

DAUGIASLUOKSNIS ELEKTROS APKROVOS NEUROMODELIS

A.Navickas, G.Svinkūnas

Kauno technologijos universitetas

Energetinės sistemos darbo ekonomiškumas labai priklauso nuo elektrinių darbo režimo. Norint optimaliai paskirstyti apkrovą tarp šiluminių ir atominių elektrinių, negalinčių greitai keisti atiduodamos galios, būtina prognozuoti keleto parų apkrovą. Kad galima būtų prognozuoti reikia sudaryti apkrovos modelį, kuris kiek galima tiksliau aprašytų apkrovos grafiką. Prognozuojama dažniausiai dekompozicijos ir autoregresijos metodais.

Apkrovos dekompozicijos metodu nustatoma, kaip sistemos apkrova priklauso nuo energijos vartotojų kiekio ir galios, meteorologinių sąlygų, neplanuotų įvykių (televizijos laidos, streikai), atsitiktinių nežinomų veiksnių [6].

Apkrovos modelis bet kuriuo laiko momentu t atrodo taip:

$$P(t) = B(t) + Q(T) + Z(v) + S(t) + V(t); \quad (1)$$

čia $P(t)$ – apkrova momentu t ; $B(t)$ – bazinė apkrova; $Q(T)$ – temperatūrinė dedamoji; $Z(v)$ – vėjo greičio dedamoji; $B(t)$ – bazinė apkrova; $S(t)$ – neplanuotų įvykių dedamoji; $V(t)$ – atsitiktinė apkrovos dedamoji; T – aplinkos temperatūra; v – vėjo greitis.

Atskirų dedamųjų įtaka nustatoma tiriant statistinius duomenis. Modelis vaizdžiai parodo apkrovos ir ją sąlygojančių veiksnių priklausomybę, tačiau jam sudaryti reikia daugelio duomenų ir detalios jų analizės. Modelio struktūra priklausys nuo prognozuojamo regiono klimatinės sąlygų ir buitinių-ekonominių veiksnių, todėl negalima tiesiogiai naudotis kitų regionų patirtimi. Pradiname tyrimų etape sunku net apytiksliai nustatyti atskirų dedamųjų matematines išraiškas, modelį sunku adaptuoti prie kintamų sąlygų. Darant prognozės modelį, kartu reikia prognozuoti ir meteorologines sąlygas.

Autoregresiniais modeliais procesas aprašomas atsižvelgiant į praėjusias proceso reikšmes [1]. Modelio išraiška laiko momentu t yra tokia:

$$K^d(t) = \Phi_1 K^d(t-1) + \dots + \Phi_p K^d(t-p) + v(t) - \Theta_1 v(t-1) - \dots - \Theta_g v(t-g); \quad (2)$$

čia $K^d(t) = P(t) - P(t-d)$ – eilutės narių, nutolusių per laiko intervalą d tarpusavio skirtumai; $\Phi_1 - \Phi_p$ – regresijos koeficientai; $v(t)$ – eilutės narių atsitiktinė dedamoji; $\Theta_1 - \Theta_g$ – atsitiktinės dedamosios regresijos koeficientai; p – regresijos koeficientų skaičius; g – atsitiktinės dedamosios narių skaičius.

Modelis parodo praėjusių proceso reikšmių įtaką esamai reikšmei ir tiksliai matematiškai išreiškia jų tarpusavio priklausomybę. Informacija apie meteorologines sąlygas netiesioginiu būdu gaunama su proceso reikšmėmis, dėl to prognozės tikslumas ilgesniam laikui mažesnis.

Apkrovos modelį galima sudaryti panaudojus dirbtinių neuronų tinklus [2], [3], [4]. Dirbtinių neuronų tinklai (DNT) apdoroja duomenis ir savo struktūra prisitaiko prie jų. Adaptavęsis neuronų tinklas yra uždavinio sprendinys, nes jo perdavimo funkcija atitinka duomenų tarpusavio priklausomybes. Tokiu atveju nereikia duomenų analizės, būtinos dekompozicijai, ir galima sudaryti priklausomybę tarp bet kurių duomenų grupių, ko negalima padaryti autoregresijos metodu, be to, modelį lengva adaptuoti duomenims keičiantis. Šio darbo tikslas – nustatyti DNT įėjimų skaičių, paslėptųjų neuronų skaičių ir mokymo duomenų kiekį atsižvelgiant į konkrečias uždavinio sąlygas, taip pat ištirti, kokių tikslumu galima modeliuoti elektros apkrovą.

Modelio bendroji išraiška artima autoregresiniam modeliui (2), tačiau į jį įtraukti papildomi nariai:

$$P(t) = f[P(t-1); \dots; P(t-k); \dots; P(t-n); \dots; P(t-n-k), T(t), \dots, T(t-k)] \quad (3)$$

čia t – laikas, h ; P – apkrova; T – temperatūra momentu t ; n – proceso periodas; k – vieno grafiko periodo reikšmių skaičius.

