

ბიზნეს-ინჟინერინგი ენერგეტიკაში

ბიზნეს-ინჟინერინგის პრინციპებით ელექტროენერგეტიკული სისტემის ოპტიმალური მართვის უზრუნველსაყოფად ელექტროენერგიის მოხმარების მოკლევადიანი პროგნოზირება

დავით ჯაფარიძე, სტუ-ს სრული პროფესორი
თენგიზ მაღრაძე, სტუ-ს დოქტორანტი

XX

ცნობილია, რომ ბიზნეს-ინჟინერინგის ქვაკუთხედს მართვისადმი პროცესული მიდგომა წარმოადგენს [17]. ამ თვალსაზრისით ნებისმიერი ორგანიზაცია შეიძლება განვიხილოთ როგორც პროცესების კრებში. პროცესის ოპტიმალურად მართვას მიჰყავართ დასახული მიზნის მიღწევისკენ და პროცესის მიზანი წარმოჩინდება როგორც ეფექტიანობის კრიტერიუმი.

ელექტროენერგეტიკული სისტემის ფუნქციონირებისადმი პროცესული მიდგომა მოითხოვს მართვის ტრადიციულ მეთოდებზე უარის თქმას, მის სერიოზულ გააზრებას. აქ წინა პლანზე დგება მისი რეჟიმების ოპერატიული მართვის, მოკლევადიან პერიოდში მუშაობის სრულყოფილად დაგეგმვის, ელექტროსადგურებსა და ელექტრულ ქსელებს შორის დატვირთვების ოპტიმალური განაწილების და ელექტროენერგიის მოთხოვნის დაკვეთილი სიდიდიდან მინიმალური გადახრის უზრუნველყოფა. საგულისხმოა, რომ დაკვეთილი სიდიდიდან ელექტროენერგიის ფაქტიური მოხმარების განსაზღვრულ პროცენტზე მეტად გადახრა განაპირობებს მაბალანსირებელი ბაზრიდან ელექტროენერგიის შესყიდვას გაზრდილი ფასებით. ნაკლები მხრისკენ გადახრა ისჯება დამატებითი გადასახადით მიუწოდებელი ელექტროენერგიისათვის.

აღნიშნულიდან გამომდინარე ბიზნეს-ინჟინერინგის პრინციპების საფუძველზე, ელექტროენერგეტიკული სისტემის ოპტიმალური პროცესული მართვის განხორციელებისათვის აუცილებელია მოკლევადიან პერიოდში (საათი, დღე-ღამე) ელექტროენერგიის მოხმარების მაღალი სიზუსტით პროგნოზირება.

ელექტროენერგიის მოხმარების მოკლევადიანი პროგნოზის მაღალი სიზუსტე საშუალებას იძლევა შევამციროთ ელექტრობაზრის სუბიექტების ფინანსური დანაკარგები. ამ ამოცანის გადაწყვეტა განსაკუთრებით საპასუხისმგებლოა საქართველოსთვის, რადგანაც ქვეყნის ელექტროენერგეტიკულ სისტემაში ელექტროენერგიის ბაზრის სუბიექტების მნიშვნელოვან ნაწილს არ გააჩნიათ საკუთარი სიმძლავრეები და არ შეუძლიათ გავლენა იქონიონ მომხ-

მარებლების დატვირთვებზე.

პრობლემის გადაწყვეტის აქტუალობიდან გამომდინარე ელექტროენერგიის მოხმარების მოკლევადიანი პროგნოზირებისადმი მრავალი ცნობილი მეცნიერის ნაშრომია მიძღვნილი [6,7,8,9,10,11,12,13,14,15,16]. ამ კვლევებში ძირითადი აქცენტები გადატანილია პროგნოზირების სტატისტიკურ მეთოდებზე (ავტორეგრესიის მეთოდი, სეზონური მრუდების მეთოდი, ფაქტორული ანალიზი, წრფივი ალგორითმი დაფუძნებული მომავლის განჭვრეტაზე უახლოესი წარსულის მონაცემების მიხედვით). ეს მეთოდები საშუალებას იძლევა დღეების სხვადასხვა ტიპებისათვის აიგოს ავტორეგრესიული მოდელები. ჰაერის ტემპერატურა, განათებულობის ხარისხი, დღის ხანგრძლივობა, კვირის დღე, ზამთრის დროის საზაფხულო დროზე გადასვლა და პირიქით, ექსტრაორდინალური მოვლენების, ამინდის პირობების პროგნოზები და სხვა ფაქტორები გამოყენებულია გასაშუალებელი სიდიდეებით, მათი გავლენა გათვალისწინებულია ელექტროენერგიის მოხმარების წინა წლების მნიშვნელობების მიხედვით. ეს მეთოდი საშუალებას იძლევა მივიღოთ პროგნოზის კარგი შედეგები სტაბილურ სიტუაციებში [6,9,11,12,13], თუმცა ფაქტორული პარამეტრების მოულოდნელი მკვეთრი ცვლილებების დროს ასეთი მიდგომა არ იძლევა საშუალებას გავაკეთოთ სიტუაციის სწორი პროგნოზი, იმის გამო, რომ საქართველოში ადგილი აქვს სიტუაციების მკვეთრი ცვალებადობას ელექტროენერგიის მომხმარების მოკლევადიანი პროგნოზირების მითითებული მეთოდი ვერ განხორციელებს სათანადო სიზუსტით.

