

Modeliranje i prognoziranje broja zaposlenih u turizmu i hotelskoj industriji u Republici Hrvatskoj primjenom modela umjetnih neuronskih mreža

Modelling and forecasting the number of employees in tourism and hotel industry in the Republic of Croatia using the model of artificial neural networks

TEA BALDIGARA

Fakultet za menadžment u turizmu i ugostiteljstvu

Sveučilište u Rijeci

Naselje Ika, Primorska 42, Opatija

Hrvatska

teab@fthm.hr

Izvorni znanstveni rad / *Original scientific paper*

UDK / UDC: 338.486-057.16:004.8(497.5).331:004.8(497.5)

Primljeno / Received: 07. svibnja 2020. / May 07th, 2020.

Prihvaćeno za objavu / Accepted for publishing: 19. svibnja 2020. / May 19th, 2020.

Sažetak: Rad istražuje performansu i prognostičku moć modela umjetnih neuronskih mreža u modeliranju i prognoziranju vremenskih serija sezonskog karaktera. Modeli umjetnih neuronskih mreža primijenjeni su u modeliranju i prognoziranju ukupnoga mjesečnog broja zaposlenih, broja zaposlenih muškaraca i broja zaposlenih žena u djelatnosti pružanja usluga smještaja te pripreme i usluživanja hrane i pića u Republici Hrvatskoj. Dobiveni rezultati modeliranja uspoređeni su rezultatima dobivenim primjenom, nekih od tradicionalno korištenih kvantitativnih modela u analizi sezonskih vremenskih serija, kao što su Holt-Wintersov model trostrukoga eksponencijalnog izgladivanja te sezonski multiplikativni model eksponencijalnoga trenda. Evaluacija performansi te prognostičke moći pojedinih modela provedena je usporedbom prosječne apsolutne te prosječne apsolutne postotne pogreške i koeficijenta korelacija između stvarnih i procijenjenih vrijednosti, a prognozirane vrijednosti uspoređene su sa stvarnim vrijednostima. Evaluacija dobivenih rezultata pokazala je kako je odabrani model acikličkog višeslojnog perceptrona pogodan za modeliranje i prognoziranje vremenskih serija sezonskoga karaktera. Usporedba prognostičkih moći te stvarnih i prognoziranih vrijednosti broja zaposlenih sugeriraju kako je dizajnirani model umjetne neuronske mreže vrlo pouzdan. Navedeno upućuje na to kako modeli umjetnih neuronskih mreža posjeduju velike aplikativne potencijale u domeni modeliranja i prognoziranja vremenskih serija sezonskog karaktera.

Ključne riječi: broj zaposlenih, turizam i hotelska industrija, sezonske vremenske serije, modeli umjetnih neuronskih mreža, model višeslojnog perceptrona

Abstract: The paper investigates the performance and prognostic power of artificial neural network models in modelling and forecasting of time series of seasonal character. Models of artificial neural networks have been applied in modelling and forecasting the monthly total number of employees, the

number of employed men and the number of employed women in the activity of providing accommodation services and preparing and serving food and beverages in the Republic of Croatia. The obtained modelling results have been compared with the results obtained by applying some of the traditionally used quantitative models in the analysis of seasonal time series, such as the Holt-Winters model of triple exponential smoothing and the seasonal multiplicative model of exponential trend. The evaluation of the performance and prognostic power of individual models was performed by comparing the average absolute and average absolute percentage error and the correlation coefficient between the actual and estimated values, and the predicted values were compared with the actual values. The evaluation of the obtained results showed that the selected model of acyclic multilayer perceptron is suitable for modelling and forecasting time series of seasonal character. The comparison of prognostic powers and actual and projected values of the number of employees suggests that the designed model of the artificial neural network is very reliable. This indicates that the models of artificial neural networks have great application potentials in the domain of modelling and forecasting of time series of a seasonal character.

Keywords: number of employees, tourism and hotel industry, seasonal time series, artificial neural network models, multilayer perceptron model

