial area, Serbia. *Chemosphere*, 77(7), 907-913.
86. Kalteh,A.M. , P. Hjorth, R. Berndtsson (2008) Review of the self-organizing map (SOM) approach in water resources: Analysis, modelling and application Department of Water Resources Engineering, Lund University, P. O. Box 118, S-221 00 Lund, Sweden
87. Kaplar, A., Smić, M., & Kovačević, A. (2017). Artificial General Intelligence Approach for Reasoning in Clinical Decision Support.
88. Kang, L., Di, L., Deng, M., Yu, E., & Xu, Y. (2016, July). Forecasting vegetation index based on vegetation-meteorological factor interactions with artificial neural network. In *2016 Fifth International Conference on Agro-Geoinformatics (Agro-Geoinformatics)*; (1-6.), IEEE.
89. Kernighan, B. W., & Ritchie, D. M. (1998). *The C programming language*. Prentice Hall.
90. Kittler, J., Zor, C., Kaloskampis, I., Hicks, Y., & Wang, W. (2018). Error sensitivity analysis of Delta divergence-a novel measure for classifier incongruence detection. *Pattern Recognition*, 77, 30-44.
91. Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *1412.6980*.

92. Kiurski-Milošević, J. (2015). Model procene kvaliteta podzemne vode sa povećanim sadržajem arsena primenom fazi logike. Doktorska disertacija, *Univerzitet u Novom Sadu*.
93. Kiurski-Milosevic J., Vojinovic-Miloradov M., Ralevic N.: Fuzzy model for determination and assessment of groundwater quality in the city of Zrenjanin, Serbia, Hemija i industrija, (2015), vol. 69 br.1, 17-28
94. Kolada, A. (2014). The effect of lake morphology on aquatic vegetation development and changes under the influence of eutrophication. *Ecological Indicators*, 38, 282-293.
95. Kolarević, S., Kračun-Kolarević, M., Kostić, J., Slobodnik, J., Liška, I., Gačić, Z., & Vuković-Gačić, B. (2016). Assessment of the genotoxic potential along the Danube River by application of the comet assay on haemocytes of freshwater mussels: The Joint Danube Survey 3. *Science of the Total Environment*, 540, 377-385.
96. Krtolica, I., Cvijanović, D., Obradović, Đ., Novković, M., Milošević, D., Savić, D., & Radulović, S. (2021). Water quality and macrophytes in the Danube River: Artificial neural network modelling. *Ecological Indicators*, 121, 107076.
97. Kriesel, D. (2007). A brief introduction on neural networks.
98. Khalil, B., Quarda T.B.M.J., St Hilaire, A., Chebana, F., (2010) A statistical approach for the rationalization of water quality indicators in surface water quality monitoring networks, *J.Hydrol.* 386, 173-185
99. Kuhar, U., Germ, M., Gaberščik, A., & Urbanič, G. (2011). Development of a River Macrophyte Index (RMI) for assessing river ecological status. *Limnologica*, 41(3), 235-243.
100. Kuo, J. T., Hsieh, M. H., Lung, W. S., & She, N. (2007). Using artificial neural network for reservoir eutrophication prediction. *Ecological modelling*, 200(1-2), 171-177.
101. Ladislas, S., El-Mufleh, A., Gérante, C., Chazarenc, F., Andrès, Y., & Béchet, B. (2012). Potential of aquatic macrophytes as bioindicators of heavy metal pollution in urban stormwater runoff. *Water, Air, & Soil Pollution*, 223(2), 877-888.
102. Lancashire, L. J., Lemetre, C., & Ball, G. R. (2009). An introduction to artificial neural networks in bioinformatics—application to complex microarray and mass spectrometry datasets in cancer studies. *Briefings in bioinformatics*, 10(3), 315-329
103. Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *biometrics*, 159-174.
104. Lawrence, S., Giles, C. L., Tsoi, A. C., & Back, A. D. (1997). Face recognition: A convolutional neural-network approach. *IEEE transactions on neural networks*, 8(1), 98-113.
105. Lek, S., Delacoste, M., Baran, P., Dimopoulos, I., Lauga, J., & Aulagnier, S. (1996). Application of neural networks to modelling nonlinear relationships in ecology. *Ecological modelling*, 90(1), 39-52.
106. Lengyel, A., Héberger, K., Paksy, L., Bánádi, O., & Rajkó, R. (2004). Prediction of ozone concentration in ambient air using multivariate methods. *Chemosphere*, 57(8), 889-896.

107. Lencioni, V., Maiolini, B., Marziali, L., Lek, S., & Rossaro, B. (2007). Macroinvertebrate assemblages in glacial stream systems: a comparison of linear multivariate methods with artificial neural networks. *Ecological modelling*, 203(1-2), 119-131.
108. Linstrom, K. R., & Boye, A. J. (2005, August). A neural network prediction model for a psychiatric application. In Sixth International Conference on Computational Intelligence and Multimedia Applications (ICCIMA'05) (36-40). IEEE.
109. Literathy, P. (2006). Monitoring and assessment of oil pollution in the Danube River during the transnational Joint Danube Survey. *Water science and technology*, 53(10), 121-129
110. Long, J. R., Gregoriou, V. G., & Gemperline, P. J. (1990). Spectroscopic calibration and quantitation using artificial neural networks. *Analytical Chemistry*, 62(17), 1791-1797
111. Ludäscher, B., Lin, K., Bowers, S., Jaeger-Frank, E., Brodaric, B., & Baru, C. (2006). Managing scientific data: From data integration to scientific workflows. *Geoinformatics: Data to knowledge*, 397, 109.
112. Maier, H.R., Dandy G.C., (2000). Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications, *Environmental Modelling and Software*, 15, pp. 101–124
113. Maric, M., Antonijevic, M., & Alagic, S. (2013). The investigation of the possibility for using some wild and cultivated plants as hyperaccumulators of heavy metals from contaminated soil. *Environmental science and pollution research*, 20(2), 1181-1188.
114. Marićić, N. (2013). *Parcijalna nitrifikacija* (Doctoral dissertation, University of Zagreb. Faculty of Food Technology and Biotechnology. Department of Food Engineering. Laboratory for the Biological Waste Water Treatment.).
115. Martindale, C. (1991). *Cognitive psychology: A neural-network approach*. Thomson Brooks/Cole Publishing Co.
116. Mathews, B. P., & Diamantopoulos, A. (1994). Towards a taxonomy of forecast error measures a factor□comparative investigation of forecast error dimensions. *Journal of Forecasting*, 13(4), 409-416.
117. Maznah, W. W., & Makhloogh, A. (2015). Water quality of tropical reservoir based on spatio-temporal variation in phytoplankton composition and physico-chemical analysis. *International Journal of Environmental Science and Technology*, 12(7), 2221-2232.
118. Michener, W. K., & Jones, M. B. (2012). Ecoinformatics: supporting ecology as a data-intensive science. *Trends in ecology & evolution*, 27(2), 85-93.
119. Milanković, J. (2015). Dunav kao saobraćajna arterija i osovina razvoja u Republici Srbiji , Doktorska disertacija
120. Milošević, D., Čerba, D., Szekeres, J., Csányi, B., Tubić, B., Simić, V., & Paunović, M. (2016). Artificial neural networks as an indicator search engine: The visualization of natural and man-caused taxa variability. *Ecological indicators*, 61, 777-789.

