

where the weights are the network's adjustable parameters. The arrangement of the network's nodes and connections defines its architecture and there are many possible variations. One popular arrangement is shown in Figure 4 where the neurons are arranged into layers and each neuron in one layer has connections only with nodes in preceding layer.

The input is presented to the first layer and this information is propagated forwards through the network, such that the output signal of each node never forms part of its own input. The signals at the output of final layer represent the network's output. [1, 3]




Figure 4 A general neural network representation

2. The automatic lighting control systems (ALCSs)

In figures 5 and 6 are presented the configuration of the automatic lighting control systems. All three controllers have a bidimensional input space and one dimensional out space. The controllers based on the values of ε (error – the difference between reference signal y_r - desired illuminance - and the measured output of the ALCS y - measured illuminance) and $\Delta\varepsilon$ (error derivate - the difference between current error and anterior error) will generate the change of control action denoted by Δu . The u signal (where $u(k)=u(k-1)+\Delta u(k)$) will be applied to the process, in the purpose to maintain the output signal y (illuminance in working plane) close to the desired values y_r . The p signal (perturbation) represents the daylight contribution




Figure 5 Feedback control system based on fuzzy controller




Figure 6 Feedback control system base on fuzzy-neural controller

We considered that the light output of electric light system is controlled by a phase-control device with triac to vary the conducting period of the lamp current. The u signal represent the time delay ($0 \dots 10$ miliseconds) of the moment of starting the conducting period of the triac which drive the lamp current.

3. Experimental results

The study was realized considering the reference illuminance in working plane at the 500 lx and with a sampled time of 20 ms. We used the same trajectory for daylight contribution for all automatic systems. The increase/decrease step for daylight has been set to 1 lx/sample. In practice, for the feedback control system configuration from Figure 6, the inverse mathematical model of the process is obtained using a classical identification method (i.e. Least Mean Square method) or training a neural or fuzzy-neural network. For this study we considered the exactly mathematical inverse model of the process (ideal case) for the fuzzy-neural and neural ALCSs.




Figure 7 Fuzzy set for ε , $\Delta\varepsilon$ and Δu (a); rule base (b)

For the inputs and the output of the fuzzy controller, we preferred fuzzy sets like the one

depicted in Figure 7 (a). The rule base for fuzzy controller is presented in Figure 7 (b). From [5] we chose for fuzzy controller the following settings of the width semi-base of membership function: 2 lx for ε , 0.5 lx for $\Delta\varepsilon$ and 0.02 ms for Δu . The fuzzy controller was designed in Mamdani fashion. [2, 3]

From [7] we chose for the inputs of fuzzy-neural controller fuzzy sets constructed with B-spline basis functions of order 5. Figure 8 shows the shape of the basis B-spline functions of order 5. These basis functions are relative to the $[2, 3]$ interval.




Figure 8 Univariate B-spline basis functions of order 5

The fuzzy-neural controller has the following settings: the B-spline network input space for ε is $[-5, 5] \text{ lx}$ and for $\Delta\varepsilon$ is $[-2.5, 2.5] \text{ lx}$. For both input spaces we chose five intervals.

For the neural controller we chose an ANN with three layers (input layer, hidden layer, output layer). The input layer has two neurons, the hidden layer has six neurons and the output layer has one neuron. The activation function (denoted by F in Figure 11) for the neurons from hidden layer is the unipolar sigmoid function (Figure 9) and for the neuron from the output layer is the bipolar sigmoid function (Figure 10).




Figure 9 Unipolar sigmoid function




Figure 10 Bipolar sigmoid function

The Σ from Figure 11 represent the sum of two terms. The first term represent the scalar product of input vector ($\underline{x}=(x_1 \ x_2 \ \dots \ x_n)$) and the weight vector ($\underline{\omega}=(\omega_1 \ \omega_2 \ \dots \ \omega_n)^t$). The second term represents the product $I \cdot \theta$. The last term may be written in the form $x_{n+1} \cdot \omega_{n+1}$ where $x_{n+1}=1$ and $\omega_{n+1}=\theta$. With these notations Σ become the scalar product of $\underline{x}=(x_1 \ x_2 \ \dots \ x_n \ x_{n+1})$ and $\underline{\omega}=(\omega_1 \ \omega_2 \ \dots \ \omega_n \ \omega_{n+1})^t$ vectors. The output of the neuron (denoted by a in Figure 11) called activation of neuron represent the evaluation of $F(\Sigma)$.