1 Uvod

Posljednjih su desetljeća provedena i objavljena mnogobrojna istraživanja iz područja modeliranja i prognožiranja raznovrsnih aspekata turističke ponude i potražnje. Zajedničko tim studijama jest naglašavanje važnosti i nužnosti iscrpnih i sustavnih kvantitativnih analiza, dizajniranja modela te prognožiranja budućih vrijednosti osnovnih determinanti turizma i hotelske industrije, kao temelja kreiranja uspješnih poslovnih i razvojnih strategija, planiranja iskorištenosti resursa te ostvarivanja boljih poslovnih rezultata. U navedenim je studijama i istraživanjima primijenjen velik broj raznovrsnih metoda, od jednostavnih do kompleksnih. Kvantitativne se metode modeliranja i prognožiranja općenito dijele na kauzalne metode i metode analize vremenskih serija te nešto inovativnije metode umjetne inteligencije. Među metodama umjetne inteligencije sve veću popularnost u domeni istraživanja u turizmu i hotelskoj industriji posljednjih desetljeća imaju modeli umjetnih neuronskih mreža, kao modeli koji svoje osobine i obrasce temelje na karakteristikama funkcioniranja i zaključivanja ljudskoga živčanog sustava. Posljednjih godina modeli umjetnih neuronskih mreža postižu veliku popularnost kao modeli koji se koriste u analiziranju i modeliranju vremenskih serija. Rastući interes za umjetne neuronske mreže rezultat je njihovih aplikativnih potencijala na velike podatke (*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 svojevrzne konkurentske prednosti navedenih modela u odnosu na tradicionalne kvantitativne modele (Folgieri, Baldigara i Mamula, 2017). Svrha ovoga rada je istražiti aplikativne potencijale modela umjetnih neuronskih mreža, kao alternative standardnim kvantitativnim metodama, u modeliranju i prognožiranju vremenskih serija u domeni turizma i hotelske industrije.


2 Metodološki i teorijski okviri istraživanja

Cilj ovoga rada je istražiti primjenjivost i efikasnost primjene modela umjetnih neuronskih mreža u modeliranju i prognožiranju vremenskih serija koje pokazuju izražene osobine sezonalnosti. U radu se primjenom modela umjetnih neuronskih mreža modelira i prognožira kretanje broja zaposlenih, i to

ukupnog broja, broja zaposlenih žena i broja zaposlenih muškaraca, u djelatnosti pružanja smještaja te priprema i usluživanja hrane i pića.

2.1 Metodološke odrednice istraživanja

Sve je veći broj istraživanja, znanstveno-stručnih radova i studija koje se bave problematikom upotrebe metoda strojnoga učenja, a posebno područjem primjene modela umjetnih neuronskih mreža u prognoziraju vremenskih serija u mnogobrojnim područjima ljudskoga djelovanja. Mamula i Duvnjak (2018) analizirali su 57 objavljenih znanstvenih članaka u razdoblju od 2008. do 2018. godine koji se bave problematikom modeliranja i prognoziranja turističke potražnje i njezinih temeljnih odrednica. Rezultati provedenoga istraživanja za stolom pokazali su kako je u 46 od 57 analiziranih znanstvenih članaka primijenjena neka od metoda umjetne inteligencije, posebno modeli umjetnih neuronskih mreža. Nadalje, u čak 16 znanstvenih članaka modeliranje i prognoziranje provedeno je kombiniranjem kauzalnih metoda ili metoda analize vremenskih serija s metodama umjetne inteligencije. U nastavku je navedeno samo nekoliko takvih istraživanja i studija koja su polazne točke ovoga rada. Fernandes, Teixeira, Ferreira i Azevedo (2008) istraživali su učinkovitost modela umjetnih neuronskih mreža u modeliranju turističke potražnje u Portugalu u odnosu na tradicionalno korištene ARIMA modele. Rezultati modeliranja pokazali su da modeli umjetnih mreža daju zadovoljavajuće rezultate te da, iako nisu nastali kao modeli analize vremenskih serija, mogu biti upotrijebljeni kao alternative standardnim modelima. Claveria, Monte i Torra (2014) prognozirali su 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. Krešić, Mikulić i Kožić (2013) istraživali su primjene višeslojnog perceptrona u analizi podataka radi dobivanja uvida u one karakteristike Sarajeva kao turističke destinacije koje imaju najviše utjecaja na cjelokupni turistički dojam. Mamula i Duvnjak (2018) zaključuju kako, bez obzira na sve veću njihovu primjenu u domeni modeliranja i prognoziranja determinanti turističke ponude i potražnje, ne postoji sustavni i opsežni pregled literature o istraživanjima koji se bave navedenom problematikom. Polazeći od pretpostavke važnosti turizma i hotelske industrije za ekonomski rast i razvoj naše zemlje, njihova radno intenzivnoga te sezonalnoga karaktera s jedne strane te uvažavanjem važnosti i nužnosti kvantitativnih analiza u modeliranju i prognoziraju kretanja broja zaposlenih, s druge strane, istraživački problem ovoga rada prikazan je na Slici 1.



