



Ž. Ujević Andrijić *

Fakultet kemijskog inženjerstva i tehnologije
Sveučilišta u Zagrebu
Zavod za mjerenja i automatsko vođenje procesa
Savska cesta 16/5a, 10 000 Zagreb


Umjetne neuronske mreže

Biološka i umjetna neuronska mreža

Umjetne neuronske mreže spadaju u metode umjetne inteligencije. Umjetna inteligencija je dio znanosti o računalima koja se bavi projektiranjem inteligentnih računalnih sustava koji predočavaju karakteristike koje povezujemo s inteligencijom u ljudskom ponašanju. Tijekom evolucije ljudski mozak poprimio je niz karakteristika koje se povezuju s inteligencijom. Neke od karakteristika ljudi koji se povezuju s inteligencijom su: paralelno odvijanje više operacija, sposobnost učenja, sposobnost generaliziranja (uopćavanja), sposobnost prilagođavanja, suvislo postupanje s informacijama, tolerancija na pogreške i nepotpune informacije. Karakteristike računalnih sustava su: brza provedba numeričkih složenih proračuna te rad s velikom količinom podataka.

Građa i struktura bioloških neuronskih mreža

Svaki neuron se, kako je prikazano na slici 1, sastoji od tri dijela:



Slika 1 – Prikaz biološkog neurona


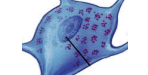


- *tijela stanice*, koje sadrži jezgru ili nukleus s informacijama o nasljednim značajkama;
- *dendrita*, kraćih niti oko stanice, koji prenose signale (impulse) s drugih neurona;
- *aksona*, dugih i tankih niti, koji prenose signal do drugih neurona pri čemu se grana u vlakna.

Sinapse su funkcionalne jedinice između završetka aksona prethodnog neurona i dendrita sljedećeg neurona koje oslobađaju materijal potreban stanici za prijenos signala, neurotransmiter, pri čemu se odvija elektrokemijska reakcija. Impuls se prenosi preko sinapsi s jednog na drugi neuron. Dendriti pojačavaju ili prigušuju impuls, sumiraju se u jezgri tijela te se putem aksona i sinapsi prenose na druge neurone.


Topologija umjetnih neuronskih mreža

Spoznaja o građi i načinu funkcioniranja ljudskog mozga i neurona potaknula je istraživanje i razvoj umjetnih neuronskih mreža. Topološka analogija umjetnih neuronskih mreža s biološkim neuronskim mrežama prikazana je u tablici 1.

Tablica 1 – Biološki i umjetni neuron

Biološki neuron	Umjetni neuron
 dendriti	Prima ulazni signal putem dendrida (sinaptičke veze)
 Obrada signala u somi	Obrada ulaza, unutarnji prag – bias (b)
 akson	Pretvara obrađeni ulaz u izlaz putem aksona
 do sljedećeg neurona	Šalje informaciju prema izlazu i sljedećim neuronima

Prvi rad o umjetnim neuronskim mrežama objavili su *McCulloch i Pitts* (1943.). Oni su koristili vrlo jednostavan model neurona koji, kao i biološki neuron, obrađuje signale putem sinaptičke i somatske operacije. Taj vrlo jednostavan model neurona nazvan je *perceptron*, slika 2. Svaka neuronska mreža sastoji se od ulaznog, skrivenog i izlaznog sloja. Ulazni sloj poprma vrijednosti ulaznih veličina. Sinaptička operacija predstavlja množenje svakog ulaznog signala s težinskim koeficijentom, w_i . Tako otežani ulazni signali se zbrajaju, a njihov zbroj uspoređuje se s pragom osjetljivosti neurona, T_j (engl. *threshold*). Težinski faktori analogni su dendritima biološkog neurona. Skriveni sloj zbraja otežane ulaze pomoću neke funkcije sumiranja i tako stvara vlastitu internu aktivaciju. Ako je zbroj otežanih signala veći od praga osjetljivosti neurona, nelinearna aktivacijska funkcija f generira izlazni signal neurona iznosa b_j . Prijenosna funkcija može biti diskontinuirana skokomična funkcija ili neka kontinuirana funkcija, kao npr. sigmoida ili tangens-hiperbolna funkcija.



