

Umjetne neuronske mreže kao statistički alat u predviđanju donje ogrjevne vrijednosti biomase

Brandić, Ivan; Peter, Anamarija; Šurić, Jona; Pezo, Lato; Voća, Neven

Source / Izvornik: **Zbornik radova 57. hrvatskog i 17. međunarodnog simpozija agronoma, 2022, 619 - 623**

Conference paper / Rad u zborniku

Publication status / Verzija rada: **Published version / Objavljena verzija rada (izdavačev PDF)**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:204:928767>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2025-02-01**



Repository / Repozitorij:

[Repository Faculty of Agriculture University of Zagreb](#)



Umjetne neuronske mreže kao statistički alat u predviđanju donje ogrjevne vrijednosti biomase

Ivan Brandić¹, Anamarija Peter¹, Jona Šurić¹, Lato Pezo², Neven Voća¹

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

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

Sažetak

Pri korištenju biomase kao sirovine za proizvodnju goriva i toplinske energije, potrebno je odrediti njezina energetska svojstva. Primjenom modela umjetnih neuronskih mreža moguće je s velikom točnošću predvidjeti donju ogrjevnu vrijednost pojedinih energetskih kultura, čime se olakšava pronalaženje optimalnog rješenja. Sposobnost samoorganizacije, optimiziranog učenja i visoke tolerancije na pogreške neuronskim mrežama omogućuje pouzdano i precizno izračunavanje donje ogrjevne vrijednosti biomase. Ispravnom konfiguracijom mreže i prikupljanjem podataka, modeli umjetnih neuronskih mreža mogu se koristiti za predviđanje donje ogrjevne vrijednosti u realnom vremenu.

Ključne riječi: biomasa, ogrjevna vrijednost, umjetne neuronske mreže.

Uvod

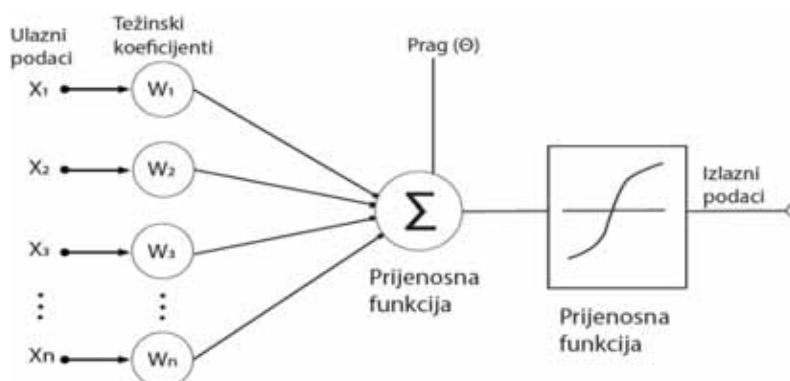
Ogrjevna vrijednost goriva važno je svojstvo koje definira energetska sadržaj sirovine. Donja ogrjevna vrijednost definirana je kao energija koja se oslobađa po jedinici mase ili volumena pri potpunom izgaranju, a obično se izražava u megadžulima po kilogramu (MJ/kg) (Ghugare i sur., 2014.). Pomoću već razvijenih matematičkih modela za predviđanje moguće je proučiti učinak pojedinih varijabli u sustavu te utvrditi njihovu povezanost sa krajnjim rezultatom. Za razliku od navedenih modela, umjetne neuronske mreže (*eng. Artificial Neural Networks*) pokazuju veliku učinkovitost u modeliranju kompleksnih procesa uvjetovanih velikim brojem varijabli (Izadifar i Demneh, 2006.). Nakon odabira odgovarajućih ulaznih podataka, umjetne neuronske mreže imaju sposobnost ispravno generalizirati podatke te ih prilagoditi ukoliko su nepotpuni. Građa modela umjetnih neuronskih mreža uključuje nekoliko organiziranih slojeva između kojih se odvijaju matematičke operacije. Poput ljudskog mozga neuronske mreže se treniraju iskustvom i stvaranjem obrasca kojim je najlakše izračunati željeni izlaz. Za testiranje točnosti modela neuronskih mreža potrebno je usporediti ekperimentalne rezultate sa rezultatima dobivenim putem modela (Kartal i Ozveren, 2020.).

