

Tea Baldigara\*

JEL klasifikacija: C53 i C45  
Izvorni znanstveni rad  
<https://doi.org/10.32910/ep.73.3.1>

## PRIMJENA UMJETNIH NEURONSKIH MREŽA U MODELIRANJU DOMAĆE TURISTIČKE POTRAŽNJE

*Rad istražuje učinkovitost primjene modela umjetnih neuronskih mreža u modeliranju domaće turističke potražnje u Republici Hrvatskoj, aproksimiranoj brojem dolazaka i brojem ostvarenih noćenja domaćih turista. Indeksi obujma industrijske proizvodnje, indeksi potrošačkih cijena, prosječna neto mjesečna plaća, broj zaposlenih te mjesečne sezonske dummy varijable odabrane su kao ulazne varijable. Za modeliranje empirijskih podataka korištene su mreže višeslojnog perceptrona. Prognostička moć modela evaluirana je prosječnom apsolutnom postotnom te prosječnom apsolutnom prognostičkom pogreškom, Pearsonovim koeficijentom korelacije te koeficijentom determinacije. Evaluacija dobivenih rezultata pokazala je kako su odabrani modeli višeslojnih perceptrona pouzdani za modeliranje domaće turističke potražnje, iako je istraživanje temeljeno na ograničenom, manjem broju podataka te broju ulaznih varijabli. Polazeći od rezultata, ali i ograničenja istraživanja, zaključuje se kako modeli umjetnih neuronskih mreža posjeduju značajne aplikativne potencijale u domeni modeliranja i prognoziranja vremenskih nizova broja dolazaka i noćenja domaćih turista u Republici Hrvatskoj.*

**Ključne riječi:** *domaća turistička potražnja, modeliranje, modeli umjetnih neuronskih mreža, model višeslojnog perceptrona*

---

\* T. Baldigara, dr. sc., redoviti profesor, Sveučilište u Rijeci, Fakultet za menadžment u turizmu i ugostiteljstvu, Opatija (e-mail: [tea.baldigara@fthm.hr](mailto:tea.baldigara@fthm.hr)). Rad je primljen u uredništvo 10.08.2020. godine, a prihvaćen je za objavu 06.10.2020. godine.

## 1. UVODNA RAZMATRANJA

Turizam je bez sumnje jedna od najsloženijih i najdinamičnijih suvremenih društveno-ekonomskih pojava te najbrže rastuća grana globale ekonomije koja obuhvaća i utječe na široki spektar odnosa i međuzavisnosti.

U Republici Hrvatskoj turizam je jedna od najpropulzivnijih gospodarskih grana i pokretač ekonomskoga rasta i razvoja. Važnost turizma za hrvatsko, ali jednako tako i za globalno gospodarstvo, implicira potrebu pažljive analize, planiranja i upravljanja čitavim nizom čimbenika i varijabli koje sačinjavaju ovaj kompleksan sustav. Priroda turizma nameće potrebu primjene suvremenih, vrlo specifičnih kvantitativnih metoda u modeliranju i prognozi budućih kretanja. Turistička potražnja i njene karakteristike, kao ključne determinante turističkoga tržišta, predstavljaju ishodište za poslovno odlučivanje i razradu poslovnih strategija u svim za turizam vezanim djelatnostima i sektorima hrvatskoga gospodarstva.

Rastući interes za kvantitativna istraživanja u području turističke potražnje motiviran je ubrzanom globalnom ekspanzijom turizma. Modeliranje turističke potražnje s ciljem proučavanja njezinih ekonomskih i neekonomskih učinaka te oblikovanje učinkovitih prognoza njezinih budućih kretanja u centru su pažnje sve brojnijih diskusija i istraživanja.

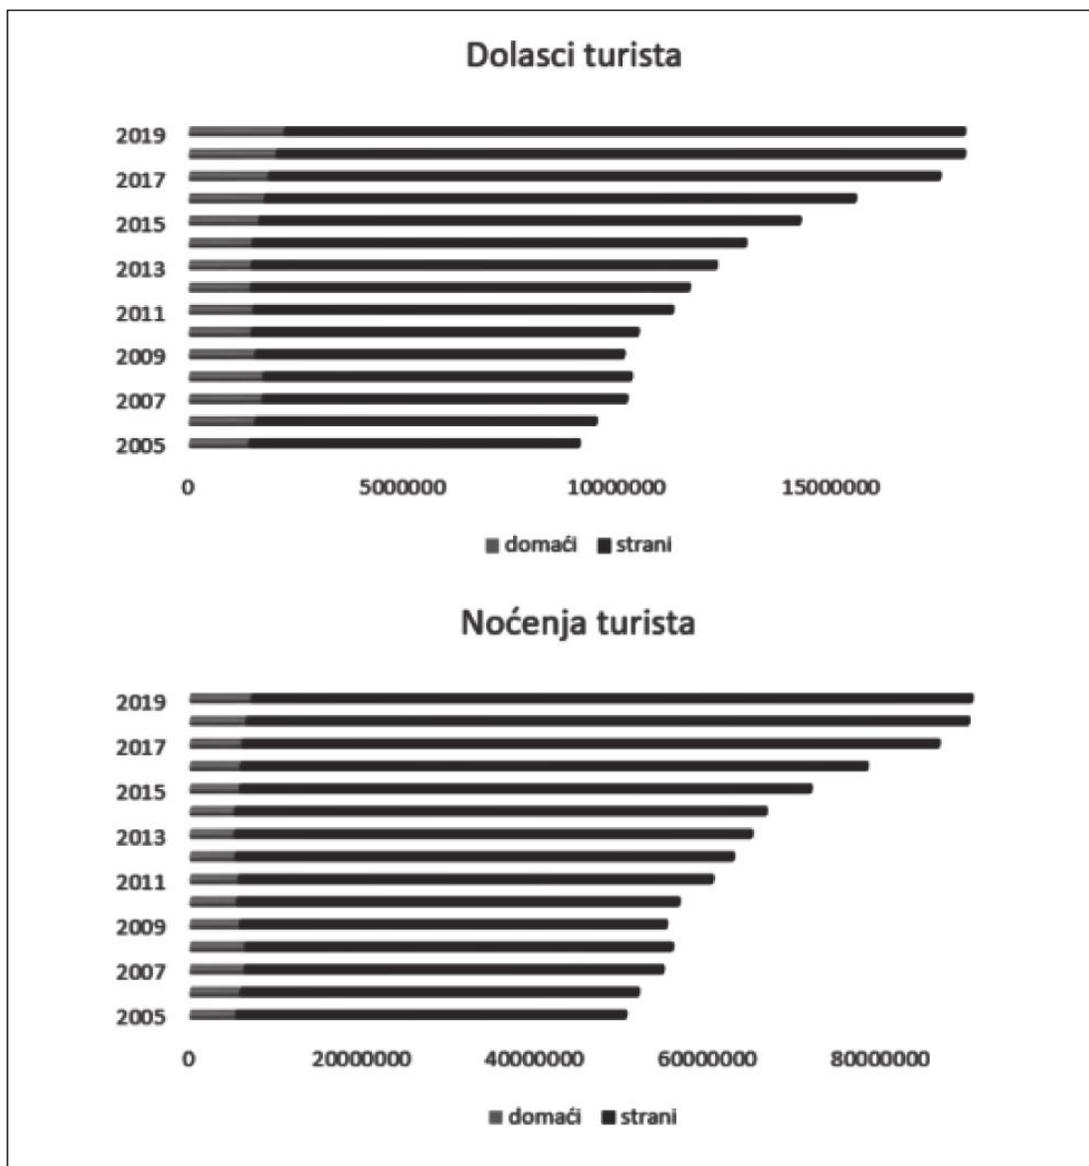
Turizam čini gotovo 20% domaćeg bruto proizvoda Hrvatske, no gospodarska kriza uzrokovana koronavirusom u 2020. godini dovesti će do značajnog smanjenja prihoda od turizma.

