

NAPOVEDOVANJE INTERVENCIJSKIH DOGODKOV Z UMETNO INTELIGENCO

INTERVENTION PREDICTION USING ARTIFICIAL INTELLIGENCE

Rok Rutnik

Gasilska brigada Maribor, Cesta proletarskih brigad 21, Maribor, rok.rutnik1@gmail.com

Povzetek

V članku sta razvita dva matematična modela napovedovanja intervencijskih dogodkov za odločitve upravljanja, ki so utemeljene na inteligentnih, kvantitativnih analizah. Obravnavano je področje napovedovanja števila interventnih dogodkov Gasilske brigade Maribor z umetno inteligenco. Učne množice podatkov so bile pridobljene iz baz podatkov SPIN in ARSO, obdelane pa so v programskem jeziku Python. Modeli napovedovanja so programirani v programskem paketu MATLAB. Cilja sta učiti umetni nevronske mreže LSTM in NARX napovedovati dogodke, rezultate pa z matrikami ocenjevanja natančnosti medsebojno primerjati. Rezultati napovedovanja nekaterih učnih množic so bili zaradi majhnih korelacijskih povezav slabi, zato teh dogodkov nismo mogli napovedovati. Požarne intervencije in naravne nesreče so dale dovolj dobre rezultate korelacijskih analiz, zato so uporabljene pri razvijanju nevronske mreže. Glede na rezultate zbranih modelov menimo, da so nevronske mreže primerne za napovedovanje interventnih dogodkov.

Abstract

The aim of this study was to create two mathematical forecasting models for management decisions based on intelligent, quantitative analyses. It deals with the field of predicting the number of intervention events of the Maribor Fire Brigade with the help of artificial intelligence. Learning data sets were obtained from the SPIN and ARSO databases, processed in the Python programming language, and then the prediction models were programmed in the MATLAB software package. The aim of the task was to train the artificial neural networks LSTM and NARX to predict events, and to compare their results with each other through metrics for estimating accuracy. The prediction results of some of the learning sets were poor due to small correlations, so we could not predict those events. Fire interventions and natural disasters gave good enough results of correlation analyses, so they were used in the construction of neural networks. Based on the results of the collected models, we believe that neural networks are suitable for predicting intervention events.

Uvod

Živimo v obdobju, v katerem shranjujemo veliko podatkov, ki jih v njihovem izobilju vse težje interpretiramo. Na podlagi preteklih izkušenj človek izkorišča pridobljeno znanje, vendar je njegova zmogljivost pomnjenja omejena. Računalniki imajo zmogljiv spomin, hranijo veliko informacij, ki pa so lahko popolnoma neuporabne. Človek s svojo inteligenco (nadarjenostjo za umske dejavnosti) podatke analizira in odkriva zakonitosti, te pa izkorišča za svoje potrebe. Najdeni vplivni parametri in njihove povezave ustvarjajo model. Za izdelavo dobrega ekspertnega modela je nujno ne le kvantitativno analizirati podatke, temveč tudi poznati področje gasilsko-tehničnih intervencij in organizacije ter delo Gasilske brigade Maribor. Nastanek intervencije je precej naključen dogodek. Analizirane so korelacije med vplivnimi parametri in dogodki. Stremimo k cilju, da se z napovedjo lahko osredotočamo na tista področja in lokacije, ki kažejo tendenco naraščanja. Vanje lahko posledično vlagamo večja sredstva in razširjeno

znanje z namenom optimizacije ljudi ter opreme. Članek obravnava pristop dveh temeljno različnih modelov, zato neposredna medsebojna primerjava ni mogoča, vendar pa je kljub temu navedena. Primerjava je zato orientacijska in namenjena nadaljnji obravnavi posameznih modelov.

Metodologija

Gasilska intervencija je precej naključen dogodek, kljub temu pa poznamo nekatere značilnosti, ki prispevajo k večji možnosti nastanka dogodka. Intervencije se delijo na kategorije, zato je v vsaki treba poiskati edinstvene parametre, ki vplivajo na njen nastanek. Omejitev so v bazah podatkov ARSO in SPIN, v katerih je nujno vsakodnevno zapisovanje parametrov v obdobju 15 let. Nekaterih vplivnih parametrov ni mogoče poiskati ali pa niso bili zapisani. Zapletenost in kompleksnost upravljanja interventnih dogodkov prisili v odločitve, ki temeljijo na subjektivnih in kvalitativnih ocenah.

Nevronska mreža LSTM

Pomnilna celica LSTM (angl. long short-term memory) spada v kategorijo rekurentnih nevronskih mrež (angl. Recurrent neural network) (Bernico, 2018). Zmožna je učenja dolgoročnih odvisnosti med časovnimi koraki v zaporedju podatkov. Celica ima pomnilno stanje za dva vektorja: c_t , ki hrani dolgoročno stanje, in h_t , ki hrani kratkoročno stanje. Temeljna ideja delovanja LSTM-mreže je v zmožnosti, kaj mora ohraniti, kaj mora pozabiti in kaj si mora zapomniti v dolgoročnem spominu. Na sliki 1 vidimo, da dolgoročno stanje c_{t-1} prehaja skozi celico od leve proti desni. Sprva naleti na vrata pozabljanja f_t , kjer izgubi nekaj spomina, nato se v naslednjih vratih sešteje z vhodnim spominom in preide iz celice v stanju c_t . Tako smo dosegli, da se v enem časovnem koraku na vratih spomin odvzema in dodaja. Matematično stanje opišemo z enačbo:

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t$$

Pri tem so:

f_t – plast pozabljanja,

i_t – vhodna plast,

g_t – glavna plast,

\odot – Hadamardov produkt.

