

Primjena modela umjetnih neuronskih mreža u predviđanju otpada od hrane na području Europske unije

Ivan Brandić¹, Lato Pezo², Jana Šic Žlabur¹, Anamarija Peter¹, Jona Šurić¹, Neven Voća¹

¹Sveučilište u Zagrebu Agronomski fakultet, Svetošimunska cesta 25, Zagreb, Hrvatska (ibrandic@agr.hr)

²Sveučilište u Beogradu, Institut za opštu i fizilku hemiju, Beograd, Srbija.

Sažetak

Porastom stanovništva dolazi do stvaranja sve većih količina otpada od hrane. Za planiranje smanjenja i stvaranja mehanizama rješavanja otpada od hrane potrebno je različitim modelima predvidjeti količinu otpada od hrane. Na stvaranje otpada od hrane utječu brojni socioekonomski i društveni čimbenici. Kao alat za nelinearno modeliranje i predviđanje nude se modeli u obliku umjetnih neuronskih mreža. U ovom istraživanju kreiran je model umjetnih neuronskih mreža za predviđanje ukupne količine otpada od hrane na području Europske unije. Provedenom analizom pogodnosti ($R^2=0,99$), utvrđena je mogućnost razvijenog za predviđanje ukupne količine otpada od hrane.

Ključne riječi: otpad od hrane, Europska unija, predviđanje, modeliranje, umjetne neuronske mreže.

Uvod

Proizvodnja hrane jedan je od ključnih čimbenika vezanih onečišćenje okoliša na području Europe. Primarna proizvodnja hrane zahtjeva korištenje resursa kao što su gorivo, zemljište i voda (Scherhauser i sur., 2018.). Najveći dio otpada od hrane nastaje u kućanstvima što predstavlja središnju točku problematike vezanu uz zbrinjavanje otpada od hrane, te kao važan pokazatelj održivosti predstavlja zbroj resursa koji se koriste pri proizvodnji hrane (Conrad i sur., 2018., Thi i sur., 2022). Povećanjem stanovništva neizbježna je pojava nastanka otpada od hrane, te je potrebno staviti naglasak na mehanizme rješavanja i ublažavanja nastanka istog (Jamaludin i sur., 2022.). Otpad od hrane smatra se društvenim problemom s dalekosežnim socioekonomskim i ekološkim posljedicama. Pham i sur. (2015.) navode da otpad od hrane predstavlja značajan dio krutog komunalnog otpada, te kao neiskorišteni resurs ima veliki potencijal za proizvodnju energije. Rješavanje problema otpada od hrane zahtjeva kombinaciju tehnoloških rješenja i izravne edukacije kako bi se promijenila ponašanja potrošača (Kibler i sur., 2018.). Iako je otpad od hrane nemoguće u potpunosti ukloniti, postoje mehanizmi kojima bi se omogućila pretvorba otpada od hrane u korisnu energiju. Modelima za predviđanje količine otpada od hrane olakšava se planiranje i upravljanje navedenim problemom. U posljednje vrijeme kao modeli za predviđanje sve se više koriste umjetne neuronske mreže (UNM) (Obafemi i sur., 2019.). Osnovne karakteristike UNM modela podrazumijevaju strukturu mreže, algoritam učenja i primjena prijenosne (aktivacijske) funkcije. Prednost UNM je mogućnost prilagodbe i generalizacija s obzirom na karakteristične ulazne vrijednosti. U primjeni, kao modeli za predviđanje, najpogodnije su UNM višeslojnog perceptrona (Kartal i Özveren, 2020.; Pattanayak i sur., 2021.). UNM se sastoje od tri osnovna dijela: ulaznog, skrivenog i izlaznog sloja, te pripada kategoriji modela za „duboko učenje“ (Rajković i sur., 2022.). Faezirad i sur. (2021.) proveli su istraživanje u kojem su kreirali model UNM za predviđanje količine otpada od hrane koji nastaje u studentskim restoranima, u svrhu planiranja smanjenje ukupnog otpada. Kreiranim modelom i daljnjom analizom utvrđeno je da bi se količina otpada od hrane mogla smanjiti za 79 % na promatranom području. Cilj ovog rada je kreirati model UNM za predviđanje ukupne količine otpada od hrane na području Europske unije s obzirom na specifične ulazne varijable koji obuhvaćaju socio-ekonomske i društvene čimbenike.