ჩვენს ქვეყანაში ელექტროენერგიის მოთხოვნის მოკლევადიანი პროგნოზის სირთულეს მნიშვნელოვანწილად განაპირობებს მომხმარებლების დიდი რიცხვის არსებობა და ელექტროენერგიის მოხმარებაზე მოქმედი მრავალი ფაქტორის გათვალისწინების აუცილებლობა.

ამასთან მეცნიერთა უმრავლესობა [7,8,10,14,15,16] ელექტროენერგიის მოხმარების მოკლევადიანი პროგნოზირებისათვის ოპტიმალურად თვლის არაკლასიკური

მეთოდების გამოყენებას (ხელოვნური ნეირონული ქსელები, არამკაფიო ლოგიკა, გენეტიკური ალგორითმები და სხვა), ვინაიდან ელექტროენერგიაზე მოთხოვნა მოკლევადიან პერიოდში როგორც წრფივად ისე არაწრფივად დამოკიდებულია მრავალ ფაქტორზე მისი კლასიკური მეთოდებით პროგნოზირება გაძნელებულია. შეუძლებელია კლასიკური მეთოდების პროგნოზირების დროს რთული კავშირების გათვალისწინება.

სწორედ ამიტომ ბოლო პერიოდში სპეციალისტების მხრიდან [7,8,10,14,15,16], რომლებიც დაკავებული არიან ელექტროენერგიის მოხმარების დროითი მწკრივების პროგნოზით სულ უფრო დიდი ყურადღება ექცევა ხელოვნურ ნეირონულ ქსელებს. ხელოვნური ნეირონული ქსელის მეშვეობით ელექტროენერგიის მოხმარების პროგნოზირების ძირითადი მიზიდველობა მდგომარეობს იმაში, რომ ამ შემთხვევაში შესაძლებელია გამოყენებული იქნეს შემაჯავლი პარამეტრების დიდი რაოდენობა – ისტორიული მონაცემები ელექტროენერგიის მოხმარებაზე და შესაბამისი ისტორიული მონაცემები მათზე მოქმედ ყველა ფაქტორზე, რაც მთავარია შემაჯავლი პარამეტრების გავლენის ფუნქცია გამოსავალ შედეგზე შეიძლება იყოს ნებისმიერი სირთულის (არასწრფივი, არასტაციონარული) და უცნობი ფორმის. გარდა ამისა, მოდელის შემაჯავლი პარამეტრების ნაწილი შეიძლება იყოს რიცხვითი ნაწილი, კატეგორიული [1,7,8,10,14,15,16].

ხელოვნური ნეირონული ქსელები წარმოადგენენ ანალიტიკურ სისტემებს, სადაც დასმული ამოცანები არასაკმარისად მკაფიოდ არის ფორმულირებული. ფორმულირების არასაკმარისი სიზუსტე შეიძლება გადაილახოს ხელოვნური ნეირონული ქსელის თვითსწავლების უნარით, მონაცემებში იპოვოს დაფარული და გაუგებარი კავშირები. ხელოვნური ნეირონული ქსელის მნიშვნელოვან თვისებას წარმოადგენს უნარი გარე გარემოს ცვლილებებზე დამოკიდებულებით შეიცვალოს თავისი ქცევა და ცოდნა.

ელექტროენერგიის მოხმარების პროგნოზირებისათვის

ხელოვნური ნეირონული ქსელის ასაგებად აუცილებელია მათზე მოქმედი ფაქტორების გათვალისწინება. ფაქტორების დასადგენად სს “თელასი“-ს მაგალითზე ჩატარებულ იქნა კორელაციური ანალიზი. კორელაციური მატრიცის შესადგენად [2] გამოთვლილია შერჩევითი საშუალოები:

$$\bar{\xi}_j = \frac{1}{n} \sum_{i=1}^n x_{ij} \quad (1) \quad \bar{\eta}_j = \frac{1}{n} \sum_{i=1}^n y_{ij} \quad (2)$$

და შერჩევითი საშუალო კვადრატული გადახრები:

$$S_{\xi_j}^2 = \sum_{i=1}^n \xi_{ij}^2 - \sum_{i=1}^n (\bar{\xi}_j)^2 \quad (3) \quad \text{და}$$

$$S_{\eta_j}^2 = \sum_{i=1}^n \eta_{ij}^2 - \sum_{i=1}^n (\bar{\eta}_j)^2 \quad (4)$$

კორელაციის შერჩევითი კოეფიციენტი ტოლია:

$$\rho_j = \frac{\sum_{i=1}^n x_{ij} \cdot y_{ij} - n \cdot \bar{\xi}_j \cdot \bar{\eta}_j}{n \cdot S_{\xi_j} \cdot S_{\eta_j}} \quad (5)$$

სადაც, x_{ij} – i ფაქტორია, j – ფაქტორის ნომერი, i – წელი, n – წლების რაოდენობა.