Dolgoročno stanje c_t se ob enem prekopiira in pošlje skozi aktivacijsko funkcijo hiperboličen tangens ter zmnoži z izhodnimi vrati, pri čemer dobimo na izhodu za rezultat kratkoročno stanje h_t . Matematična formulacija se zapiše kot:

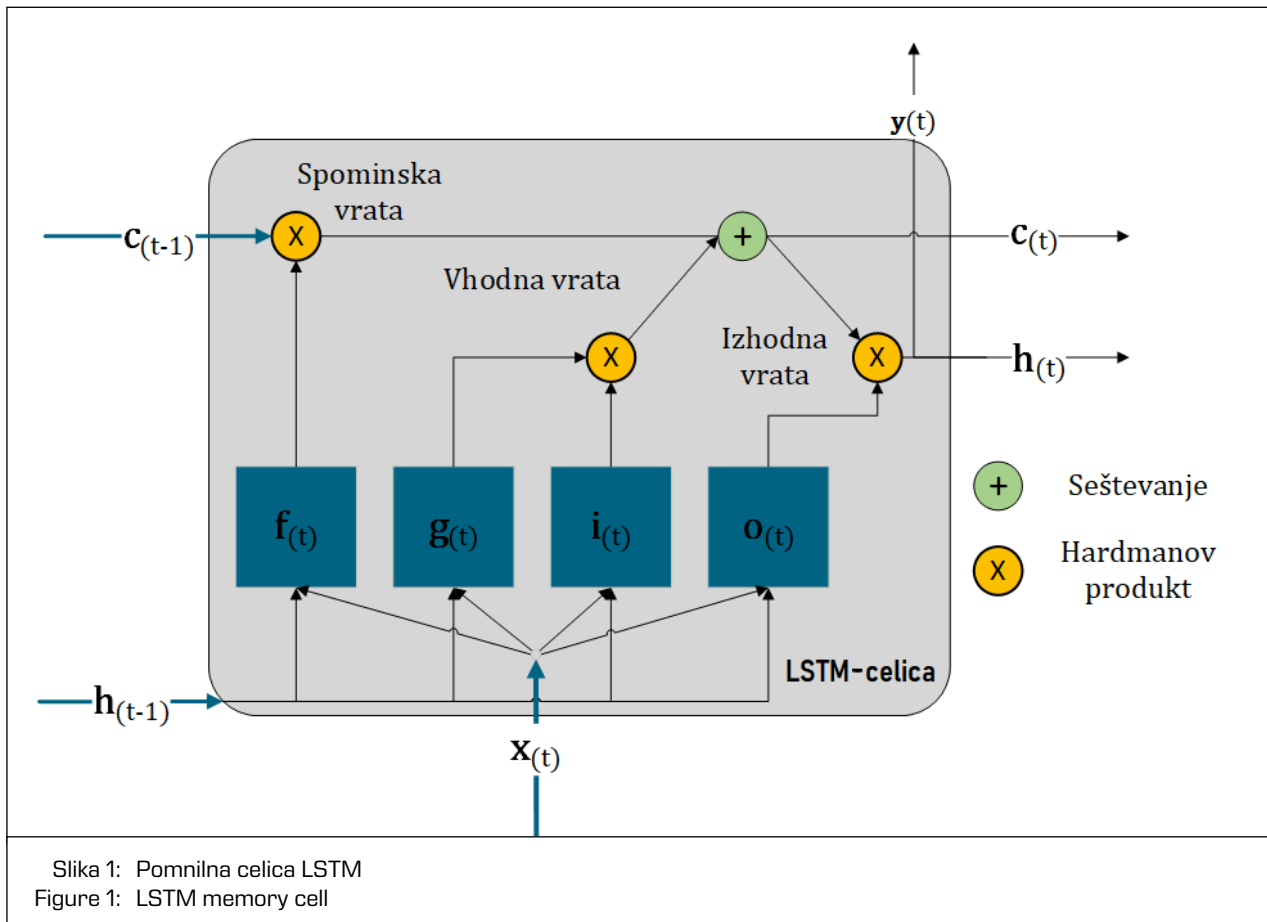
$$h_t = o_t \odot \sigma_c(c_{t-1})$$

Pri tem sta:

o_t – izhodna vrata,

$$\sigma_c = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} .$$

Delovanje spominske celice poteka čez tri vrhode. x_t predstavlja vhodni vektor v časovnem koraku t , c_{t-1} in h_{t-1} vnašata kratkoročni in dolgoročni spomin. V vsakem časovnem koraku štiri plasti dodajo ali odstranijo informacije iz stanja v celici čez vrata. Glavna plast g_t analizira trenutni vhod x_t in prejšnje kratkoročno stanje h_{t-1} . Njen rezultat je delno shranjen v dolgoročnem spominu. Preostale tri plasti so kontrolne plasti vrat. Uporabljajo sigmoidno aktivacijsko funkcijo, zato je njihov izhod na intervalu med [0,1]. Vrednost, ki sovpada z 0, nakazuje zaprta vrata, 1 pa odprta. Vrata pozabljanja (nadzoruje jih plast f_t) opredeljujejo, kateri deli dolgoročnega spomina bodo izbrisani. Vhodna vrata (nadzoruje jih plast i_t) izbirajo, kateri deli glavne plasti bodo dodani dolgoročnemu spominu. Izhodna vrata (nadzoruje jih plast o_t) obvladujejo, kateri deli dolgoročnega spomi-



Slika 1: Pomnilna celica LSTM
Figure 1: LSTM memory cell

na naj se zapišejo v kratkoročni spomin in izhodno stanje celice. V preglednici 1 so prikaz plasti, njihov namen in formula za izračun komponente v časovnem koraku t .

Za učenje plasti LSTM opredelimo vhodne uteži W , rekurzivne uteži R in prag b . Matrike W , R in b so nizi uteži za vsako plast [2-3].

$$W = \begin{bmatrix} W \\ W_f \\ W_g \\ W_o \end{bmatrix}, R = \begin{bmatrix} R_i \\ R_f \\ R_g \\ R_o \end{bmatrix}, b = \begin{bmatrix} b_i \\ b_f \\ b_g \\ b_o \end{bmatrix}$$

V formulah sta zapisani dve aktivacijski funkciji. Glavna plast preide transformacijo v hiperboličnem tangensu z oznako σ_c , preostale pa v sigmoidno funkcijo σ_g .

Umetne nevronske mreže z znanimi odzivi naučimo napovedovati tako, da v vsakem časovnem koraku vhodne sekvence mreža LSTM iz preteklih vrednosti predvidi naslednjo vrednost. Postopek izvaja iterativno tako, da zmanjšuje napako med napovedanim in resničnim izhodom. Učna baza je sestavljena iz dveh matrik. V prvi je shranjenih 23 vremenskih parametrov v 1460 časovnih korakih, v drugi pa število resničnih intervencij v vsakem korespondenčnem časovnem koraku. Časovni korak je bil izbran na podlagi spremljanja natančnosti napovedi. V 15-letnem obdobju zapisovanja polurnih vremenskih parametrov je bilo treba 262.800 korakov združiti v izbran časovni korak, ki bo vpeljan v nevronske mreže. V napovedovalnem obdobju znaša vsak časovni korak 90 ur oziroma 3,75 dne in obsega povprečne vrednosti znotraj izbranega intervala. Združitev podatkov posledično predstavlja tudi optimizacijo časa učenja. Predhodna obdelava je potekala z deljenjem učne baze na učno množico s 1314 časovnimi koraki (90 % baze) in testno množico zadnjih 146 časovnih korakov (10 %). Učna in testna množica imata v svoji domeni dve matriki. Prva matrika (X_{train}) vsebuje 23 vrednosti vremenskih parametrov. Za izboljšanje učenja in zagotovitev konvergence je bila učna množica standardizirana. Standarizacija podatkov poteka tako, da vsaki vrednosti v časovni vrsti odštejemo srednjo vrednost in delimo s standardnim odklonom učnega seta.