121. Miljković, Z. (2007). Machine learning of intelligent mechatronic systems. *Tehnika-Mašinstvo*, 56(5), 1-14.
122. Mihajlović, I., Nikolić, Đ., Šrbac, N., & Živković, Ž. (2010). Statistical modelling in ecological management using the artificial neural networks. *Serbian Journal of Management*, 5(1), 39-50.
123. Mihajlovic, I., Fedajev, A. P. A., Nikolic, A. P. I., Zivkovic, Z., Mihajlović, I., & Živković, Ž. Nonlinear Statistical Methodology Applied on Modeling the Growth Correlation of Some Global Macroeconomic Parameters.
124. Mohsen, H., El-Dahshan, E. S. A., El-Horbaty, E. S. M., & Salem, A. B. M. (2018). Classification using deep learning neural networks for brain tumors. *Future Computing and Informatics Journal*, 3(1), 68-71.
125. Moss, B. R. (2009). *Ecology of fresh waters: man and medium, past to future*. John Wiley & Sons.
126. Mozejko, J., & Gniot, R. (2008). Application of neural networks for the prediction of total phosphorus concentrations in surface waters. *Polish Journal of Environmental Studies*, 17(3), 363-368.
127. Muhammad, I., Muhammad, A., Niaz, S., Shams, S., Khan, A., Khan, I., & Ullah, A. (2016). Physico-chemical analysis of river Swat at Batkhela district malakand, KPK Pakistan. *International Journal of Pure and Applied Zoology*, 4(1), 70-76.
128. Musa, K. H., Abdullah, A., & Al-Haiqi, A. (2016). Determination of DPPH free radical scavenging activity: application of artificial neural networks. *Food chemistry*, 194, 705-711.
129. Najah, A., Elshafie, A., Karim, O. A., & Jaffar, O. (2009). Prediction of Johor River water quality parameters using artificial neural networks. *European Journal of Scientific Research*, 28(3), 422-435.
130. Ochoa-Estopier, L. M., Jobson, M., & Smith, R. (2013). Operational optimization of crude oil distillation systems using artificial neural networks. *Computers & chemical engineering*, 59, 178-185.
131. O'Hare, M. T., Baattrup-Pedersen, A., Baumgarte, I., Freeman, A., Gunn, I. D., Lázár, A. N., ... & Bowes, M. J. (2018). Responses of aquatic plants to eutrophication in rivers: a revised conceptual model. *Frontiers in plant science*, 9, 451.
132. Onkal-Engin, G., Demir, I., & Engin, S. N. (2005). Determination of the relationship between sewage odour and BOD by neural networks. *Environmental Modelling & Software*, 20(7), 843-850.
133. Olaya-Marín, E. J., Martínez-Capel, F., & Vezza, P. (2013). A comparison of artificial neural networks and random forests to predict native fish species richness in Mediterranean rivers. *Knowledge and Management of Aquatic Ecosystems*, (409), 07.
134. Olden, J. D., Lawler, J. J., & Poff, N. L. (2008). Machine learning methods without tears: a primer for ecologists. *The Quarterly review of biology*, 83(2), 171-193.
135. Ostad-Ali-Askari, K., Shayannejad, M., & Ghorbanizadeh-Kharazi, H. (2017). Artificial neural network for modeling nitrate pollution of groundwater in marginal area of Zayandeh-rood River, Isfahan, Iran. *KSCE Journal of Civil Engineering*, 21(1), 134-140.

136. Oťahel'ová, H., Valachovic, M., & Hrvnák, R. (2007). The impact of environmental factors on the distribution pattern of aquatic plants along the Danube River corridor (Slovakia). *Limnologica*, 37(4), 290-302.
137. Pajević, S., Igić, R., Krstić, B., Vukov, D., Borišev, M., & Nikolić, N. (2005). Chemical compositions of aquatic macrophytes from the Danube-role in biomonitoring and bioremediation. In *Proceedings of the Balcan scientific conference of biology.-Plovdiv* (pp. 485-498).
138. Palialexis, A., Georgakarakos, S., Karakassis, I., Lika, K., & Valavanis, V. D. (2011). Prediction of marine species distribution from presence-absence acoustic data: comparing the fitting efficiency and the predictive capacity of conventional and novel distribution models. *Hydrobiologia*, 670(1), 241-266.
139. Park, J. E., Kim, H. S., Park, K. J., Choi, C. G., & Kim, S. J. (2015). Histogram analysis of amide proton transfer imaging to identify contrast-enhancing low-grade brain tumor that mimics high-grade tumor: increased accuracy of MR perfusion. *Radiology*, 277(1), 151-161.
140. Pekárová, P., Onderka, M., Pekár, J., Rončák, P., & Miklánek, P. (2009). Prediction of water quality in the Danube River under extreme hydrological and temperature conditions. *Journal of Hydrology and Hydromechanics*, 57(1), 3-15.
141. Perović, M. (2019). Procena uticaja i regionalne specifičnosti hidrogeohemijskih uslova na transformaciju azotnih jedinjenja u podzemnim vodama. Doktorska disertacija, *Univerzitet u Novom Sadu*.
142. Pešić, V., Krčmar, D., Dalmacija, B., Bečelić-Tomin, M., KerNez, Đ., Varga, N., & Slijepčević, N. Ocena kvaliteta vode reke Tise na osnovu hemijskih parametara kvaliteta. *Srpsko društvo za zaštitu voda*, 145.
143. Petrović, M. (2011). Basis of ANN and the importance of their application. *Zbornik radova Građevinskog fakulteta, Subotica*, (20), 47-55.
144. Petruzzella, A., Guariento, R. D., da Rocha Gripp, A., Marinho, C. C., Figueiredo-Barros, M. P., & de Assis Esteves, F. (2015). Herbivore damage increases methane emission from emergent aquatic macrophytes. *Aquatic Botany*, 127, 6-11.
145. Pravilnik o parametrima ekološkog i hemijskog statusa površinskih voda i parametrima hemijskog i kvantitativnog statusa podzemnih voda (2011). Službeni glasnik RS, br. 74/2011, Beograd
146. Predojević, D. (2017). Procena ekološkog statusa reke Zasavice na osnovu algoloških parametara. Doktorska disertacija, *Univerzitet u Beogradu*.
147. Rabrenović, M., Rabrenović, V., & Zoranović, U. (2006). Development of hyperbaric medicine. *Vojnosanitetski pregled*, 63(7), 667-671.
148. Rai, S. V., & Rajashekhar, M. (2014). Seasonal assessment of hydrographic variables and phytoplankton community in the Arabian Sea waters of Kerala, southwest coast of India. *Brazilian Journal of Oceanography*, 62(4), 279-289.
149. Raskin, I., & Ensley, B. D. (2000). *Phytoremediation of toxic metals*. John Wiley and Sons.
150. Recknagel, F. (1997). ANNA-Artificial Neural Network model for predicting species abundance and succession of blue-green algae. *Hydrobiologia*, 349(1), 47-57.

151. Relić, B. (2019). *Read classification using deep learning methods*. Doktorska disertacija, Fakultet elektrotehnike i računarstva, Sveučilište u Zagrebu.
152. Rigosi, A., Carey, C. C., Ibelings, B. W., & Brookes, J. D. (2014). The interaction between climate warming and eutrophication to promote cyanobacteria is dependent on trophic state and varies among taxa. *Limnology and Oceanography*, 59(1), 99-114.
153. Ritchie, D. M., Kernighan, B. W., & Lesk, M. E. (1988). *The C programming language*. Englewood Cliffs: Prentice Hall.
154. Robach, F., Thiébaut, G., Trémolières, M., & Muller, S. (1996). A reference system for continental running waters: plant communities as bioindicators of increasing eutrophication in alkaline and acidic waters in north-east France. *Hydrobiologia*, 340(1), 67-76.
155. Safranov, T., Berlinskyi, N., & Volkov, A. (2016). Water resources of Ukraine: usage, qualitative and quantitative assessment (with detail description of Odessa region).
156. Salski, A. (1992). Fuzzy knowledge-based models in ecological research. *Ecological modelling*, 63(1-4), 103-112.
157. Salt, D. E., Smith, R. D., & Raskin, I. (1998). Phytoremediation. *Annual review of plant biology*, 49(1), 643-668.
158. Saltelli, A., Ratto, M., Andres, T., Campolongo, F., Cariboni, J., Gatelli, D., ... & Tarantola, S. (2008). *Global sensitivity analysis: the primer*. John Wiley & Sons.
159. Santo, V., Ćavar, S., Sučić, H., & Santo, T. Koncentracije nitrata u vodi za ljudsku potrošnju i methemoglobinemija u Baranji, nekada i sada. *Voda i javna vodoopskrba*, 88.
160. Sarkar, A., & Pandey, P. (2015). River water quality modelling using artificial neural network technique. *Aquatic procedia*, 4, 1070-1077.
161. Saxe, J., & Berlin, K. (2015, October). Deep neural network based malware detection using two dimensional binary program features. In *2015 10th International Conference on Malicious and Unwanted Software (MALWARE)* (11-20). IEEE.
162. Scardi, M. (1996). Artificial neural networks as empirical models for estimating phytoplankton production. *Marine Ecology Progress Series*, 139, 289-299.
163. Schiemer, F., Guti, G., Keckeis, H., Staras, M., Welcomme, R. L., Petr, T., & Mekong River Commission. (2004). Ecological status and problems of the Danube River and its fish fauna: a review.
164. Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
165. Schmidt-Hieber, J. (2020). Nonparametric regression using deep neural networks with ReLU activation function. *Annals of Statistics*, 48(4), 1875-1897.
166. Schneider, S. (2007). Macrophyte trophic indicator values from a European perspective. *Limnologica*, 37(4), 281-289.
167. Schneider, S. C., Cara, M., Eriksen, T. E., Goreska, B. B., Imeri, A., Kupe, L. & Sarafiloska, E. V. (2014). Eutrophication impacts littoral biota in Lake Ohrid while water phosphorus concentrations are low. *Limnologica*, 44, 90-97.