Princip rada umjetnih neuronskih mreža u određivanju donje ogrjevne vrijednosti

Za racionalno iskorištavanje biomase energetskih kultura potrebno je poznavati njihova energetska svojstva. Mjerenje donje ogrjevne vrijednosti je postupak koji zahtjeva posebnu pripremu uzoraka kako bi se smanjila mogućnost pogreške. Za predviđanje donje ogrjevne vrijednosti uglavnom se koriste već razvijeni matematički modeli. Odnos između varijabli korištenih za predviđanje donje ogrjevne vrijednosti sugerira nelinearne međusobne odnose, stoga se razvijanje nelinearnih modela smatra primjerenijim u predviđanju (Ghugare i sur., 2014.). Postoji međusobna povezanost između donje ogrjevne vrijednosti i razvijenih matematičkih modela temeljenih na elementnoj analizi organskih tvari te analizama gorivih i negorivih tvari biomase. Matematički modeli koji obuhvaćaju međusobnu povezanost


navedenih analiza i donje ogrjevne vrijednosti su jednostavni i pružaju brzo, ali ponekad i netočno predviđanje.

Umjetne neuronske mreže su sustavi koji obrađuju podatke na sličan način kao neuroni u ljudskom mozgu, gdje se umjetni neuroni povezuju različitim geometrijskim vezama (Staub i sur., 2015.). Osnovne značajke umjetnih neuronskih mreža su sposobnost samostalnog učenja, mogućnost prilagodbe sustava s obzirom na dostupne informacije te obrada podataka i složenih matematičkih operacija velikom brzinom. Pod učenjem umjetne neuronske mreže podrazumijeva se iterativni postupak podešavanja vrijednosti težinskih faktora na osnovu pogreške između proračunate vrijednosti modela i stvarne vrijednosti mjerne veličine (Andrijić i Bolf, 2019.). Umjetne neuronske mreže izračunavaju pomoću statističkih teorija učenja koje su metode prikladne za rješavanje izračuna nelinearnih modela te uspostavljanja odnosa između ulaznih varijabli i izlaznih podataka. Prema Ujević Andrijić i Bolf (2019.), umjetni neuroni primaju ulazne podatke koji su određeni težinskim koeficijentima nakon čega se podaci obrađuju pomoću unutarnjeg praga (*eng. bias*). Prijenosnom funkcijom dobiveni podaci se šalju prema izlazu i sljedećim neuronima.



Slika 1. Prikaz umjetnog neurona (shorturl.at/kAS18)

Postoji više različitih vrsta neuronskih mreža no u primjeni za izračunavanje nelinearnih modela je najučinkovitija višeslojna perceptron neuronska mreža (*eng. Multilayer Perceptron Neural Network*) (Pattanayak i sur., 2021.). Višeslojna mreža sastoji se od tri sloja: ulaznog, skrivenog i izlaznog sloja (Slika 2.) (Svaki sloj se sastoji od niza neurona a veze između neurona određene su pomoću težinskih koeficijenata. Optimizacijom težinskih koeficijenata među neuronima računa se krajnji željeni izlaz (Pattanayak i sur., 2021.). Osnovne značajke umjetnih neuronskih mreža opisani su u tablici 1.



Slika 2. Prikaz umjetne neuronske mreže (shorturl.at/deruJ)

Tablica 1. Značajke umjetnih neuronskih mreža (Staub i sur., 2015.)

Značajka	Opis
Nelinearni modeli	Mogućnost rješavanja složenih nelinearnih zadataka.
Tolerancija pogreške	Ravnomjerna raspodjela zadataka unutar sustava.
Trening sustava	Sposobnost prilagodbe u svrhu rješavanja problema.
Učenje	Prilagođavanje opterećenja pomoću algoritama.
Generalizacija	Stvaranje željenog odgovora tokom procesa učenja.

Osnovna jednadžba za računanje izlaznih podatak u neuronskoj mreži:


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

Y izlazni vektor; X ulazni vektor, W1 težinski vektor između skrivenog i ulaznog sloja; B1 vektor pristranosti (eng. bias) skrivenog sloja, W2 težinski vektor između izlaznog i skrivenog sloja, B2 vektor pristranosti skrivenog sloja.

Prema Bašić i sur. (2008.) najčešći oblik prijenosne funkcije jest sigmoidalna funkcija (slika 3). Sigmoidalna funkcija je derivabilna, što predstavlja bitnu prednost pri postupku učenja neuronske mreže. Sigmoidalna funkcija je definirana kao:

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

U posljednje vrijeme umjetne neuronske mreže se sve više koriste kao alat za predviđanje jer modeli umjetnih neuronskih mreža mogu predvidjeti donju ogrjevnu vrijednost biomase sa velikom točnošću.