U tome Hrvatska nije izuzetak jer Svjetska turistička organizacija predviđa pad globalnoga turističkog sektora.

Ograničavanje kretanja stanovništva i djelomično ili potpuno zatvaranje nacionalnih granica aktualizira pitanje revitalizacije i poticanja razvoja domaćeg turizma. Iako turizam predstavlja značajan izvor zarade, Hrvatska je pretežno međunarodna turistička destinacija, u kojoj domaći turisti čine tek oko 8% cjelokupne turističke potražnje (grafikon 1).

Grafikon 1.

### DOLASCI I NOĆENJA: STRANI TURISTI VS DOMAĆI TURISTI



Izvor: Državni zavod za statistiku, dostupno na <https://www.dzs.hr/default.htm>

Usprkos dosadašnjem relativno skromnom doprinosu domaćih turističkih potrošača ukupnim prihodima od turizma, upravo je razdoblje krize ukazalo na potrebu revitalizacije i poticanja razvoja domaćeg turizma kao faktora stabilnosti ukupnog turističkog prometa. Revitalizacija i poticanje razvoja domaćeg turizma postali su nada i *codicio sine qua non* budućeg razvoja i rasta konkurentnosti turističkoga sektora i hotelske industrije Republike Hrvatske.

Preduvjet na kojem se treba temeljiti razvoj domaćega turizma jest razumijevanje i analiza odrednica i determinanti na kojima počiva domaća turistička potražnja. Sustavna primjena kvantitativnih istraživanja nameće se kao šansa i nužnost u razradi smjernica razvoja domaće turističke potražnje. Cilj ovoga rada je stoga eksplorativna analiza i pružanje doprinosa u istraživanju nekih od temeljnih odrednica za koje se pretpostavlja da utječu na domaću turističku potražnju.

## 2. TEORIJSKE I METODOLOŠKE ODREDNICE ISTRAŽIVANJA

Posljednjih su desetljeća provedena i objavljena mnogobrojna istraživanja iz područja modeliranja i prognoziranja determinanti turističke potražnje. Svim tim studijama zajedničko je naglašavanje važnosti i nužnosti detaljnih i sustavnih kvantitativnih analiza, dizajniranja modela te prognoziranja budućih vrijednosti kao temelja kreiranja uspješnih poslovnih i razvojnih strategija. Istraživački problem ovoga rada počiva s jedne strane na činjenici i premisi o važnosti turističkoga sektora za hrvatsko gospodarstvo i nužnosti primjene metoda kvantitativnih istraživanja u upravljanju njegovim razvojem, te s druge strane, na potrebi za revitalizacijom i razvojem domaćeg turizma.

### 2.1. Pregled dosadašnjih istraživanja

Među kvantitativnim metodama korištenim u modeliranju i prognoziranju turističke potražnje, sve veću popularnost posljednjih desetljeća imaju modeli umjetnih neuronskih mreža, kao modeli koji svoje osobine i obrasce temelje na karakteristikama funkcioniranja i zaključivanja ljudskoga živčanoga sustava.

U svom istraživanju Abas i Lasarudin (2019) prognoziraju dolaske domaćih i stranih turista u Gorontalu (Indoneziji) upotrebom modela umjetnih mreža te upotrebom genetskih algoritama optimiziraju parametre što je rezultiralo visokom pouzdanošću odabranog modela.

Upotrebom modela umjetnih neuronskih mreža temeljenih na genetskom algoritmu optimizacije Wang, Zhang i Wu (2019) modeliraju i prognoziraju turističku potražnju u zavisnosti od broja turista i turističkoga prihoda.

Sveobuhvatni pregled dosadašnjih istraživanja koja koriste modele umjetnih neuronskih mreža u modeliranju i prognoziranju turističke potražnje dale su Mamura i Duvnjak (2018). Analiza 57 objavljenih znanstvenih članaka u razdoblju od

2008. do 2018. godine pokazala je kako su u 46 od 57 analiziranih znanstvenih članaka korišteni modeli umjetnih neuronskih mreža.

Claveria, Monte i Torra (2014) prognoziraju turističke dolaske u Kataloniju (Španjolska) primjenom različitih vrsta modela umjetnih neuronskih mreža, uspoređujući prognostičke moći višeslojnog perceptrona, mreža s radijalno zasnovanom funkcijom te Elmanove mreže. Rezultati su pokazali kako su višeslojni perceptron i mreža s radijalno zasnovanom funkcijom generirali prognoze boljih performansi.

Constantino, Teixeira i Fernandes (2016) modeliraju i prognoziraju turističku potražnju Mozambiquea, aproksimiranom brojem ostvarenih noćenja, primjenom modela umjetnih neuronskih mreža. Pritom kao ulazne varijable koriste indekse potrošačkih cijena, bruto domaći proizvod i devizni tečaj u emitivnim zemljama. Najefikasniji dobiveni model iskazao je vrijednost prosječne apsolutne postotne pogreške od 6,5% te vrijednost Pearsonovog koeficijenta korelacije od 0,696. Autori zaključuju kako su modeli sa značajnom točnošću prognoziranja važan alat svih dionika uključenih u turistički sektor te temelj budućeg razvoja.

Fernandes, Teixeira, Ferreira i Azevedo (2008) istražuju učinkovitost modela umjetnih neuronskih mreža u modeliranju turističke potražnje u Portugalu u odnosu na tradicionalno korištene integrirane autoregresijske modele pomičnih prosjeka (ARIMA modele). Rezultati modeliranja su pokazali da modeli umjetnih mreža daju zadovoljavajuće rezultate te da, iako nisu nastali kao modeli analize vremenskih serija, mogu biti upotrijebljeni kao vrlo učinkovite alternative standardnim modelima.

## *2.2. Metodologija istraživanja*

U suvremenim uvjetima globalizacije i sve veće konkurencije, modeliranje temeljeno na kvantitativnim metodama postalo je značajnim alatom prepoznavanja konkurentnih prednosti i usmjeravanja budućega razvoja turističke potražnje. U radu se pristupa modeliranju domaće turističke potražnje upotrebom modela umjetnih neuronskih mreža. Umjetne neuronske mreže matematički su modeli proračuna zasnovani na strukturi biološkog živčanog sustava. Prednosti umjetnih neuronskih mreža naspram konvencionalnih načina obrade podataka su (Dalbelo Bašić, Čupić i Šnajder, 2008):

- pouzdanost u procjeni nelinearnih odnosa uzoraka,
- mogućnost obrade nejasnih ili manjkavih podataka,
- robusnost na pogreške u podacima,