Slika 1. Istraživački problem

Izvor: Izrada autora (2020)


Utemeljena je činjenica kako su turizam i hotelska industrija radno intenzivne djelatnosti, koje svoju konkurentnost temelje na ljudskim resursima kao ključnim čimbenicima uspjeha. U suvremenim tržišnim uvjetima globalizacije i jake tržišne konkurentnosti, segmentiranosti tržišta, sve većim i specifičnim zahtjevima i potrebama turista, ključno pitanje opstanka i uspjeha postaje dostupnost kvalificiranih i dostupnih ljudskih resursa. U nastavku je opisana metodologija istraživanja te su iznesene osnovne teorijske postavke korištenih kvantitativnih modela.

2.2 Metodologija i podaci

Učinkovitost i performanse modela umjetnih neuronskih mreža uspoređeni su s rezultatima dobivenim uporabom dvaju kvantitativnih modela tradicionalno korištena u analizi sezonskih vremenskih serija, i to Holt-Wintersova modela trostrukoga eksponencijalnog izgladivanja te sezonskoga multiplikativnog modela eksponencijalnoga trenda.

Performansa prognostičkih modela te učinkovitost prognoza evaluirana je prosječnom apsolutnom pogreškom (MAE), prosječnom postotnom apsolutnom pogreškom (MAPE) te koeficijentom korelacije između stvarnih i procijenjenih vrijednosti.

Modeliranje i prognoziranje odabranim prognostičkim provedeno je kao na Slici 2.




Slika 2. Vremenski horizont modeliranja i *ex post* prognoze broja zaposlenih

Izvor: Preuzeto i prilagođeno prema Song, H., Witt, S., Li (2020)

Prognostički modeli procijenjeni su na temelju stvarnoga mjesečnog broja zaposlenih od siječnja 2014. do prosinca 2019. godine ($n = 72$). *Ex post* prognoza temeljena je na podacima za siječanj i veljaču 2020. godine ($h = 2$).

Podaci o kretanju ukupnog broja zaposlenih, broja zaposlenih muškaraca te broja zaposlenih žena u djelatnosti pružanja usluga smještaja, te pripreme i pružanja usluga hrane i pića u razdoblju od siječnja 2014. godine do veljače 2020. godine preuzeti su s mrežnih stranica Državnoga zavoda za statistiku Republike Hrvatske. Grafikon 1 prikazuje kretanje analiziranih empirijskih vremenskih serija.



Grafikon 1. Kretanje broja zaposlenih: ukupno i prema spolu:
od siječnja 2014. godine do veljače 2020. godine
Izvor: Izrada autora (2020)

U analiziranim vremenskim serijama očita je izražena sezonalnost, ali i trend rasta. Tablica 1 prikazuje osnovne rezultate provedene deskriptivne analize.


Tablica 1. Deskriptivna analiza empirijskih vremenskih serija
Izvor: Izrada autora (2020)

	<i>Ukupno</i>	<i>Muškarci</i>	<i>Žene</i>
$\bar{x}$	70 720,338	32 606,824	38 113,514
σ	14 925,182	6 878,456	8 070,473
Var	2 22 761 067,323	47 313 154,832	65 132 528,719
α_4	2,131	2,232	2,053
α_3	0,186	0,290	0,101
<i>Jarque-Bera</i>	2,664	2,751	2,807
$p(JB)$	0,264	0,253	0,246
$\min(x)$	42598	19975	22623
$\max(x)$	101312	47400	53912

Iz Grafikona 1. vidljivo je kako je tijekom cijeloga razmatranog razdoblja veći broj zaposlenih žena u odnosu na broj zaposlenih muškaraca. Rezultati t testa ($t = -32,46$) pokazali su statistički značajnu različitost aritmetičkih sredina broja zaposlenih žena i broja zaposlenih muškaraca. Geometrijskom sredinom verižnih indeksa izračunate su stope promjene ukupnog broja zaposlenih, zaposlenih žena te muškaraca u djelatnosti pružanja smještaja te pripreme i pružanja hrane i pića u razmatranom razdoblju. Stope su pokazale da su sve tri razmatrane vremenske serije rasle po prosječnoj stopi rasta od 0,5 % u cjelokupnom razdoblju. U nastavku su dane osnovne teorijske postavke korištenih prognostičkih modela.

Model umjetne neuronske mreže

Umjetne neuronske mreže metode su strojnog učenja inspirirane radom biološkog neurona, odnosno modelom zaključivanja na temelju ljudskog mozga. Slika 3. prikazuje strukturu biološkog i umjetnog neurona.



Slika 3. Biološki neuron Vs Umjetni neuron

Izvor: Preuzeto i prilagođeno prema Laubscher, R., Engelbrecht, Q., Marais, C. F. P.

Biološki živčani sustav sastoji se od velikog broja međusobno gusto povezanih živčanih stanica, neurona, koji su osnovne jedinice za obradu podataka.