Ar reikia atsižvelgti į temperatūrą ir kitus veiksnius, priklauso nuo to, kokiam laikui progno-

zuojama. Šiuo atveju prognozuojama vienai valandai. Per tą laiką temperatūros pokyčiai didesnės įtakos apkrovai nepadarė, ir jų galima nepaisyti.

Bet kuriam uždaviniui išspręsti pakanka dviejų sluoksnių neuronų tinklo. Jo perdavimo funkcija yra tokia:

$$\|y_2\| = f_2[\|w_2\| f_1(\|x\| \|w_1\|)]; \quad (4)$$

čia $\|x\|$ – įėjimo reikšmių matrica; $\|w_1\|$ – pirmojo sluoksniu svorio koeficientų matrica; $\|w_2\|$ – antrojo sluoksniu svorio koeficientų matrica; $\|y_2\|$ – išėjimo reikšmių matrica; f_1, f_2 – neuronų tinklo funkcijos.

Parentant šio modelio įėjimų skaičių reikia sudaryti apkrovos grafiko reikšmių autokoreliacijos funkciją. Įėjimams naudojamos tos apkrovų reikšmės, kurių autokoreliacijos koeficientai didžiausi. Pagal tai parenkami parametrai k ir n . Ieškant optimalios tinklo architektūros reikia pamokyti keletą skirtingų neuronų tinklų struktūrų ir iš jų išrinkti tą, kuri aproksimuoja su mažiausia paklaida. Taip pat būtina nustatyti optimalų DNT apmokymo duomenų imties ilgį, nes lėti proceso vidurkio ir dispersijos pokyčiai gali padidinti modelio paklaidą. Patogiausia keisti mokymo imties ilgį ir paslėptąjo sluoksniu neuronų skaičių minimizuojant tinklo testavimo paklaidą. Tinklą mokome Levenbergo ir Makvardo metodu (jame panaudotas Niutono ir Rafsono metodas netiesinėms lygčių sistemoms spręsti), kuris konverguoja greičiau už kitus DNT apmokymo algoritmus.

Modeliui apmokyti buvo panaudoti AB "Lietuvos energija" telematavimo archyvų 1995. 09.01 – 1996.02.29 apkrovos grafiko duomenys.

Atlikus skaičiavimus nustatyta tokia optimali DNT struktūra Lietuvos energetinės sistemos apkrovos grafikui aproksimuoti: aštuoni įėjimai ($k=3, n=24$); nuo 2 iki 4 neuronų paslėptajame sluoksnyje; mokymo imties ilgis $75 \div 100$ reikšmių.

DNT tiksliausiai aproksimuoja kreivę, kai mokymo paklaida apytiksliai lygi testavimo paklaidai. Tinklas buvo mokomas iki 1.5% paklaidos, tačiau testavimo paklaida gaunama 3.02–3.61%. Tolesni tyrimai parodė, kad testavimo paklaida gaunama minimali ir apytiksliai lygi mokymo paklaidai, kai ši yra apie 2.4%. Vadinasi, testavimo ir mokymo paklaidų minimumai nesutampa. Šis reiškinys vadinamas tinklo permokymu. Permokymo reiškinys apsunkina optimalios DNT struktūros paieškos automatizavimą (negalima siekti minimalios mokymo paklaidos). Todėl būtina išsiaiškinti, ar permokymo reiškinį sukelia apkrovos grafiko vidutinės vertės kitimas ir kaip šį reiškinį pašalinti.

DNT apkrovos grafiko vidurkio svyravimų įtaką galima nustatyti, naudojantis (4) formule:

$$\|y_2 + a\| = f_2[\|w_2\| f_1(\|x + a\| \|w_1\|)]; \quad (5)$$

čia a – duomenų grupės poslinkis, $a < \bar{x}$; $\bar{x}$ – apmokymo duomenų vidurkis.

Prognozės modelio paklaida, pakitus apkrovos grafiko vidutinei vertei dydžiu a , yra tokia:

$$\Delta y = \|y_2 + a\| - f_2[\|w_2\| f_1(\|x + a\| \|w_1\|)]; \quad (6)$$

Lygtis pertvarkoma remiantis diferencialo apibrėžimu (funkcija f_2 – tiesinė). Pertvarkius (6) lygtį gaunama tokia paklaidos išraiška:

$$\Delta y = a - \|w_2\| * f_1'(\|x_1\| \|w_1\|) * \|a\| * \|w_1\| \quad (7)$$

čia Δy – paklaida; f_1' – vidinės funkcijos išvestinė.