Materijal i metode

Podaci za izradu modela UNM prikupljeni u bazama podataka „The World Bank (za 2020. godinu)“, te su podijeljeni u smislene kategorijske varijable. Statistički obrađeni podaci prikazani su u obliku srednje vrijednosti sa standardnom devijacijom. Analizom varijance (ANOVA) i Tukey HSD post hoc testom utvrđene su varijabilnosti promatranih uzoraka (Brandić i sur., 2022.). Podaci korišteni za izradu modela UNM nasumično su podijeljeni na dio za učenje (70%), testiranje (15%) i validaciju (15 %) modela. Model je kreiran sa 100 000 ciklusa učenja s nasumičnim brojem skrivenih neurona u skrivenom sloju (1-10). UNM kreirana za predviđanje UOG (ukupna količina otpada od hrane) temelji se na ulaznih varijablama OH (otpad od hrane po stanovniku godišnje), populacije (POP), BDP (bruto domaći proizvod) i ZPO (postotak stanovništva sa završenim primarnim obrazovanjem).

Pogreška razvijenog modela izračunavat će se pomoću idućih statističkih parametara: Korijen iz prosječnog kvadrata pogreške (RMSE), prosječna pogreška pristranosti (MBE) i prosječna postotna pogreška (MPE):

$$RMSE = \left[\frac{1}{N} \cdot \sum_{i=1}^N (x_{pre,i} - x_{exp,i})^2 \right]^{1/2}$$


$$MBE = \frac{1}{N} \cdot \sum_{i=1}^N (x_{pre,i} - x_{exp,i})$$

$$MPE = \frac{100}{N} \cdot \sum_{i=1}^N \left(\frac{|x_{pre,i} - x_{exp,i}|}{x_{exp,i}} \right)$$

Izlazne vrijednosti modela UNM računa se pomoću jednadžbe (Pezo i sur., 2013.):

$$Y = f_1(W_2 \cdot f_2(W_1 \cdot X + B_1) + B_2)$$

Y - izlazna vrijednost, X - ulazna vrijednosti, W1 - težinski koeficijent između ulaznog i skrivenog sloja, B1, B2 – vektori pristranosti skrivenog sloja, W2 – težinski koeficijent između skrivenog i izlaznog sloja.



Slika 1. Struktura razvijenog modela umjetne neuronske mreže (4-8-1)

Na slici 1. prikazana je struktura razvijenog modela UNM sa 4 umjetna neurona u ulaznom sloju, 8 umjetnih neurona u skrivenom sloju i 1 skrivenim neuronom u izlaznom sloju. Razvijeni model pokazao je najbolje performanse u predviđanju UOG

Rezultati i rasprava


U tablici 1. prikazana je provedena statistička analiza promatranih varijabli korištenih za kreiranje modela UNM. Podaci su podijeljeni u 4 kategorije s obzirom na broj stanovnika na određenom području Europske unije; ≤ 1 mil. stanovnika, 1 - 10 mil. stanovnika, 10 - 40 mil. stanovnika, ≥ 40 mil. stanovnika.

Tablica 1. Statistička analiza promatranih varijabli

Kategorija	OH (kg)	UOG (tis. t/god.)	POP. (mil. stan.)	BDP (tis.d.stan./god.)	ZPO (%)
≤ 1 mil. stanovnika	109,5 \pm 27,58 ^a	55,97 \pm 1,19 ^a	0,58 \pm 0,09 ^a	84,47 \pm 72,43 ^a	81,55 \pm 5,16 ^a
1 - 10 mil. stanovnika	70,38 \pm 18,63 ^a	323,63 \pm 223,29 ^{ab}	4,67 \pm 2,79 ^{ab}	36,5 \pm 25,2 ^a	91,42 \pm 13,38 ^a
10 - 40 mil. stanovnika	75,38 \pm 29,92 ^a	1101,14 \pm 513,98 ^b	16,01 \pm 9,46 ^b	34,21 \pm 19,09 ^a	90,1 \pm 7,65 ^a
≥ 40 mil. stanovnika	76 \pm 7,39 ^a	4864,97 \pm 1238,57 ^c	64,26 \pm 15,06 ^c	30,00 \pm 19,7 ^a	86,23 \pm 7,01 ^a
Minimum	70,38	55,97	0,58	30,00	81,55
Maksimum	109,50	4864,97	64,26	84,47	91,42
Prosjek	82,81	1586,43	21,38	46,29	87,32

OH – Otpad od hrane po stanovniku godišnje; UOG – Ukupna količina otpada od hrane; POP. – Populacija; BDP – Bruto domaći proizvod u dolarima; ZPO – Završeno primarno obrazovanje. Srednje vrijednosti u istom stupcu, s različitim eksponentom su statistički različite ($p \leq 0,05$), prema Tukeyjevom HSD testu.