საწყისი ინფორმაციის სახით გამოყენებულია სს “თელასი“-ს მიერ 2011 წლის მარტის თვეში მოხმარებული ელექტროენერგიის მაჩვენებლები. პროგნოზის მეტი სიზუსტის უზრუნველსაყოფად ელექტროენერგიის მოხმარებასთან კავშირის დასადგენად განხილულია 16 ფაქტორი. მათ შორის, ჰაერის მინიმალური და მაქსიმალური ტემპერატურა, ქარის სიჩქარე, ნალექები, დღის ხანგრძლივობა, სადღესასწაულო და უქმე დღეებში ელექტროენერგიის მოხმარება, საპროგნოზო პერიოდში დამატებით მიერთებული მომხმარებლების რაოდენობა [3,4,5].

კორელაციური ანალიზის ჩასატარებლად საჭირო საწყისი ინფორმაცია მოცემულია №1 და №2 ცხრილებში:

ცხრილი №1.

№	ფაქტორი	აღნიშვნა	განზომილება
1	1 დღის წინ არსებული მოხმარება	X1	მლნ. კვტ. სთ
2	2 დღის წინ არსებული მოხმარება	X2	მლნ. კვტ. სთ
3	3 დღის წინ არსებული მოხმარება	X3	მლნ. კვტ. სთ
4	4 დღის წინ არსებული მოხმარება	X4	მლნ. კვტ. სთ
5	5 დღის წინ არსებული მოხმარება	X5	მლნ. კვტ. სთ
6	6 დღის წინ არსებული მოხმარება	X6	მლნ. კვტ. სთ
7	7 დღის წინ არსებული მოხმარება	X7	მლნ. კვტ. სთ
8	დღე	X8	დღის ნომერი (1,2,3,...,7)
9	14 დღის წინ არსებული მოხმარება	X9	მლნ. კვტ. სთ
10	მინიმალური ტემპერატურა	X10	გრადუსი
11	მაქსიმალური ტემპერატურა	X11	გრადუსი
12	დღის განმავლობაში ქარის საშუალო სიჩქარე	X12	მეტრი წამში
13	დღის განმავლობაში ნალექების საშუალო რაოდენობა	X6	მმ
14	დღის ხანგრძლივობა	X14	სთ და წუთი
15	დღესასწაული	X15	(0 ან 1)
16	დამატებით მიერთებულ მომხმარებელთა რაოდენობა/სიმძლავრე	X16	რაოდენობა/მგვტ
17	საპროგნოზო პერიოდში ელექტროენერგიის დღე-ღამური მოხმარება	Y	მლნ. კვტ. სთ

№	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10
1	7,5	7,215	7,493	7,54	7,946	8,09	8,001	2	8,193	-1
2	7,614	7,5	7,215	7,493	7,54	7,946	8,09	3	7,985	-2
3	7,214	7,614	7,5	7,215	7,493	7,54	7,946	4	7,499	2
4	7,001	7,214	7,614	7,5	7,215	7,493	7,54	5	8,201	5
5	6,567	7,001	7,214	7,614	7,5	7,215	7,493	6	7,808	8
6	6,488	6,567	7,001	7,214	7,614	7,5	7,215	7	7,43	7
7	6,093	6,488	6,567	7,001	7,214	7,614	7,5	1	7,756	6
8	6,977	6,093	6,488	6,567	7,001	7,214	7,614	2	8,001	5
9	6,933	6,977	6,093	6,488	6,567	7,001	7,214	3	8,09	3
10	7,023	6,933	6,977	6,093	6,488	6,567	7,001	4	7,946	3
11	7,359	7,023	6,933	6,977	6,093	6,488	6,567	5	7,54	3
12	7,338	7,359	7,023	6,933	6,977	6,093	6,488	6	7,493	3
13	6,584	7,338	7,359	7,023	6,933	6,977	6,093	7	7,215	2
14	6,144	6,584	7,338	7,359	7,023	6,933	6,977	1	7,5	6
15	6,269	6,144	6,584	7,338	7,359	7,023	6,933	2	7,614	6
16	6,122	6,269	6,144	6,584	7,338	7,359	7,023	3	7,214	5
17	5,887	6,122	6,269	6,144	6,584	7,338	7,359	4	7,001	6

გაგრძელება:

№	X11	X12	X13	X14	X15	X16	Y
1	9	13,6	0	11:03	0	3832/119	7,614
2	16	18,2	0	11:06	0	0	7,214
3	18,4	24,5	0	11:12	0	0	7,001
4	19	16,4	0	11:15	0	0	6,567
5	14,2	23,6	0	11:16	0	0	6,488
6	21	26,6	0	11:19	0	0	6,093
7	10,2	19	0,8	11:22	0	0	6,977
8	12,5	44,9	1	11:23	0	0	6,933
9	9	36,4	0	11:26	0	0	7,023
10	10	54,4	0	11:30	0	0	7,359
11	10,4	48,9	0	11:33	0	0	7,338
12	15,5	35,1	0	11:34	0	0	6,584
13	22	22,2	0	11:37	0	0	6,144
14	22	25,3	0	11:40	0	0	6,269
15	20,8	21,7	0	11:44	0	0	6,122
16	22	24,5	0	11:47	0	0	5,887
17	23	22	0	11:50	0	0	5,857

კორელაციური ანალიზის შედეგები ასახულია №3 ცხრილში:

ფაქტორი	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	X ₉	X ₁₀	X ₁₁
მოხმარება	0,64	0,17	-0,17	-0,24	-0,13	0,18	0,44	-0,49	0,59	-0,66	-

გაგრძელება:

ფაქტორი	X12	X13	X14	X15	X16
მოხმარება	-0,61	-0,82	0,26	0,11	0,43

ხელოვნური ნეირონული ქსელების მეშვეობით ელექტროენცეფალიოგრაფიის მონიტორინგის მოკლევადიანი პროგნოზის განსახორციელებლად აუცილებელია შემაჯავლი და გამომაჯავლი ფაქტორების ერთმანეთთან დაკავშირება. შემაჯავლი და გამომაჯავლი ფაქტორები ერთმანეთს უკავშირდებიან $F(k)$ აქტივაციის ფუნქციით [1,7,8,10,14,15,16].

სიგნალის გადაცემის მექანიზმის გასაგებად განვიხილოთ ნეირონი, რომელშიც შემოდის $(w_1, w_2, \dots, w_k)$ წახანაგის გავლით სიგნალები $(x_1, x_2, \dots, x_k)$. ჯამური შეწონილი სიგნალი ტოლია:

$$net = \sum_{i=1}^k w_i x_i. \quad (6)$$

გამომაჯავლი სიგნალი ნეირონზე იანგარიშება როგორც $output=f(net)$ (7)

სადაც, $F(net)$ ფუნქციას ეწოდება შემომსახვერელი ან აქტივაციის ფუნქცია.

მსოფლიო პრაქტიკაში [1,7,8,10,14,15,16] გავრცელებულია $F(k)$ აქტივაციის შემდეგი ფუნქციები: ლოგისტიკურ-სიგმოიდური, ზღვრული, ჰიპერბოლურ-ტანგენსური, ნელოვანი ლოგისტიკურ-სიგმოიდური, ბიპოლარულ-სიგ-

მოიღწერი.

აქტივაციის ფუნქციის სახის შესარჩევად ჩატარდა ექსპერიმენტალური კვლევა. ჩამოთვლილი ფუნქციებიდან ოპტიმალურის შერჩევას საფუძვლად დაედო საშუალო კვადრატული შეცდომის მინიმუმის კრიტერიუმი [1,7,8,10,14,15,16]. საშუალო კვადრატული შეცდომა გამოთვლილია შემდეგი ფორმულით:

$$J(n) = \frac{1}{2} \sum_k e_k^2(n) \quad (8) \text{ სადაც,}$$

$$e_k(n) = y_k(n) - d_k(n)$$

$d_k(n)$ – ფაქტიური მნიშვნელობა k ნეირონის n დროს,


$Y_k(n)$ – მოდელით მიღებული მნიშვნელობა k ნეირონის n დროს.

ხელოვნური ნეირონული ქსელის შემდგომი ოპტიმიზაცია ხდება $Y_k(n)$ მნიშვნელობის მინიმიზაციით ფაქტორების სხვადასხვა წონების გათვალისწინებით. მათი წონების ცვალებადობის ფორმულას აქვს შემდეგი სახე:

$$\Delta w_{kj} = \eta e_k(n) x_j(n) \quad (9)$$

სადაც, η -შესწორების კოეფიციენტი, x_j - j ფაქტორია.


აღნიშნული კრიტერიუმით შემუშავებულია ფაქტიური და მოდელით განსაზღვრულ გამოძავალ ფაქტორებს შორის მინიმიზაციისათვის შეცდომების გასწორების ალგორითმი, რომელსაც აქვს ნახ. №1-ზე მოცემული სახე:



ნახ. 1. შეცდომების გასწორების ალგორითმი

ხელოვნური ნეირონული ქსელის სტრუქტურების ანალიზის შედეგად მივედით იმ დასკვნამდე, რომ ელექტროენერგიის მოხმარების მოკლევადიანი პროგნოზირებისათვის უმჯობესია გამოყენებული იქნეს ხელოვნური ნეირონული ქსელის კონფიგურაცია პირდაპირი გავრცელების (პერცეპტონები) შეცდომის უკუ გავრცელების მეთოდით სწავ-

ლება. ხელოვნური ნეირონული ქსელის სტრუქტურის შერჩევის დროს გათვალისწინებული იქნა დაფარული შრეების და ამ შრეებში ნეირონების ისეთი რაოდენობა, რომლებიც სრულად აკმაყოფილებენ ელექტროენერგიის მოხმარების მოკლევადიანი პროგნოზის სიზუსტისადმი მოთხოვნას.



