

Nela Zavaljevski, Ljiljana Kostić
Institut za nuklearne nauke "Vinča"

ODREDJIVANJE KONSTANTE SLABLJENJA PROMPTNIH NEUTRONA KORIŠĆENJEM NEURALNE MREŽE

ESTIMATION OF PROMPT NEUTRON DECAY CONSTANT USING NEURAL NETWORK

Sadržaj - Razvijena je bekpropagaciona neuralna mreža za identifikaciju konstante slabljenja promptnih neutrona na nultom teškovodnom RB reaktoru. Mreža je trenirana i testirana eksperimentalnim vrednostima neutronskega šuma da bi se kasnije korištila za odredjivanje osnovnog moda slabljenja promptnih neutrona za različite nivoje potkritičnosti.

Abstract - A backpropagation neural network for identifying fundamental prompt neutron decay constant at zero power heavy water RB reactor was evaluated. The network was trained and tested on experimental neutron noise data. It was then used to predict first decay mode for different reactor conditions.

1. Uvod

Kontinualno praćenje rada i donošenje pravih odluka u kritičnim trenucima zahteva od osoblja elektrane manipulisanje velikim brojem numeričkih, simboličkih i kvantitativnih informacija, čak i u toku rutinskog rada elektrane. Veliki broj procesnih parametara i sistemskih interakcija stvara teškoće operatorima, naročito u vreme abnormanih situacija ili oštećenja. U takvim situacijama, pojedinci su katkad pod stresom ili emocijama što može s promenljivim uticajem da utiče na njihove odluke. Real-time dijagnostikom postiglo bi se medjutim, izbegavanjem grešaka koje mogu da dovedu do praznog hoda ili većih oštećenja, eliminisanje nepouzdanosti i tako stvorio potencijal za povećanje raspoloživosti, pouzdanosti i sigurnosti elektrane. Tehnologija neuralnih mreža koja je u fazi nastajanja nudi mogućnost real-time praćenja rada i dijagnostike nuklearne elektrane.

Mreža veštačkih neurona (ili neuralna mreža) je procesni sistem, sastavljen od jednostavnih, međusobno jako povezanih procesnih elemenata, inspirisan načinom funkcionisanja mozga. Neuralne mreže su sposobne da obavljaju aktivnosti koje ljudi ili životinje dobro rade a koje konvencionalni računari obično rade slabo. Neuralne mreže obavljaju ono što je teško postići korišćenjem drugih poznatih tehnologija. One mogu da prepoznaju oblike, čak i kada je informacija, koja se na njih odnosi, zagadjena šumom ili nekompletna.

Možda je najvažnija karakteristika neuralnih mreža njihova sposobnost da modeliraju procese i sisteme na osnovu aktuelnih

podataka. Neuralnoj mreži se dostavljaju podaci na kojima se ona "vežba" da odredi ulaz-izlaz vezu procesa ili sistema. One poseduju sposobnost da u realnom vremenu, na osnovu kontinualnih senzorskih ulaza, odgovore na promene stanja sistema.

Da bi se sagledale realne mogućnosti nove tehnologije u nuklearnoj energetici razvijena je odgovarajuća bekpropagaciona neuralna mreža korišćenjem raspoloživih eksperimentalnih podataka.

2. Bekpropagaciona višeslojna neuralna mreža

Bekpropagaciona mreža (BPM) je višeslojna potpuno povezana heteroasocijativna neuralna mreža. BPM algoritam računa težine između parova procesnih elemenata tako da razlika između stvarnog i željenog izlaza mreže bude minimalna u smislu najmanjih kvadrata. Opšte delta pravilo [4] se koristi za izračunavanje greške između stvarnog i željenog izlaza kao i za generisanje težinski podešenih koeficijenata. Osnovni algoritam su prvi diskutovali Rumelhart i McClelland [1].

BPM je potpuno povezana mreža kod koje je svaki neuron povezan sa svakim neuronom susednog ali ne i istog sloja. Za vreme treninga informacija se prenosi u direktnom smeru od ulaznog do izlaznog sloja a greška u obrnutom smeru pri čemu dolazi do podešavanja težina. Treningom se postiže modifikacija težina sve dok se greška ne smanji do prihvatljivog nivoa.

Jedan od zahteva BPM algoritma je normalizacija trening podataka na opseg (0 - 1). Algoritam razvijen za WAX računarski sistem vrši automatski tu normalizaciju. Da bi se minimizirala numerička greška, normalizacija se vrši pre treninga.