Na području ≤ 1 mil. stanovnika utvrđena je najveća prosječna vrijednost OH (109,5 kg), BDP (84,47 tis. d.stan./god.) i najniža prosječna vrijednost UOG (55,97 tis.t/god.) i ZPO (81,55 %). Na području ≥ 40 mil. stanovnika utvrđena je najviša prosječna vrijednost UOG (4864,97 tis.t/god.) i BDP (30,00 tis.d.stan./god.). U kategoriji 1 - 10 mil. stanovnika utvrđena je najviša prosječna vrijednost ZPO (91,42 %).



Slika 2. Dijagram korelacije promatranih varijabli

Na slici 2. prikazan je dijagram korelacije promatranih varijabli. Pozitivne vrijednosti korelacije promatranih varijabli prikazani su plavom bojom, dok su negativne prikazane crvenom bojom. Intenzitet obojenja proporcionalan je koeficijentu korelacije (Brandić i sur., 2022). UOG u pozitivnoj je korelaciji sa varijablom POP, dok je sa varijablama OH, POP i BDP i ZPO u negativnoj korelaciji.

Tablica 2. Statistička analiza pogodnosti razvijenog modela UNM

RMSE	MBE	MPE	R ²	Kurtosis
26604,62	549,23	1,80	0,99	17,30

RMSE – korijen prosječnog kvadrata pogreške; MBE – Prosječna pogreška pristranosti; MPE – Prosječna postotna pogreška; R² – Koeficijent determinacije.


U tablici 2. prikazana je statistička analiza pogodnosti (eng. „Goodness of fit“) razvijene UNM u mogućnosti modela za predviđanju UOG. Parametrima RMSE (26604,62), MBE (549,23), MPE (1,80) i R² (0,99) utvrđena je sposobnost razvijenog modela u predviđanju izlazne vrijednosti UOG s malom razinom pogreške.

Tablica 3. Performanse razvijenog UNM modela

UNM	PU	PT	PV
MLP 4-8-1	0,99	0,99	0,99

UNM – Umjetna neuronska mreža; PU – Performanse učenja modela; PT – Performanse testiranja modela; PV – Performanse validacije modela

Tablica 3. prikazuje performanse učenja (PU), testiranja (PT) i validacije (PV) modela UNM koji su izraženi koeficijentom korelacije (0,99). Razvijeni model strukture 4-8-1 pogodan je za modeliranje UOG s obzirom na podatke ulaznih varijabli OH, POP, BDP i ZPO.



Grafikon 1. Odnos predviđenog i ciljanog UOG

Dijagram raspršenosti kao tehnika vizualizacije prikazuje odnos podataka na x i y osi (Keim i sur., 2010.). Na grafikonu 1. prikazan je dijagram raspršenosti predviđenog i ciljanog UOG. S obzirom na preklapanje podataka predviđenih i ciljanih vrijednosti, dokazano je da je model UNM pogodan za predviđanje UOG.

Zaključak

Povećanjem stanovništva neizbježna je pojava nastanka sve većih količina otpada od hrane. Kao važan pokazatelj održivosti, otpad od hrane predstavlja zbroj resursa koji se direktno koriste u proizvodnji hrane. Kako bi se smanjila količina nastanka istog, potrebno je predvidjeti ukupnu količinu otpada od hrane čime se omogućuje prilagodba postojećih ali i stvaranje novih mehanizama za kontrolu i redukciju. Regresijskim modelima umjetnih neuronskih mreža moguće je predvidjeti ukupnu količinu otpada od hrane na području Europske unije s obzirom na karakteristične ulazne varijable koji obuhvaćaju socioekonomske i društvene čimbenike. U istraživanju predstavljen

je model umjetne neuronske mreže za predviđanje ukupne godišnje količine otpada, te je utvrđena mogućnost predviđanja s malom razinom pogreške ($R^2=0,99$).