168. Schneider, S., & Melzer, A. (2003). The Trophic Index of Macrophytes (TIM)—a new tool for indicating the trophic state of running waters. *International Review of Hydrobiology: A Journal Covering all Aspects of Limnology and Marine Biology*, 88(1), 49-67.
169. Slobodnik, J., Mrafkova, L., Carere, M., Ferrara, F., Pennelli, B., Schüürmann, G., & von der Ohe, P. C. (2012). Identification of river basin specific pollutants and derivation of environmental quality standards: A case study in the Slovak Republic. *TrAC Trends in Analytical Chemistry*, 41, 133-145.
170. Sparks, R. E., Bayley, P. B., Kohler, S. L., & Osborne, L. L. (1990). Disturbance and recovery of large floodplain rivers. *Environmental Management*, 14(5), 699-709.
171. Sremački, M., Obrovski, B., Petrović, M., Mihajlović, I., Dragičević, P., Radić, J., & Miloradov, M. V. (2020). Comprehensive environmental monitoring and assessment of protected wetland and lake water quality in Croatia and Serbia. *Environmental monitoring and assessment*, 192(3), 1-11.
172. Szilágyi, F., Ács, É., Borics, G., Halasi-Kovács, B., Juhász, P., Kiss, B.& Tóthmérész, B. (2008). Application of water framework directive in Hungary: development of biological classification systems. *Water Science and Technology*, 58(11), 2117-2125.
173. Szoszkiewicz, K., Ferreira, T., Korte, T., Baattrup-Pedersen, A., Davy-Bowker, J., & O'Hare, M. (2006). European river plant communities: the importance of organic pollution and the usefulness of existing macrophyte metrics. In *The ecological status of European rivers: Evaluation and intercalibration of assessment methods* (pp. 211-234). Springer, Dordrecht.
174. Silva, C. T., Freire, J., & Callahan, S. P. (2007). Provenance for visualizations: Reproducibility and beyond. *Computing in Science & Engineering*, 9(5), 82-89.
175. Seginer, I., Boulard, T., & Bailey, B. J. (1994). Neural network models of the greenhouse climate. *Journal of Agricultural Engineering Research*, 59(3), 203-216.
176. Shanmuganathan, S., Sallis, P., & Buckeridge, J. (2006). Self-organising map methods in integrated modelling of environmental and economic systems. *Environmental Modelling & Software*, 21(9), 1247-1256.
177. Shannon, C. E. (1949). *The Mathematical Theory of Communication, by CE Shannon (and Recent Contributions to the Mathematical Theory of Communication)*, W. Weaver. University of Illinois Press.
178. Sheela, K. G., & Deepa, S. N. (2013). Review on methods to fix number of hidden neurons in neural networks. *Mathematical Problems in Engineering*, 2013.
179. Simpson, E. H. (1949). Measurement of diversity. *nature*, 163(4148), 688-688.
180. Singh, O. V., & Jain, R. K. (2003). Phytoremediation of toxic aromatic pollutants from soil. *Applied microbiology and biotechnology*, 63(2), 128-135.
181. Sommerwerk, N., Bloesch, J., Paunović, M., Baumgartner, C., Venohr, M., Schneider-Jacoby, M. & Tockner, K. (2010). Managing the world's most international river: the Danube River Basin. *Marine and Freshwater*

182. Sondergaard, M., Johansson, L. S., Lauridsen, T. L., Jorgensen, T. B., Liboriussen, L., & Jeppesen, E. (2010). Submerged macrophytes as indicators of the ecological quality of lakes. *Freshwater Biology*, 55(4), 893-908.
183. Spence, D. H. N. (1982). The zonation of plants in freshwater lakes. *Advances in ecological research*, 12, 37-125.
184. Stamenković, S., Takić, Lj., (2014) Ecological status of the Danube in Serbia as a function of ammonium concentration, 1st International student conference, Bor, Srbija.
185. Stathopoulou, I. O., & Tsihrintzis, G. A. (2011). Appearance-based face detection with artificial neural networks. *Intelligent Decision Technologies*, 5(2), 101-111.
186. Stevanović, B. M., & Janković, M. M. (2001). *Ekologija biljaka: sa osnovama fiziološke ekologije biljaka*. NNK international.
187. Stockwell, D. R., & Noble, I. R. (1992). Induction of sets of rules from animal distribution data: a robust and informative method of data analysis. *Mathematics and computers in simulation*, 33(5-6), 385-390.
188. Stroustrup, B. (1997). The C++ Programming Language . Addison & Wesley. *Reading, Mass.*
189. Suzuki, K. (Ed.). (2011). *Artificial neural networks: methodological advances and biomedical applications*. BoD–Books on Demand.
190. Szoszkiewicz, K., Ferreira, T., Korte, T., Baattrup-Pedersen, A., Davy-Bowker, J., & O'Hare, M. (2006). European river plant communities: the importance of organic pollution and the usefulness of existing macrophyte metrics. In *The ecological status of European rivers: Evaluation and intercalibration of assessment methods* (pp. 211-234). Springer, Dordrecht.
191. Szoszkiewicz, K., Budka, A., Pietruczuk, K., Kayzer, D., & Gebler, D. (2017). Is the macrophyte diversification along the trophic gradient distinct enough for river monitoring?. *Environmental monitoring and assessment*, 189(1), 1-14.
192. Shah, M., Hashmi, H. N., Ali, A., & Ghumman, A. R. (2014). Performance assessment of aquatic macrophytes for treatment of municipal wastewater. *Journal of Environmental Health Science and Engineering*, 12(1), 1-12.
193. Sheoran, A. S. (2017). Management of acidic mine waste water by constructed wetland treatment systems: a bench scale study. *European Journal of Sustainable Development*, 6(2), 245-245.
194. Sommerwerk, N., Bloesch, J., Paunović, M., Baumgartner, C., Venohr, M., Schneider-Jacoby, M., ... & Tockner, K. (2010). Managing the world's most international river: the Danube River Basin. *Marine and Freshwater Research*, 61(7), 736-748.
195. Snelder, T. H., Biggs, B. J., & Weatherhead, M. A. (2004). Nutrient concentration criteria and characterization of patterns in trophic state for rivers in heterogeneous landscapes 1. *Journal of the American Water Resources Association*, 40(1), 1-13.
196. Szkuta, B. R., Sanabria, L. A., & Dillon, T. S. (1999). Electricity price short-term forecasting using artificial neural networks. *IEEE transactions on power systems*, 14(3), 851-857.