Nevronska mreža NARX

Nelinearna avtoregresivna umetna nevronska mreža z eksogenim vhomom je vrsta rekurzivne nevronske mreže, primerna za modeliranje nelinearnih sistemov in časovnih vrst (Tsunghan in sod., 1999). NARX UNM z gradientnim sestopom izpostavlja učinkovito učenje in hitrejšo konvergenco v primerjavi s preostalimi vrstami nevronske mreže. Rezultati kažejo dobro zmožnost pomnjenja dolgoročnih odvisnosti, kar se doseže s členi zakasnitve (Yang in Meng, 2005). V nelinearnih in nestacionarnih časovnih vrstah se pojavijo težave s pomnjenjem dolgoročnih odvisnosti pri uporabi učnega pravila z gradientnim sestopom. Izginjajoči gradient se v nevronske mreži NARX rešuje z vpeljavo časovnih zamikov v nevronih in njegovih povezavah ter z uporabo nevronov, katerih aktivacije se seštevajo s časovnim intervalom (Diaconescu, 2008). Topologija izbrane nevronske mreže bi za izbiro napovedovanja interventnih dogodkov morala ustrezati, saj poznamo časovne vrste posameznih intervencij in njihove korelacijske parametre. Združene informacije, simultano vpeljane kot vhod v mrežo, nam iz števila intervencij v predhodnem časovnem intervalu in vplivnih parametrov v naslednjem obdobju napovejo število dogodkov. Enačba NARX je definirana kot:

$$y(t) = f(y_{(t-1)}, y_{(t-2)}, \dots, y_{(t-n_y)}, u_{(t-1)}, u_{(t-2)}, \dots, u_{(t-n_u)})$$

Pri tem so:

f – preslikovna funkcija,

$y(t)$ – odvisen izhodni signal,

n_y – število časovnih zamikov izhodnega signala,

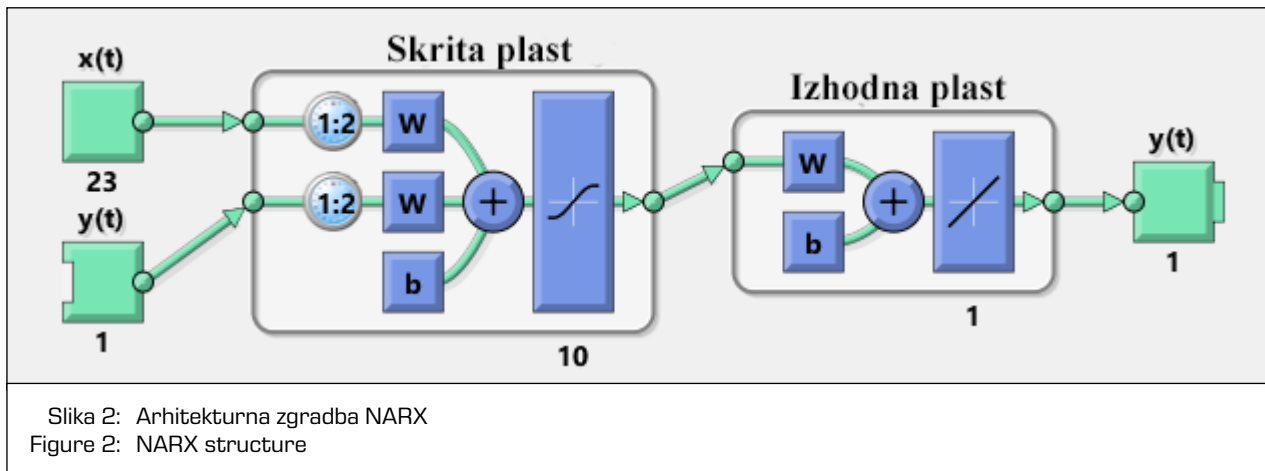
n_u – število časovnih zamikov vhodnega signala,

$u_i(t)$ – neodvisni vhodni signali.

Enačba prikazuje izračun vrednosti izhodnega signala $y(t)$ čez regresijo časovne vrste preteklih vrednosti izhodnega signala ($y_{(t-1)}$) in vrednosti eksogenih vhodnih signalov $u_i(t)$.

Komponenta	Oznaka	Namen	Formula
Vhodna plast	$i(t)$	Nadzoruje raven posodabljanja celice z novim stanjem	$i(t) = \sigma_g(W_i x(t) + R_i h_{(t-1)} + b_i)$
Plast pozabljanja	$f(t)$	Nadzoruje raven odstranjevanja informacij v celici	$f(t) = \sigma_g(W_f x(t) + R_f h_{(t-1)} + b_f)$
Glavna plast	$g(t)$	Dodaja informacije v celici	$g(t) = \sigma_c(W_g x(t) + R_g h_{(t-1)} + b_g)$
Izhodna plast	$o(t)$	Nadzoruje raven izhoda iz celice	$o(t) = \sigma_g(W_o x(t) + R_o h_{(t-1)} + b_o)$

Preglednica 1: Komponente celice LSTM
Table 1: LSTM cell components



Za treniranje mreže z vzratnim razširjanjem (posodabljanje uteži in pragov) se uporablja Levenberg-Marquardtov algoritem. Ta interpolira med Gauss-Newtonovo metodo in metodo gradientnega sestopa za reševanje nelinearnih funkcij (Marquardt, 1963). Validacijska množica se uporablja za ustavitev treniranja, če se mreža preneha izboljševati in ne konvergira. Testna množica daje neodvisno preverjanje generalizacije nevronske mreže in na učenje ne vpliva. Algoritem lahko trenira tako dolgo, dokler je prenosna funkcija zvezno odvedljiva (Hudson in sod., 2004).