ნახ. 3. ქ. თბილისში ელექტროენერგიის დღე-ღამური მოხმარების მოკლევადიანი პროგნოზირების მოდელი

ზემოთ ჩამოყალიბებული მეთოდოლოგიის და ცხრილი №1-ის მონაცემების საფუძველზე პროგრამული პაკეტის PredictorXL მეშვეობით, სხვადასხვა აქტივაციის ფუნქციის, ნეირონების არაფარული და ფარული შრეების სხვადასხვა რაოდენობების მიხედვით ექსპერიმენტით დადგენილ იქნა ქ. თბილისში ელექტროენერგიის დღე-ღამური მოხმარების მოკლევადიანი პროგნოზირების ოპტიმალური მოდელი. ჩატარებულმა კვლევამ აჩვენა, რომ ქ. თბილისის ელექტროენერგიის დღე-ღამური მოხმარების მოკლევადიანი პროგნოზის ყველაზე დიდი სიზუსტით განხორციელება შესაძლებელია, ნეირონების ფარული შრეების – 2 და აქტივაციის ლოგისტიკურ-სიგმოიდური ფუნქციით.

ამ ფუნქცია აქვს შემდეგი სახე:

$$f(x, a, b) = \frac{e^{a_i + b_i x_i}}{1 + e^{a_i + b_i x_i}} \quad (10)$$

სადაც, X – ელექტროენერგიის მოხმარებაზე მოქმედი x_i ფაქტორია;

a_i და b_i – რეგრესიის კოეფიციენტებია;

ზემოთ მოყვანილი მონაცემების საფუძველზე ქ. თბილისში ელექტროენერგიის დღე-ღამური მოხმარების მოკლევადიანი (დღე-ღამური) პროგნოზირების ხელოვნური ნეირონული ქსელების მოდელს აქვს შემდეგი ნახ. 3-ში მოყვანილი სახე.

ხელოვნური ნეირონული ქსელების გამოყენებით ელექტროენერგიის მოხმარების მოკლევადიანი პროგნოზირების მეთოდის უპირატესობის დასაბუთების მიზნით შესრულდა კლასიკური მრავალფაქტორიანი მათემატიკური მოდელით ელექტროენერგიის მოხმარების მოკლევადიანი (დღე-ღამე) პროგნოზირება [2]. მრავალფაქტორიანი მოდელის შესადგენი და მისი რეგრესიის კოეფიციენტების გამოსათვლელ განტოლებათა სისტემა მიიღებს შემდეგ სახეს:

$$\begin{aligned} & 7,5 z1 + 7,215 z2 + 7,493 z3 + 7,54 z4 + 7,946 z5 + 8,09 z6 + 8,001 z7 + \\ & + 2 z8 + 8,193 z9 - z10 + 9 z11 + 13,6 z12 + 11,3 z14 + 119 z16 + b = 7,614 \\ & 7,614 z1 + 7,5 z2 + 7,215 z3 + 7,493 z4 + 7,54 z5 + 7,946 z6 + 8,09 z7 + \\ & + 3 z8 + 7,985 z9 - 2 z10 + 16 z11 + 18,2 z12 + 11,06 z14 + b = 7,214 \\ & 7,214 z1 + 7,614 z2 + 7,5 z3 + 7,215 z4 + 7,493 z5 + 7,54 z6 + 7,946 z7 + \\ & + 4 z8 + 7,499 z9 + 2 z10 + 18,4 z11 + 24,5 z12 + 11,12 z14 + b = 7,001 \\ & 7,001 z1 + 7,214 z2 + 7,614 z3 + 7,5 z4 + 7,215 z5 + 7,493 z6 + 7,54 z7 + \\ & + 5 z8 + 8,201 z9 + 5 z10 + 19 z11 + 16,4 z12 + 11,15 z14 + b = 6,567 \\ & 6,567 z1 + 7,001 z2 + 7,214 z3 + 7,614 z4 + 7,5 z5 + 7,215 z6 + 7,493 z7 + \\ & + 6 z8 + 7,808 z9 + 8 z10 + 14,2 z11 + 23,6 z12 + 11,16 z14 + b = 6,488 \\ & 6,488 z1 + 6,567 z2 + 7,001 z3 + 7,214 z4 + 7,614 z5 + 7,5 z6 + 7,215 z7 + \\ & + 7 z8 + 7,43 z9 + 7 z10 + 21 z11 + 26,6 z12 + 11,19 z14 + b = 6,093 \\ & 6,093 z1 + 6,488 z2 + 6,567 z3 + 7,001 z4 + 7,214 z5 + 7,614 z6 + 7,5 z7 + \\ & + z8 + 7,756 z9 + 6 z10 + 10,2 z11 + 19 z12 + 0,8 z13 + 11,22 z14 + b = 6,977 \\ & 6,977 z1 + 6,093 z2 + 6,488 z3 + 6,567 z4 + 7,001 z5 + 7,214 z6 + 7,614 z7 + \\ & + 2 z8 + 8,001 z9 + 5 z10 + 12,5 z11 + 44,9 z12 + z13 + 11,23 z14 + b = 6,933 \\ & 6,977 z1 + 6,093 z2 + 6,488 z3 + 6,567 z4 + 7,001 z5 + 7,214 z6 + 7,614 z7 + \\ & + 2 z8 + 8,001 z9 + 5 z10 + 12,5 z11 + 44,9 z12 + z13 + 11,23 z14 + b = 6,933 \\ & 6,933 z1 + 6,977 z2 + 6,093 z3 + 6,488 z4 + 6,567 z5 + 7,001 z6 + 7,214 z7 + \\ & + 3 z8 + 8,09 z9 + 3 z10 + 9 z11 + 36,4 z12 + 11,26 z14 + b = 7,023 \\ & 7,023 z1 + 6,933 z2 + 6,977 z3 + 6,093 z4 + 6,488 z5 + 6,567 z6 + 7,001 z7 + \\ & + 4 z8 + 7,946 z9 + 3 z10 + 10 z11 + 54,4 z12 + 11,3 z14 + b = 7,359 \\ & 7,359 z1 + 7,023 z2 + 6,933 z3 + 6,977 z4 + 6,093 z5 + 6,488 z6 + 6,567 z7 + \\ & + 5 z8 + 7,54 z9 + 3 z10 + 10,4 z11 + 48,9 z12 + 11,33 z14 + b = 7,338 \\ & 7,338 z1 + 7,359 z2 + 7,023 z3 + 6,933 z4 + 6,977 z5 + 6,093 z6 + 6,488 z7 + \\ & + 6 z8 + 7,493 z9 + 3 z10 + 15,5 z11 + 35,1 z12 + 11,34 z14 + b = 6,584 \\ & 6,584 z1 + 7,338 z2 + 7,359 z3 + 7,023 z4 + 6,933 z5 + 6,977 z6 + 6,093 z7 + \\ & + 7 z8 + 7,215 z9 + 2 z10 + 22 z11 + 22,2 z12 + 11,37 z14 + b = 6,144 \\ & 6,144 z1 + 6,584 z2 + 7,338 z3 + 7,359 z4 + 7,023 z5 + 6,933 z6 + 6,977 z7 + \\ & + z8 + 7,5 z9 + 6 z10 + 22 z11 + 25,3 z12 + 11,4 z14 + b = 6,269 \\ & 6,269 z1 + 6,144 z2 + 6,584 z3 + 7,338 z4 + 7,359 z5 + 7,023 z6 + 6,933 z7 + \\ & + 2 z8 + 7,614 z9 + 6 z10 + 20,8 z11 + 21,7 z12 + 11,44 z14 + b = 6,122 \\ & 6,122 z1 + 6,269 z2 + 6,144 z3 + 6,584 z4 + 7,338 z5 + 7,359 z6 + 7,023 z7 + \\ & + 3 z8 + 7,214 z9 + 5 z10 + 22 z11 + 24,5 z12 + 11,47 z14 + b = 5,887 \\ & 5,887 z1 + 6,122 z2 + 6,269 z3 + 6,144 z4 + 6,584 z5 + 7,338 z6 + 7,359 z7 + \\ & + 4 z8 + 7,001 z9 + 6 z10 + 23 z11 + 22 z12 + 11,50 z14 + b = 5,857 \end{aligned}$$

სადაც, Z - რეგრესიის კოეფიციენტი, b – რეგრესიის მუდმივი წევრია

ამ განტოლებათა სისტემის კომპიუტერული პროგრამა Excel-ით ამოხსნით მივიღებთ რეგრესიის კოეფიციენტების შემდეგ მნიშვნელობებს:

$$\begin{aligned} z_1 &= 0,846928 & z_2 &= 0 & z_3 &= 0,542948 & z_4 &= -0,38486 \\ z_5 &= 0,12242 & z_6 &= 0,723798 & z_7 &= -0,45708 \\ z_8 &= -0,15163 & z_9 &= -0,41705 & z_{10} &= 0,066227 \\ z_{11} &= -0,09715 & z_{12} &= 0,002387 & z_{13} &= -0,33725 \\ z_{14} &= 0 & z_{15} &= 0 & z_{16} &= -0,0053 & b &= 2,183897 \end{aligned}$$

