

RAZVOJ I REALIZACIJA SISTEMA NADZORA I UPRAVLJANJA TOKOVIMA ENERGENATA U PROCESNOJ INDUSTRIFI – DEO II: NAPREDNE FUNKCIJE DEVELOPMENT AND REALIZATION OF ENERGY MANAGEMENT SYSTEM IN PROCESS INDUSTRY – PART II: ADVANCED FUNCTIONS

Dr Filip KULIĆ, mr Veroslav JANKOVIĆ**, dr Đura OROS*, dr Veran VASIĆ*,

* Fakultet tehničkih nauka, 21000 Novi Sad; Trg Dositeja Obradovića 6

** PRO-ENERGO d.o.o., 21000 Novi Sad, Bulevar Kralja Petra I 28c / IV-13

REZIME

Jedna od specifičnih funkcija sistema energetskog menadžmenta jeste i predikcija potrošnje energenata u cilju pravovremenog reagovanja i sprečavanja neželjenih situacija i havarija. Pored navedenog, predikcija potrošnje omogućava bolje planiranje proizvodnje te smanjenje ukupnih troškova. U ovom radi je prikazan nov i originalan algoritam za predikciju potrošnje energenata baziran na teoriji vektora podrške. Celokupan razvijeni nadzorno upravljački sistem je realizovan i pušten u pogon u fabriku Sojaprotein AD Bečeji.

Ključne reči: tokovi energenata, nadzorno upravljački sistem, procesna industrija, teorija vektora podrške

SUMMARY

One of the specific functions of the energy management system is the prediction of energy consumption for the purpose of the timely reaction to and prevention of undesirable situations. Moreover, the energy consumption prediction enables better planning of the energy production and contributes to the reduction of all production costs. This paper shows a new original algorithm for energy consumption forecasting based on support vector machines. The developed energy management system is realized and it operates in Sojaprotein AD Bečeji, soybean processing factory.

Key words: Energy Flow, Supervisory and Control, Process Industry

UVOD

Pored svih dobrih strana i do sada postignutih rezultata EMIS (Energy Management Information System - EMIS) u svetu, celokupan posao na njihovom razvoju nije završen. Predikcija potrošnje energije kao važan faktor u donošenju odluka još nije po svom kvalitetu na zadovoljavajućem nivou. Prediktorski algoritmi se još razvijaju i testiraju i svakodnevno se pojavljaju nova rešenja. Predikcijom potrošnje je moguće ne samo predvideti potrošnju u cilju upravljanja opterećenjem, smanjenja vršnog opterećenja i kontrole potrošnje energije već je moguće i rano detektovati gubitke koji su posledica havarija na transportnim putevima ili otkriti neispravne uređaje i delove pogona (Petrovački i dr, 2008). Na taj način je moguće sprečiti havarijsko održavanje i zameniti ga preventivnim. Ovim se ne samo postiže ušteda u potrošnji energije već se ušteda proširuje na ceo proizvodni proces i smanjuju ukupni troškovi poslovanja (npr. nema hitnih intervencija, hitne nabavke rezervnih delova, prekovremenog rada ljudi i sl.).

U našoj zemlji se EMIS slabo, odnosno retko primenjuju. Osnovni preduslov za primenu ovakvih sistema jeste postojanje akvizicija podataka iz procesa, pre svega onih koji se odnose na parametre potrošnje energenata a to je u tesnoj vezi sa automatizacijom proizvodnog procesa. Generalno, u našim fabrikama su retki slučajevi računarskih nadzorno-upravljačkih sistema ali se situacija svakodnevno poboljšava. Cene energenata i povećana konkurenca na tržištu zahtevaju od proizvođača da racionalizuju svoju proizvodnju. Najčešći prvi korak u racionalizaciji jeste uvođenje računarske akvizicije i nadzora nad procesom. Jedan od najčešćih sledećih koraka u racionalizaciji, ali i najlakše ostvarivih, jeste smanjenje potrošnje energenata, u prvom redu električne energije. Iz tog razloga mnoga preduzeća počinju sa uvođenjem EMS (Energy Management System) i prvi korak je postavljanje sistema za akviziciju, vizualizaciju i praćenje tokova energenata u proizvodnom procesu. Dobar primer pogona gde je ovakav sistem realizovan jeste Sojaprotein AD Bečeji gde postoji sistem za praćenje tokova energenata (Petrović i dr, 2007) i

koncern „Farmakom“ gde je isti sistem u fazi projektovanja i realizacije. Ipak, navedeni sistemi su samo prva faza pravog EMIS pošto im nedostaju moduli za predikciju potrošnje energije i predlaganje upravljačkih akcija u cilju smanjenja i optimizacije registrovane potrošnje energije.