Nelinearna avtoregresivna umetna nevronska mreža z zunanjim vhomom je uporabljena za modeliranje dinamičnega sistema napovedovanja števila interventnih dogodkov v 15-letnem obdobju. Podatki so razdeljeni v dve matriki $\mathbf{X}(t)$, v katerih so zbrani vremenski podatki s 1460 časovnimi koraki in 23 prediktorjev ter $\mathbf{y}(t)$, ki predstavlja želeni izhod – število interventnih dogodkov. Vhodna podatkovna matrika je razdeljena na trening-množico v obsegu 70 % podatkov (1022 primerov), validacijsko in testno množico. Vsaka obsega 15 % (219 primerov). S trening-množico se nevronska mreža uči in prilagaja uteži glede na izhodno napako, validacijska množica je uporabljena za spremljanje posploševanja. Učenje se ustavi, ko se posploševanje preneha izboljševati. Testna množica ne vpliva na učenje in je uporabljena kot neodvisna mera za ugotavljanje kakovosti napovedi.

Za izpolnitev delujoče umetne nevronske mreže za napovedovanje števila interventnih dogodkov je nujno iterativno določanje števila skritih nevronov, saj ni natančne definicije arhitekture za specifično učno množico vhodnih podatkov. Slika 3 prikazuje definirano zgradbo nevronske mreže NARX za primere napovedovanja interventnih dogodkov. Za učenje nevronske mreže je ta uporabljena v odprtozančnem sistemu, saj nam med treniranjem omogoča oskrbovanje s pravilnimi preteklimi vrednostmi, da vrne predvidene napovedane vrednosti. Prilaganje uteži tako poteka z minimizacijo napake $e(t) = y(t) - \hat{y}(t)$. Izdelana nevronska mreža je sestavljena iz dveh plasti. V skrito

plast vpeljemo dva vhoda. Eksogeno matriko $\mathbf{X}(t)$ s 23 elementi in zelenimi vrednosti izhoda $\mathbf{y}(t)$, ki s sigmoidno prenosno funkcijo preide v izhodno plast. Skriti plasti definiramo 10 nevronov. Izbira števila skritih nevronov je odvisna od kompleksnosti modeliranega dinamičnega problema.

Uporabljeni podatki

Vremenski podatki so bili pridobljeni iz arhiva Agencije Republike Slovenije za okolje v obdobju od 1. januarja 2005 do 1. januarja 2020 (Agencija RS za okolje, 2020). Podatki, zapisani vsake pol ure, so zajeti s samodejne vremenske postaje na letališču Edvarda Rusjana Maribor, na nadmorski višini 264 metrov. Intervencijski dogodki v enakem obdobju so pridobljeni iz baze podatkov sistema SPIN (sistem za poročanje o intervencijah in nesrečah, URSZR).

Urejanje baze podatkov poteka v programskem jeziku Python z uporabo knjižnice Pandas, ki je namenjena urejanju in analizi podatkov. Treba je združiti bazo interventnijskih dogodkov, vremenskih veličin in geografske lokacije. Tam se zaznavajo manjkajoče vrednosti in napake pri zajemanju podatkov, ki jih je treba filtrirati in urediti, da so pripravljene za vhodno učno množico algoritmov strojnega učenja.

Korelacijska analiza

Izračunani korelacijski koeficienti na intervencijah so zbrani v preglednici 2. Izračunane povezanosti interpretiramo po razredih (Mukaka, 2012):

0,00	ni povezanosti
0,01–0,19	neznatna povezanost
0,20–0,39	nizka/šibka povezanost
0,40–0,69	srednja/zmerna povezanost
0,70–0,89	visoka/močna povezanost
0,90–0,99	zelo visoka/zelo močna povezanost
1,00	popolna (funkcijska) povezanost

	Naravne nesreče	Nevarne snovi	Požari	Prometne nesreče	Tehnična pomoč
Povprečen zračni tlak	0,06	0,00	0,17	0,17	-0,03
Povprečna temperatura	0,14	0,09	-0,23	0,10	0,09
Povprečna rel. vlažnost	-0,03	-0,12	-0,11	-0,06	-0,10
Količina padavin	0,54	-0,03	-0,28	-0,05	0,11
Hitrost vetra	0,10	0,13	-0,15	0,01	0,19
Oblačnost	-0,05	-0,08	-0,15	-0,12	0,01
Višina snega	-0,01	-0,10	0,09	-0,19	0,02
Višina novega snega	-0,03	-0,12	0,10	-0,15	-0,11
Trajanje sonca	0,13	0,08	-0,07	0,09	0,11
Močan veter	0,05	0,08	-0,05	0,08	0,06
Viharni veter	0,32	0,04	0,08	0,00	0,15
Dež	0,05	0,04	-0,23	0,05	0,05
Ploha dežja	0,24	0,00	-0,15	0,12	0,02
Nevihta	0,20	0,01	-0,10	0,09	0,01
Dež, ki zmrzuje	0,11	-0,03	0,06	-0,06	0,01
Rosenje, ki zmrzuje	0,12	-0,06	-0,01	-0,08	0,12
Toča	0,19	-0,01	0,00	0,01	0,03
Megla	-0,07	-0,15	-0,10	-0,06	0,01
Talna megla	0,02	0,05	-0,08	-0,01	0,00
Poledica	0,17	0,01	0,02	-0,09	0,03
Padavine	0,08	-0,10	-0,27	-0,07	0,01

Preglednica 2: Izračunani korelacijski koeficienti vplivnih parametrov

Table 2: Calculated correlation coefficients of influence parameters

Negativni predznak predstavlja obratno-sorazmerno povezanost. Korelacijske vrednosti so za dani primer majhne, zato lahko pričakujemo široke razpore napak. Predpostavljamo lahko hipotezo, da bomo največje ujemanje napovedanih in resničnih vrednosti dobili pri modeliranju naravnih nesreč in požarov, saj imata ti dve kategoriji največ povezav s prediktorji. Zavedati se je treba dejstva, da je interventni dogodek precej nključen. V posamezni kategoriji lahko najdemo nekatere parametre, ki povečajo možnost za njegov nastanek.

Večja poenostavitev modela je kategorizacija interventnih dogodkov v pet skupin. K naravnim nesrečam spadajo poplave, vetrolomi, plazovi, podori, udari strele in snegolomi. V skupino nevarnih snovi spadajo nesreče z naravnimi snovmi v industriji in prometu, sproščanja nevarnih plinov, onesnaženja in posegi v okolje. Kategorizacija požarov zajema široko področje požarov v objektih, naravi in na prostem, na prometnih sredstvih ter eksplozije. K tehnični pomoči prištevamo odpiranje stanovanj, zapiranje vode, odstranjevanje morebitnih nevarnosti in druge vrste pomoči.