197. Šiljić Tomić, A. N. (2018). *Modelovanje kiseoničnih parametara kvaliteta površinskih voda primenom veštačkih neuronskih mreža*. Doktorska disertacija, Univerzitet u Beogradu-Tehnološko-metalurški fakultet.
198. Talib, A., Abu Hasan, Y., & Abdul Rahman, N. (2009, July). Predicting biochemical oxygen demand as indicator of river pollution using artificial neural networks. In *18th World IMACS/MODSIM Congress, Cairns, Australia* (pp. 13-17).
199. Teodorović, I., Knežević, V., Tunić, T., Čučak, M., Lečić, J. N., Leovac, A., & Tumbas, I. I. (2012). *Myriophyllum aquaticum* versus *Lemna minor*: sensitivity and recovery potential after exposure to atrazine. *Environmental Toxicology and Chemistry*, 31(2), 417-426.
200. Thawornwong, S., & Enke, D. (2004). The adaptive selection of financial and economic variables for use with artificial neural networks. *Neurocomputing*, 56, 205-232.
201. Todić, D. (2016). Institucionalni aspekti saradnje država u slivu reke Dunav, EU integracije i Republika Srbija. *Dunavska strategija Evropske unije u 21. veku*, 181.
202. Tomović, J., Paunović, M., Atanacković, A., Marković, V., Gačić, Z., Csányi, B., & Simić, V. (2014). Biotic typology of the Danube River based on distribution of mollusc fauna as revealed by the Second Joint Danube Survey (2007). *Acta zoologica bulgarica*, 66(4), 527-537.
203. Trajković, F., Stošić, I., Đogo Mračević, S., & Krstić, M. Z. (2016). Određivanje hemijskih pokazatelja kvaliteta površinskih voda u uzorcima Save, Dunava i Topčiderske reke. *Medicinski podmladak*, 67(3).
204. Tremp, H., & Kohler, A. (1995). The usefulness of macrophyte monitoring-systems, exemplified on eutrophication and acidification of running waters. *Acta Botanica Gallica*, 142(6), 541-550.
205. Tunić, T. (2015). Razvoj testova inhibicije rasta vrsta roda *Myriophyllum* L. 1754 (Saxifragales, Haloragaceae) za potrebe ekološke procene rizika od herbicida i kontrole kvaliteta sedimenta. Doktorska disertacija, *Univerzitet u Novom Sadu*.
206. Ukrainy, C. M. Natsionalna dopovid pro yakist pytnoi vody ta stan pytnoho vodopostachannia v Ukraini u 2015 r.[National report on the quality of potable water and drinking water supply in Ukraine in 2015. The official site of the Ministry of Regional Development of Ukraine].
207. Varga, P., Abraham, M., & Simor, J. (1990). Water quality of the Danube in Hungary and its major determining factors. *Water Science and Technology*, 22(5), 113-118.
208. Vastag, G., Apostolov, S., Perišić-Janjić, N., & Matijević, B. (2013). Multivariate analysis of chromatographic retention data and lipophilicity of phenylacetamide derivatives. *Analytica Chimica Acta*, 767, 44-49.
209. Vogel, B., Bernerth, H., Boyanovski, B., Gulyas, P., Janauer, G., Kavka, G. & Tobias, W. (2004). Ecological status of the Danube river—evaluation results from the Danube Survey 2001. *Monitoring Tailor-Made IV*, 291.

210. Volta, C., Laruelle, G. G., Arndt, S., & Regnier, P. (2016). Linking biogeochemistry to hydro-geometrical variability in tidal estuaries: a generic modeling approach. *Hydrology and Earth System Sciences*, 20(3), 991-1030.
211. Vukov, D., Ilić, M., Ćuk, M., Igić, R., & Janauer, G. A. (2017). The relationship between habitat factors and aquatic macrophyte assemblages in the Danube River in Serbia. *Archives of Biological Sciences*, 69(3), 427-437.
212. Xing, W., Wu, H., Hao, B., Huang, W., & Liu, G. (2013). Bioaccumulation of heavy metals by submerged macrophytes: looking for hyperaccumulators in eutrophic lakes. *Environmental science & technology*, 47(9), 4695-4703.
213. Wagh, V., Panaskar, D., Muley, A., Mukate, S., & Gaikwad, S. (2018). Neural network modelling for nitrate concentration in groundwater of Kadava River basin, Nashik, Maharashtra, India. *Groundwater for Sustainable Development*, 7, 436-445.
214. Wanke, D. (2011). The ABA-mediated switch between submersed and emersed life-styles in aquatic macrophytes. *Journal of plant research*, 124(4), 467-475.
215. Wu, P., Qin, B., & Yu, G. (2016). Estimates of long-term water total phosphorus (TP) concentrations in three large shallow lakes in the Yangtze River basin, China. *Environmental Science and Pollution Research*, 23(5), 4938-4948.
216. Wang, S. C. (2003). Artificial neural network. In *Interdisciplinary computing in java programming* (pp. 81-100). Springer, Boston, MA.
217. White, H. (1988, July). Economic prediction using neural networks: The case of IBM daily stock returns. In *ICNN* (Vol. 2, pp. 451-458).
218. Wilhm, J. L., & Dorris, T. C. (1968). Biological parameters for water quality criteria. *Bioscience*, 477-481.
219. Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate research*, 30(1), 79-82.
220. Wilson, H., & Recknagel, F. (2001). Towards a generic artificial neural network model for dynamic predictions of algal abundance in freshwater lakes. *Ecological Modelling*, 146(1-3), 69-84.
221. WHO, G. (2011). Guidelines for drinking-water quality. *World Health Organization*, 216, 303-304.
222. Wong, T. T. (2015). Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation. *Pattern Recognition*, 48(9), 2839-2846.
223. Wu, N., Huang, J., Schmalz, B., & Fohrer, N. (2014). Modeling daily chlorophyll a dynamics in a German lowland river using artificial neural networks and multiple linear regression approaches. *Limnology*, 15(1), 47-56.
224. Ji-Woong Choia, Jeong-Ho Hana, b, Chan-Seo Parka, b, Dae-Geun Koa, Han-Il Kanga, Ji Yoon Kima, Young-Jin Yuna, Hyuk-Hyun Kwona, Kwang-Guk Ana, (2015), Nutrients and sestonic chlorophyll dynamics in Asian lotic ecosystems and ecological stream health in relation to land-use patterns and water chemistry, *Ecological engineering*, Vol 79, pp 15 – 31
225. Zeng, Qinghui, Qin, Lihuan, Li, Xuyong (2015), The potential impact of an inter-basin water transfer project on nutrients (nitrogen and phosphorous) and chlorophyll a

- of the receiving water system. Science of the total environment Volume: 536, pp 675-686
226. Zhang, W. (2010). *Computational ecology: artificial neural networks and their applications*. World Scientific.
227. Zhong, X., Lewis, J., & N-Nagy, F. L. (1996). Inverse robot calibration using artificial neural networks. *Engineering Applications of Artificial Intelligence*, 9(1), 83-93.
228. Zhu, X., & Goldberg, A. B. (2009). Introduction to semi-supervised learning. Synthesis lectures on artificial intelligence and machine learning, 3(1), 1-130.
229. Zou, D., Cao, Y., Zhou, D., & Gu, Q. (2019). Gradient descent optimizes over-parameterized deep ReLU networks. *Machine Learning*, 109(3), 467-492.
230. Ziegler, Paul; Sree, Kandregula Sowjanya. Appenroth, Klaus-Juergen (2017), The uses of duckweed in relation to water remediation, Desalination and water treatment, Volume: 63, 327-342
231. Zuber, N., & Ličen, H. (2011). Mogućnosti primene metoda veštačke inteligencije u automatizaciji vibrodijagnostičkih metoda. *Tehnička dijagnostika*, 10(2), 9-16.
232. Zweimüller, I., Zessner, M., & Hein, T. (2008). Effects of climate change on nitrate loads in a large river: the Austrian Danube as example. *Hydrological Processes: An International Journal*, 22(7), 1022-1036.
233. Živković, M., Anđelković, A., Novković, M., Damnjanović, B., Banjac, N., Pankov, N. & Radulović, S. (2018), Određivanje ekološkog statusa reke Krivaje na osnovu bioloških, hemijskih i hidromorfoloških parametara. *Srpsko društvo za zaštitu voda*, 223.