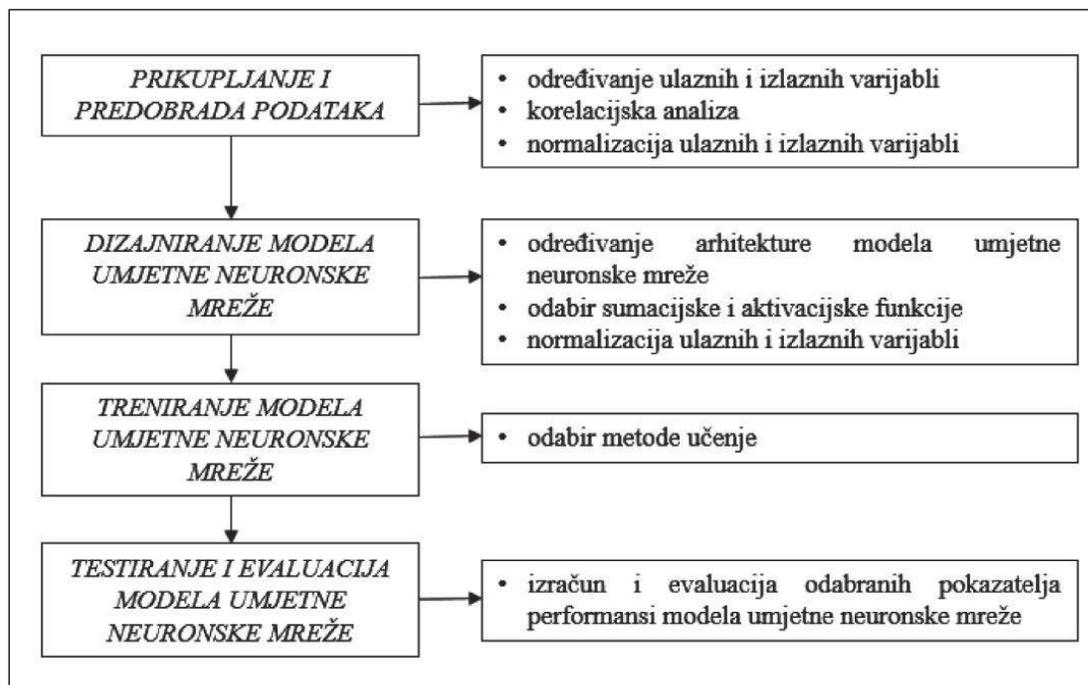
- mogućnost manipuliranja s velikim brojem varijabli ili parametara,
- prilagodljivost okolini, te
- sposobnost formiranja znanja učeći iz iskustva.

Rastući interes za umjetne neuronske mreže rezultat je njihovih aplikativnih potencijala u korištenju velikoj podatka (*big data*), sposobnosti uočavanja i obrađivanja nelinearnih i vrlo složenih obrazaca u podacima, ali i mogućnosti modeliranja procesa s više ulaza i više izlaza te drugih osobina koje predstavljaju svojevrsne konkurentske prednosti navedenih modela u odnosu na tradicionalno korištene kvantitativne modele (Folgieri, Baldigara, Mamula, 2017). Pored brojnih prednosti koje modeli umjetnih neuronskih mreža iskazuju, postoje naravno i određeni nedostaci, među kojima se svakako ističe činjenica da prilikom njihova dizajniranja ne postoje pravila determiniranja optimalne arhitekture.

U svrhu dobivanja pouzdanog i učinkovitog modela umjetne neuronske mreže, istraživanje je provedeno u nekoliko standardnih uobičajenih koraka i faza. Metodologija istraživanja korištena u radu opisana je na slici 1.

Slika 1.

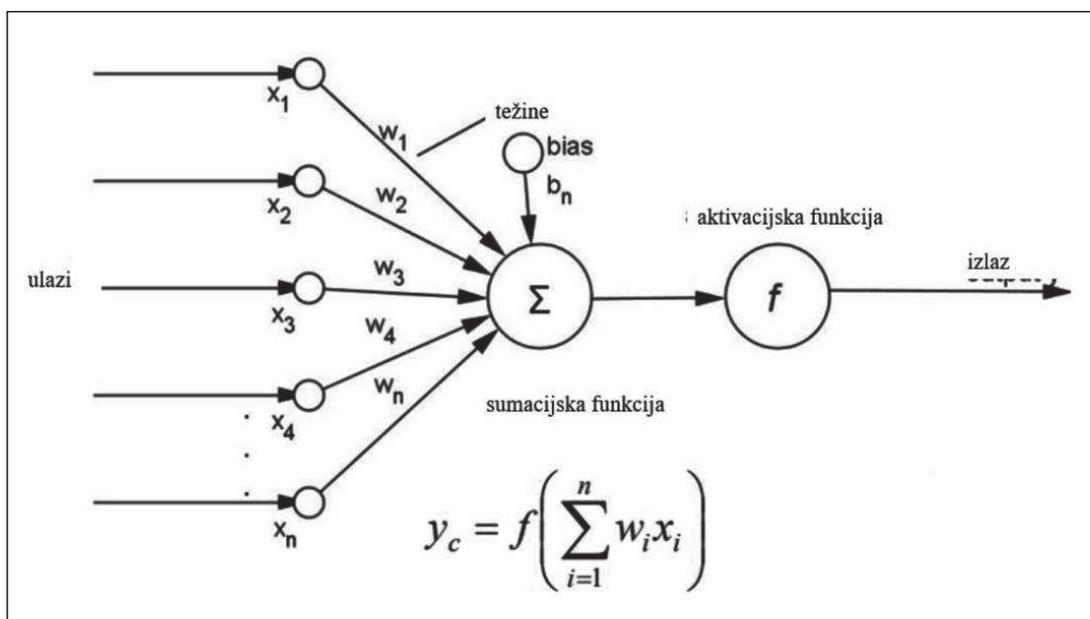
## METODOLOGIJA ISTRAŽIVANJA



Modeli umjetnih neuronskih mreža, u ovome radu, kreirani su temeljem analize i evaluacije postojanja potencijalnih međuzavisnosti ciljnih varijabli te odabranih ulaznih varijabli, za koje se pretpostavlja da ostvaruju utjecaj na izlazne varijable. U radu je korišten model višestrojnog perceptrona, kao univerzalni aproksimator te jedan od najčešće korištenih modela umjetne neuronske mreže. Opći model mreže višeslojnoga perceptrona prikazan je na slici 2.

Slika 2.

### MODEL VIŠESLOJNOGA PERCEPTRONA



Izvor: Preuzeto i prilagođeno prema Haykin, 1999.

Kako je prikazano na slici 2, ulazni podaci šire se od ulaznog sloja prema skrivenom sloju. Neuron u skrivenom sloju, a pomoću sumacijske (ulazne) funkcije, poprimaju određene težine te ih prenose u sljedeći sloj. U izlaznom sloju računa se pogreška za svaki neuron te se prilagođavaju težine, nakon čega se podaci šire unatrag do ulaznog sloja. Ulazne vrijednosti šire se kroz skriveni sloj do izlaznog sloja, nakon čega se određuje pogreška koja se, širenjem unatrag do ulaznog sloja ugrađuje u formulu za učenje. Vrijednosti ulaza neurona, koje on prima iz prethodnog sloja, računaju se prema ulaznoj ili sumacijskoj funkciji koja je u općem obliku dana izrazom:

$$input_i = \sum_{j=1}^n (w_{ij} \cdot output_j) \quad (1)$$

gdje su  $w_{ij}$  težine veza od neurona  $j$  do neurona  $i$ , a  $n$  predstavlja broj neurona u sloju koji šalje izlaz. Drugim riječima, inputi nekog neurona jesu suma svih vagnih izlaza koji pristižu u taj neuron. Neuroni u skrivenim slojevima primaju sumu ponderiranih inputa te primjenjuju aktivacijsku funkciju za dobivanje vrijednosti izlaza. Svaki neuron skrivenog sloja prima sumu svih ponderiranih inputa, a zatim primjenjuje aktivacijsku funkciju da bi se dobio izlaz neurona skrivenog sloja (Zekić-Sušac, 2017):

$$y_c = f\left(\sum_{i=1}^n w_i x_i\right) \quad (2)$$

gdje je  $f$  odabrana aktivacijska funkcija određenoga oblika

Učenje mreže iterativni je proces prilagođavanja težina veza tako da mreža poprimi željenu funkcionalnost. Učenje u modelima višeslojnog perceptrona odvija se pomoću algoritma „širenja unatrag“ (*backpropagation algorithm*), što navedene modele čini posebno učinkovitim u prognoziranju i aproksimiranju nelinearnosti u podacima. U postupku učenja mreže potrebno je odrediti derivacije funkcije gubitka u odnosu na težine i pragove (*bias*), što se postiže pomoću algoritma širenja pogreške unazad koji računa optimalne vrijednosti kako bi se minimizirala funkcija gubitka:

$$\min_E f(\theta) \quad (3)$$

Jedan od najčešćih algoritama smanjivanja pogreške je metoda gradijentnog spusta (*Gradient descent*) koja pomiče težine u smjeru suprotno od gradijenta, a dana je izrazom:

$$w_{j+} = w_j - \alpha \nabla C(w_j) \quad (4)$$

gdje  $j$  predstavlja poziciju težine  $w$ , koeficijent brzine učenja, a  $\nabla C(w_j)$  gradijent funkcije. Proizlazi stoga, da je gradijent funkcije cilja dan izrazom:

$$C(w_j) = \frac{\partial C(w)}{\partial w_j} \quad (5)$$

Pri učenju neuronske mreže primjenom metode gradijentnog spusta izračunava se nagib ili gradijent  $G$  funkcije  $E = f(w)$  nazvan gubitkom (*loss*). Gradijentni spust optimizacijska je metoda koja minimizira  $E$  iterativnim modificiranjem težina u malim koracima u svakom od kojih se vektor težina mijenja u smjeru naj-

većega spusta, sve dok se ne dosegne lokalni minimum pogreške. Metrika procjenjivanja točnosti mreže proizlazi iz funkcije gubitka (*loss function*) koja definira razliku željenih vrijednosti i dobivenih vrijednosti izlaznog sloja neuronske mreže. S obzirom na definiciju funkcije gubitka, u velikom broju slučajeva, učenje mreže ima za cilj njenu minimizaciju. Postoji više mjerila uspješnosti mreže, a neke od njih su srednje-kvadratna pogreška (*mean square error*), srednja apsolutna pogreška (*mean absolute error*), korijen srednje-kvadratne pogreške (*root mean square error*) te suma kvadrata pogreške (*sum of square error*).

### ***2.3. Prikaz korištenih varijabli***

Prikupljanje i pred-obrađivanje podataka ključni su polazni koraci u procesu dizajniranja učinkovitoga i pouzdanoga modela umjetne neuronske mreže. U radu su korištene dvije ciljane i šesnaest ulaznih varijabli. Slijedi kratki opis korištenih varijabli.

#### *Ciljne varijable*

Prema Song, Witt i Li (2009) najčešće korištena mjera turističke potražnje je broj ostvarenih dolazaka i noćenja turista neke turističke destinacije. Podaci o ostvarenim dolascima i noćenjima turista trebaju se smatrati značajnim izvorom informacija za sve dionike u turizmu budući da predstavljaju osnovu za izračun pokazatelja turizma, omogućuju efikasno donošenje odluka, planiranje i organiziranje potrebne infrastrukture te predstavljaju ishodište za sve relevantne prognoze kretanja budućih vrijednosti.

Kao aproksimacija domaće turističke potražnje u Republici Hrvatskoj u ovome se radu koristi broj (u tisućama) ostvarenih dolazaka domaćih turista (DDT) i broj (u tisućama) ostvarenih noćenja domaćih turista (NDT) u razdoblju od siječnja 2005. do prosinca 2019. godine. Podaci su iskazani na mjesečnoj razini te preuzeti sa mrežnih stranica Državnoga zavoda za statistiku Republike Hrvatske.

#### *Ulazne varijable*

Turistička potražnja općenito se smatra funkcijom skupa varijabli. U sveobuhvatnoj i iscrpnoj studiji Song and Li (2008) daju pregled istraživanja koja se bave problematikom modeliranja i prognoziranja turističke potražnje te zaključuju kako je jedna od glavnih prednosti ekonometrijskoga pristupa u odnosu na modele

iz domene vremenskih nizova, njegova sposobnost uočavanja i analiziranja međuzavisnosti između zavisne i odabranih nezavisnih varijabli. Ekonomska teorija postulira da su dohodak i cijena među najznačajnijim odrednicama koje utječu na turističku potražnju, dok mnogobrojna kvantitativna istraživanja turističke potražnje spominju, među ostalima i prihod, potrošnju kućanstava, stopu nezaposlenosti te indeks potrošačkih cijena kao nezavisne varijable. (Serra, Correia i Rodrigues, 2014)

U modeliranju umjetnih neuronskih mreža u ovome je istraživanju korišteno 16 nezavisnih varijabli za koje se pretpostavlja da utječu na zavisne varijable. Podaci su mjesečni te obuhvaćaju vremensko razdoblje od siječnja 2005. do prosinca 2019. godine. U nastavku slijedi popis korištenih ulaznih varijabli:

- *P*: prosječna mjesečna neto plaća po zaposlenome u pravnim osobama, u kn;
- *IPC*: prosječni godišnji indeks potrošačkih cijena (prethodna godina=100); odražava promjene na razini cijena dobara i usluga koje u tijeku vremena nabavlja, koristi se njima ili plaća referentno stanovništvo radi osobne potrošnje te je jedinstvena i opća mjera inflacije u Republici Hrvatskoj;
- *IIP*: indeksi fizičkog obujma industrijske proizvodnje; prema agregatima GIG-a 2009. i po područjima i odjeljcima NKD-a 2007; prethodna godina=100;
- *Z*: broj zaposlenih osoba;
- *M1, ..., M12*: mjesečne sezonske *dummy* varijable.

Korelacijskom analizom i Perasonovim koeficijentom korelacije utvrđena je važnost te pretpostavljeni potencijalni utjecaj kao i priroda odnosa pojedinih ulaznih i ciljnih varijabli (tablica 1).

Tablica 1.