Figure 11 Configuration of used artificial neuron

For training of ANN we used the generalized Delta learning rule.[2, 3, 8] Learning rate has the value 0.95. The inputs values of the ANN are scaled. [9]

The behavior of the illuminance in working plane and the control error (difference between desired illuminance and measured illuminance) are presented in:

- Figures 12, 13, 14 for fuzzy ALCS;
- Figures 15, 16, 17 for fuzzy-neural ALCS;
- Figures 18, 19, 20 for neural ALCS.




Figure 12 Fuzzy ACS: the behavior of the illuminance in working plane




Figure 13 Fuzzy ACS: the control error




Figure 14 Fuzzy ACS: detail from Figure 13




Figure 15 Fuzzy-Neural ACS: the behavior of the illuminance in working plane




Figure 16 Fuzzy-Neural ACS: the control error




Figure 17 Fuzzy-Neural ACS: detail from Figure 16




Figure 18 Neural ACS: the behavior of the illuminance in working plane




Figure 19 Neural ACS: the control error




Figure 20 Neural ACS: detail from Figure 17

In Figures 12, 15, 18 were represented four trajectory: trajectory 1 is the level of daylight illuminance in working plane denoted by $E_{daylight}$; trajectory 2 is the level of illuminance in working plane due to electric light system denoted by $E_{artificial}$; trajectory 3 represents the real level of total illuminance in working plane (the sum of trajectories 1 and 2) denoted by $E_{measured}$; and trajectory 4 represents the desired level of illuminance in working plane denoted by $E_{desired}$ (represented by an horizontal line at 500 lx). The trajectory of $E_{daylight}$ has multiple dwells at different levels of illuminance [500 lx, 0 lx, intermediary values into (0, 500) lx] and multiple ascending/ descending fronts. The trajectory of $E_{artificial}$ tries to approximate the complementary trajectory for $E_{daylight}$. The sum of $E_{daylight}$ and $E_{artificial}$ trajectories, which represent the $E_{measured}$, tries to approximate the trajectory of $E_{desired}$.

4. Conclusions

When the daylight contribution will decrease from maximum constant value (500 lx) to minimum values, the control error will increase along a number of samples. After that, the control error will decrease due to the action of controller. So, for this situation we have a maximum of control error. As one can see in Figures 14, 17 and 20, the maximum control error will have bigger value for fuzzy-neural and neural ALCSs like the value for the fuzzy ALCS. As one can see in Figure 17, for the fuzzy-neural ALCS the stationary error have an oscillatory behavior for a number of samples. From the point of view of the automation theory, the fuzzy ALCS have a better behavior like the fuzzy-neural and neural ALCSs because the control error is not oscillatory

and the maximum control error is smaller. But from the human eye perception all ALCs have the same behavior because these control error behaviors are not perceived. Thus, these three types of ALCs with the settings presented in previous section are recommended for those of applications where, from the human eye perception point of view, the illuminance must be constant at the desired level on working plane (i.e. design laboratory). For those application where the users need to feel the changes of daylight contribution even if is necessary to maintain the desired illuminance level on working plane (i.e. offices) you must change the settings for controllers. For fuzzy controller decrease the width semi-base of membership function for Δu , for fuzzy-neural controller increase the order of B-spline basis functions and for neural controller decrease the learning rate.

The performance of fuzzy-neural and neural ALCs will be influenced by the exactitude of the mathematical inverse model of process. So, for these configurations of the ALCs the fuzzy ALC has a better behaviour like the other two ALCs.