Neuron se sastoji od some, odnosno tijela stanice, dendrita i aksona.


Signali se prenose iz jednog u drugi neuron elektrokemijskim reakcijama. Dendriti se granaju oko some, dok se akson proteže na dendritima i somama drugih neurona. Kemijske tvari koje se ispuštaju iz sinapsi djeluju na promjenu električnoga potencijala tijela stanice. U trenutku kada električni potencijal dosegne određeni prag, električni impuls šalje akcijski potencijal preko aksona do sinapse, povećavajući ili smanjujući njezin potencijal.

Jedna od temeljnih karakteristika bioloških mreža je sposobnost učenja, odnosno korištenje iskustva radi poboljšanja performansi. Navedene osobine ljudskoga živčanoga sustava temelj su funkcioniranja umjetnih neuronskih mreža.

Analogno biološkom neuronu, umjetni neuron, perceptron, je osnovna jedinica za obradu podatka. On prima ponderirane ulazne vrijednosti od drugih varijabli, prema određenoj funkciji transformira dobivene vrijednosti te ih u obliku izlaza šalje drugim varijablama.

Proces učenja temelji se na promjeni vrijednosti težina među varijablama. Težine predstavljaju pondere kojima se množe ulazne vrijednosti u neki određeni neuron.

Struktura umjetne neuronske mreže analogna je strukturi biološke neuronske mreže. Neuronske mreže kao metode strojnog učenja temelje se na matematičkim modelima s arhitekturom analognom ljudskom živčanom sustavu. Slika 4. prikazuje karakterističnu strukturu umjetne neuronske mreže.



Slika 4. Struktura umjetne neuronske mreže

Izvor: Preuzeto i prilagođeno prema Pouliakis, A., Karakitsou, E., Margari, N., Bountris, P., Haritou, M., Panayiotides, J., Koutsouris, D.

Kako je prikazano na Slici 4., osnovni elementi umjetne neuronske mreže su: ulazi s težinskim koeficijentima, ulazna ili sumacijska funkcija, aktivacijska funkcija te izlazi.

Neuronske mreže sastavljene su od skupa međusobno povezanih neurona (perceptrona) koji su organizirani u slojeve: ulazni sloj, jedan ili više skrivenih slojeva i izlazni sloj. U ulaznom sloju svaki neuron prihvaća jednu vrijednost/varijablu te generira izlaznu vrijednost koja će se koristiti kao ulaz za neurone sljedećeg sloja. Kada neuron prima ulaz iz prethodnog sloja, vrijednost njegova ulaza računa se prema ulaznoj ili sumacijskoj funkciji čiji je opći oblik (Zekić Sušac, 2017):


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

pri čemu je w_{ij} težina veze od neurona j do neurona i , n je broj neurona u sloju koji šalje svoj izlaz.

$Input_i$ predstavlja stoga sumu svih ponderiranih izlaza koji pristižu u taj neuron. Svaki neuron skrivenoga sloja prima sumu svih ponderiranih ulaza, a zatim primjenjuje određenu aktivacijsku funkciju kako bi se generirao izlaz neurona skrivenoga sloja. Izračunati se izlaz mreže zatim uspoređuje sa stvarnim izlazima, a njihova razlika predstavlja pogrešku koja se koristi za podešavanje pondera u ulaznom sloju primjenom određenoga pravila učenja. Učenje je postupak podešavanja težinskih faktora tako da mreža dobije željeno ponašanje i funkcionalnost.

Uobičajeno je da polazne težine poprimaju niske slučajno određene vrijednosti, koje se tijekom učenja podešavaju primjenom određenoga odabranog pravila učenja. Težine se tako ažuriraju na temelju usporedbe dobivenog i očekivanog izlaza te ocjenjuju na temelju odabrane funkcije pogreške.

Prilikom odabira modela umjetne neuronske mreže postoji nekoliko kriterija razlikovanja između različitih algoritama umjetnih neuronskih mreža. Neki od tih kriterija su broj slojeva, tip učenja i veze između neurona, tip veze između ulaznih i izlaznih podataka, tip sumacijske i aktivacijske funkcije, sigurnost ispaljivanja i tako dalje. Općenito se dizajniranje i upotreba modela umjetne neuronske mreže sastoji od nekoliko logički povezanih koraka kako je prikazano na Slici 5.



Slika 5. Metodologija dizajniranja modela umjetne neuronske mreže

Izvor: Izrada autora (2020)

Uobičajeno je da se metodologija dizajniranja modela umjetne neuronske mreže sastoji od predobrade podataka, određivanja arhitekture mreže, postupka učenja i testiranja mreže.