Pomembno dejstvo, ki ga upoštevamo pri analizah, je, da samo korelacija še ne pomeni vzroka. Sklepanje, ki ga v latinščini imenujemo *cum hoc ergo propter hoc – s tem, torej zaradi tega*, je napačno. Izhajamo lahko iz

primera korelacije med količino padavin in nastankom požara, pri čemer opazimo obratno sorazmerno povezavo. Na podlagi tega bi lahko sklepali, da večje število padavin zmanjša možnost požara. Torej naj bi suša povzročila požar, kar pa ni res. Obdobja z zmanjšano količino padavin ustvarjajo le razmere, pri katerih se ob nepravilni uporabi ognja ali odprtega ognja, ob malomarnosti, samovžigih in drugih vzrokih požar lahko razvije.

Rezultati napovedovanja

Med 5.256.000 vremenskimi podatki in 11.081 intervencijami v 15 letih na območju posredovanja Gasilske brigade Maribor algoritmi učenja nevronske mreže ustvarijo povezave med posameznimi parametri, ki so bili zaznani, ko je interventni dogodek nastal.

Napoved nevronske mreže LSTM za požarne intervencije

Za učenje smo nastavili parametre učenja. Uporabljen je optimizacijska metoda »adam«, ki trenira na 300 epohah. V vsaki epohi je ena iteracija. Začetna hitrost

učenja je definirana s faktorjem 0,005 in se zmnoži vsako 125. epoko s faktorjem spreminjanja hitrosti 0,2, kar pripomore k hitrejši konvergenci.

Umetno nevronska mrežo treniramo od zaporedja do zaporedja, pri čemer so odzivi zaporedja v časovnem sosledju premaknjeni za en časovni korak, ki znaša mesec dni. To pomeni, da se na vsakem časovnem koraku vhodnega zaporedja mreža LSTM nauči predvideti vrednost naslednjega časovnega koraka. Implantacija algoritma za napovedovanje daljšega, 18-mesečnega, obdobja je predhodno napovedano vrednost vedno vključila v učno množico in izvedla napoved v naslednjem časovnem koraku.

Zaradi lažje programske implementacije nevronske mreže LSTM je napovedovanje števila požarnih intervencij izvedeno na zadnjih 10 % časovne vrste. V učnem procesu je nevronska mreža v 162-mesečnem obdobju naučila dolgoročnih in kratkoročnih povezav iz časovne vrste in njihove povezave z značilnostmi ter napovedala število intervencij za naslednjih 18 mesecev. En učni primer je predstavljal število intervencij v enem mesecu. Nevronska mreža smo učili na prvih 162 mesecih in ovrednotili na zadnjih 18 mesecih. Z naučeno nevronska mrežo smo napovedovali število intervencijskih dogodkov po mesec dni vnaprej in ob vsaki napovedi posodabljali stanje v mreži. Napovedovanje je potekalo tako, da smo za prvo napoved (t) kot vhodni podatek mreži poslali vse informacije pred tem časovnim korakom, torej t^{-1} , t^{-2} itn. Sledil je premik v časovno točko t^{-1} , pri katerem smo v mrežo prikazali že napovedano vrednost prvega koraka (t) in v časovnem sosledju vse prejšnje, t^{-1} , t^{-2} itn. Vhodni podatki za prediktorje so bili uporabljeni vremenski podatki iz točke t^{-1} .

Koeficient odločnosti (R^2)	Koren povprečne kvadratne napake (RMSE)	Povprečna kvadratna napaka (MSE)	Povprečna absolutna napaka (MAE)
0,209	6,54 int.	42,84	4,53 int.


Preglednica 3: Parametri ocenjevanja natančnosti LSTM za napovedovanje požarnih intervencij
 Table 3: Metrics for the assessment of the LSTM's accuracy in forecasting fire emergency response

Čeprav je napoved število požarov v poletnih mesecih nekoliko precenila, je dobro sledila vsem trendom v napovedovalnem obdobju, kot prikazuje primerjalni graf na sliki 3.


V preglednici 3 razberemo velikost absolutne napake mreže, ki v napovedovalnem obdobju znaša 4,53 intervencije.

Napoved nevronske mreže LSTM za naravne nesreče


Nastavitve parametrov učenja nevronske mreže za napovedovanje števila naravnih nesreč se od požarnih intervencij v določenih segmentih razlikujejo, saj ima časovna vrsta naravnih nesreč bistveno drugačne trende. Uporabljena je optimizacijska metoda »adam«, ki se uči na 150 epohah. Število skritih enot, kar povežemo s količino shranjenih informacij med časovnimi koraki, je 150. Hitrost učenja znaša 0,005 in se pomnoži s faktorjem 0,2 vsako 125. epoko.



Slika 3: Primerjava zapisanih in napovedanih požarnih intervencij
 Figure 3: Comparison of recorded and forecast fire emergency responses



Slika 4: Primerjava zapisanih in napovedanih naravnih nesreč
Figure 4: Comparison of recorded and announced natural disasters



Slika 5: Primerjava resničnega števila požarnih intervencij z napovedanim v 15-letnem obdobju
Figure 5: Comparison of the actual number of fire emergency responses with those forecast over a 15-year period

Že med učenjem smo prepoznali težave konvergiranja algoritma, saj napaka RMSE kljub padajočemu trendu vmes večkrat narašča.

Slika 4 prikazuje resnično število intervencij v primerjavi s predvidenimi v 18-mesečnem napovedovalnem obdobju. Cilj nevronske mreže je čim natančneje napovedovati

število interventnih dogodkov, tega pa ne dosežemo, saj so napake napovedanih prevelike, kar potrjujeta tudi napaki RMSE in MAE v preglednici 4. Iz analize primerjalnih grafov pa lahko razberemo, da so trendi napovedanih dogodkov naraščali, skladno z naraščanjem resničnih dogodkov. Temu pojavu pripisujemo (pre)dobro shranjevanje dolgoročnega spomina v celici LSTM.


Koeficient odločnosti (R^2)	Koren povprečne kvadratne napake (RMSE)	Povprečna kvadratna napaka (MSE)	Povprečna absolutna napaka (MAE)
-0,840	15,4 int.	237,2	12 int.

Preglednica 4: Parametri ocenjevanja natančnosti LSTM za napovedovanje naravnih nesreč
 Table 4: Metrics for the assessment of the LSTM's accuracy in forecasting natural disasters


Napake, zbrane v preglednici 4, dokazujejo, da nevronska mreža LSTM ni bila uspešna pri napovedovanju naravnih nesreč.