Iš išraiškos matyti, kad paklaidos vertė priklauso ne tik nuo poslinkio a , bet ir nuo DNT svorių koeficientų matricių $\|w_2\|$ ir $\|w_1\|$ ir nelygi nuliui (jeigu aprašomas procesas stacionarus, autoregresiniam modeliui (2) ši paklaida lygi nuliui). Iš paklaidos išraiškos kokių nors apibendrinančių išvadų apie paklaidos ir poslinkio tarpusavio ryšį padaryti negalima, reikia tirti konkretų atvejį.

Paveiksle parodytos anksčiau nustatytos optimalios DNT struktūros testavimo paklaidų priklausomybės nuo poslinkio a . Paveiksle a) parodyti rezultatai, kai tinklas mokytas naudojant duomenų grupes X ir Y , o testuotas su duomenimis $X+a$ ir $Y+a$. Tinklo mokymo vidutinė kvadratinė paklaida 2.1%. Testavimo paklaidos gaunamos daug didesnės už apmokymo ir kinta nuo 2.5 iki 25.0%. Šiuo atveju dėl poslinkio testavimo paklaidos labai padidėjo.

Iš paveikslo b) matyti, kad tinklo mokymo ir testavimo duomenys yra masyvai, sudaryti iš dviejų duomenų grupių sąjungos $X \cup X+a/3$ ir $Y \cup Y+a/3$. Tinklas testuojamas su duomenimis $X+a$ ir $Y+a$, paklaida gaunama mažesnė negu ankstesniu atveju (1.9÷6.0%), bet padidėjo mokymo paklaida (2.4 %). Papildomai perslinkta duomenų grupė $X+a/3$ sumažino tinklo testavimo paklaidą.

Iš paveikslo c) matyti, kad tinklas mokomas su $X \cup X+2a$ ir $Y \cup Y+2a$ duomenų grupėmis, testuojamas su $X+a$ ir $Y+a$ duomenimis. Mokymo paklaida 3.01%, testavimo paklaida kinta nuo 1.6% iki 2.6%.

Iš šių skaičiavimų matyti, kad papildomų duomenų grupės sumažina paklaidas, atsirandančias dėl grafiko vidurkio svyravimų, ir padidina mokymo paklaidą, tačiau testavimo paklaida tampa mažesnė už mokymo. Tokiu būdu sudarius mokymo duomenų masyvus galima siekti minimalios mokymo paklaidos. Permokymo reiškinio šiuo atveju nepastebima.



Pav. Testavimo paklaidų priklausomybė nuo duomenų poslinkio α :

- α – testavimo duomenys perslinkti mokymo duomenų atžvilgiu per α ;
 b – tinklo mokymo duomenys yra masyvai $X \cup X + \alpha/3$, tinklas testuotas su duomenimis $X + \alpha$;
 c – tinklas mokytas su $X \cup X + 2\alpha$ duomenų grupėmis, testuotas su $X + \alpha$ duomenimis

Išvados

1. Apkrovai prognozuoti geriausiai tinka dirbtinių neuronų tinklo (DNT) modelis.
2. Tinklo permokymo reiškinį, apsunkinantį optimalios DNT struktūros paiešką, sukelia grafiko vidurkio kitimas.
3. Permokymo reiškiniui pašalinti dalį mokymo duomenų būtina perslinkti vidutinės reišmės atžvilgiu – pridėti ir atimti prie visų duomenų skaičių, mažesni už duomenų vidutinę vertę.
4. Optimali DNT struktūra Lietuvos energetinės sistemos apkrovos grafikui aproksimuoti: aštuoni įėjimai; nuo 2 iki 4 neuronų paslėptajame sluoksnyje; mokymo imties ilgis $75 \div 100$ reikšmių.
5. Vidutinė kvadratinė aproksimavimo paklaida – 2.4%.

Literatūros sąrašas

- [1] М.С.Бернер, И.Унжиков. Оперативный прогноз нагрузки заводского электропотребления. *Промышленная энергетика*, 1981, № 10.
- [2] A.M.Osama, P.C.Dong. Implementation of adaptive neural network short-term electric load forecasting system in the Energy Control Center. *IEEE world congress on computational intelligence*, vol.6, 1994.
- [3] Kwang Y. Lee, Tae-II Choi. Neural network architectures for short-term load forecasting. *IEEE world congress on computational intelligence*, vol.6, 1994.
- [4] A.G.Bakirtzis, J.B.Theocharis. Short term load forecasting using fuzzy neural networks. *IEEE transactions on power systems* vol.10, no 3, August 1995.
- [5] A.Navickas, G.Svinkūnas. Daugiasluoksnis neuromodelis elektros apkrovų charakteristikoms prognozuoti. *Biudžetinio mokslinio darbo BK5-24 ataskaita, KTU, Kaunas*, 1995.
- [6] Atif.s. Debs. Modern Power Systems Control and Operation. London KLUWER ACADEMIC PUBLISHERS, 1988.