5. References

- 1 Brown, M., Harris, C., 1994, Neurofuzzy Adaptive Modelling and Control, Prentice Hall International (UK) Limited
- 2 Fuller, R., 1995, Neural Fuzzy Systems, Abo Akademi University, Abo
- 3 David, L.; Marton, L., 2000, Rețele neuronale și logica fuzzy în automatizări, Editura Universității "Petru Maior", Tg.-Mureș
- 4 Grif, H.Șt., Gligor, A., Dub, V., 2003, Fuzzy Logic Theory in Daylight Control, International Lighting Conference ILUMINAT 2003, Cluj Napoca, pp. 24-1...24-4
- 5 Grif, H.Șt., Gligor, A., Oltean, S., 2003, Fuzzy Daylight Control, Proceedings of the Inter-Ing 2003, Volume II, Tg. Mureș, pp. 85-90
- 6 Grif, H.Șt., Pop, F., Beu, D., 2003, Daylight Control Based On Fuzzy-Neural Controller, Proceedings of the Inter-Ing 2003, Volume II, Tg. Mureș, pp. 91-96
- 7 Grif, H.Șt., Gligor, A., Pop, F., 2004, Fuzzy Daylight Control Vs. Adaptive B-spline Network Daylight

Control, Bucharest 2004 International Lighting Symposium, "Quality Solutions for an Efficient Lighting", Bucharest, pp. 55-62

- 8 Grif, H.Șt., Gyorgy, K., 2004, Generalized Delta Learning Rule For Multi-Hidden Layers Artificial Neural Networks. The Recursive Algorithm, Buletinul Științific al Universității "Petru Maior", Vol. XVII, Tg. Mureș, pp. 167-173
- 9 Grif, H.Șt., Gyorgy, K., Gligor, A., Bucur, D., 2004, Ways To Improve The Behavior Of A Neural Automatic Daylight Control System, Buletinul Științific al Universității "Petru Maior", Vol. XVII, Tg. Mureș, pp. 175-181



Horațiu Ștefan GRIF

"Petru Maior" University from Tg. Mureș
1, N. Iorga Street, Tg. Mureș, Romania
Ph.:+40.766.678773 (mobil),
Fax:+40.265.236213
e-mail:hgrif@upm.ro

Assistant Professor at the Electrical Engineering Department, Engineering Faculty, "Petru Maior" University of Tg. Mureș. PhD student in Civil Engineering, Technical University of Cluj-Napoca. Interest fields: Automatic Control, Artificial Intelligence, Optimization and Information Technology



Adrian GLIGOR

"Petru Maior" University from Tg. Mureș
1, N. Iorga Street, Tg. Mureș, Romania
Ph.:+40.265.233212,
Fax:+40.265.236213
e-mail:agligor@upm.ro

Assistant Professor at the Electrical Engineering Department, Engineering Faculty, "Petru Maior" University of Tg. Mureș. PhD student in Civil Engineering, Technical University of Cluj-Napoca. Interest fields: Automatic Control, Optimization, Artificial Intelligence, and Information Technology

Received 1 December 2004

Reviewers:

Prof. Mircea CHINDRIȘ, Prof. Florin POP

REGLAREA FUZZY, FUZZY-NEURONALĂ ȘI NEURONALĂ A ILUMINATULUI INTERIOR ÎN FUNCȚIE DE LUMINA NATURALĂ. STUDIU COMPARATIV

Lucrarea descrie comportarea a trei sisteme de reglare automată a iluminatului (SRAI), primul folosind un regulator fuzzy, al doilea folosind un regulator fuzzy-neuronal iar al treilea folosind un regulator neuronal. Nivelul de iluminare naturală va reprezenta semnalul de perturbație pentru SRAI. SRAI fuzzy are o comportare mai bună decât sistemele SRAI fuzzy-neuronal și neuronal chiar dacă rețelele fuzzy-neuronale și neuronale au potențialul de a învăța din interacțiunile din trecut cu mediul înconjurător. Ultimele două SRAI au nevoie de modelul matematic invers al procesului. Performanța sistemelor de reglare automată cu regulator fuzzy-neuronal și regulator neuronal va fi influențată de acuratețea modelului invers al procesului.

1. Introducere

1.1 Sistem de reglare cu reacție negativă

Scopul unui sistem de reglare cu reacție negativă (Figura 1) este de a garanta valoarea dorită pentru ieșirea y . Procesul de păstrare a ieșirii y apropiată de valoarea de referință y_r , ignorând prezența perturbațiilor parametrilor sistemului sau a zgomotelor de măsurare, este cunoscut sub numele de reglare. Ieșirea regulatorului este semnalul de comandă u (este totodată și semnalul de intrare al procesului), e reprezintă eroarea dintre valoarea de referință y_r și ieșirea sistemului de reglare. [2, 5]

În următoarele subcapitole vom prezenta pe scurt trei tipuri de regulatoare: fuzzy, fuzzy-neuronal și neuronal.