PRILOZI

PRILOG 1.

Stepen trofičnosti makrofita korišćenih u modelovanju i ključne indikatorske vrste određene primenom analize osetljivosti

Ključne indikatorske vrste (KIV) obeležene su simbolom *.

Vrste makrofita	KIV za NO ₃	KIV za DO	KIV za PO ₄ ³⁻	All	Ellen. N	IBMR (CSI)	IBMR (EI)	MIR (L)	MIR (W)	TIM	MTR (STR)
<i>Agrostis stolonifera L.</i>	*	*	*	*	5.00	10.00	1.00				
<i>Alopecurus geniculatus L.</i>					7.00			4.00	1.00		
<i>Amblystegium riparium (Hedw.) Schimp.</i>	*	*	*	*				1.00	1.00		
<i>Azolla filiculoides Lam.</i>					8.00						
<i>Azolla filiculoides Lam.</i>					8.00	6.00	3.00				
<i>Bidens frondosa L.</i>					8.00						
<i>Bidens tripartita L.</i>					8.00						
<i>Butomus umbellatus L.</i>					7.00	9.00	2.00			2.98	5.00
<i>Carex acuta L.</i>			*	*	5.00			5.00	1.00		5.00
<i>Carex elata All.</i>					5.00						
<i>Carex riparia Curtis</i>					4.00			4.00	2.00		4.00
<i>Ceratophyllum demersum L.</i>					8.00	5.00	2.00	2.00	3.00	3.18	2.00
<i>Cinclidotus riparius (Host ex Brid.) Arn.</i>					8.00	5.00	2.00	2.00	3.00		2.00
<i>Cladophora glomerata (Linnaeus) Kützing</i>			*	*		13.00	2.00				
<i>Cyperus fuscus L.</i>		*	*	*		6.00	1.00	1.00	2.00		
<i>Dichostylis micheliana (L.) Nees</i>	*			*	4.00						
<i>Eleocharis acicularis (L.) Roem. & Schult.</i>					6.00						
<i>Eleocharis palustris (L.) Roem. & Schult.</i>	*			*	2.00						
<i>Elodea nuttallii (Planch.) H.St.John</i>		*		*		12.00	2.00	6.00	2.00		
<i>Equisetum fluviatile L.</i>		*		*	7.00	8.00	2.00			2.75	3.00
<i>Fontinalis antipyretica Hedw.</i>			*	*	5.00	12.00	2.00	6.00	2.00		5.00
<i>Glyceria fluitans (L.) R.Br.</i>		*		*		10.00	1.00	6.00	2.00		5.00
<i>Glyceria maxima (Hartm.) Holmb.</i>	*			*	7.00	14.00	2.00	5.00	2.00		
<i>Gnaphalium uliginosum L.</i>					9.00			3.00	1.00	3.00	
<i>Hydrocharis morsus-ranae L.</i>			*	*	4.00						
<i>Iris pseudacorus L.</i>		*		*	6.00			6.00	2.00		
<i>Lemna gibba L.</i>			*	*	7.00	10.00	1.00	6.00	2.00		
<i>Lemna minor L.</i>					8.00	5.00	3.00	1.00	3.00		
<i>Lemna turionifera Landolt</i>					6.00	10.00	1.00	2.00	2.00		
<i>Lythrum salicaria L.</i>											

Doktorska disertacija

Ivana Krtolica

Vrste makrofita	KIV za NO ₃	KIV za DO	KIV za PO ₄ ³⁻	All	Ellen. N	IBMR (CSI)	IBMR (EI)	MIR (L)	MIR (W)	TIM	MTR (STR)
<i>Mentha aquatica L.</i>			*	*							
<i>Mentha pulegium L.</i>					5.00	12.00	1.00	5.00	1.00	2.00	
<i>Myriophyllum spicatum L.</i>					7.00						
<i>Najas marina L.</i>	*	*	*	*	7.00	8.00	2.00	3.00	2.00	2.83	3.00
<i>Najas minor All.</i>					6.00	5.00	3.00				
<i>Nuphar lutea (L.) Sm.</i>					4.00	6.00	3.00				
<i>Nymphoides peltata (S.G.Gmel.) Kuntze</i>		*		*	6.00	9.00	1.00	4.00	2.00	3.15	3.00
<i>Phalaris arundinacea L.</i>					7.00	10.00	2.00				
<i>Phragmites australis (Cav.) Trin. ex Steud.</i>					7.00	10.00	1.00	2.00	1.00		
<i>Polygonum hydroppiper L.</i>	*	*	*	*	7.00	9.00	2.00				
<i>Polygonum lapatifolium L.</i>	*		*	*	8.00	8.00	2.00	3.00	1.00		
<i>Potamogeton crispus L.</i>	*		*	*	8.00						
<i>Potamogeton friesii Rupr.</i>					5.00	7.00	2.00	4.00	2.00	2.88	3.00
<i>Potamogeton gramineus L.</i>					6.00	10.00	1.00	3.00	2.00	2.68	3.00
<i>Potamogeton lucens L.</i>	*			*	5.00	13.00	2.00	7.00	1.00		
<i>Potamogeton natans L.</i>					7.00	7.00	3.00	4.00	3.00	2.65	3.00
<i>Potamogeton nodosus Poir.</i>					5.00	12.00	1.00	4.00	1.00	2.00	5.00
<i>Potamogeton pectinatus L.</i>					5.00	4.00	3.00	3.00	2.00		
<i>Potamogeton pusillus L.</i>	*			*	8.00	2.00	2.00	1.00	1.00	2.88	1.00
<i>Potamogeton trichoides Cham. & Schldl.</i>					6.00	9.00	2.00	4.00	2.00	2.38	
<i>Ranunculus fluitans Lam.</i>					5.00			4.00	2.00		4.00
<i>Riccia crystallina L.</i>					4.00	7.00	2.00	2.00	2.00		2.00
<i>Rorippa amphibia (L.) Besser</i>			*	*	8.00	10.00	2.00	7.00	2.00	3.00	7.00
<i>Salvinia natans (L.) All.</i>	*		*	*							
<i>Schoenoplectus lacustris (L.) Palla</i>					8.00	9.00	1.00	3.00	1.00		3.00
<i>Sparganium emersum Rehmann</i>					7.00						
<i>Sparganium erectum L.</i>					6.00						
<i>Spirodela polyrhiza (L.) Schleid.</i>					7.00	13.00	2.00	4.00	2.00	2.78	3.00
<i>Stratiotes aloides L.</i>					7.00	10.00	1.00	3.00	1.00	3.00	3.00
<i>Trapa natans L.</i>					6.00	6.00	2.00	2.00	2.00		2.00
<i>Typha angustifolia L.</i>			*	*	6.00			6.00	2.00		
<i>Typha latifolia L.</i>					8.00	10.00	3.00				
<i>Vallisneria spiralis L.</i>					7.00	6.00	2.00	3.00	2.00		2.00
<i>Zannichellia palustris L.</i>					8.00	8.00	1.00	2.00	2.00		2.00
Vrednosti indeksa trofičnosti (osetljive – tolerantne)					1-9	20-0		10-1		1-4	10-1
Vrednosti indikatorskih težina / ekološke valence								1-3		1-3	

Maksimalna-minimalna (median) indikatorska vrednost za sve vrste makrofita					2-9 (7)	2-14 (9)	1-3 (2)	1-7 (4)	1-3 (2)	2-3.18 (2.855)	1-7 (3)
Maksimalna-minimalna (median) indikatorska vrednost za odabране indikatorske vrste								1-7 (5) ****	1-2 (1) **		3-7 (5) ***
Maksimalna-minimalna (median) indikatorska vrednost za odabране neindikatorske vrste								1-5 (3) ****	1-3 (2) **		1-5 (3) ***

* Ellen. N - Ellenberg N value (Ellenberg, 1979); IBMR (CSI) - the Macrophyte Biological Index for Rivers (Species Score); IBMR (EI) - the Macrophyte Biological Index for Rivers (Ecological Amplitude) (Haury i saradnici 2006); MIR (L) - the Macrophyte Index of Rivers (Species index value) (Szoszkiewicz i saradnici., 2010); MIR (W) - the Macrophyte Index of Rivers (Species index weight) (Szoszkiewicz i saradnici, 2010); TIM - the Trophic Index of Macrophytes -TIM (Schneider i Melzer, 2003); STR - the Species Trophic Rank -STR (Dawson i saradnici 1999).