Holt-Wintersov model trostrukog eksponencijalnoga izgladivanja

Holt-Wintersov model trostrukoga eksponencijalnoga izgladivanja prikladan je za prognoziranje pojava s trend i sezonskom komponentom. U multiplikativnom Holt-Winters modelu polazi se od pretpostavke da je svako opažanje umnožak nesezonske vrijednosti i sezonskog indeksa za dano razdoblje. Model se temelji na tri jednadžbe izgladivanja – prvom se izgladuje razina pojave, drugom trend komponenta, a trećom sezonska komponenta. Formalno se model notira kako slijedi (Fretchling, 2001):

$$\text{Razina:} \quad L_t = \alpha \cdot \frac{y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (2)$$

$$\text{Trend:} \quad b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (3)$$

$$\text{Sezona:} \quad S_t = \gamma \frac{y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (4)$$

$$\text{Prognoza:} \quad F_{t+h} = (L_t + hb_t)S_{t-s+h} \quad (5)$$

gdje je

Y = stvarna vrijednost pojave

L = izgladena vrijednost razine pojave

α = konstanta izgladivanja razine

s = broj sezonskih razdoblja unutar godine

b = trend vrijednosti pojave

β = konstanta izgladivanja trend komponente

S = procjena sezonskoga utjecaja

γ = konstanta izgladivanja sezonske komponente

t = razdoblje

F = prognozirana vrijednost pojave za $t+h$ razdoblja unaprijed

h = broj razdoblja za koje se vrši prognoza

Izračunima inicijalnih vrijednosti pristupa se upotrebom sljedećih izraza:

Inicijalne vrijednosti razine pojave:
$$L_s = \frac{A_1 + A_2 + \dots + A_s}{s} \quad (6)$$

Inicijalne vrijednosti trend komponente:
$$b_s = \frac{1}{s} \left(\frac{A_{s+1} - A_1}{s} + \frac{A_{s+2} - A_2}{s} + \dots + \frac{A_{s+s} - A_s}{s} \right) \quad (7)$$

Inicijalne vrijednosti sezonske komponente:
$$S_1 = \frac{A_1}{L_s}, S_2 = \frac{A_2}{L_s}, \dots, S_s = \frac{A_s}{L_s} \quad (8)$$

Alternativno, inicijalne vrijednosti mogu se izračunati interpolacijom trenda povijesnih podataka vremenske serije metodom najmanjih kvadrata.

Sezonski multiplikativni model eksponencijalnoga trenda

Za modeliranje vremenskih serija sezonskoga karaktera s mjesečnim podacima koristi se model eksponencijalnoga trenda prikazan izrazom:

$$Y_t = \beta_0 \cdot \beta_1^{x_t} \cdot \varepsilon_t \quad (9)$$

gdje je

Y_t = vrijednosti vremenske serije u razdoblju t

x_t = vrijednost pojave u razdoblju t

ε_t = slučajno odstupanje u razdoblju t

Ako je sezonska komponenta konstantna tijekom čitavoga razdoblja (regresijski pristup), sezonalnost se uklanja dodatnim uključivanjem u model sezonskih *dummy* varijabli.

Pri analiziranju sezonskih vremenskih serija s mjesečnim podacima izraz (9) modificira i prilagođava sezonskom i mjesečnom karakteru analizirane serije. Dobije se tako izraz:

$$Y_t = \beta_0 \beta_1^{x_t} \beta_2^{M_1} \beta_3^{M_2} \beta_4^{M_3} \beta_5^{M_4} \beta_6^{M_5} \beta_7^{M_6} \beta_8^{M_7} \beta_9^{M_8} \beta_{10}^{M_9} \beta_{11}^{M_{10}} \beta_{12}^{M_{11}} \quad (10)$$

gdje je

Y_t = vrijednosti vremenske serije u razdoblju t

x_t = vrijeme

β_0 = konstanti član

$(\beta_1 - 1) \cdot 100$ = procjena mjesečne stope rasta

$\beta_2, \dots, \beta_{12}$ = mjesečni multiplikator u odnosu na bazni mjesec

$M_1, \dots, M_{11}$ = sezonske *dummy* varijable

Model (10) sadrži konstanti član, a broj *dummy* varijabli je za jedan manji od broja jediničnih intervala, pri čemu vrijedi:

$$M_i = \begin{cases} 1 & \text{za } i - ti \text{ mjesec} \\ 0 & \text{za ostale mjesece} \end{cases}, i = 1, 2, \dots, 11.$$

Nedostatak modeliranja ovakvim modelom očituje se u pretpostavkama modela i to determinističkom karakteru trenda i sezonskih varijacija. U nastavku su opisani rezultati provedenoga empirijskog istraživanja.