Komercijalno dostupni sistemi na našem tržištu danas, nemaju module za predikciju potrošnje i upravljanje opterećenjem (bilo u normalnom ili havarijskom režimu), kao i module za post-havarijski oporavak koji određuju redosled uključenja potrošača posle havarijskih isključenja.

U svetu svega prethodno navedenog na našem tržištu je otvoren prostor za namenski softver koji bi vršio predikciju potrošnje energenata, kao i softver za upravljanje opterećenjem na osnovu predviđene potrošnje i trenutnih merenja, odnosno stanja procesa.

Različite tehnike prognoze su primenjivane u cilju povećanja tačnosti i efektivnosti kratkoročne prognoze potrošnje energenata. Većina postojećih metoda kratkoročne prognoze je bazirana: modelima vremenskih serija, neparametarskim regresionim metodama ili na metodama aproksimacije podataka. Prednost ovih modela je jednostavna fizička interpretacija parametara modela. Navedeni modeli su linearni i zbog toga neadekvatni za prepoznavanje visokolinearnih unutrašnjih veza među podacima koji opisuju potrošnju i veza između podataka koji opisuju potrošnju i drugih relevantnih podataka kakvi su temperatura, relativna vlažnost i drugi faktori vezani za okolinu (Živković, 2006). Generalno, tehnike za kratkoročnu prognozu možemo podeliti na tradicionalne i moderne. U praksi su dugo primenjivane tradicionalne statističke tehnike prognoze: regresione (Papalexopoulos et al, 1990), vremenske serije (Hagan and Behr, 1987), prepoznavanje oblika (Dhadashti et al, 1982), Kalmanovi filtri (Toyada et al, 1970) i sl. U okviru savremenih metoda kratkoročne prognoze mesto su našle i, takozvane, metode veštačke inteligencije: neuronske mreže (Dash et al, 1997; Lu, 1993; Papalexopoulos et al, 1994), rasplinuta (fuzzy) logika (Papadakis, 1998), wavelets (Zheng et al, 2000). Ove metode predstavljaju moderne tehnike za prognozu opterećenja.

U okviru ovog rada će detaljnije biti objašnjena primena teorije vektora podrške - TVP (Support Vector Machine - SVM) (Kecman, 1993; Smola and Scholkopf, 1998; Vapnik, 1995) u predikciji potrošnje energije (Lugonja, 2008; Ostojin et al, 2008; Petrujić et al, 2008). TVP je relativno nova teorija i njena primena još nije široko rasprostranjena ali dosadašnji rezultati potvrđuju opravdanost ovakvog pristupa.

TVP predstavlja nelinearnu generalizaciju Generalized Portrait algoritma razvijenog u Rusiji tokom 60-tih godina prošlog veka. Kao takav, ovaj algoritam ima čvrste osnove u okviru statističke teorije učenja ili Vapnik-Chervonenkis (VC) teorije, koja je razvijena u toku poslednje tri decenije (Smola and Scholkopf, 1998; Vapnik, 1995). U osnovi VC teorije je dobra sposobnost generalizacije algoritma obuke (learning machines). U sadašnjoj formi SVM su razvili Vapnik i saradnici. Vladimir Vapnik i njegovi saradnici su TVP metod obuke prvi put predstavili u radu prezentovanom na konferenciji COLT 1992 (Boser et al, 1992). Ipak, svi ovi pojmovi su od ranije bili poznati i korišteni u okviru teorije mašinskog učenja još od 1960-ih (Cover, 1965; Duda and Hart, 1973; Vapnik and Charvonens, 1964; Vapnik and Lerner, 1963). Ipak, tek 1992. su svi ovi rezultati istraživanja sklopljeni u celinu i tako je nastao TVP klasifikator sa maksimalnom marginom u svom osnovnom obliku, da bi 1995 nastala proširena verzija koja je uključila postojanje meke margine (Smola and Scholkopf, 1998).