** Vrednosti indikatorskih vrsta za nitratne anjone

*** Vrednosti indikatorskih vrsta za fosfatne anjone

****Vrednosti za sve indikatorske vrste

PRILOG 2.

Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža tačno odredila III klasu ekološkog statusa na osnovu izmerenih vrednosti koncentracija rastvorenog kiseonika

JDS lokalitet	[DO]	$[\text{NO}_3^-]$	$[\text{PO}_4^{3-}]$	Detektovane makrofite
JDS 35 (D)	5.2 mg/L	1.4 mg/L	0.25 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Hydrocharis morsus-ranae L.;</i> <i>Lemna gibba L.; Lemna minor L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Dichotostylis micheliana (L.) Nees;</i> <i>Glyceria maxima (Hartm.) Holmb.;</i> <i>Polygonum lapatifolium L.</i>
JDS 38 (L)	6.7 mg/L	5.3 mg/L	0.14 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Dichotostylis micheliana (L.) Nees;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 40 (L)	5.9 mg/L	5.3 mg/L	0.18 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Dichotostylis micheliana (L.) Nees;</i> <i>Polygonum lapatifolium L.;</i> <i>Rorippa amphibia (L.) Besser;</i> <i>Schoenoplectus lacustris (L.) Palla;</i> <i>Cladophora glomerata (Linnaeus) Kützing;</i> <i>Typha latifolia L.; Typha angustifolia L.</i>
JDS 40 (D)	5.9 mg/L	5.3 mg/L	0.18 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.; Lemna minor L.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Glyceria maxima (Hartm.) Holmb.;</i> <i>Rorippa amphibia (L.) Besser;</i> <i>Cladophora glomerata (Linnaeus) Kützing;</i> <i>Typha latifolia L.</i>
JDS 42 (L)	6.3 mg/L	5.5 mg/L	0.14 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.; Lemna minor L.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Dichotostylis micheliana (L.) Nees;</i> <i>Glyceria maxima (Hartm.) Holmb.;</i> <i>Polygonum lapatifolium L.;</i> <i>Schoenoplectus lacustris (L.) Palla;</i> <i>Cladophora glomerata (Linnaeus) Kützing;</i> <i>Typha latifolia L.; Typha angustifolia L.</i>
JDS 42 (D)	6.3 mg/L	5.5 mg/L	0.14 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.; Lemna minor L.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Dichotostylis micheliana (L.) Nees;</i> <i>Polygonum lapatifolium L.;</i> <i>Rorippa amphibia (L.) Besser;</i> <i>Cladophora glomerata (Linnaeus) Kützing;</i> <i>Typha latifolia L.</i>
JDS 43 (L)	6.2 mg/L	5.5 mg/L	0.18 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Glyceria maxima (Hartm.) Holmb.;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing;</i> <i>Typha angustifolia L.</i>

Doktorska disertacija

Ivana Krtolica

JDS lokalitet	[DO]	[NO ₃ ⁻]	[PO ₄ ³⁻]	Detektovane makrofite
JDS 43 (D)	6.2 mg/L	5.5 mg/L	0.18 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.; Lemna minor L.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Dichotostylis micheliana (L.) Nees;</i> <i>Glyceria maxima (Hartm.) Holmb.;</i> <i>Polygonum lapatifolium L.;</i> <i>Schoenoplectus lacustris (L.) Palla;</i> <i>Cladophora glomerata (Linnaeus) Kützing;</i> <i>Typha angustifolia L.</i>
JDS 44(D)	6.5 mg/L	5.8 mg/L	0.16 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.; Lemna minor L.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 46 (L)	5.9 mg/L	4.7 mg/L	0.13 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.; Lemna minor L.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 46 (D)	5.9 mg/L	4.7 mg/L	0.13 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 47 (D)	6.5 mg/L	4.4 mg/L	0.33 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 49(D)	6.4 mg/L	4.6 mg/L	0.18 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Schoenoplectus lacustris (L.) Palla;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 58 (L)	6.7 mg/L	6.1 mg/L	1.5 mg/L	<i>Ceratophyllum demersum L.</i>

PRILOG 3.

Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetu na kom je neuronska mreža tačno odredila VII klasu ekološkog statusa na osnovu izmerenih vrednosti koncentracija nitratnih anjona

JDS lokalitet	[DO]	[NO_3^-]	[PO_4^{3-}]	Detektovane makrofite
JDS 1 (L)	8.1 mg/L	15 mg/L	0.11 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Ranunculus fluitans</i> Lam.; <i>Fontinalis antipyretica</i> Hedw.; <i>Amblystegium riparium</i> (Hedw.) Schimp.; <i>Iris pseudacorus</i> L.; <i>Lythrum salicaria</i> L.; <i>Phalaris arundinacea</i> L.
JDS 1 (D)	8.1 mg/L	15 mg/L	0.11 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Fontinalis antipyretica</i> Hedw.; <i>Amblystegium riparium</i> (Hedw.) Schimp.; <i>Lythrum salicaria</i> L.; <i>Phalaris arundinacea</i> L.
JDS 2(L)	7.8 mg/L	11 mg/L	0.12 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Ceratophyllum demersum</i> L.; <i>Fontinalis antipyretica</i> Hedw.; <i>Myriophyllum spicatum</i> L.; <i>Phragmites australis</i> (Cav.) Trin. ex Steud.; <i>Agrostis stolonifera</i> L.; <i>Phalaris arundinacea</i> L.; <i>Lythrum salicaria</i> L.
JDS 2 (D)	7.8 mg/L	11 mg/L	0.12 mg/L	<i>Cinclidotus riparius</i> (Host ex Brid.) Arn.; <i>Fontinalis antipyretica</i> Hedw.; <i>Agrostis stolonifera</i> L.; <i>Phalaris arundinacea</i> L.
JDS 3 (L)	7.4 mg/L	12 mg/L	0.17 mg/L	<i>Ceratophyllum demersum</i> L.; <i>Cinclidotus riparius</i> (Host ex Brid.) Arn. <i>Elodea nuttallii</i> (Planch.) H.St.John; <i>Fontinalis antipyretica</i> Hedw.; <i>Myriophyllum spicatum</i> L.; <i>Najas marina</i> L.; <i>Nuphar lutea</i> (L.) Sm.; <i>Potamogeton lucens</i> L.; <i>Potamogeton crispus</i> L.; <i>Typha latifolia</i> L.; <i>Phragmites australis</i> (Cav.) Trin. ex Steud.; <i>Phalaris arundinacea</i> L. <i>Lythrum salicaria</i> L.; <i>Iris pseudacorus</i> L.; <i>Butomus umbellatus</i> L. <i>Sparganium emersum</i> Rehmann; <i>Sparganium erectum</i> L.; <i>Potamogeton trichoides</i> Cham. & Schleidl.; <i>Potamogeton nodosus</i> Poir.; <i>Potamogeton pectinatus</i> L.; <i>Potamogeton perfoliatus</i> L.; <i>Potamogeton lucens</i> L.