Jedan primer višeslojne neuralne mreže je prikazan na slici 1. Njena arhitektura obuhvata jedan ulazni, jedan izlazni i jedan skriveni sloj. Prvi sloj prima ulaz, modifikuje ga koristeći set težina i prenosi ga skrivenom sloju. Skriveni sloj prenosi modifikovane ulaze izlaznom sloju gde se računa ukupna greška. Skriveni sloj se obično koristi za predstavljanje nelinearnih karakteristika podataka i njegova veličina zavisi od kompleksnosti problema. Mada je određivanje veličine skrivenog sloja još uvek vrsta umetnosti, napravljeno je nekoliko studija koje sugeriraju empiričke formule za računanje dimenzija skrivenog sloja [2].

Uloga skrivenog sloja je fundamentalne prirode. Mreža bez skrivenih jedinica, (t.j., bez sposobnosti za internim predstavljanjem) neće biti u stanju da izvrši potreban preobražaj ulaznih oblika u izlazne.

Procesna jedinica (PJ) je osnovna konstruktivna jedinica mreže i prikazana je na slici 2. PJ sumira proizvode ulaza i odgovarajućih težina veza sa prethodnim slojem a zatim primenjuje sigmoid aktivacionu funkciju f u kojoj je definisan prag. Vrednost praga može da se odabere, baš kao i druge težine procesne jedinice, da bude uvek jednaka 1.

Ako X_j^i predstavlja stanje jedinice j sloja i, a w_{hk}^i težinu između jedinice k sloja i jedinice h susednog sloja i+1, dobijamo sledeće relacije koje definišu stanje svake jedinice u odnosu na težine i ulazne jedinice:

$$X_h^i = f(A_h^i) \quad A_h^{i+1} = \sum_{j=1}^{N_i} w_{hj}^i \cdot X_j^i \quad (1)$$

Na osnovu seta primera, učenje mreže se sastoji u modifikaciji

težina da bi se minimizirala objektivna funkcija u odnosu na set primera koji će biti predstavljeni mreži. Ako o predstavlja izlazni sloj, objektivna funkcija je kvadrat razlike izmedju izlaznog vektora X^o mreže i željenog vektora Y za 1-ti primer. Sa N_o , broj jedinica izlaznog sloja, tj., ista dimenzija izlaznog vektora Y , možemo da dobijemo za svaki p-ti primer, p-ti deo funkcije greške

$$E_p = \sum_{j=1}^{N_o} (X_j^o - Y_j)^2 \quad (2)$$

Za modifikaciju težina se koristi Widrow-Hoff zakon tj., modifikacija težina se definiše i primenjuje na svaki primer. Promene se definišu gradijentnim metodom. Tako, npr., kada se p-ti primer prezentira mreži, dobija se sledeća relacija koja definiše promene sinaptičkih težina:

$$\Delta W_{hk}^i = -\eta \cdot \frac{\partial E_p}{\partial W_{hk}^i} \quad (3)$$

Pad gradijenta zahteva preduzimanje infinitezimalnih koraka. Konstanta proporcionalnosti η je brzina učenja. Praktične primene zahtevaju da brzina učenja bude što je moguće veća i bez oscilacija. Metod koji je predložio Rumelhart za povećanje brzine učenja obuhvata uključenje momentnog člana koji filtrira visokofrekventne varijacije greške u težinskom prostoru:

$$\delta W_{hk}^i(n+1) = -\eta \cdot \Delta W_{hk}^i + \beta \cdot \delta W_{hk}^i(n) \quad (4)$$

n označava broj prezentacija a β je momentna konstanta koja određuje uticaj prethodnih promena težina na trenutni smer promena u težinskom prostoru, analogno konjugovanim gradijentnim metodama.

Tako, cilj bekpropagacionog algoritma je definisanje parcijalnih izvoda E_p saglasno sinaptičkim težinama:

$$\frac{\partial E_p}{\partial W_{hk}^i} = \frac{\partial E_p}{\partial A_h^{i+1}} \cdot \frac{\partial A_h^{i+1}}{\partial W_{hk}^i} = \frac{\partial E_p}{\partial A_h^{i+1}} \cdot X_k^i \quad (5)$$

Sledećom notacijom:

$$D_h^{i+1} = \frac{\partial E_p}{\partial A_h^{i+1}} \quad (6)$$

se na kraju dobija:

$$\Delta W_{hk}^i = D_h^{i+1} \cdot X_k^i \quad (7)$$

Članovi D_h^{i+1} su definisani na sledeći način:

$$D_h^i = \sum_{j=1}^{N_{i+1}} \frac{\partial E_p}{\partial A_j^{i+1}} \cdot \frac{\partial A_j^{i+1}}{\partial A_h^i} = \sum_{j=1}^{N_{i+1}} D_j^{i+1} \cdot \frac{\partial A_j^{i+1}}{\partial A_h^i} \quad (8)$$

Pošto članovi D_h^{i+1} sloja i zavise od D_h^{i+1} prethodnog sloja $i+1$, ovaj algoritam je bekpropagacioni od izlaznog do ulaznog sloja.