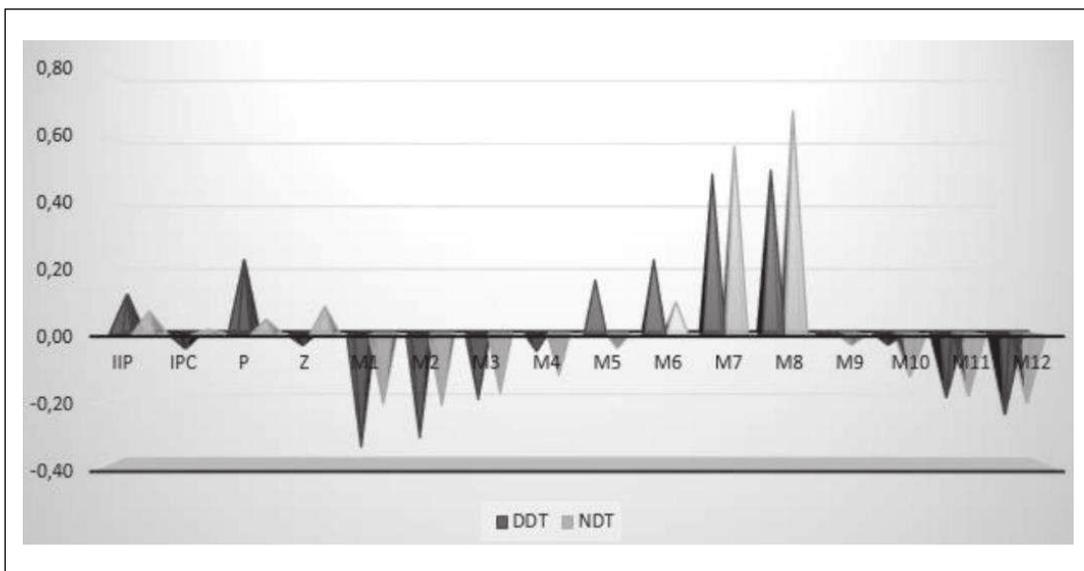
KORELACIJSKA MATRICA

	DDT	NDT	IIP	IPC	P	Z	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M11	M12
DDT	1,00																	
NDT	0,90	1,00																
IIP	0,12	0,07	1,00															
IPC	-0,05	0,01	0,48	1,00														
P	0,23	0,05	-0,28	-0,45	1,00													
Z	-0,04	0,09	0,39	0,65	-0,63	1,00												
M1	-0,35	-0,21	-0,04	-0,01	-0,04	-0,05	1,00											
M2	-0,32	-0,22	-0,03	-0,01	-0,07	0,00	-0,09	1,00										
M3	-0,20	-0,18	-0,05	0,00	0,00	-0,05	-0,09	-0,09	1,00									
M4	-0,05	-0,13	-0,01	0,00	-0,03	-0,03	-0,09	-0,09	-0,09	1,00								
M5	0,17	-0,04	-0,01	0,00	0,01	0,00	-0,09	-0,09	-0,09	-0,09	1,00							
M6	0,23	0,10	0,02	0,00	0,02	0,03	-0,09	-0,09	-0,09	-0,09	-0,09	1,00						
M7	0,49	0,58	0,00	0,00	-0,02	0,06	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	1,00					
M8	0,51	0,69	0,00	0,00	0,01	0,05	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	1,00				
M9	0,01	-0,03	0,02	0,01	-0,03	0,03	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	1,00			
M10	-0,03	-0,13	0,02	0,01	0,00	0,01	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	1,00		
M11	-0,20	-0,19	0,03	0,00	0,09	-0,02	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	1,00	
M12	-0,25	-0,21	0,04	-0,01	0,05	-0,05	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	-0,09	1,00

Najveći utjecaj na zavisne varijable imaju sezonske varijable M8 i M7 (mjeseci kolovoz i srpanj), čime se potvrđuje izrazito sezonski karakter domaće turističke potražnje (grafikon 2).

Grafikon 2.

## REZULTATI KORELACIJSKE ANALIZE



Ulazne varijable koje odražavaju odabrane ekonomske pokazatelje, iako očekivanih predznaka, ne pokazuju izrazito visoke koeficijente korelacije u odnosu na ciljnu varijable.

### 3. PROCES MODELIRANJA I ANALIZA EMPIRIJSKIH REZULTATA

Dolasci i noćenja domaćih turista u zavisnosti od odabranih ulaznih varijabli modelirani su upotrebom dviju acikličkih mreža višeslojnog perceptrona s unaprijednom propagacijom funkcijskog signala (*multilayer feedforward perceptron*). Procesu definiranja arhitekture neuronskih mreža prethodila je pred-obrađivanje podataka. Ulazne varijable kao i sve izlazne varijable normalizirane su *min-max* metodom danom izrazom (Morariu, Iancu, Vlad, 2009):

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (6)$$

gdje je,  $x$  originalna vrijednost, a  $x'$  normalizirana vrijednost.

Normaliziranje podataka rezultira boljim performansama neuronske mreže te postupkom treniranja poboljšanje kvalitete. Nakon skaliranja, podaci su podijeljeni u podgrupe za treniranje i testiranje. Kao sumacijska funkcija u oba modela korištena je hiperboličko-tangentna funkcija dana izrazom:

$$f(x) = \frac{e^u - e^{-u}}{e^u + e^{-u}} \quad (7)$$

gdje je  $u = g \cdot input$ , a  $g$  parametar koji određuje gradijent funkcije.

Hiperboličko-tangentna funkcija, zajedno sa sigmoidnom funkcijom, derivabilne su te se često koriste kao aktivacijske funkcije, jer najbolje prikazuju nelinearne odnose među varijablama.

Postojanje više skrivenih slojeva sa nelinearnim aktivacijskim funkcijama daje mreži sposobnost da nauči linearne i nelinearne interakcije između ulaznih i izlaznih vektora.

Linearna funkcija dana izrazom

$$f(x) = x \quad (8)$$

korištena je kao aktivacijska funkcija u oba modela višeslojnog perceptrona. Linearni izlazni sloj omogućava da izlazi mreže poprimo vrijednosti izvan intervala  $[-1,+1]$ . Linearna aktivacija funkcije daje izlaz koji je jednak neuronskom prosječnom ulazu, a neuroni s linearnom funkcijom često se koriste za linearne aproksimacije.

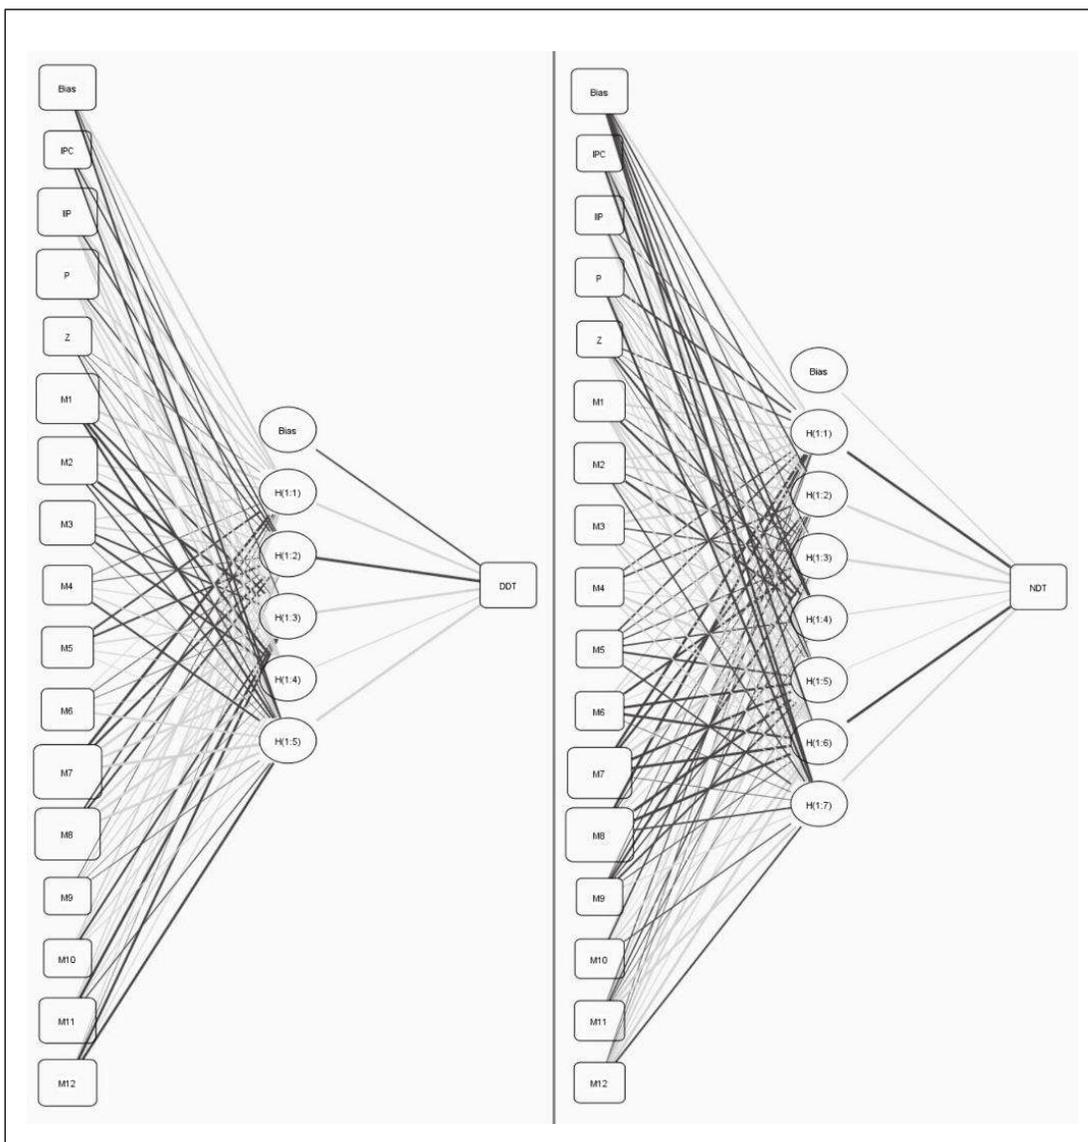
Kao mjerilo uspješnosti mreža korištena je suma kvadrata pogreške između procijenjenih  $t_1$  i stvarnih  $y_1$  vektora podataka dana izrazom:

$$E = sse = \frac{1}{2} \sum_{i=1}^n (t_i - y_i)^2 \quad (9)$$

Arhitekture dobivenih višeslojnih perceptrona prikazane su na slici 3.