Napoved nevronske mreže NARX za požarne intervencije

V NARX najprej uvozimo eksogene spremenljivke, shranjene v matriki 23 vremenskih prediktorjev. Ciljni izhodni podatki so zbrani v ločeni matriki in predstavljajo resnično število požarnih intervencijskih dogodkov. Velikost matrik je odvisna od izbranega časovnega koraka, ki znaša 1460 časovnih korakov in predstavlja 3,75 dne. Ustvarjena nevronska mreža je sestavljena iz dveh plasti. Skrita plast vključuje tangens sigmoidno prenosno funkcijo, izhodna pa linearno. Z dvoplastno mrežo se lahko NM prilega vsakemu močno nelinearnemu vzhodno-izhodnemu razmerju. Pogoj za doseganje učinkovitih napovedi je ustrezno število nevronov v skritih plasteh. Njihovo določanje



Slika 6a: Linearna funkcija glede na število resničnih požarov v 15 letih
 Figure 6a: Linear function through the number of actual fires in 15 years



Slika 6b: Linearna funkcija glede na število napovedanih požarov v 15 letih
 Figure 6b: Linear function through the number of forecast fires within 15 years

Linearna funkcija	
Resnično število požarov	$f(x) = -0,078x + 32,3$
Napovedano število požarov	$f(x) = -0,056x + 31,2$

Preglednica 5: Izračunane vrednosti koeficientov linearne funkcije
Table 5: Calculated values of the linear function coefficients

poteka iterativno, pri čemer z matrikami ocenjevanja natančnosti primerjamo vpliv nevronske mreže z različnimi števili nevronov.

Na sliki 5 analiziramo prileganje grafov med številom zapisanih požarnih intervencij in napovedanih z UNM v 15-letnem časovnem obdobju.

Napovedani podatki sledijo dolgoletnim trendom, ki jih kažejo zapisane intervencije. V 15-letnem obdobju opazimo zmanjševanje, vendar so tudi obdobja, ko se njihovo število poveča. To potem pripišemo posameznim sušnim obdobjem. Napovedani podatki dobro sledijo individualnim skokom, prav tako je odziv na zmanjšanje ustrezen. Na podlagi napovedanih in realnih podatkov je izdelano linearno prileganje podatkov, kot prikazujeta sliki 6a in 6b.


Preglednica 5 predstavlja matematični zapis linearne funkcije za podatkovno množico resničnih in napovedanih požarnih intervencij. V obeh zapisih razberemo padajoči smerni koeficient, kar dokazuje, da obe množici kažeta tendenco zmanjševanja požarov. Rezultati

napovedanega števila iz nevronske mreže imajo manjši smerni koeficient, kar pomeni manjšo strmino premice linearne prileganja. Posledično sklepamo, da nevronska mreža vrača izhode s prevelikim napovedanim številom. To je razvidno tudi iz odzivnega grafa na sliki 5.

NARX UNM je sposobna napovedovanja požarnih interventnih dogodkov v različnih časovnih intervalih. Graf na sliki 7 primerja napovedano vrednost z resnično v obdobju enega leta. V obdobju poletnih mesecev vidimo porast požarov v naravnem okolju, prometnih sredstvih in komunalnih zabojujkih. Analiza korelacijskih faktorjev, ki vplivajo na nastanek omenjenih vrst požarov, pokaže srednje močno povezavo med nastankom omenjenih vrst požara, povprečno temperaturo in količinami padavin. UNM se nauči povezav tako, da ustrezno prilagodi vrednosti uteži in tako minimizira napako med izhodom in resničnim številom intervencij. Izhodno napovedano število požarnih intervencij sledi sezonskim trendom med letom, prav tako se odzove na posamezna mesečna povečanja. Rezultati kažejo

Koeficient odločnosti (R^2)	Koren povprečne kvadratne napake (RMSE)	Povprečna kvadratna napaka (MSE)	Povprečna absolutna napaka (MAE)
0,355	7,79 int.	61	6,24 int.

Preglednica 6: Parametri merjenja natančnosti naučene UNM za požarne intervencije
Table 6: Parameters for measuring the accuracy of the trained Artificial Neural Networks (ANN) for fire emergency response



Slika 7: Primerjava napovedi v enoletnem obdobju
Figure 7: Comparison of forecasts in a one-year period

Koeficient odločnosti (R^2)	Koren povprečne kvadratne napake (RMSE)	Povprečna kvadratna napaka (MSE)	Povprečna absolutna napaka (MAE)
0,268	5,85 int.	34,3	3,57 int.

Preglednica 7: Parametri merjenja natančnosti naučene UNM za naravne nesreče
Table 7: Parameters for measuring the accuracy of the trained Artificial Neural Networks (ANN) for natural disasters

povečanje požarov v sušnih obdobjih, kar je skladno s Pearsonovo korelacijsko analizo.

Velikosti napak, zbranih v preglednici 6, prikazujejo natančnost naučene UNM. Absolutna napaka mreže pri napovedovanju je majhna, saj znaša 6,24 požarnih intervencij.


Napoved nevronske mreže NARX za naravne nesreče

Za oblikovanje UNM-napovedovanja naravnih nesreč je izbrana enaka arhitekturna zasnova mreže kot pri požarnih intervencijah. Učna množica s 1460 časovnimi koraki, vsaka s 23 vplivnimi parametri, je ponovno razdeljena na učno, validacijsko in testno množico. Nevronska mreža se lahko preveč prilega samo primerom iz učne množice, pri tem pa ne posplošuje dobro, kar pomeni, da se bo slabo obnesla ob novih, še ne prepoznanih, primerih. S pravočasno ustavitvijo učenja


izračunamo napake testne množice in jih prikažemo v preglednici 7. Koeficient odločnosti R^2 je v raziskavi dosegel največje vrednosti. Povprečni srednja kvadratna in absolutna napaka sta veliki v primerjavi s povprečjem, ki znaša 4,4 intervencije, vendar te ocene pokvarijo ekstremna povečanja, ki jih mreža močno podceni.