Neke od primena TVP u rešavanju problema klasifikacije su: prepoznavanje rukom napisane cifre, raspoznavanje oblika, identifikaciju govora, prepoznavanje lica na slikama i kategorizaciju teksta. U slučaju regresije, TVP su primenjene u rešavanju problema predikcije primenom vremenske serije, problem Boston-skih domaćinstava i (na veštački generisanim podacima) na probleme inverzije PET operatora. U većini ovih slučajeva sposobnost generalizacije TVP (tj. veličine greške nad test podacima) ili se podudara ili je značajno bolja nego kod konkurentnih metoda kao što su na primer veštačke neuronske mreže (Ostojin et al, 2008). Iako TVP ima dobru sposobnost generalizacije, one mogu biti spore u test fazi. Noviji radovi generalizuju osnovne ideje pokazujući vezu sa teorijom regulizacije i pokazujući kako ideje TVP mogu biti ugrađene u širok dijapazon drugih algoritama. Takođe, TVP pokazuju dobre rezultate u rešavanju problema kratkoročne prognoze potrošnje električne energije (Ostojin et al, 2008; Petrujić et al, 2008).

MATERIJAL I METOD

Napredne funkcije sistema energetskog menadžmenta – predikcija potrošnje primenom teorije vektora podrške

Teorija Vektora Podrške (TVP) su relativno nov koncept koji je razvijen u okviru statističke teorije učenja, unapređivanjem neuronskih mreža. Na osnovu obučavajućeg skupa, koji se sastoji iz skupa ulaznih i skupa izlaznih podataka, dobija se funkcija razdvajanja (u slučaju klasifikacije) ili regresiona funkcija (u slučaju regresije) (Kecman, 2001). U ovom radu obrađen je problem regresije primenom TVP. Cilj regresije je nalaženje funkcije koja aproksimira ulazno-izlaznu relaciju. U konkretnom slučaju, regresija je bila korištena da se na osnovu merenih podataka izvrši ekstrakcija pravila ponašanja potrošnje energetskog sistema u toku vremena i zatim izvrši predikciju trenda potrošnje u budućnosti.

Neka je dat obučavajući skup (\mathbf{x}_i, y_i) , gde je $\mathbf{x}_i \in R^N$ skup ulaznih i $y_i \in R$ skup izlaznih podataka. Linearna regresiona funkcija je oblika:

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b \quad (1)$$


Koeficijenti \mathbf{w} i b dobijaju se minimizacijom funkcije stvarne greške. Prvi član izraza minimizuje Vaonik-Chervonenkis (VC) dimenziju modela čime se obezbeđuje dobra generalizacija, a drugi član predstavlja grešku aproksimacije:

$$\min_{\mathbf{w}, b} R = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l |y_i - f(\mathbf{x}_i)| \quad (2)$$

Greška aproksimacije je Vapnikova funkcija sa ϵ -zonom neosetljivosti. Ova funkcija definiše zonu (takozvanu ϵ -tubu), unutar koje je greška jednaka nuli, a van koje se greška računa kao udaljenost do oboda tube (sl. 1):

$$|y - f(\mathbf{x})| = \begin{cases} 0, & |y - f(\mathbf{x})| \leq \epsilon \\ |y - f(\mathbf{x})| - \epsilon, & |y - f(\mathbf{x})| > \epsilon \end{cases} \quad (3)$$

Da bi se u matematičkom modelu uzele u obzir i greške, uvođe se dodatni parametri. To su kazneni parametar C koji predstavlja odnos greške obuke i VC dimenzije modela, i relaksirajuće (slack) varijable ξ i ξ^* koje predstavljaju udaljenost podataka van ϵ -tube (sl. 1).