3 Analiza empirijskih rezultata

Za modeliranje i prognoziranje kretanja mjesečnoga broja zaposlenih korištena je aciklička mreža višeslojnog perceptrona s unaprijednom propagacijom funkcijskog signala (*multilayer feedforward network*).

U dizajniranju modela višeslojnoga perceptrona definirane su dvije ulazne i tri izlazne varijable.

Mjesečni podaci o ukupnom broju zaposlenih, broju zaposlenih muškaraca i broju zaposlenih žena predstavljaju izlaze mreže. Kao ulazi uzete su dvije varijable, koje predstavljaju godinu i mjesec, kao vremenske varijable koja odražava sezonalni karakter podatka.

Odabir ulaznih i izlaznih varijabli temelj se na pretpostavci da, temeljem povijesnih podataka višeslojni perceptron, podvrgnut procesu učenja može modelirati podatke te efikasno predvidjeti buduće vrijednosti broja zaposlenih.

Procesu dizajniranja i određivanja arhitekture mreže prethodila je predobrada podataka. Ulazni i izlazni podaci su normalizirani minimum-maximum metodom danom izrazom (Morariu, Iancu i Vlad, 2009):

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (11)$$

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

Normaliziranje podataka rezultira boljim performansama neuronske mreže te postupkom treniranja poboljšanja kvalitete. Nakon skaliranja, podaci su podijeljeni u podskupine za treniranje i testiranje. Trening podskupina sastojao se od 70 % ukupnoga skupa podataka, dok je za testiranje mreže korišteno preostalih 30 % podataka.

Za sumacijsku funkciju korištena je sigmoidna funkcija dana izrazom:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (12)$$

Prednost sigmoidne aktivacijske funkcije dana je činjenicom da mala promjena ulaza rezultira malom promjenom izlaza, a upravo takva karakteristika pomaže u efikasnijem radu neuronske mreže. Kao aktivacijska funkcija korištena je hiperboličko-tangentna funkcija dana izrazom:

$$f(x) = \sigma(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (13)$$


Hiperboličko-tangenta funkcija sa sigmoidnom funkcijom su derivabilne te se često koriste kao aktivacijske funkcije, jer najbolje prikazuju nelinearne odnose među varijablama. U procesu učenja mreže korištena je Quasi Newtonova. Iako je algoritam povratnoga širenja (*Backpropagation*) među najpopularnijim algoritmima učenja acikličkih mreža, njegovi se nedostaci očituju u sporoj konvergenciji mreže.

U mnogim se studijama stoga preporučuje korištenje alternativnih pristupa učenja mreže. Među takvim algoritmima spominje se i pseudo-Newtonov algoritam učenja, koji ubrzava konvergenciju mreže. S druge strane, nedostatak je pseudo-Newtonova algoritma što je zahtjevan u pogledu matematičkih izračuna, ali i memorijskog prostora za provođenje ažuriranja Hessianove matrice, što ograničava njegovu primjenu na baze podataka srednje veličine (Robitaille, Marcos, Veillette i Payre, 1996).

Dobiveni model višeslojnoga perceptrona ima sljedeće karakteristike:

- jedan ulazni sloj s dva neurona koji predstavljaju ulazne varijable
- dva skrivena sloja, svaki s po tri neurona
- jedan izlazni sloj s tri neurona koji predstavljaju izlazne varijable.


Arhitektura umjetne neuronske mreže prikazana je na Slici 6.



Slika 6. Arhitektura višeslojnog acikličkog perceptrona
Izvor: Izrada autora (Ispis iz R programskog okruženja, 2020)

Odabrani model acikličkoga dvoslojnog perceptrona strukture je 2:3:3. Na Grafikonu 2. prikazane su stvarne i modelirane vrijednosti pojedinih vremenskih serija.


Iz grafikona je vidljivo kako su procijenjene vrijednosti vremenskih serija dobivene modelom višeslojnog perceptrona blizu stvarnim vrijednostima.



Grafikon 2. Model višeslojnoga perceptrona: stvarne te procijenjene vrijednosti ukupnoga broja zaposlenih, broja zaposlenih muškaraca i broja zaposlenih žena
Izvor: Izrada autora (2020)

U nastavku su dani rezultati modeliranja dobiveni Holt-Wintersovim modelom trostrukoga izgladivanja te sezonskim multiplikativnim modelom eksponencijalnoga trenda, a radi usporedbe i evaluacije performansi upotrebe modela višeslojnog perceptrona u prognoziraju vremenskih serija.

Grafikon 3. prikazuje rezultate primjene sezonskoga Holt-Wintersova modela.