Graf resničnih in napovedanih intervencij v 15-letnem obdobju je združen na sliki 8. Opazimo lahko, da so nekatere napovedane vrednosti negativne, kar je praktično nemogoče, vendar je to numerična napaka, saj lahko določene uteži v nevronih zavzamejo tudi negativne vrednosti. Do sredine grafa nevronska mreža nekoliko precenjuje število intervencij, vendar posameznim dvigom smiselno sledi. Razberemo lahko pet večjih, sunkovitih skokov števila v drugem delu grafa. Mreža sledi vsem dvigom, vendar nekatere podceni tudi za polovico. Takšen odziv je posledica poplav leta 2012, žledoloma leta 2014 in vetroloma leta 2017. Pearsonova korelacijska analiza je pokazala največji vpliv na razvoj intervencije naravnih nesreč prav za količino padavin (0,54), hitrost vetra (0,32), količino toče (0,19) in moč poledice (0,17).

Iz 15-letnega obdobja pogledamo izsek enoletnega napovedovalnega obdobja na sliki 9. Graf napovedanih intervencij se sklada z resničnimi, v povezavi z napovedmi trenda naraščanja in padanja, vendar natančnega števila ne more napovedati. Vsi porasti dogodkov se skladajo z napovedjo, vendar natančno število redko dosežemo. V obdobjih, v katerih zaznamo zmanjšano število naravnih nesreč oziroma jih ni, se napoved sklada z resničnim stanjem. Na podlagi podrobnejše ana-



Slika 8: Primerjava resničnega števila naravnih nesreč z napovedanim v 15-letnem obdobju
Figure 8: Comparison of the actual number of natural disasters with the forecast number over a 15-year period



Slika 9: Primerjava resničnega števila naravnih nesreč z napovedanimi v enoletnem obdobju
 Figure 9: Comparison of the actual number of natural disasters with the forecast number


lize množice vremenskih podatkov in ob zmanjšanem številu naravnih nesreč dobimo izsledke, da se v teh obdobjih ni povečala hitrost vetra, neviht in padavin.

Primerjava umetne nevronske mreže z regresijskim modelom


Smiselno je primerjati naučene umetne nevronske mreže s preprostim modelom večkratne regresije, da

bi dokazali prednosti, ki jih imajo nevronske mreže s sposobnostjo modeliranja močno nelinearnih sistemov.

Linearna regresija je statistična analiza, ki modelira odnose med dvema vrstama spremenljivk, med odvisno (odziv) in neodvisno. Z njo lahko preverimo, ali neodvisne spremenljivke uspešno napovejo rezultat funkcije in katere imajo največji vpliv (Koloğlu in sod., 2018). Koefficiente določimo tako, da minimiziramo vsoto kvadratov napak v zbrani množici učnih primerov. Določena



Slika 10: Odzivni graf napovedi multiregresije za naravne nesreče
 Figure 10: Response chart for multi-regression forecasts of natural disasters



Slika 11: Odzivni graf napovedi multiregresije za požarne intervencije
 Figure 11: Response chart for multi-regression forecasts of fire interventions

hiperravnina je rezultat linearne regresije, odstopanje od te ravnina, v smeri osi, pa je napaka.

Kadar imamo več regresijskih spremenljivk, govorimo o multipli linearni regresiji. Odvisna spremenljivka y vsebuje več členov, kot prikazuje enačba 3.2 (Montgomery in sod., 2015).

$$y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + \epsilon_i, \quad i = 1, \dots, n$$

Pri tem so:

y_i – odvisna spremenljivka,

β_k – k -ti koeficient, pri čemer je β_0 konstanta,

X_{ij} – i -ti člen regresijske spremenljivke $j = 1, \dots, p$,

ϵ_i – člen napake.

Z metodo najmanjših kvadratov SSE aproksimiramo koeficiente $\beta_0, \beta_1, \dots, \beta_k$. Vsota kvadratov razlike med

odvisno spremenljivko y_i in premo črto mora biti najmanjša (Sunthornjittanon, 2015). V primeru popolnega prileganja je lahko nič, vendar se realni podatki težko popolnoma matematično ujemajo na pripadajoči funkciji.

Odzivni graf linearne regresije prikazuje slika 10. Modro obarvane točke na grafu v posameznem mesecu prikazujejo število resničnih naravnih nesreč, rumene točke napovedano vrednost, oranžna črta pa napako. Težave regresijskega modela se kažejo v veliki napaki pri napovedi povečanega števila naravnih nesreč, zlasti ob poplavah leta 2012, žledolomu 2014 in vetrolomu leta 2017.

V preglednici 8 so zbrani rezultati matrik, s katerimi primerjamo rezultate obeh modelov umetnih nevronskih mrež z regresijskim modelom. Nevronska mreža LSTM je imela težave pri napovedovanju naravnih nesreč. Težave vidimo v naravi trenda gibanja naravnih nesreč v obdobju, v katerem se je ob žledolomu in

	Koeficient odločnosti (R^2)	Koren povprečne kvadratne napake (RMSE)	Povprečna kvadratna napaka (MSE)	Povprečna absolutna napaka (MAE)
NARX	0,268	5,85 int.	34,3	3,57 int.
LSTM	-0,840	15,4 int.	237,2	12 int.
Regresija	-0,17	9,0 int.	81	3,6 int.

Preglednica 8: Primerjava parametrov merjenja natančnosti med NARX, LSTM in regresijskim modelom za naravne nesreče
 Figure 8: Comparison of parameters for measuring the accuracy of NARX and LSTM and the regression model for natural disasters

	Koeficient odločnosti (R^2)	Koren povprečne kvadratne napake (RMSE)	Povprečna kvadratna napaka (MSE)	Povprečna absolutna napaka (MAE)
NARX	0,355	7,79 int.	61	6,24 int.
LSTM	0,209	6,54 int.	42,84	4,53 int.
Regresija	0,08	10,39 int.	108	8,03 int.

Preglednica 9: Primerjava parametrov merjenja natančnosti med NARX, LSTM in regresijskim modelom za požarne intervencije

Figure 9: Comparison of parameters for measuring the accuracy of NARX and LSTM and the regression model for fire emergency response

snegolomu povečalo število intervencij v primerjavi s preteklimi leti. Ta anomalija časovne vrste se je ohranila v kratkoročnem spominu celice LSTM, zaradi nje so napovedi ostale v visokih vrednostih. NARX-mreža se je izkazala za najprimernejšo. Razlika med korenem povprečne kvadratne napake (RMSE) v nevronske mreži NARX ter regresijskim modelom znaša 3,15 intervencije, medtem ko je razlika v povprečni absolutni napaki (MAE) zanemarljivo majhna. Prav po tej razliki sklepamo superiornost nevronske mreže v primerjavi z regresijskimi modeli, saj napaka ni prevelika, mreža pa bo sposobna posploševanja novih primerov.