Sl. 1. Aproksimirajuća funkcija, ϵ -tuba i relaksirajuće varijable
Fig. 1. Function approximation, ϵ -tube and slack variable

Za podatke izvan ϵ -tube važi:

$$|y - f(\mathbf{x}, \mathbf{w})| - \epsilon = \xi, \quad (4)$$

odnosno:

$$|y - f(\mathbf{x}, \mathbf{w})| - \epsilon = \xi^* \quad (5)$$

tako da stvarna greška koja se minimizuje može da se izrazi kao:

$$\min_{\mathbf{w}, b} R = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (6)$$

pri čemu moraju biti zadovoljena sledeća ograničenja:

$$y_i - \mathbf{w}^T \mathbf{x}_i + b \leq \epsilon + \xi_i \quad (7)$$

$$\mathbf{w}^T \mathbf{x}_i + b - y_i \leq \epsilon + \xi_i^* \quad (8)$$

$$\xi_i, \xi_i^* \geq 0, i = 1 \dots l. \quad (9)$$

Ovaj problem se rešava formiranjem Lagranžove funkcije postavljanjem Karush-Kuhn-Tucker uslova (KKT) [21]. Na taj način dobija se dualni optimizacioni problem:

$$\begin{aligned} \max_{\alpha, \alpha^*} D(\alpha, \alpha^*) &= -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \mathbf{x}_i^T \mathbf{x}_j \\ &- \epsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \end{aligned} \quad (10)$$

uz sledeća ograničenja:

$$\sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0, \quad (11)$$

$$\alpha_i, \alpha_i^* \in [0, C]. \quad (12)$$

U realnosti je najčešći slučaj u kojem je klase neophodno razdvojiti nelinearnom granicom razdvajanja. Kada je u pitanju ova vrsta problema, do rešenja se dolazi upotrebom kernel trika. Ulagani podaci se nelinearnom funkcijom $\Phi(\mathbf{x})$ prebacuju u visokodimenzionalni prostor karakteristika (feature space) gde su linearno razdvojivi (Vapnik, 1995). U prostoru karakteristika proizvod $\mathbf{x}_i^T \mathbf{x}_j$ postaje $\Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}_j)$. S obzirom da su vektori veoma visokih dimenzija, ovaj proizvod se zamenjuje kernel funkcijom $K(\mathbf{x}_i, \mathbf{x}_j)$, koja omogućava lakše računanje. Primena ovog izraza naziva se kernel trik.

Kada je u pitanju nelinearna regresija, nakon primene kernel trika dualni optimizacioni problem izgleda ovako:

$$\begin{aligned} \max_{\alpha, \alpha^*} D(\alpha, \alpha^*) &= -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) Q_{ij} \\ -\varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \\ \sum_{i=1}^l (\alpha_i - \alpha_i^*) &= 0 \\ \alpha_i, \alpha_i^* &\in [0, C], \end{aligned} \quad (13)$$

gde je $Q_{ij} = \Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}_j) = K(\mathbf{x}_i, \mathbf{x}_j)$ kernel funkcija.

Rešavanjem QP problema iz KKT uslova dobijaju se koeficijenti \mathbf{w} i b (Smola and Scholkopf, 1998). Optimalna regresiona hiperravan je oblika:

$$f(\mathbf{x}) = \mathbf{w}^T \Phi(\mathbf{x}) + b \quad (14)$$

$$f(\mathbf{x}) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \quad (15)$$

Većina Lagranžovih množitelja α i α^* su jednaki nuli. Podaci koji odgovaraju Lagranžovim množiteljima različitim od nule su support vektori. Kao što se vidi, regresiona funkcija je u potpunosti definisana support vektorima i biasom b (Živković, 2006).

REZULTATI I DISKUSIJA

Realizacija predikcije potrošnje električne energije primenom teorije vektora podrške