რეგრესიის კოეფიციენტის გათვალისწინებით ელექტროენერგიის მოხმარების მოკლევადიანი პროგნოზირების მრავალფაქტორიანი მატემატიკური მოდელი იქნება:

$$\begin{aligned} y &= 0.846928x_1 + 0.542948x_3 - 0.38486x_4 + \\ &+ 0.12242x_5 + 0.72379x_6 - 0.45708x_7 - \\ &- 0.15163x_8 - 0.41705x_9 + 0.066227x_{10} - \\ &- 0.09715x_{11} + 0.002387x_{12} - 0.33725x_{13} - \\ &- 0.0053x_{16} + 2.183897 \end{aligned} \quad (12)$$

ნახ. 3-ზე მოცემული ხელოვნური ნეირონული ქსელის მოდელის და ცხრილ 1-ში მოყვანილი მონაცემების შეტანის საფუძველზე გამოთვლილი ხელოვნური ნეირონული ქსელით განსაზღვრული ელექტროენერგიის მოხმარების პროგნოზული სიდიდეები შეტანილია ცხრილ 4-ში.

ცხრილი 4. ფაქტორი პერიოდის საპროგნოზო მაჩვენებლები და პროცენტული გადახრა:

№	ქ. თბილისის 2011 წ. მარტის თვის ელექტრო-ენერგიის მოხმარება მლნ. კვტ/სთ. (ფაქტობრივი)	მოხმარება (პროგნოზი)	პროცენტული გადახრა, %
		მოდელის სტრუქტურა: 16-2-1	
		ნულოვანი ლოგარითმული-სიგმოიდური ფუნქცია	
		10000 იტერაცია	
1	7,614	7,605	0,018
2	7,214	7,228	0,022
3	7,001	6,994	-0,034
4	6,567	6,559	-0,015
5	6,488	6,506	-0,104
6	6,093	6,055	0,619
7	6,977	6,978	0,044
8	6,933	6,933	-0,072
9	7,023	7,017	-0,042
10	7,359	7,365	0,011
11	7,338	7,335	0,025
12	6,584	6,581	0,016
13	6,144	6,152	-0,232
14	6,269	6,270	-0,008


შედარებითი ანალიზისათვის ხელოვნური ნეირონული ქსელებით და (12) მრავალფაქტორიანი მათემატიკური მოდელით შესრულებული ელექტროენერგიის მოხმარების

მოხმარების პროგნოზული სიდიდე შეტანილია ცხრილ 5-ში.

ცხრილი №5. მომავალი პერიოდის (დღე-ღამური) პროგნოზი და პროცენტული გადახრა სხვადასხვა მეთოდთან შედარებით

№	ქ. თბილისის 2011 წ. მარტის თვის ელექტროენერგიის მოხმარება (ფაქტობრივი)	მოხმარების (პროგნოზი)		პროცენტული გადახრა %	
		მოდელის სტრუქტურა: 16-2-1			
		ნულოვანი ლოგარითმული-სიგმოიდური ფუნქცია	მრავალფაქტორიანი მოდელი	ხელოვნური ნეირონული ქსელის მოდელი	მრავალფაქტორიანი მოდელი
1	6,122	6,14	6,001	0,29	2

როგორც ცხრილი №5-ში ასახული მონაცემებიდან ჩანს ხელოვნური ნეირონული ქსელებით ელექტროენერგიის მოხმარების მოკლევადიანი პროგნოზირება მრავალფაქტორიანი მოდელთან შედარებით გაცილებით მაღალი სიზუსტით ხასითდება. პროგნოზირების კლასიკურ მეთოდებთან შედარებით ნეირონული ქსელების შემთხვევაში უპირატესობას წარმოადგენს ის ფაქტი, რომ ამ ქსელების საშუალებით შეიძლება დიდი რაოდენობის ფაქტორების გათვალისწინება შედარებით ნაკლები სტატისტიკური მონაცემების პირობებში. აღნიშნულიდან გამომდინარე ელექტროენერგიის მოხმარების მოკლევადიანი პროგნოზირებისათვის შერჩეულ იქნა ხელოვნური ნეირონული ქსელების მოდელი. ამ მოდელით შესრულებული მოკლევადიანი პროგნოზი ასახულია გრაფიკი №1-ზე:



გრაფიკი №1. ქ. თბილისის 2011 წლის მარტის თვის ელექტროენერგიის დღე-ღამური მოხმარების ფაქტობრივი და საპროგნოზო მაჩვენებლები, მლნ. კვტ. სთ

დასკვნა

1. კორელაციური ანალიზის საფუძველზე დადგინდა ელექტრო-ენერგიის მოკლევადიანი მოხმარებაზე მოქმედი ფაქტორები;
2. ელექტროენერგიის მოხმარების მოკლევადიანი

პროგნოზირებისათვის შეიქმნა ხელსაწყო ნეირონული ქსელის სტრუქტურა, კონფიგურაცია, აქტივაციის ფუნქცია და შემუშავდა ელექტროენერგიის მოხმარების პროგნოზირების ოპტიმალური მოდელი;