Doktorska disertacija

Ivana Krtolica

JDS lokalitet	[DO]	[NO ₃ ⁻]	[PO ₄ ³⁻]	Detektovane makrofite
JDS 3 (D)	7.4 mg/L	12 mg/L	0.17 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Elodea nuttallii (Planch.) H.St.John;</i> <i>Fontinalis antipyretica Hedw.;</i> <i>Myriophyllum spicatum L.;</i> <i>Najas marina L.;</i> <i>Nuphar lutea (L.) Sm.;</i> <i>Potamogeton lucens L.;</i> <i>Typha angustifolia L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.;</i> <i>Phalaris arundinacea L.;</i> <i>Lythrum salicaria L.;</i> <i>Iris pseudacorus L.;</i> <i>Sparganium emersum Rehmann;</i> <i>Sparganium erectum L.;</i> <i>Potamogeton trichoides Cham. & Schltl.;</i> <i>Potamogeton nodosus Poir.;</i> <i>Potamogeton pectinatus L.;</i> <i>Potamogeton perfoliatus L.</i> <i>Potamogeton lucens L.</i>
JDS 4 (L)	7 mg/L	12 mg/L	0.22 mg/L	<i>Myriophyllum spicatum L.;</i> <i>Nuphar lutea (L.) Sm.;</i> <i>Potamogeton pectinatus L.;</i> <i>Sparganium emersum L.;</i> <i>Butomus umbellatus L.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.;</i> <i>Polygonum lapatifolium L.</i>
JDS 4(D)	7 mg/L	12 mg/L	0.22 mg/L	<i>Myriophyllum spicatum L.;</i> <i>Nuphar lutea (L.) Sm.;</i> <i>Sparganium emersum L.;</i> <i>Butomus umbellatus L.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.;</i> <i>Typha latifolia L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 5 (L)	7.3 mg/L	12 mg/L	0.23 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Fontinalis antipyretica Hedw.;</i> <i>Agrostis stolonifera L.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.</i>
JDS 5 (D)	7.3 mg/L	12 mg/L	0.23 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Fontinalis antipyretica Hedw.;</i> <i>Agrostis stolonifera L.;</i> <i>Amblystegium riparium (Hedw.) Schimp.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.;</i> <i>Phragmites australis (Cav.) Trin. ex Steud.</i>

PRILOG 4.

Vrednosti koncentracija rastvorenog kiseonika (DO), nitratnih (NO_3^-) i ortofosfatnih anjona (PO_4^{3-}) i listing makrofita na lokalitetima na kojima je neuronska mreža umesto V klase ekološkog statusa odredila IV klasu ekološkog statusa na osnovu izmerenih vrednosti koncentracija ortofosfatnih anjona

JDS lokalitet	[DO]	$[\text{NO}_3^-]$	$[\text{PO}_4^{3-}]$	Detektovane makrofite
JDS 4 (D)	7 mg/L	12 mg/L	0.22 mg/L	<i>Myriophyllum spicatum L.;</i> <i>Nuphar lutea (L.) Sm.;</i> <i>Sparganium emersum Rehmann;</i> <i>Butomus umbellatus L.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Typha latifolia L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 5 (L)	7.3 mg/L	12 mg/L	0.23 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Fontinalis antipyretica Hedw.;</i> <i>Agrostis stolonifera L.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Typha latifolia L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing</i>
JDS 5 (D)	7.3 mg/L	12 mg/L	0.23 mg/L	<i>Cinclidotus riparius (Host ex Brid.) Arn.;</i> <i>Fontinalis antipyretica Hedw.;</i> <i>Agrostis stolonifera L.;</i> <i>Lythrum salicaria L.;</i> <i>Phalaris arundinacea L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Typha latifolia L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing;</i> <i>Amblystegium riparium (Hedw.) Schimp.</i>
JDS 35 (L)	5.2 mg/L	1.4 mg/L	0.25 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Bidens frondosa L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Rorippa amphibia (L.) Besser</i>
JDS 35 (D)	5.2 mg/L	1.4 mg/L	0.25 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Hydrocharis morsus-ranae L.;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Salvinia natans (L.) All.;</i> <i>Spirodela polyrhiza (L.) Schleid.;</i> <i>Dichostylis micheliana (L.) Nees;</i> <i>Glyceria maxima (Hartm.) Holmb.;</i> <i>Polygonum lapatifolium L.;</i>
JDS 47 (L)	6.5 mg/L	4.4 mg/L	0.33 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Myriophyllum spicatum L.;</i> <i>Potamogeton crispus L.;</i> <i>Potamogeton lucens L.;</i> <i>Potamogeton perfoliatus L.;</i> <i>Vallisneria spiralis L.;</i> <i>Butomus umbellatus L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing;</i> <i>Potamogeton pectinatus L.</i>

Doktorska disertacija

Ivana Krtolica

JDS lokalitet	[DO]	[NO ₃ ⁻]	[PO ₄ ³⁻]	Detektovane makrofite
JDS 47 (D)	6.5 mg/L	4.4 mg/L	0.33 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Myriophyllum spicatum L.;</i> <i>Potamogeton crispus L.;</i> <i>Potamogeton lucens L.;</i> <i>Potamogeton perfoliatus L.;</i> <i>Vallisneria spiralis L.;</i> <i>Butomus umbellatus L.;</i> <i>Polygonum lapatifolium L.;</i> <i>Cladophora glomerata (Linnaeus) Kützing;</i> <i>Lemna gibba L.;</i> <i>Lemna minor L.;</i> <i>Lemna turionifera Landolt;</i> <i>Trapa natans L.;</i> <i>Alopecurus geniculatus L.;</i> <i>Cyperus fuscus L.;</i> <i>Lythrum salicaria L.</i>
JDS 51 (L)	8.2 mg/L	4.6 mg/L	0.28 mg/L	<i>Myriophyllum spicatum L.;</i> <i>Bidens frondosa L.;</i> <i>Polygonum lapatifolium L.</i>
JDS 54 (L)	7.3 mg/L	4.2 mg/L	0.22 mg/L	<i>Ceratophyllum demersum L.;</i> <i>Bidens frondosa L.;</i> <i>Butomus umbellatus L.;</i> <i>Polygonum lapatifolium L.</i>
JDS 54 (D)	7.3 mg/L	4.2 mg/L	0.22 mg/L	<i>Najas marina L.;</i> <i>Polygonum lapatifolium L.</i>

Овај Образац чини саставни део докторске дисертације, односно докторског уметничког пројекта који се брани на Универзитету у Новом Саду. Попуњен Образац укоричити иза текста докторске дисертације, односно докторског уметничког пројекта.

План третмана података

Назив пројекта/истраживања
Процена екостатуса речних система на примеру дунавског басена применом модела вештачких неуронских мрежа
Назив институције/институција у оквиру којих се спроводи истраживање
a) Факултет техничких наука, Департман за инжењерство заштите животне средине и заштите на раду, Нови Сад б) Природно – математички факултет, Нови Сад; Департман за биологију и екологију, Лабораторија за екологију биљака
Назив програма у оквиру ког се реализује истраживање
Докторске академске студије: Доктор наука - Инжењерство заштите животне средине
1. Опис података
<p>1.1 Врста студије</p> <p>Укратко описати тип студије у оквиру које се подаци прикупљају</p> <p>Докторска дисертација</p> <p>1.2 Врсте података</p> <p><u>а)</u> квантитативни</p> <p><u>б)</u> квалитативни</p> <p>1.3. Начин прикупљања података</p> <p>а) анкете, упитници, тестови</p> <p>б) клиничке процене, медицински записи, електронски здравствени записи</p> <p>в) генотипови: навести врсту _____</p> <p>г) административни подаци: навести врсту _____</p> <p>д) узорци ткива: навести врсту _____</p> <p>ђ) снимци, фотографије: навести врсту _____</p>

e) текст, навести врсту **Анализа доступне литературе**

ж) мапа, навести врсту _____

з) остало: описати **Подаци треће експедиције ICPDR-а, пројекта SOLUTIONS, и оригинални подаци Лабораторије за екологију биљака Департамана за биологију и екологију Природно-математичког факултета у Новом Саду**