Slika 3.

## VIŠESLOJNI PERCEPTRONI



Karakteristike dobivenih višeslojnih perceptrona sažete su tablici 2.

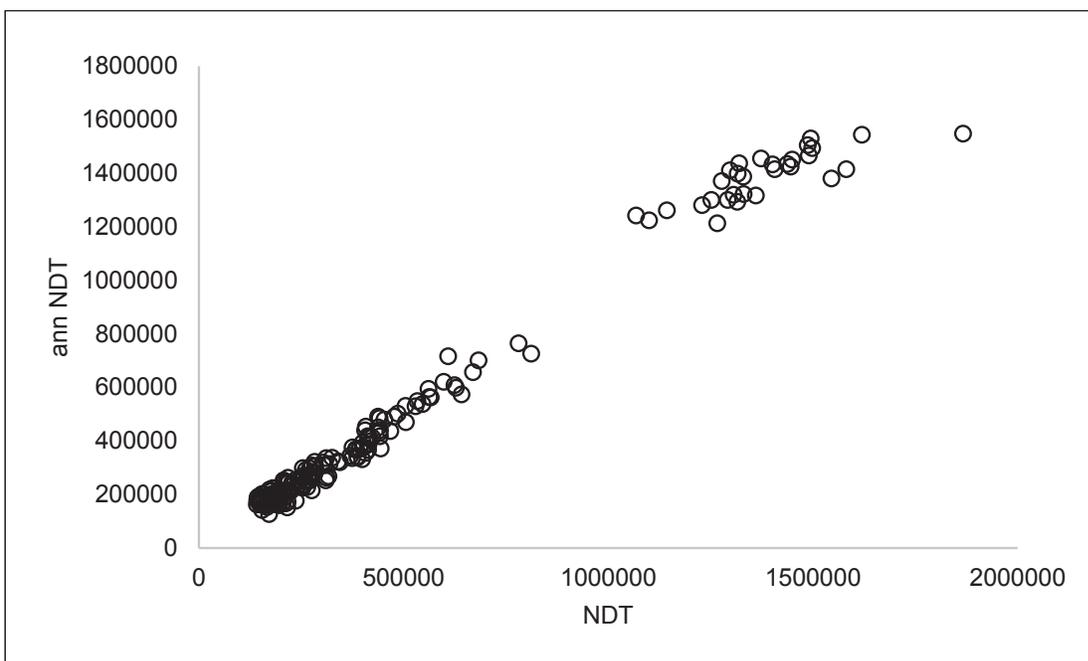
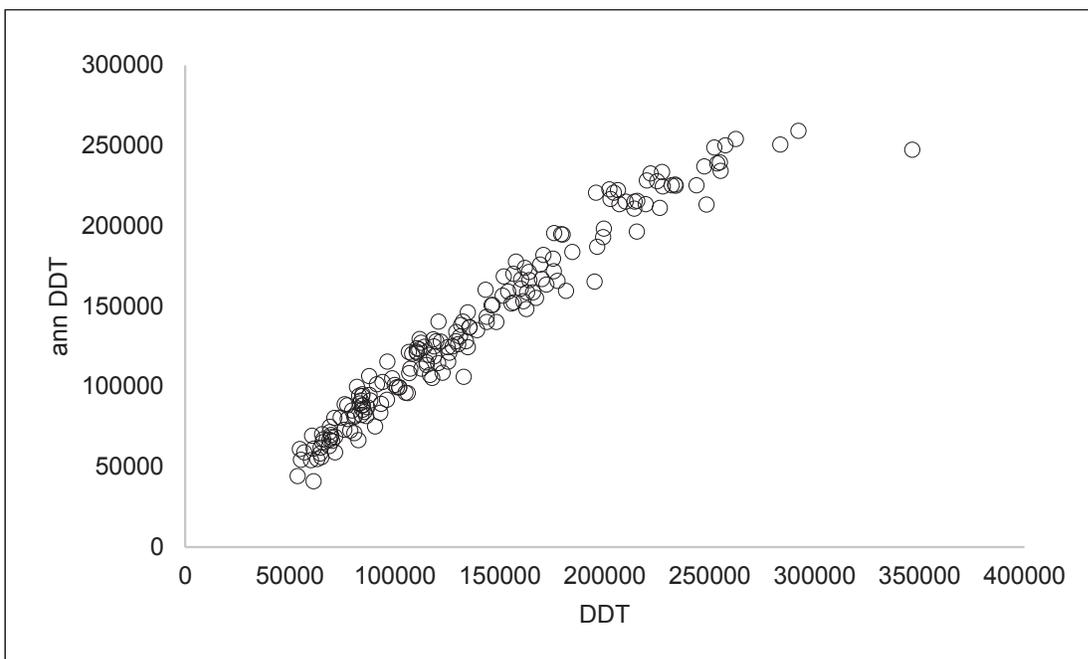
Tablica 2.

### KARKTERISTIKE VIŠESLOJNIH PERCEPTRONA

Algoritam	Višeslojni perceptron	
Metoda učenja	Metoda „širenja unatrag“	
Pravilo učenja	Metoda gradijentnog spusta	
Uzorkovanje	DDT	NDT
	treniranje=94 testiranje=40 validacija=46 ukupno=180	treniranje=113 testiranje=32 validacija=35 ukupno=180
Metoda normalizacije podataka	<i>min-max</i> metoda	
Arhitektura mreže	DDT	NDT
	16:5:1	16:5:1
Sumacijska funkcija	Hiperbolični tangens	
Aktivacijska funkcija	Linearna funkcija	
Koeficijent učenja	0,4	
Momentum	0,9	
Mjerilo uspješnosti mreže	Suma kvadrata pogreške	
	DDT	NDT
	treniranje	
	0,114	0,064
	testiranje	
	0,046	0,026

Jedna od uobičajeno korištenih metoda testiranja gubitka modela je provođenje linearne regresijske analize između stvarnih izlaza neuronske mreže i procijenjenih vrijednosti ciljnih varijabli. Analiza rezultira trima parametrima, među kojima je i koeficijent determinacije. Rezultati provedene regresijske analize nad stvarnim i procijenjenim brojem dolazaka i noćenja pokazali su vrijednosti koeficijenata determinacije više od 95% u oba slučaja te dobru prilagodbu stvarnih i dobivenih ciljnih varijabli (grafikon 3).