ელექტროენერგიის მოხმარების მოკლევადიანი პროგნოზირების მიღებული მოდელი ატარებს უნივერსალურ ხასიათს. ამ მოდელით შესაძლებელია ნებისმიერი ქალაქის, რაიონის და მთელი ქვეყნის ელექტროენერგიის მოხმარების მოკლევადიანი (საათი, დღე-ღამე) პროგნოზის მაღალი სიზუსტით შესრულება. ელექტროენერგიის პროგნოზირების მაღალი სიზუსტე საშუალებას იძლევა განხორციელდეს ელექტროენერგეტიკული სისტემის ოპტიმალური ოპერატიული მართვა, მოკლევადიან პერიოდში მუშაობის სრულყოფილი დაგეგმვა, რეჟიმების სათანადო სიზუსტით გაანგარიშება, ელექტროსადგურებსა და ელექტრულ ქსელებს შორის დატვირთვების ოპტიმალური განაწილება. უზრუნველყოფილი იქნას ელექტროენერგიის მოთხოვნის დაკვეთილი სიდიდიდან მინიმალური გადახრა.

DAVID JAPARIDZE
TENGIZ MAGHRADZE

SHORT-TERM DEMAND FORECASTING OF ELECTRICITY BASED ON BUSSINESS-ENGINEERING PRINCIPLES IN ORDER TO PROVIDE ELECTRIC POWER SYSTEM OPTIMAL MANAGEMENT

SUMMARY

The article presents the survey results of the short-term forecasting of electricity demand by using of Artificial Neural Networks. By Correlation analysis it is determined factors affecting the demand of electricity. For short-term prognosis of electricity demand optimal structure, configuration and activation function of artificial neural network were determined.

The optimal short-term electricity demand forecasting model was developed. Based on this model Daily forecast of electricity demand of the city Tbilisi is made.

In Georgian for short-term electricity demand forecasting it is scientifically proved practical application of the desiged method.

ლიტერატურა:

1. ა. ელიზბარაშვილი. ნეირონული ქსელები. Georgian Electronic Scientific Journal: Computer Science and Telecommunications. 2006. No.3(10).
2. დ. ჯაფარიძე, თ. მაღრაძე. საქართველოში ელექტროენერგიის მოთხოვნის საშუალოვადიანი პროგნოზირება მრავალფაქტორული მოდელის გამოყენებით. „საქართველოს ეკონომიკა“. 2009 წ. №9.
3. სს „საქართველოს სახელმწიფო ელექტროსისტემ“-ის 2011 მარტის თვის ანგარიში. www.gse.com.ge
4. სს „თელასი“-ს 2011 წლის ანგარიში. www.telasi.ge
5. Campo, R. & Ruiz, P. (1987). Adaptive weather-sensitive short-term load forecasting. IEEE Transactions on Power Systems, 3, 592-600.
6. Chow, T.W.S. & Leung, C.T. (1996). Neural network based short-term load forecasting system using weather compensation. IEEE Transactions on Power Systems, 11, 1736-1742.
7. Hippert HS, Pedreira CE, Souza RC. Neural networks for short-term load forecasting: a review and evaluation, IEEE Transactions on Power Systems 2001; 16; 44-55.
8. Makukule N.A, Sigauke C. and Lesaoana M.. Daily electricity demand forecasting in South Africa. African Journal of Business Management Vol. 6 (9), pp. 3246-3252, 7 March, 2012.
9. Rui, Y. & El-Keib, A.A. (2004). A review of ANN-based short-term load forecasting models, mimeo, Department of Electrical Engineering, University of Alabama.
10. Taylor, J. W. (2003). Short-term Electricity Demand Forecasting using Double Seasonal Exponential Smoothing. Journal of the Operational Research Society, Vol 54, 799-805.
11. Taylor, J.W. & Buizza R. (2003). Using weather ensemble predictions in electricity demand forecasting. International Journal of Forecasting, 19, 57-70.
12. Taylor, J. W. (2006). A Comparison of Univariate Methods for Forecasting Electricity Demand up to a Day Ahead. International Journal of Forecasting, Vol 22, 1-16
13. Zhang, G., Patuwo, B.E. & Hu, M.Y. (1998). Forecasting with artificial neural networks: The state of the art. International Journal of Forecasting, 14, 35-62.
14. Соломкин А.В. “Краткосрочное прогнозирование потребления электроэнергии с помощью нейросетевых методов”. Электронное научное издание “Электроника и информационные технологии”. 2011.
15. Соломкин А.В. “Применение нейросетевых методов для прогнозирования потребления электроэнергии”. Электронное научное издание «Электроника и информационные технологии». 2009.
16. Чернов С. С. Перминов А. Ю. Кузичев В. М. Методический подход к моделированию бизнес-процессов управляющей компании. Проблемы современной экономики, N 2 (30), 2009