U procesu obuke korišćeni su podaci dobijeni merenjem parametara električne energije u transformatorskim stanicama TS2, TS3 i TS4 u AD "Sojaprotein" u Bečeju. Merenja su vršena sa uzorkovanjem srednje vrednosti merenih veličina svake minute, u periodu od 27. maja do 1. avgusta 2005. U ovom radu su obrađeni i prikazani rezultati merenja na transformatoru TR1 u transformatorskoj stanci TS2 u periodu od 30. juna do 6. jula 2005. Svi transformatori i frekventni regulatori su bili u normalnom pogonu. Slika 2 prikazuje opremu za merenje i akviziciju podataka instaliranu na mestu merenja u transformatorskoj stanci, dok slika 3 prikazuje električnu šemu merenja. Sedmodnevnim merenjem opterećenja na transformatoru sa periodom uzorkovanja od jedan minut se dobija veliki broj podataka, oko 10000. Za spore procese kao što su procesi u pogonu AD "Sojaprotein" ovo je veoma dobar uzorak. Time je omogućeno da se odabere deo skupa, nad kojim se vrši obučavanje, dok se podaci koji tokom obuke nisu uzeti u obzir koriste prilikom testiranja. Da bi se do-

bio kvalitetan skup za obuku, neophodno je da se obuhvate sve vrste promena u opterećenju, kao i svi periodi - periodi male potrošnje, velike potrošnje i iznenadni skokovi u vrednostima.

Treba primetiti da se merene vrednosti tokom vremena menjaju u skladu sa poremećajima do kojih je dolazilo. Može se videti da je potrošnja manja noću i vikendom. Do naglih skokova u vrednostima dolazi obično u slučaju havarije, što je prikazano na slikama 4 i 5. Ovo je takođe veoma bitno kada se vrši odabir skupa za obuku. Akvizicijom su obuhvaćene karakteristične veličine električne energije - frekvencija mrežnog napona, fazni napon na izvodima niskog napona i njegovo totalno harmonijsko izobličenje, struja faznih i neutralnog provodnika kao i totalno harmonijsko izobličenje faznih struja i snage. Algoritam za predikciju baziran na TVP je obučen i testiran na izmerenim aktivnim snagama.

Algoritam je implementiran u programskom jeziku MATLAB. Sam proces obuke obuhvata sledeće korake:

1. predprocesiranje ulaznih podataka, koje podrazumeva selekciju podataka i skaliranje na opseg [0,1];
2. odabir kernel funkcije i određivanje njenih parametara. U ovom slučaju izabran je Gausov RBF kernel čiji je oblik određen varijansom, $K(\mathbf{x}, \mathbf{x}_k) = \exp(-\|\mathbf{x} - \mathbf{x}_k\|_2^2 / \sigma^2)$;
3. određivanje parametara C (kazneni parametar) i (tačnost aproksimacije),
4. rešavanje QP problema,
5. testiranje dobijenog modela.

Ukoliko model ne zadovoljava zahtevanu tačnost, ponovo se biraju parametri i rešava QP problem sve dok tačnost ne bude zadovoljena.

Nakon završetka obuke algoritam je testiran na on-line podacima. Kao mera tačnosti rada korištena je srednja vrednost greške u procentima (Mean Average Percentage Error – MAPE):

$$MAPE = \frac{1}{n \cdot Inter} \cdot \sum_{d=1}^n \sum_{t=1}^{Inter} R_{aps}(d, t) \quad (16)$$

gde je: n – dužina perioda merenja (predikcije); $Inter$ – dužina intervala između dva susedna merenja; $R_{aps}(d, t)$ – apsolutna vrednost greške.




Sl. 2. Merenje potrošnje električne energije u transformatorskoj stanci

Fig. 2. Electric power consumption measuring in a transformer station


Vršena je predikcija potrošnje u periodima 15[min], 60[min], 12[h] i 24[h]. Rezultati su prikazani na slikama 6-9. Slika 6 prikazuje rezultate predikcije za 15-minutni interval a slika 7 za 60-minutni. Slike 8 i 9 prikazuju rezultate predikcije za 12 i 24-časovni interval. Odgovarajuće vrednosti MAPE su prikazane u tabeli 1. U tabeli 1 se može primetiti da vrednost MAPE opada sa povećanjem dužine intervala predikcije, što je i logično pošto

se na dužem intervalu može bolje „uhvatiti“ trend promene analizirane veličine. Maksimalna vrednost MAPE je zabeležena na 15-minutnom intervalu predikcije i iznosi 0,0221% ili, na izmerenu snagu od 365 kW greška je bila oko 80 W, dok je maksimalna greška na istom intervalu oko 120 W što govori u prilog dobroj obučenosti algoritma.