Regresijski model na učni množici požarnih intervencij na sliki 11 ni vračal uporabnih napovedi dogodkov. Odločitveni koeficient R^2 se približa vrednosti 0,08, kar pomeni, da ugibamo in da bomo zadeli večkrat, kadar vzamemo povprečno število nesreč v časovnem obdobju.

Preglednica 9 primerja rezultate požarnih intervencij. V tej učni množici nevronske mreže LSTM ni bilo težav pomnjenja kratkoročnega spomina. V vseh parametrih merjenja natančnosti lahko vidimo superiornost nevronske mreže pred regresijskim modelom, saj so koreni povprečnih kvadratnih napak in povprečne absolutne napake bistveno manjši.

Sklepne misli

V članku je predstavljena implementacija dveh algoritmov nevronske mreže z namenom napovedovanja števila posameznih interventnih dogodkov v prihodnosti. Kvantitativne metode napovedovanja uporabljajo zajete podatke iz preteklosti in z matematičnimi modeli predvidijo stanje v prihodnosti.

V obeh pristopih se zaznava težava prediktorjev, saj je njihova korelacijska zveza z nastankom intervencije vedno majhna. Pomembno je pravilno nastavljanje parametrov učenja in dobro, poglobljeno poznavanje delovanja algoritmov, ki dosegajo različne rezultate na

posameznih učnih množicah. Nastavljanje parametrov učenja je pogosto postopek s poskušanjem, optimizacija pa poteka kot iteracijski postopek, da se zagotovi najboljši model. Težave se pojavljajo v majhnih učnih množicah, zato je treba modele večkrat naučiti z različnimi začetnimi utežmi za doseganje konsistentnih rezultatov različnih inicializacij uteži. Skladanje s trendi naraščanja in padanje števila interventnih dogodkov pri napovedovanju dajeta algoritme nevronske mreže v dober položaj pri izbiri napovedovalnih modelov. Med pisanjem algoritmov prihaja do različnih sklepov za izboljšanje napovedovanja in zmanjšanja napak. S strojnimi učenji bi bistveno natančneje napovedovali, če bi posamezne kategorije razčlenili v sklope. Pri požarnih intervencijah bi bilo treba izdelati ločen model za požare v naravi, požare v objektih, požare na prometnih sredstvih in eksplozije. Prav tako bi bilo treba ločiti naravne nesreče na poplave, vetrolom, snegolom, žledolom itn. Dosegli bi boljše korelacijske povezave v posameznih kategorijah, saj so za njihov nastanek odgovorni različni mehanizmi.

Druga izboljšava za povečanje natančnosti je razširitev obsega zajetih podatkov. Pri tem je treba razširiti geografsko področje in vključiti dodatna mesta. Vsekakor območje ne bi smelo zajemati intervencij v vsej Sloveniji, saj se geografske značilnosti Slovenije bistveno razlikujejo in območja zato med seboj niso primerljiva. Tretja izboljšava je dodajanje prediktorjev, ki vplivajo na nastanek. Težave v tem segmentu se pojavijo z njihovim zapisovanjem v preteklem 15-letnem obdobju. Za posamezne kategorije dogodkov bi bilo smiselno izvesti študijo korelacijskih parametrov in jih dodati v sistem poročil.

Pristop, izdelan v matematičnih modelih, predstavlja podatkovne izhajajoče rešitve za utemeljene in inteligentne odločitve, ki temeljijo na subjektivnih in kvalitativnih ocenah. Odločitve kompleksnega upravljanja in organiziranja v kriznih razmerah tako podpremo s sodobnimi in inteligentnimi metodami, ki nas vedno bolj obkrožajo na vseh področjih.

Viri in literatura

1. Agencija RS za okolje, Arhiv meteoroloških podatkov Agencije RS za okolje. <https://meteo.arso.gov.si/met/sl/archive/>.
2. Bernico, M., 2008. Deep Learning Quick Reference: Useful hacks for training and optimizing deep neural networks with TensorFlow and Keras. Birmingham: Packt Publishing.
3. Diaconescu, E., 2008. The use of NARX Neural Networks to predict Chaotic Time Series. Researchgate. https://www.researchgate.net/publication/228571349_The_use_of_NARX_neural_networks_to_predict_chaotic_time_series, 12. 6. 2020.
4. Géron, A., 2019. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools and Techniques to Build Intelligent Systems, 2. izdaja. Sebastopol: O'Reilly Media, Inc, USA.
5. Hochreiter, S., Schmidhuber, J., 1997. Long short-term memory, Neural Computation, let. 9, št. 8, str. 1735–1780.
6. Hudson, B., Demuth, H., 2004. Neural Network Toolbox User's Guide. The MathWorks inc. https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&cad=rja&uact=8&ved=2ahUKewjOr8vog77rAhUHtosKHRO6Cv8QFjABegQIBRAB&url=http%3A%2F%2Fcd.psych.uiuc.edu%2Fmatlab_pdf%2Fnnnet.pdf&usg=AOvVaw2J9KviZGU6yuCxHpP9GULb, 15. 7. 2020.
7. Koloğlu, Y., Birinci, H., Kanalmaz, S. I., Özyılmaz, B., 2018. A Multiple Linear Regression Approach For Estimating the Market Value of Football Players in Forward Position, Abdullah Gül University Industrial Engineering Department.
8. Marquardt, D., 2012. An Algorithm for Least-Squares Estimation of Nonlinear Parameters, SIAM Journal on Applied Mathematics, let. 11, št. 2, str. 431–441, junij 1963.
9. Montgomery, D., Peck, E., Vinning, G., 2012. Introduction to Linear Regression Analysis, 5. izdaja. New Jersey: Wiley.
10. Mukaka, M., 2012. Statistics Corner: A guide to appropriate use of Correlation coefficient in medical research. Malawi Medical Journal, let. 12, št. 24, str. 69–71.
11. Sunthornjittanon, S., 2015. Linear Regression Analysis on Net Income of an Agrochemical Company in Thailand, Portland State University.
12. Tsungnan, L., Horne, B., Tino, P., Giles, C., 1999. Learning long-term dependencies in NARX recurrent neural networks, IEEE Transactions on Neural Networks, let. 7, št. 6, str. 1329–1351.
13. URSZR, 2020. SPIN – Sistem za poročanje o intervencijah in nesrečah. <https://spin3.sos112.si>.
14. Yang, G., Meng, J., 2005. NARMAX time series model prediction: feedforward and recurrent fuzzy neural network approaches, Fuzzy Sets and Systems, let. 150, št. 2, str. 331–350.