Grafikon 3. Holt-Wintersov model: stvarne i procijenjene vrijednosti ukupnoga broja zaposlenih, broja zaposlenih muškaraca te broja zaposlenih žena
Izvor: Izrada autora (2020)

Grafički prikazi upućuju na dobru prilagođenost modela stvarnim podacima.

Sezonski multiplikativni model eksponencijalnoga trenda

Za analizu empirijskih vremenskih serija broja zaposlenih na temelju eksponencijalnoga trenda i sezonskih indikator-varijabli početni je model lineariziran logaritmiranjem.

Model, stoga glasi:

$$\ln \hat{Y} = \ln \beta_0 + X_t \ln \beta_1 + M_{1t} \ln \beta_2 + M_{2t} \ln \beta_3 + M_{3t} \ln \beta_4 + M_{4t} \ln \beta_5 + M_{5t} \ln \beta_6 + M_{6t} \ln \beta_7 + M_{7t} \ln \beta_8 + M_{8t} \ln \beta_9 + M_{9t} \ln \beta_{10} + M_{10t} \ln \beta_{11} + M_{11t} \ln \beta_{12} \quad (14)$$

Metodom najmanjih kvadrata procijenjena su tri modela, za svaku vremensku seriju zasebno. Kao bazno razdoblje odabran je prosinac 2019. godine.

Vrijednosti procijenjenih sezonskih indikator-varijabli za pojedine mjesece upućuju na prosječnu promjenu broja zaposlenih za jediničnu promjenu varijable vrijeme. Dobivene vrijednosti empirijskih koeficijenata predstavljaju mjesečne stope rasta u odnosu na bazni mjesec te upućuju na zaključke kako je, zbog utjecaja sezone, od svibnja do kolovoza broj zaposlenih znatno rastao u odnosu na bazno razdoblje.


Iz vrijednosti pojedinih regresijskih koeficijenata β_{1i} izračunate su prosječne mjesečne stope rasta promatranih vremenskih serija (Tablica 2.)

Tablica 2. Prosječne mjesečne stope rasta

Izvor: Izrada autora (2020)

Broj zaposlenih	$\ln \beta_{1i}$	$\beta_{1i} = e^{\ln \beta_{1i}}$	Stopa promjene
Ukupno	0,007109	1,00713	0,713%
Muškarci	0,007395	1,00742	0,742%
Žene	0,006865	1,00689	0,689%

U nastavku su prikazane stvarne, procijenjene i prognozirane vrijednosti analiziranih vremenskih serija.



Grafikon 4. Model eksponencijalnoga trenda: stvarne te procijenjene vrijednosti ukupnoga broja zaposlenih, broja zaposlenih muškaraca te broja zaposlenih žena
Izvor: Izrada autora (2020)

Provedena analiza regresijskih rezultata te dijagnostičkih testova upućuje na normalnost i homoskedastičnost reziduala. Vrijednosti korigiranih koeficijenata determinacije ($> 0,98$) upućuju na visoku reprezentativnost trenda. Svi procijenjeni regresijski koeficijenti značajni su na razini od 1 % signifikantnosti.

Analiza prognostičke performanse modela provedena je prosječnom apsolutnom pogreškom (*Mean Absolute Error – MAE*), prosječnom apsolutnom postotnom pogreškom (*Mean Absolute Percentage Error – MAPE*) te izračunom koeficijenta korelacije između stvarnih i procijenjenih vrijednosti, radi utvrđivanja valjanosti rezultata dobivenih primjenom višeslojnog perceptrona. Odabrani pokazatelji performanse izračunati su za sva tri odabrana prognostička modela (Tablica 3.).

Tablica 3. Prognostička performansa odabrani modela

Izvor: Izrada autora (2020)

MODEL	VREMENSKA SERIJA	MAE	MAPE	r	2020M1		2020M2	
					STVARNI	PROGNOZA	STVARNI	PROGNOZA
MLP	UKUPNO	1666,3	2,6	0,99	73045	73445,3	69275	73006,86
	MUŠKARCI	766	2,6	0,99	34050	34138,2	32171	34064,7
	ŽENE	1063,4	3,1	0,98	39355	39354,1	37104	39287,8
HW	UKUPNO	1087,3	1,713	0,99	73045	80135,1	69275	76791,7
	MUŠKARCI	425,9	1,5	0,99	34050	37787,8	32171	36377,1
	ŽENE	721,5	2,1	0,99	39355	42273,7	37104	40349,45
EXP TREND	UKUPNO	1565,4	2,5	0,99	73045	79059,9	69275	75961,1
	MUŠKARCI	622,7	2,1	0,99	34050	36889,6	32171	35606,5
	ŽENE	984,9	2,7	0,98	39355	42172,6	37104	40359,1

Rezultati upućuju na dobru prilagođenost višeslojnog perceptrona u odnosu na Holt-Wintersov model i model eksponencijalnoga trenda, ako modele koji uvažavaju sezonski karakter podataka i koji se standardno koriste u modeliranju sezonskih vremenskih serija.