Sl. 3. Električna šema merenja potrošnje električne energije u transformatorskoj stanicu

Fig. 3. Electric diagram of conducted electric power consumption measuring




Sl. 4. Nedeljni dijagram potrošnje aktivne električne energije za jedan transformator u transformatorskoj stanicu

Fig. 4. Weekly diagram of active power consumption measured for one transformer in transformer station




Sl. 5. Nedeljni dijagram potrošnje reaktivne električne energije za jedan transformator u transformatorskoj stanicu

Fig. 5. Weekly diagram of reactive power consumption measured for one transformer in transformer station




Sl. 6. Predikcija potrošnje električne energije za petnaestominutni interval

Fig. 6. Electric power consumption prediction for 15-minute interval



Sl. 7. Predikcija potrošnje električne energije za jednočasovni interval

Fig. 7. Electric power consumption prediction for 60-minute interval




Sl. 8. Predikcija potrošnje električne energije za dvanaestočasovni interval

Fig. 8. Electric power consumption prediction for 12-hours interval

Tabela 1. Vrednost MAPE za pojedinačne vremenske intervale predikcije

Table 1. MAPE value for single handed prediction time interval

Period predikcije Forecasting period	15 [min]	60 [min]	12 [h]	24 [h]
MAPE [%]	0,0221	0,0194	0,0132	0,0109



Sl. 9. Predikcija potrošnje električne energije za jednodnevni interval

Fig. 9. Electric power consumption prediction for 24-hours interval

ZAKLJUČAK

U ovom radu je prikazan način razvoja i implementacije jedne od naprednih funkcija EMS-a, predikcije potrošnje energije i energetskog menadžmenta. Realizovana funkcija se bazira na regresiji vremenskih serija primenom teorije vektora podrške. Algoritam je testiran i pušten u rad u fabrici Sojaprotein AD Bečeji u okviru njihovog sistema energetskega menadžmenta. Dobijeni rezultati su potvrdili opravdanost navedenog pristupa, tako da ova metoda posredovanog doprinosa ima i veliku praktičnu primenu. U radu je prikazana primena teorije vektora podrške za predikciju potrošnje električne energije ali je ta metodologija potpuno primenljiva i na sve ostale energente i izvore energije, kao i druge vrste i tipove vremenskih serija. Prikazani rezultati su u potpunosti opravdali predloženi pristup rešavanju problema predikcije potrošnje električne energije u industrijskim postrojenjima.

NAPOMENA: Ovaj rad je nastao kao rezultat rada na FP7 projektu iz oblasti Informaciono-komunikacionih tehnologija pod nazivom "PRODI – Power plants Robustification based On fault Detection and Isolation algorithms" ugovor broj 224233 finansiran od strane Evropske Komisije, Generalnog Direktora za Informacionu zajednicu i Mediju.