1.3 Формат података, употребљене скале, количина података

1.3.1 Употребљени софтвер и формат датотеке:

а) Excel фајл, датотека _____

б) SPSS фајл, датотека _____

c) PDF фајл, датотека **.pdf**

d) Текст фајл, датотека **.doc**

е) JPG фајл, датотека _____

ф) Остало, датотека _____

1.3.2. Број записа (код квантитативних података)

а) број варијабли **67 (64 врсте макрофита и 3 селектована кључна хемијска параметра)**

б) број мерења (испитаника, процена, снимака и сл.) **126 (обе стране речне обале)**

1.3.3. Поновљена мерења

а) да

б) не

Уколико је одговор да, одговорити на следећа питања:

а) временски размак између поновљених мера је _____

б) варијабле које се више пута мере односе се на _____

в) нове верзије фајлова који садрже поновљена мерења су именоване као _____

Напомене: _____

Да ли формати и софтвер омогућавају дељење и дугорочну валидност података?

a) Да

б) *Не*

*Ако је одговор *не*, образложити* _____

2. Прикупљање података

2.1 Методологија за прикупљање/генерисање података

2.1.1 У оквиру ког истраживачког нацрта су подаци прикупљени?

а) експеримент, навести тип **Оригинални лабораторијски подаци; модел вештачких неуронских мрежа; статистичке методе**

б) корелационо истраживање, навести тип _____

ц) анализа текста, навести тип _____

д) остало, навести шта _____

2.1.2 Навести врсте мерних инструмената или стандарде података специфичних за одређену научну дисциплину (ако постоје).

2.2 Квалитет података и стандарди

2.2.1 Третман недостајућих података

а) Да ли матрица садржи недостајуће податке? Да **Не**

Ако је одговор да, одговорити на следећа питања:

а) Колики је број недостајућих података? _____

б) Да ли се кориснику матрице препоручује замена недостајућих података? Да **Не**

в) Ако је одговор да, навести сугестије за третман замене недостајућих података

2.2.2 На који начин је контролисан квалитет података? Описати

Квалитет података је контролисан поређењем и утврђивањем индекса сличности експерименталних, рачунских и теоријских података

2.2.3. На који начин је извршена контрола уноса података у матрицу?

Контрола уноса података у матрицу је извршена унакрсним поређењем вредности у матрици са вредностима из иницијалне базе података

3. Третман података и пратећа документација

3.1. Третман и чување података

3.1.1. Подаци ће бити депоновани у **Репозиторијум докторских дисертација на Универзитету у Новом Саду**

3.1.2. URL адреса <https://www.cris.uns.ac.rs/searchDissertations.jsf>

3.1.3. DOI _____

3.1.4. Да ли ће подаци бити у отвореном приступу?

a) Да

б) Да, али после ембарга који ће трајати до _____

в) Не

Ако је одговор не, навести разлог _____

3.1.5. Подаци неће бити депоновани у репозиторијум, али ће бити чувани.

Образложење

3.2 Метаподаци и документација података

3.2.1. Који стандард за метаподатке ће бити примењен? _____

3.2.1. Навести метаподатке на основу којих су подаци депоновани у репозиторијум.

Ако је потребно, навести методе које се користе за преузимање података, аналитичке и процедуралне информације, њихово кодирање, детаљне описе варијабли, записа итд.

3.3 Стратегија и стандарди за чување података

3.3.1. До ког периода ће подаци бити чувани у репозиторијуму? _____

3.3.2. Да ли ће подаци бити депоновани под шифром? Да **Не**

3.3.3. Да ли ће шифра бити доступна одређеном кругу истраживача? Да **Не**

3.3.4. Да ли се подаци морају уклонити из отвореног приступа после извесног времена?

Да **Не**

Образложити

4. Безбедност података и заштита поверљивих информација

Овај одељак МОРА бити попуњен ако ваши подаци укључују личне податке који се односе на учеснике у истраживању. За друга истраживања треба такође размотрити заштиту и сигурност података.

4.1 Формални стандарди за сигурност информација/података

Истраживачи који спроводе испитивања с лјудима морају да се придржавају Закона о заштити података о личности (https://www.paragraf.rs/propisi/zakon_o_zastiti_podataka_o_licnosti.html) и одговарајућег институционалног кодекса о академском интегритету.

4.1.2. Да ли је истраживање одобрено од стране етичке комисије? Да Не

Ако је одговор Да, навести датум и назив етичке комисије која је одобрила истраживање

4.1.2. Да ли подаци укључују личне податке учесника у истраживању? Да **Не**

Ако је одговор да, наведите на који начин сте осигурали поверљивост и сигурност информација везаних за испитанике:

- а) Подаци нису у отвореном приступу
- б) Подаци су анонимизирани
- ц) Остало, навести шта

5. Доступност података

5.1. Подаци ће бити

а) јавно доступни

б) доступни само уском кругу истраживача у одређеној научној области

ц) затворени

Ако су подаци доступни само уском кругу истраживача, навести под којим условима могу да их користе:

Ако су подаци доступни само уском кругу истраживача, навести на који начин могу приступити подацима:

5.4. Навести лиценцу под којом ће прикупљени подаци бити архивирани.

Ауторство – некомерцијално

6. Улоге и одговорност

6.1. Навести име и презиме и мејл адресу власника (аутора) података

Кртолица Г. Ивана, мејл адреса: ivanakrt@gmail.com

6.2. Навести име и презиме и мејл адресу особе која одржава матрицу с подацима

Кртолица Г. Ивана, мејл адреса: ivanakrt@gmail.com

6.3. Навести име и презиме и мејл адресу особе која омогућује приступ подацима другим истраживачима

Кртолица Г. Ивана, мејл адреса: ivanakrt@gmail.com

BIOGRAFIJA AUTORA:



Krtolica G. Ivana, rođena Vojnović, rođena je 22.09.1982. u Vrbasu gde 2001. godine završava gimnaziju „Žarko Zrenjanin“, prirodno – matematički smer. Iste godine upisuje Prirodno – matematički fakultet Univerziteta u Novom Sadu, studijski program dvopredmetne studije, smer Biologija – hemija. Osnovne studije završava maja 2007. godine. Diplomski rad iz predmeta Fiziologija biljaka na temu „*Uticaj nikla na fitoremedijaciju klonova vrba Salix sp.*“ odbranila je sa ocenom 10. 2007. godine upisuje master studije na studijskom programu dvopredmetne studije, smer biologija – hemija, i iste završava 2008. godine sa prosečnom ocenom 10.00. Master rad iz predmeta Metodika nastave hemije, na temu „*Analiza usvojenosti ekoloških pojmove u srednjoškolskoj nastavi medicinske struke*“, odbranila je sa ocenom 10. Po završetku master studija nagrađena je Izuzetnom nagradom za postignut uspeh u toku studija koju dodeljuje Univerzitet u Novom Sadu. Školske 2010./2011. godine upisuje doktorske studije na Fakultetu tehničkih nauka Univerziteta u Novom Sadu, studijski program Inženjerstvo zaštite životne sredine. Sve ispite predviđene nastavnim planom i programom položila je sa prosečnom ocenom 9.43. Kvalifikacioni ispit – Teorijske osnove doktorske disertacije polaže 13.07.2016. sa ocenom 10. Autor je i koautor više naučnih radova od kojih posebno izdvaja rad iz doktorske disertacije *Water quality and macrophytes in the Danube River: Artificial neural network modelling* objavljen u časopisu ranga M21, *Ecological indicators*. Kao autor i koautor učestvovala je na nacionalnim i međunarodnim kongresima.

U svom radu koristi se osnovnim i naprednim softverskim paketima. Tečno govori engleski jezik i služi se ruskim.

Zaposlena kao predmetni nastavnik biološke grupe predmeta u Srednjoj stručnoj školi „4.juli“ u Vrbasu od 2007. godine.

Majka Teodore i Tijane.