Slika 3. Sigmoidalna (logistička) funkcija (shorturl.at/kEQU6)

Predviđanje donje ogrjevne vrijednosti pomoću umjetnih neuronskih mreža

Çakman i sur. (2021.) su u istraživanju razvili model umjetnih neuronskih mreža za predviđanje donje ogrjevne vrijednosti biougljena. Usporedbom dobivenih podataka sa rezultatima dobivenim preko već razvijenih empirijskih modela, model umjetne neuronske mreže pokazao je veliku točnost. Također Estiati i sur. (2016.) prikazuju mogućnost korištenja modela umjetnih neuronskih mreža u procjeni donje ogrjevne vrijednosti. Dokazano je da model prikazuje zadovoljavajuću korelaciju i izlazne podatke. Za razliku od primijenjenih empirijskih modela, pojednostavljuju prikaz i strukturu podataka. Iako korišteni nelinearni modeli i modeli neuronskih mreža koriste iste principe podešavanja pojedinih parametara, učinak neuronskih mreža je bio viši.

Patel i sur. (2006.) navode da su postojeći modeli temeljeni na analizama elemenata ili gorivih tvari linearnog karaktera. Kroz istraživanje primjećuje se nelinearan odnos ulaznih podataka sa krajnjim rezultatom. Razvijeni modeli umjetnih neuronskih mreža za predviđanje ogrjevnih vrijednosti jasno prikazuju točnost pri predviđanju i generalizaciji

podataka. Uspoređujući navedeni modeli s tri linearna modela autori su dokazali da modeli neuronskih mreža s većom točnošću izračunavaju izlazne podatke.

Kartal i Ozveren (2020.) koriste model umjetnih neuronskih mreža za procjenu donje ogrjevne vrijednosti sintetskog plina dobivenog iz biomase. Kroz istraživanje dokazano je da modeli procjenjuju donju ogrjevnu vrijednost sa visokom točnošću ukoliko model koristi dovoljan broj podataka za treniranje mreže.

Pandey i sur. (2016.) u istraživanju koriste modele umjetne neuronske mreže za predviđanje donje ogrjevne vrijednosti, gdje krajnji rezultati pokazuju da se prediktivna izvedba modela dobro slaže s eksperimentalnim skupovima podataka, čime se dokazuje da se neuronske mreže mogu koristiti kao alternativna metoda za modeliranje složenih procesa predviđanja. U istraživanju koje su proveli Patel i sur. (2007.) razvijeno je sedam različitih nelinearnih modela neuronskih mreža. Rezultati navedenog istraživanja jasno prikazuju točnost pri predviđanju i simplifikaciji podataka. Također, usporedbom modela neuronskih mreža sa linearnim modelima koji koriste iste podatke, prikazana je veća preciznost i točnost modela neuronskih mreža.

Prema Ozveren (2016.) podaci dobiveni laboratorijskim analizama mogu se koristiti kao ulazne varijable za razvoj modela umjetnih neuronskih mreža. Model je pri predviđanju energetske vrijednosti koristio ulazne podatke udjela fiksiranog ugljika, hlapive tvari i pepela te je pokazao zadovoljavajuće izlazne vrijednosti.

Postojeći empirijski modeli za procjenu uglavnom daju zadovoljavajuće rezultate te se koriste gdje je nemoguće eksperimentalno odrediti donju ogrjevnu vrijednost. No radi svoje stope pogreške nisu povoljni za točno određivanje vrijednosti. Najčešće se koristi umjetna neuronska mreža sa algoritmom unazadne propagacije radi jednostavne implementacije (Mousavian i sur., 2012.).

Zaključak

Ispitivanjem energetske svojstava biomase određuje se mogućnost iskorištenja biomaterijala u smislu pretvorbe u energiju pri čemu su utvrđene razlike u sadržaju energije po jedinici mase za različitu biomasu. Razvojem sustava nelinearnih modela poput umjetnih neuronskih mreža izlazni podaci se mogu dobiti sa većom preciznošću. U usporedbi sa već korištenim metodama predviđanja, umjetne neuronske mreže mogu pojednostavljeno predvidjeti donju ogrjevnu vrijednost biomase. Najčešće se koriste u donošenju odluka, identifikaciji, kontroli pojedinih sustava i predviđanju. Među brojnim drugim prednostima, umjetne neuronske mreže mogu podnijeti obradu nepotpunih podataka. Nakon što model uspostavi obrazac, može obavljati složene podatke poput predviđanja, modeliranja i optimizacije. Modeli umjetne inteligencije u vidu neuronskih mreža radi svoje točnosti imaju potencijal zamijeniti postojeće empirijske modele razvijene za predviđanje donje ogrjevne vrijednosti.