4 Zaključak

Cilj istraživanja bio je evaluirati primjenjivost i učinkovitost modela umjetnih neuronskih mreža u analiziranju vremenskih serija sezonskoga karaktera. Polazeći od definiranoga istraživačkog problema, dizajniran je model višeslojnoga perceptrona za opisivanje procesa generiranja mjesečnog broja zaposlenih u djelatnosti pružanja smještaja te pripremi i usluživanju hrane i pića u Republici Hrvatskoj od siječnja 2014. do prosinca 2019. godine. Ex post prognozirane izvršeno je za siječanj i veljaču 2020. godine. Performansa te prognostička moć modela višeslojnoga perceptrona evaluirani su odabranim uobičajeno korištenim pokazateljima i to njihovom usporedbom s rezultatima dobivenim primjenom Holt-Wintersova modela trostrukoga eksponencijalnog izgladivanja te sezonskim multiplikativnim modelom eksponencijalnoga trenda. Poznato je kako su navedene dvije metode vrlo efikasne u modeliranju i prognožiranju vremenskih serija sezonskoga karaktera. Analiza rezultata pokazala je visoku pouzdanost i efikasnost modela višeslojnoga perceptrona u modeliranju i prognožiranju empirijskih podataka. Rezultati upućuju stoga na zaključak kako modeli umjetnih neuronskih mreža pokazuju vrlo velike aplikativne potencijale i potrebu za daljnjim sustavnijim i detaljnijim istraživanjima mogućnosti i prednosti njihove primjene u analizi vremenskih serija koje pokazuju izrazita kretanja sezonskoga karaktera.

Literatura

Claveria, O., Monte, E., Torra, S. (2014). Tourism demand forecasting with neural network models: Different ways of treating information, *International Journal of Tourism Research*, 17. 492-500. doi: 10.1016/j.econmod.2013.09.024

Fernandes, P. O., Teixeira, J. P., Ferreira, J., Azavedo Susana (2008). Modelling tourism demand: a comparative study between Artificial Neural Networks and the Box-Jenkins methodology, *Romanian Journal of Economic Forecasting*, 9, 30- 50.

Folgieri, R., Baldigara, T., 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, 4, 169-182.

Frechtling, D. C. (2001). *Forecasting Tourism Demand: Methods and Strategies*, Butterworth Heinemann, Elsevier plc group, Woburn

Krešić, D., Mikulić, J., Kožić, I. (2013). Artificial Neural Network-Based Applications in Travel and Tourism Research: A Review and Case Study, *International critical tourism studies conference*, Sarajevo, 25-28. 6. 2013.

Laubscher, R., Engelbrecht, Q., Marais, C. F. P. (2018). Application of machine learning algorithms in boiler plant root cause analysis: a case study on an industrial scale biomass unit co-firing sugarcane bagasse and furfural residue at excessive final steam temperatures, *Proceedings of the Ninety first South African Sugar Technologists' Association Congress*, South African Sugar Technologists' Association, August 14-16, 2018., Durban, South Africa, 91, 283-293.

Mamula, M., 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.

Morariu, N., Iancu, E., Vlad, S. (2009). A Neural Network model for time-series forecasting, *Romanian Journal of Economic Forecasting*, 4, 213-223.

Pouliakis, A., Karakitsou, E., Margari, N., Bountris, P., Haritou, M., Panayiotides, J., Koutsouris, D., Karakitsos, P. (2016). Artificial Neural Networks as Decision Support Tools in Cytopathology: Past Present and Future, [Online], *Biomed Eng Comput Biol*. 2016. 1-18. 10.4137/BECB.S31601. Dostupno na: https://www.researchgate.net/figure/Typical-structure-of-a-feed-forward-multilayer-neural-network_fig1_291339457 (pristupljeno 20. 4. 2020.)

Robitaille, B., Marcos, B., Veillette, M., Payre, G. (1996). Modified quasi-Newton methods for training neural networks, *Computer & Chemical Engineering*, 20 (9), 1133-1140.

Song, H., Witt, S., Li, G. (2009). *The Advanced Econometrics of Tourism Demand*, Routledge, London:.

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_Neuronske-mreze-2017.pdf (pristupljeno 20. 4. 2020.)