Slika 2 – Prikaz perceptrona

Postupak učenja umjetnih neuronskih mreža


Pod učenjem (engl. *learning, training*) podrazumijeva se iterativni postupak podešavanja (optimiranja) vrijednosti težinskih faktora na osnovu pogreške između proračunate vrijednosti modelom i

* Dr. sc. Željka Ujević Andrijić
e-pošta: zujevic@fkit.hr

stvarne vrijednosti mjerene veličine. Učenje, tj. podešavanje težinskih faktora odvija se prema jednom od pravila učenja kao što je tzv. pravilo širenja unatrag ili algoritam unatragne propagacije izlazne pogreške (engl. *back propagation*). Danas, zahvaljujući intenzivnom razvoju teorije i praktične primjene neuronskih mreža, na raspolaganju nam stoje brojne strukture i algoritmi učenja.

Prilikom jednog prolaza informacije kroz neuronsku mrežu generira se vrijednost koja se potom uspoređuje sa stvarnom vrijednošću. Na temelju razlike stvarne i izračunate vrijednosti, korigiraju se težinski faktori.

Korekcijom težinskih faktora neuronska mreža uči predviđati stvarne vrijednosti te se smanjuje razlika stvarnih i predviđenih vrijednosti izlaznih veličina. Kriterij pogreške govori o kvaliteti i robusnosti (generalizaciji) mreže. Provjerom mreže na novom skupu podataka – skupu za provjeru, sprječava se “pretreniranje” (engl. *overfitting*) mreže prilikom učenja. Pretreniranje se javlja kad mreža s visokom točnošću opisuje vladanje podataka na skupu podataka na kojem je razvijana, dok izvan tog skupa pokazuje lošije rezultate. Na slici 3 prikazana je ovisnost pogreške učenja (engl. *training error*) i pogreške provjere (engl. *testing error*) o broju iteracija učenja. Prije točke minimuma pogreške provjere smanjuju se obje pogreške, dok nakon te točke pogreška učenja i dalje pada, ali pogreška provjere raste, što je pokazatelj pretreniranja neuronske mreže. Kako bi se to spriječilo, učenje neuronskih mreža treba se zaustaviti u trenutku kada pogreška provjere počne rasti.



Slika 3 – Prikaz učenja neuronske mreže s tehnikom ranog zaustavljanja (engl. *early stopping*)

Podjela neuronskih mreža

Zbog velikog broja vrsta neuronskih mreža teško ih je sustavno klasificirati. Sa strukturnog gledišta neuronske mreže dijele se na statičke unaprijedne (engl. *feedforward*) i dinamičke (povratne, engl. *feedback*), ovisno o modelu neurona od kojeg su građene te po načinu prostiranja signala kroz mrežu. Za primjenu u identificiranju i vođenju nelinearnih dinamičkih procesa najčešće se rabe višeslojne statičke neuronske mreže. Od dinamičkih neuronskih mreža uglavnom se rabe višeslojne neuronske mreže s elementima zadržke (engl. *time delay neural networks*). Kao zasebne strukture izdvajaju se neizrazite neuronske mreže (engl. *fuzzy neural networks*). U okviru *BigData* platformi razvijaju se neuronske mreže koje imaju po nekoliko stotina skrivenih slojeva, što se danas naziva duboko učenje (engl. *deep learning*).

Koraci pri razvoju neuronske mreže kod identificiranja procesa

Pri modeliranju određenog složenog procesa potrebno je najprije istražiti mogućnost primjene fizikalnog modela procesa. Ako nismo u mogućnosti u cijelosti razviti fizikalni model za određenu primjenu, treba potražiti druge mogućnosti.

Identificiranje procesa pomoću neuronskih mreža na temelju ulazno-izlaznih podataka dobivenih eksperimentalno u načelu obuhvaća sljedeće korake:

• Planiranje i provedba eksperimenta

Ako podatci za razvoj modela nisu već dostupni, potrebno je provesti planiranje eksperimenta. Planiranje eksperimenta važan je korak s obzirom da je potrebno donijeti odluku o vrsti i veličini ulaznih promjena, radnom području, veličini promjena ulaza, itd. Pri tome treba paziti da se ne utječe na kvalitetu produkta jer se ispitivanja odvijaju tijekom rada na postojećem procesu. Stoga treba obratiti pozornost na to koliko ulazi mogu varirati, a da se istodobno ulazne varijable mijenjaju dovoljno da bi dale dovoljno informacija o dinamičkom vladanju procesa.