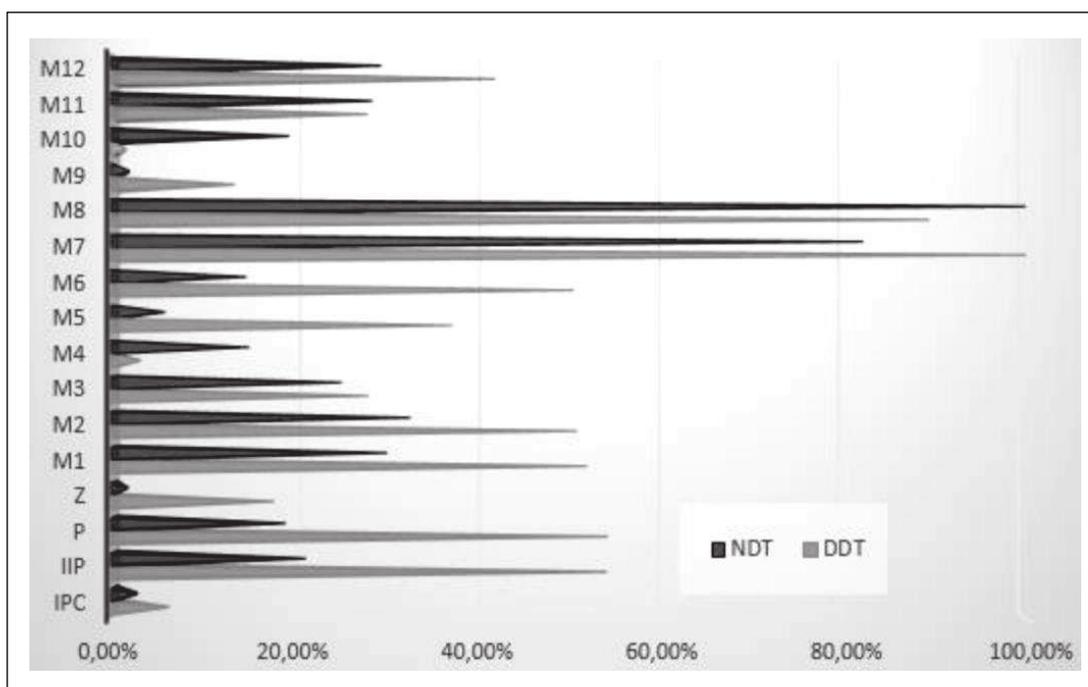
Grafikon 3.

REGRESIJSKA ANALIZA: STVARNE I PROCIJENJENE VRIJEDNOSTI  
BROJA DOLAZAKA I BROJA NOĆENJA DOMAĆIH TURISTA

Analiza važnosti ulaznih varijabli na ciljne varijable ukazala je na najutjecajnije varijable (grafikon 4).

Grafikon 4.

#### ANALIZA VAŽNOSTI ULAZNIH VARIJABLI

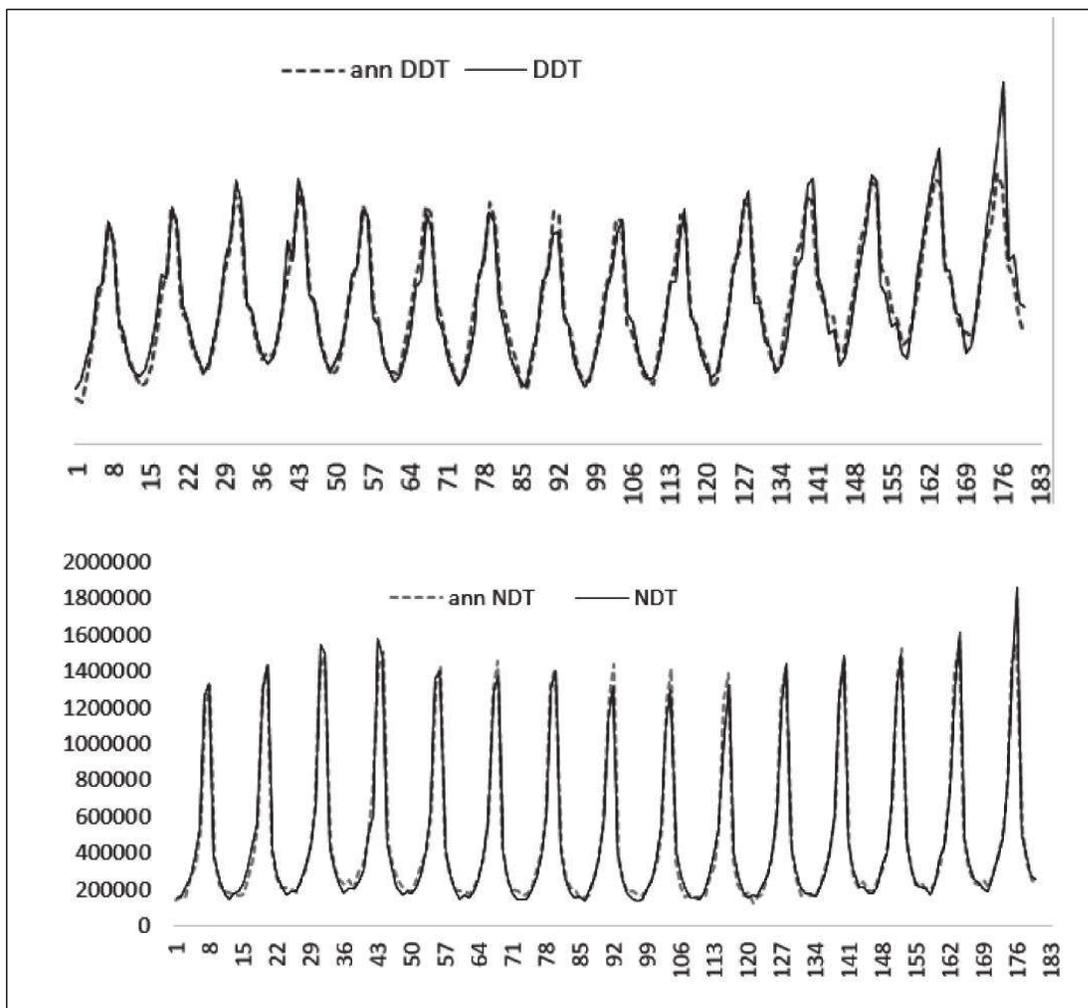


Između odabrani ulaznih varijabli najveći utjecaj na dolazak i ostvarena noćenja domaćih turista imaju sezonske *dummy* varijable M8 i M7 (100%). Rezultati su pokazali kako su dolasci domaćih turista osjetljivi i na indekse potrošačkih cijena i plaće (oko 50%), dok na ostvarena noćenja značajniji utjecaj pokazuju samo mjesečne sezonske *dummy* varijable.

Usporedba stvarnih i procijenjenih vrijednosti ukazuje na dobru prilagodbu dobivenih rezultata (grafikon 5)

Grafikon 5.

### KRETANJE STVARNIH I PROCIJENJENIH VRIJEDNOSTI BROJA DOLAZAKA I BROJA NOĆENJA DOMAĆIH TURISTA



Evaluacija performansi dizajniranih modela umjetnih neuronskih mreža procijenjena je prosječnom apsolutnom postotnom pogreškom, prosječnom apsolutnom pogreškom, te koeficijentom korelacije između stvarnih i procijenjenih vrijednosti. Vrijednosti prosječnih postotnih apsolutnih pogrešaka niske su i iznose 6,8% te 8,7%. Vrijednosti prosječne apsolutne pogreške (8859,3 za niz broja dolazaka domaćih turista i 31826,7 za niz ostvarenih noćenja domaćih turista), kao i vrijednosti koeficijenata korelacije između stvarnih i procijenjenih vrijednosti 98%, odnosno 99%, ukazuju na dobru prilagodbu stvarnih i procijenjenih vrijednosti te zadovoljavajuće rezultate modeliranja.

#### 4. ZAKLJUČAK

Svrha je ovoga rada bila istražiti učinkovitost primjene te evaluirati performanse modela višeslojnih perceptrona u modeliranju domaće turističke potražnje aproksimirane brojem dolazaka i ostvarenih noćenja domaćih turista. Kao ulazne varijable odabrane su prosječna mjesečna neto plaća, prosječni godišnji indeks potrošačkih cijena, indeksi fizičkoga obujma industrijske proizvodnje, broj zaposlenih te mjesečne *dummy* varijable, kao odraz sezonskog karaktera analiziranih vremenskih serija. Analiza rezultata pokazala je visoku pouzdanost i efikasnost modela višeslojnoga perceptrona u modeliranju empirijskih podataka. Analiza važnosti ulaznih varijabli potvrdila je visoku značajnost sezonskih *dummy* varijabli te izrazitu sezonsku osjetljivost domaće turističke potražnje.