$$\frac{\partial A_j^{i+1}}{\partial A_h^i} = \frac{\partial A_j^{i+1}}{\partial f(A_h^i)} \cdot \frac{\partial f(A_h^i)}{\partial A_h^i} = \frac{\partial A_j^{i+1}}{\partial f(A_h^i)} \cdot f'(A_h^i) \quad (9)$$

Iz relacije:

$$\frac{\partial A_h^{i+1}}{\partial f(A_h^i)} = W_{jh}^i \quad (10)$$

se dobija:

$$D_h^i = \sum_{j=1}^{N_{j+1}} D_j^{i+1} \cdot W_{jh}^i \cdot f'(A_h^i) \quad (11)$$

Ovaj BPM postupak, koji koristi silazni gradijent za pronalaženje minimuma zbirne kvadratne funkcije greške, čine dva koraka. U prvom koraku, ulazi se prezentiraju mreži i prostiru kroz nju u direktnom smeru da bi se na kraju izračunala izlazna vrednost za svaku jedinicu. Zatim se izlazi uporedjuju sa etalon vrednostima, rezultat čega je signal greške za svaku izlaznu jedinicu. Da bi se definisale odgovarajuće promene težina, drugi korak predstavlja obrnuti prolaz kroz mrežu.

3. Odredjivanje konstante slabljenja promptnih neutrona

Za odredjivanje osnovnog moda slabljenja promptnih neutrona u teškovodnom nultom reaktoru RB razvijena je troslojna bekpropagaciona neuralna mreža. Ulazni sloj mreže čini 20 ulaznih nodova, svaki povezan sa po jednom vrednošću vremenski zavisne eksperimentalno odredjene autokorelaceione funkcije. Skriveni sloj se sastoji iz 10 novdova a izlazni sloj ima samo jednu izlaznu vrednost, konstantu slabljenja.

Vremenske fluktuacije neutronskog fluksa su merene na različitim potkritičnim nivoima [5]. Konfiguracija reaktora RB sa 52 gorivna elementa od 2 % urana koraka rešetke 8/2 odabrana je za merenje. Za postizanje stacionarnog stanja na potkritičnom nivou korišćen je Am-a-Be neutronski izvor, zbog malog γ fona. Merna instrumentacija je prikazana na slici 3. Za akviziciju statističkih fluktuacija korišćen je višekanalni vremenski analizator sa 8K kanala memorije. Po završetku akvizicije podaci se prebacuju u računar VAX-8250 gde se vrši njihova dalja obrada. Širina kanala analizatora je iznosila 5 msec i odabrana je kao kompromis izmedju potrebe da autokorelaceiona funkcija bude što tačnije odredjena i da se dobije dovoljan broj impulsa (broj impulsa je mali zbog slabog intenziteta Am-a-Be izvora), kako bi se smanjila statistička greška merenja. Zadovoljavajuća statistička tačnost je postizana ponavljanjem merenja na svakom nivou teške vode 15-20 puta. Merenja su vršena na nivoima teške vode od 115-121 cm u koracima od 1 cm. Za datu konfiguraciju teške vode je iznosio 122.17 cm. Autokorelaceione funkcije su računate za svaki set podataka korišćenjem programskog paketa AUTOCOR, bilo direktno bilo korišćenjem postupka brze Furijeove transformacije (FFT).

Za obučavanje mreže korišćen je set od 15 tako odredjenih vremenski zavisnih autokorelacionih funkcija u 20 vremenskih tačaka. Ostalih 15 autokorelacionih funkcija je korišćeno za interpolaciju

a vrednosti.

Dobijeni rezultati uporedjeni sa teorijskim vrednostima i rezultatima drugih alternativnih eksperimentalnih metoda su prikazani u donjoj tabeli.

Tabela 1. Poredjenje a vrednosti

Teorijsko predviđanje	Feynmann-ova metoda	ARMA (1,1) model	Neuralna mreža
37.75	30.53	23.49	36.15
33.62	29.27	20.11	31.03

Poredjenje pokazuje da su vrednosti dobijene korišćenjem neuralne mreže suštinski ekvivalentne rezultatima drugih alternativnih metoda a možda i superiornije.

4. Zaključak

Jasno je da neuralne mreže nude interesantno i produktivno sredstvo u odnosu na mnoge probleme koji se javljaju u nuklearnim elektranama. Nada je sve još uvek u početnoj fazi, prvi rezultati su ohrabrujući i pokazuju da ove tehnike mogu da se koriste za poboljšanje performansi i sigurnosti nuklearnih elektrana.