• Prikupljanje i obrada podataka

Kemijska postrojenja općenito su karakterizirana velikim vremenskim konstantama i vremenskim zadržkama, pa vrijeme za postizanje ustaljenog stanja može biti reda veličine više sati, a eksperimentiranje na procesu može potrajati kontinuirano nekoliko dana. Podatke dobivene iz procesa potrebno je filtrirati da bi se uklonile smetnje karakteristične za realna mjerenja kao i ekstremne vrijednosti (engl. *outliers*) što se javljaju zbog mjernih pogrešaka.

• Odabir strukture modela neuronske mreže

Za razliku od tradicionalnih metoda identificiranja, neuronska mreža ne zahtijeva eksplicitno definiranje funkcije. Potrebno je specificirati samo topologiju mreže. Specifikacija obuhvaća broj neurona u ulaznom, skrivenom i izlaznom sloju mreže. Broj neurona u ulaznom i izlaznom sloju određuje se prema broju ulaznih i izlaznih varijabli u procesu. Broj neurona u skrivenom sloju obično se određuje postupkom “pokušaja i pogreške”. Pri dinamičkom modeliranju, uzimaju se prošle vrijednosti ulaza i izlaza. Broj prošlih vrijednosti ulaza ovisi o zadržci i dinamici procesa, dok broj prošlih vrijednosti izlaza određuje red veličine procesa.

• Učenje neuronske mreže i vrednovanje modela

U svrhu razvoja modela, eksperimentalni podatci se dijele u tri skupa: skup za učenje, skup za provjeru i skup za testiranje. Podatci iz skupa za učenje stavljaju se u mrežu, a težinski koeficijenti se kontinuirano računaju dok se pogreška mreže minimizira. Na kraju jedne iteracije, mreža predviđa vrijednosti na skupu za provjeru. Proces se ponavlja sve dok pogreška na skupu za provjeru ne bude manja od specificiranog odstupanja ili je dosegnut maksimalni broj iteracija. Za konačnu provjeru modela rabi se treći skup podataka – skup za testiranje. Ako sposobnost predviđanja s tim skupom nije zadovoljavajuća, onda se struktura modela može izmijeniti promjenom broja skrivenih neurona, promjenom broja prošlih vrijednosti ulaza i/ili izlaza ili promjenom aktivacijske funkcije.

Primjena neuronskih mreža

Kako su u kemijskom inženjerstvu funkcionalni odnosi između varijabli pretežno nelinearni, neuronske mreže nalaze veliku primjenu. Primjenjuju se kod modeliranja procesa za predviđanje budućeg vladanja procesa i u sklopu naprednog vođenja procesa, te u dijagnostici stanja pri radu procesa i strojeva. U metodama strojnog učenja neuronske mreže se dosta primjenjuju za klasifikaciju: prepoznavanje slika, govora, prevodjenje, analiza društvenih mreža, inteligentno internetsko pretraživanje, ciljani marketing i sl. I na kraju važno je naglasiti da je s obzirom na strukturu crne kutije (*black-box*) neuronskih mreža izrazito važno razumjeti i interpretirati dobivene rezultate u skladu s domenskim znanjem.

Literatura

1. D. R. Baughman, Y. A. Liu, Neural networks in Bioprocessing and Chemical Engineering, Academic Press, 1995.
2. G. Galinec, Razvoj softverskih senzora za identificiranje i inferencijsko vođenje rafinerijskih procesa, disertacija, FKIT Sveučilište u Zagrebu, Zagreb, 2010.
3. N. Bolf, I. Jerbić, Primjena umjetnih neuronskih mreža pri identificiranju i vođenju procesa, Kem. Ind. (2006).
4. <http://eris.foi.hr/11neuronske/>, Fakultet organizacije i informatike, Sveučilište u Zagrebu.