Provedeno istraživanje tek je doprinos detaljnijoj analizi i boljem razumijevanju temeljnih determinanti domaće turističke potražnje u Republici Hrvatskoj. Polazeći od ograničenja provedenoga istraživanja, a koja se očituju u relativno malom uzorku podataka te broju odabranih varijabli, dobiveni rezultati potvrđuju efikasnost dobivenih višeslojnih perceptrona.

Naime, kada se radi o većoj količini podataka i o kompleksnijim problemima, poznato je kako modeli umjetnih neuronskih mreža pokazuju bolje rezultate te veću učinkovitost i prognostičke performanse u odnosu na tradicionalne modele.

Slijedom navedenoga, potrebno je napomenuti, kako bi rezultati provedenoga istraživanja dobili na kvaliteti povećanjem broja opažanja, odnosno veličine uzorka, što je svakako i preporuka za buduće detaljnije i sustavnije analize tretirane problematike.

Nadalje, s obzirom na važnost i nužnost kvantitativnog modeliranja i prognoziranja ključnih determinanti domaće turističke potražnje, na povećanje performansi modela višeslojnih perceptrona svakako bi utjecalo i povećanje broja ulaznih varijabli. Osim odabranih ulaznih varijabli, u budućim je analizama potrebno uključiti i neke varijable koje upućuju na temeljne socio-demografske pokazatelje stanovništva Republike Hrvatske kao što su broj odseljenih stanovnika, stopa prirodnog kretanja stanovništva, stopa rizika od siromaštva, Ginijev koeficijent te indeks razvijenosti. U buduća istraživanja kretanja domaće turističke potražnje potrebno je uključiti i varijable koje se odnose na osnovne odrednice turističke ponude. Naime polazeći od činjenice da je Republika Hrvatska profilirana kao turistička destinacija koja svoj turistički razvoj temelji na međunarodnom turizmu, poticanje razvoja domaće turističke potražnje treba temeljiti na detaljnoj analizi karakteristika turističke ponude i njenoga prilagođavanja zahtjevima i potrebama domaćih turista.

Unatoč već spomenutim ograničenjima provedenoga istraživanja, dobiveni rezultati ukazuju na robustnost modela višeslojnih perceptrona u modeliranju domaće turističke potražnje, što je potvrđeno niskim prognostičkim pogreškama i visokim koeficijentom determinacije.

Rad dokazuje primjenjivost modela umjetnih neuronskih mreža u modeliranju turističke potražnje, ali i, zahvaljujući primjeni procesa učenja prilikom obrade velikog broja heterogenih podataka, značajnu učinkovitost u prognoziranju budućih vrijednosti razmatranih pojava.

U tom se smislu modeli umjetnih neuronskih mreža mogu smatrati vrlo korisnim alatom u procesu donošenja odluka.

Polazeći od rezultata, ali i ograničenja istraživanja, zaključno se može reći kako modeli umjetnih neuronskih mreža posjeduju velike aplikativne potencijale u modeliranju i prognoziranju vremenskih nizova broja dolazaka i noćenja domaćih turista u Republici Hrvatskoj.

Slične, detaljnije i sustavnije studije trebale bi se smatrati polazištima za razradu budućih razvojnih strategija, kako za turizam, tako i za ostale gospodarske grane.

## LITERATURA

1. Abas, M. i Lasarudin, A. (2019). Prediction of arrival domestic and foreign tourists based on regions using neural network algorithm based on genetic algorithm. *Journal of Physics: Conference Series*. 1175. 10.1088/1742-6596/1175/1/012045.  
Dostupno na <https://www.researchgate.net/publication/333671252>
2. Claveria, O., Monte, E. i Torra, S. (2014). Tourism demand forecasting with neural network models: Different ways of treating information. *International Journal of Tourism Research*, Vol. 17. 492-500. doi: 10.1016/j.econmod.2013.09.024
3. Constantino, H.A., Fernandes, P. i Teixeira, J. (2016). Tourism demand modelling and forecasting with artificial neural network models: The Mozambique case study. *Tékhne*. 51. 10.1016/j.tekhne.2016.04.006.
4. Dalbelo Bašić, B. Čupić, M. i Šnajder, J. (2008). Umjetne neuronske mreže, Umjetna inteligencija, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, Zavod za elektroniku, mikroelektroniku i inteligentne sustave, Zagreb.

5. Fernandes, P.O., Teixeira, J.P., Ferreira, J. i Azavedo Susana (2008). Modeling tourism demand: a comparative study between Artificial Neural Networks and the Box-Jenkins methodology. *Romanian Journal of Economic Forecasting*, Vol. 9, 30- 50.
6. Folgieri, R., Baldigara, T. i Mamula, M. (2017), Artificial Neural Network Based Econometric Models for Tourism Demand Forecasting, Proceedings of the Tourism in Southern and Eastern Europe International Conference, Faculty of Tourism and hospitality management, May 4-6, 2017, Opatija, Croatia, Vol. 4, 169-182.
7. Haykin, S. (1999). *Neural Networks and learning machines*, 3rd edition, New York Pearson Prentice Hall.
8. Mamula, M. i Duvnjak, K. (2018). Artificial neural networks implementation potentials – A literature review. In Proceeding of the 2nd International Statistical Conference in Croatia - ISCCRO'18, Croatian Statistical Association May 10 – 11 2018, Opatija, Hrvatska.: ISSN: 1849-9872. 86-93.
9. Morariu, N., Iancu, E. i Vlad, S. (2009) A Neural Network model for time-series forecasting, *Romanian Journal of Economic Forecasting*, Vol. 4. 213-223.
10. Serra, J., Correia, A. i Rodrigues, P. (2014). A comparative analysis of tourism destination demand in Portugal. *Journal of Destination Marketing Management*. 2. 221-227. doi: 10.1016/j.jdmm.2013.10.002.
11. Song, H., Witt, S. i Li, G. (2009) *The Advanced Econometrics of Tourism Demand*, London: Routledge.
12. Song, Haiyan i Li, Gang. (2008). Tourism demand modelling and forecasting - A review of Recent research. *Tourism Management*. 29. 203-220. doi: 10.1016/j.tourman.2007.07.016.
13. Zekić-Sušac, M. (2017) Neuronske mreže, Sveučilište J.J. Strossmayera u Osijeku, Ekonomski fakultet u Osijeku. Dostupno na: <http://www.efos.unios.hr/upravljanje-marketingom/wp-content/uploads/sites/192/2013/04/P3>.
14. Wang, M., Zhang, H. i Wu, Z. (2019). Forecast and Application of GA Optimization BP Neural Network Tourism Demand in High-speed Railway Era, IOP Conference Series: Materials Science and Engineering, 569(4). Dostupno na <https://iopscience.iop.org/article/10.1088/1757-899X/569/4/042053>

## THE APPLICATION OF ARTIFICIAL NEURAL NETWORKS IN MODELLING DOMESTIC TOURISM DEMAND

### Summary

The paper investigates the efficiency of artificial neural networks in modelling domestic tourist demand in the Republic of Croatia, approximated by the number of arrivals and the number of realized overnight stays of domestic tourists. Industrial production volume indices, consumer price indices, average net monthly wages, the number of employees and the monthly seasonal *dummy* variables were selected as input variables. Two multilayer perceptrons neural networks models were used to model empirical data. The model predictive efficiency was evaluated using the mean average, mean absolute percentage, mean squared root forecast errors, as well as the coefficient of determination and the Pearsons correlation coefficient. The obtained results evaluation showed that the selected multilayer perceptrons models are reliable for modelling domestic tourism demand, although the research is based on a limited small amount of data as well as the number of input variables. Given the research results, as well as the research limitations, it can be concluded that the artificial neural networks models have significant application potentials in modelling time-series of arrivals and overnight stays of domestic tourists in the Republic of Croatia.

Key words: domestic tourism demand, modelling, artificial neural networks models, multi-layer perceptron