LITERATURA

- [1] Boser, B.E, Guyon, I, Vapnik V: A Training Algorithm for Optimal Margin Classifiers, Proceedings of the Fifth Annual ACM Conference on Computational Learning Theory (COLT 1992), July 27-29, 1992, Pittsburgh, PA, USA, 1992 p.144-152.
- [2] Bugarski, V, Kulić, F, Jelićić, Z, Vasić, V, Oros, Đ: Konceptacija i realizacija sistema daljinskog nadzora i upravljanja u procesu proizvodnje mineralnih đubriva, PTEP – Časopis za procesnu tehniku i energetiku u poljoprivredi, 11(2007)4, s.187- 190.
- [3] Cover, T.M: Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition, IEEE Transactions on Electronic Computers, (1965)14 p.326-334
- [4] Dash, P.K, Satpathy, H. P, Liew, A.C, Rahman, S: A Real-time Short-Term Load Forecasting System Using Functional Link Network, IEEE Trans. Power Systems, 12 (1997) 2, p.675–680.
- [5] Dhdashti, S, Tudor, J.R, Smith, M.C: Forecasting of Hourly Load By Pattern Recognition: A Deterministic Approach, IEEE Trans. Power Apparatus and Systems, 101 (1982)9, p.3290–3294.
- [6] Duda, R.O, Hart, P.E: Pattern Classification and Scene Analysis, Wiley, NY, USA, 1973, p.654.
- [7] Hagan, M. T, Behr, S.M: The Time Series Approach to Short-Term Load Forecasting, IEEE Trans. Power Systems, 2 (1987)3, p.785–791.
- [8] Karadžić, B: The possibilities of electro-hydraulic control system by the fuzzy controller application (on Serbian), PTEP, Journal on processing and energy in agriculture, 11(2008)3, p. 144-150.
- [9] Kecman, V: Learning and Soft Computing, The MIT Press, New York, USA, 2001, s.557.
- [10] Lu, C.N: Neural Network Based Short Term Load Forecasting, IEEE Trans. on Power Systems, 8 (1993)1, p.336-341
- [11] Lugonja, J, Kulić, F, Francuski, Lj, Janković, V: Prediction of electric power consumption in process industry using support vector machines, CD Proceedings of Regional conference Industrial energetic and environmental protection in countries of Southeast Europe IEEP 2008, 24-27. Jun 2008. Zlatibor, Serbia
- [12] Ostojin, S, Kulić, F, Švenda, G, Bibić, R: Short-Term Electrical Load Forecasting Using Support Vector Machines, Computers and simulation in Modern Science Vol I; Mathematics and Computers in Science Engineering, A Series of Reference Books and Textbooks; WSEAS Press, ISBN: 978-960-474-010-9, 2008, pp.138-142.
- [13] Papadakis, S.E: A Novel Approach to Short-Term Load Forecasting Using Fuzzy Neural Network, IEEE Tran. Power Systems, 13 (1998)2, p.480–492.
- [14] Papalexopoulos, A.D, Hao, S, Peng, T.M: An Implementation of a Neural Network Based Load Forecasting Model for the EMS, IEEE Trans. on Power Systems, 9 (1994)4, p.1956-1962.
- [15] Papalexopoulos, A.D, Hesterberg, T.C: A Regression Based Approach to Short-Term System Load Forecasting, IEEE Transactions on Power Systems, 5 (1990)4, p.1535-1547.
- [16] Petrovački, D, Kulić, F, Jelićić, Z, i saradnici: Primena upravljačko-informacionih tehnologija u poboljšanju procesa upravljanja energetskim sistemima - konačni izveštaj o istraživanju, Nacionalni program energetske efikasnosti, projekat broj NPEE 232020, FTN, Novi Sad, jun 2008.
- [17] Petrović, M, Đukanović, D, Urošević, D: Energetski bilans fabrike "Sojaprotein" A.D. Bečeji, Mašinski fakultet, Beograd, 2007.
- [18] Petrujić, M, Jelićić, Z, Kulić, F, Papić, O: Electric Power Consumption Prediction in Oil Production Using Support Vector Machines, CD Proceedings of Regional conference Industrial energetic and environmental protection in countries of Southeast Europe IEEP 2008, 24-27. Jun 2008. Zlatibor, Serbia
- [19] Smola, A.J, Schölkopf, B: A Tutorial on Support Vector Regression, NeuroCOLT2 Technical Report Series NC2-TR-1998-030, Berlin, Germany, 1998, p.71.
- [20] Toyoda, J, Chen, M, Inoue, Y: An Application of State Estimation to Short-Term Load Forecasting, I and II," IEEE Trans. on Power Systems, (1970)89 p.1678–1688.
- [21] Vapnik, V, Chervonenkis, A: A note on one class of perceptrons, Automation and Remote Control (1964)25 p.838-845.
- [22] Vapnik, V, Lerner, A: Pattern recognition using general portrait method, Automation and Remote Control, (1963)24, p.774-780
- [23] Vapnik, V.N: The Nature of Statistical Learning Theory, Springer New York, 1995, s.238.
- [24] Zheng, T, Grgić, A.A, Makram, E.B: A Hybrid Wavelet-Kalman Filter Method for Load Forecasting, Electric Power Systems Research, 54 (2000)1, p.11–17.
- [25] Živković, S: Primena Support vector machines u predikciji potrošnje električne energije, Magistarska teza, FTN, Novi Sad, 2006, p.91.

Received: 08.07.2009.

Accepted: 28.08.2009.