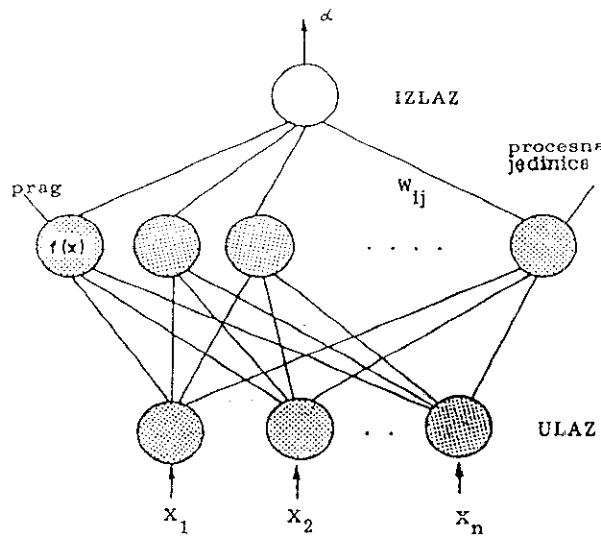
Za procenu parametara, neuralne mreže poseduju prednost u poredjenju sa tradicionalnim empiričkim modelima. Nije potrebno definisati funkcionalni oblik koji povezuje set promenljivih. Do izvesnog stepena na neuralne mreže ne utiče prisustvo štetnog šuma.

U nekim slučajevima neuralne mreže mogu da budu podesnije za identifikaciju parametara od konvencionalnih metoda a da se tom prilikom dobije ekvivalentna tačnost. Sa računarskog stanovišta takođe može da bude efikasnije koristiti neuralne mreže za obezbeđenje početnih procena parametara za konvencionalne metode identifikacije parametara.

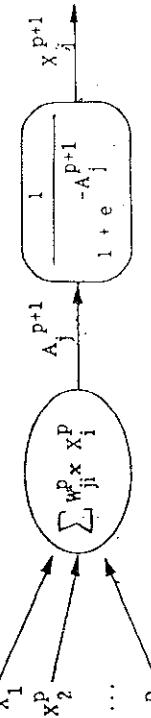
Broj skrivenih slojeva treba minimizirati u slučaju primene neuraine mreže na identifikaciju parametara i može se očekivati da će mreže sa raznolikim linearno zavisnim prenosnim funkcijama biti korisnije za identifikaciju parametara nego one sa samo sigmoid funkcijama.

References

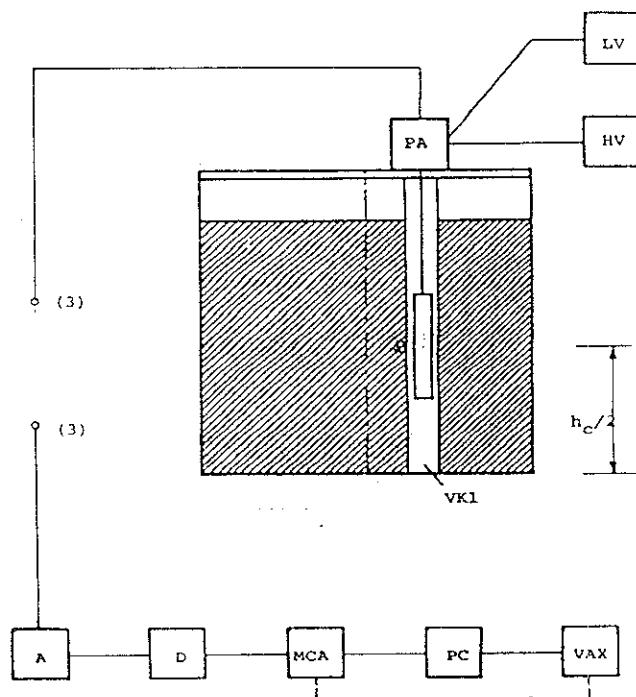
- [1] Lippmann, R. P.: "An Introduction to Computing with Neural Networks", IEEE ASSP Magazine, Vol. 4, No 2, pp. 2-22, 1987
- [2] Rumelhart, D. E., Mc Clelland, J. L.: "Parallel Distributed Processing", MIT Press, 1986
- [3] Kryter, R. C.: "Nuclear Reactor Surveillance and Diagnostics", OECD Nuclear Energy Agency, Vol. 2, 1991
- [4] Stanley, J.: "Introduction to Neural Networks", California Scientific Software, Sierra Madre, CA 91024, 1989, USA
- [5] N. Zavaljevski et al.: "Određivanje kinetičkih parametara reaktora RB statističkim metodama", XXXIII Jugoslovenska konf. ETAN-a, IX sveska, str. IX.42-IX.55, Novi Sad, 1989



Sl. 1. Tro-slojna neuralna mreža



Sl. 2. Procesna jedinica



Sl. 3. Merna instrumentacija

- B - detektor BF_3
- LV - izvor niskog napona
- HV - izvor visokog napona
- PA - prepojačavač
- A - pojačavač
- D - diskriminator
- MCA - višekanalni analizator
- PC - personalni računar
- VAX - VAX-8250