Napomena

Ovo istraživanje financirala je Hrvatska zaklada za znanost u okviru projekta br. IP-2018-01-7472, "Zbrinjavanje mulja kroz proizvodnju energetske kultura" u okviru projekta „Projekt razvoja karijera mladih istraživača – izobrazba novih doktora znanosti“ uz sufinanciranje od strane Europske unije, u okviru OP „Učinkoviti ljudski potencijali 2014-2020“ iz sredstava ESF-a.

This research was funded by the Croatian Science Foundation (HRZZ) under project No. IP-2018-01-7472 „Sludge management via energy crops' production“, and within the project “Young Researchers' Career Development Project – Training of Doctoral Students”, co-financed by the European Union, under the OP “Efficient Human Resources 2014-2020” from the ESF funds.

Literatura

- Bašić B. D., Čupić M., Šnajder J., (2008). Umjetne neuronske mreže, Umjetna inteligencija, Fakultet elektrotehnike i računarstva, Zagreb (2008).
- Çakman G., Gheni S., Ceylan S. (2021). Prediction of higher heating value of biochars using proximate analysis by artificial neural network. *Biomass Conversion and Biorefinery*. 1-9.
- Estiati I., Freire F., Freire J., Aguado R., Olazar M. (2016). Fitting performance of artificial neural networks and empirical correlations to estimate higher heating values of biomass. *Fuel*. 180: 377-383. j.fuel.2016.04.051.
- Ghugare S.B., Tiwary S., Elangovan V., Tambe S.S. (2014). Prediction of Higher Heating Value of Solid Biomass Fuels Using Artificial Intelligence Formalisms. *BioEnergy Research*. 7: 681–692.
- Izadifar M., Demneh F. (2006). Comparison between neural network and mathematical modeling of supercritical CO₂ extraction of black pepper essential oil. *The Journal of Supercritical Fluids*. 35: 37.
- Kartal F., Özveren U. (2020). A deep learning approach for prediction of syngas lower heating value from CFB gasifier in Aspen plus®. *Energy*, Elsevier, 209.
- Mousavian, M. , Mofrad, M. , Vakili, M. , Ashouri, D. , Alizadeh, R. (2012), 'Investigation of Artificial Neural Networks Performance to Predict Net Heating Value of Crude Oil by Its Properties', *International Journal of Chemical and Molecular Engineering*, 6 (12): 1180-1184.
- Ozveren U. (2017). An artificial intelligence approach to predict gross heating value of lignocellulosic fuels. *Journal of the Energy Institute*. 90(3): 397-407.
- Pandey D.S., Das S., Pan I., Leahy J.J., Kwapinski W. (2016). Artificial neural network based modelling approach for municipal solid waste gasification in a fluidized bed reactor. *Waste Management*. 58: 202-213.
- Patel S., Kumar B., Badhe Y., Sharma B.K., Saha S., Biswas S., Chaudhury A., Tambe, S., Kulkarni B. (2007). Estimation of gross calorific value of coals using artificial neural networks. *Fuel*. 86: 334-344.
- Pattanayak S., Loha C., Hauchhum L., Lalsangzela S. (2021). Application of MLP-ANN models for estimating the higher heating value of bamboo biomass. *Biomass Conversion and Biorefinery*. 11: 2499–2508.
- Staub S., Karaman E., Kaya S., Karapınar H., Güven E. (2015). Artificial Neural Network and Agility. *Procedia - Social and Behavioral Sciences*. 195: 1477-1485.
- Ujević-Andrijić Ž., Bolf N. (2019). Umjetne neuronske mreže. *Kemija u industriji*. 6(5- 6): 219-220.

Artificial neural networks as a statistical tool for predicting the net calorific value of biomass

Abstract

When using biomass as a raw material for the production of fuel and heat, it is necessary to determine its energy properties. By applying the model of artificial neural networks, it is possible to predict net calorific values of individual energy cultures with great accuracy, which makes neural networks good solution in finding the optimal values. The possibility of self-organization, optimized learning and high tolerance to errors, neural network allows reliable and accurate calculation of the lower calorific value of energy crops. With the correct network configuration and data collection, artificial neural network models can be used to predict the calorific value in real time.

Key words: biomass, energy crops, calorific value, artificial neural networks.