Napomena

Ovo istraživanje financirano je kroz projekt „Zero food waste education of „Z“ generation of European citizens“, Erasmus+ programme, Action Type KA220-HED-Cooperation partnership in higher education.

Literatura

- Brandić I., Pezo L., Bilandžija N., Peter A., Šurić J., Voća N. (2022). Artificial Neural Network as a Tool for Estimation of the Higher Heating Value of Miscanthus Based on Ultimate Analysis. *Mathematics*. 10 (20): 1–12.
- Conrad Z., Niles M.T., Neher D.A., Roy E.D., Tichenor N. E., Jahns L. (2018). Relationship between food waste, diet quality, and environmental sustainability. *PLoS ONE*. 13 (4):1-18.
- Faezirad M., Pooya A., Naji-Azimi Z., Amir Haeri M. (2021). Preventing food waste in subsidy-based university dining systems: An artificial neural network-aided model under uncertainty. *Waste Management and Research*. 39 (8): 1027–1038.
- Jamaludin H., Elmaky H.S.E., Sulaiman S. (2022). The future of food waste: Application of circular economy. *Energy Nexus*. 7: 100098.
- Kartal F., Özveren U. (2020). A deep learning approach for prediction of syngas lower heating value from CFB gasifier in Aspen plus®. *Energy*. 209.
- Keim D.A., Hao M.C., Dayal U., Janetzko H., Bak P. (2010). Generalized scatter plots. *Inform. Visual*. 9: 301-311.
- Kibler K.M., Reinhart D., Hawkins C., Motlagh A.M., Wright J. (2018). Food waste and the food-energy-water nexus: A review of food waste management alternatives. *Waste Management*. 74: 52-62.
- Obafemi O., Stephen A., Ajayi O., Nkosinathi M. (2019). A survey of artificial neural network-based prediction models for thermal properties of biomass. *Procedia Manufacturing*. 33: 184-191.
- Pattanayak S., Loha C., Hauchhum L., Sailo L. (2021). Application of MLP-ANN models for estimating the higher heating value of bamboo biomass. *Biomass Conversion and Biorefinery*. 11 (6): 2499–2508.
- Pezo L.L., Ćurčić B.L., Filipović V.S., Nićetin M.R., Koprivica G.B., Mišljenović N.M., Lević L.B. (2013). Artificial neural network model of pork meat cubes osmotic dehydration. *Hemijska industrija*. 67 (3): 465-475.
- Pham T.P.T., Kaushik R., Parshetti G.K., Mahmood R., Balasubramanian R. (2015). Food waste-to-energy conversion technologies: Current status and future directions. *Waste Management*. 38 (1): 399-408.
- Rajković D., Jeromela A.M., Pezo L., Lončar B., Zanetti F., Monti A., Špika A.K. (2022). Yield and Quality Prediction of Winter Rapeseed—Artificial Neural Network and Random Forest Models. *Agronomy*. 12 (1).
- Scherhauser S., Moates G., Hartikainen H., Waldron K., Obersteiner G. (2018). Environmental impacts of food waste in Europe. *Waste Management*. 77: 98-113.
- The World Bank, World Bank Open Dana (2020).
- Thi T., Nguyen T., Malek L., Umberger W.J., Connor P.J.O. (2022). Household food waste disposal behaviour is driven by perceived personal benefits, recycling habits and ability to compost. *Journal of Cleaner Production*. 379 (P1):134636.

Application of artificial neural network models to predict food waste in the European Union

Abstract

As the population grows, more and more food waste is generated. In order to plan the reduction and establish mechanisms for dealing with food waste, it is necessary to predict the amount of food waste using various models. The generation of food waste is influenced by numerous socio-economic and social factors. Models in the form of artificial neural networks are offered as tools for non-linear modelling and prediction. In this study, an artificial neural network model was built to predict the total amount of food waste in the European Union. The „Goodness of fit“ analysis ($R^2=0.99$) showed that the developed tool is suitable for predicting the total amount of food waste.

Keywords: food waste, European union, prediction, modelling, artificial neural networks

This research was funded by project „Zero food waste education of „Z“ generation of European citizens“, Erasmus+ programme, Action Type KA220-HED-Cooperation partnership in higher education.