1.2 Regulator cu logică fuzzy

Logica fuzzy este utilizată pe scară largă în sistemele de reglare inteligente datorită regulilor vagi de descriere a relației dintre evaluările lingvistice imprecise și calitative ale stărilor intrării și ieșirii sistemului.

Există caracteristici principale ale sistemelor fuzzy care le conferă o performanță mai bună pentru aplicații tipice: (a) sistemele fuzzy sunt potrivite pentru un raționament imprecis sau aproximativ, în special pentru sistemul al cărui model matematic poate fi dificil de obținut; (b) logica fuzzy permite realizarea unei decizii cu valori estimate din informații incomplete sau imprecise. [2]

Într-un regulator cu logică fuzzy (RLF), dinamica comportării unui sistem fuzzy este caracterizată de un set de reguli de descriere lingvistice bazate pe cunoștințele unui expert. Cunoștințele expertului

sunt de obicei în forma: *DACĂ* (un set de condiții sunt satisfăcute) *ATUNCI* (un set de consecințe vor fi deduse). Datorită faptului că antecedentele și consecințele regulilor *DACĂ-ATUNCI* sunt asociate cu concepte fuzzy (termeni lingvistici), ele sunt numite deseori declarații condiționale fuzzy. În terminologia noastră, o regulă de reglare fuzzy este o declarație condițională fuzzy în care antecedentul este o condiție în domeniul ei de aplicare iar consecința este mărimea de comandă pentru sistemul (procesul) supus reglării. În general, regulile de reglare fuzzy oferă o cale convenabilă pentru exprimarea procesului de reglare și a cunoștințelor. [2, 5]

Un regulator fuzzy este constituit, de obicei, din patru părți importante: interfața de fuzzificare, baza de reguli fuzzy, motorul de deducție fuzzy și interfața de defuzzificare (Figura 2).

Blocul de fuzzificare convertește datele de intrare în grade de apartenență al uneia sau mai multor funcții de apartenență. Astfel blocul de fuzzificare compară o dată de intrare cu condițiile regulilor pentru a determina în ce măsură condiția fiecărei reguli se potrivește cu acea instanță particulară de intrare. Datei de intrare considerate i se atașează un grad fuzzy de apartenență corespunzător fiecărui termen lingvistic. *Baza de reguli* conține informații despre universale (domeniile de variație) ale variabilelor, metodele de normalizare a variabilelor și seturile fuzzy. De asemenea, baza de reguli conține și regulile *DACĂ-ATUNCI*. *Motorul de deducție* determină influența fiecărei reguli asupra răspunsului final al regulatorului. Interfața de defuzzificare convertește ieșirea procesului de deducție, accesibilă ca și set fuzzy, într-o valoare crisp (semnalul de comandă aplicat procesului). [2, 5]

1.3 Regulator fuzzy-neuronal

Există două modele pentru regulatorul fuzzy-neuronal. Pentru o înțelegere mai ușoară vom pleca de la blocurile regulatorului fuzzy (a se vedea Figura 2). Primul model de regulator fuzzy-neuronal este obținut păstrând blocul de fuzzificare și înlocuind blocurile bază de reguli, motor de inferență și cel de defuzzificare cu o rețea neuronală artificială. Al doilea model este obținut înlocuind blocul de fuzzificare cu o rețea neuronală artificială și păstrând celelalte trei blocuri. [2]

În studiul nostru am utilizat primul tip de model pentru regulatorul fuzzy-neuronal și a fost implementat utilizând un tip de rețea memorie asociativă (RMA) cum este rețeaua B-spline. O ilustrare schematică a unei rețele B-spline este prezentată în Figura 3 unde funcțiile bază sunt definite pe o grilă n -dimensională.

Din punct de vedere fuzzy funcțiile bază univariabile B-spline reprezintă declarații lingvistice fuzzy, cum ar fi *eroarea este pozitiv mică*, iar seturile fuzzy multivariabile sunt formate utilizând operatorul produs pentru a reprezenta conjuncția fuzzy. Această legătură dă posibilitate rețelei B-spline să fie interpretată ca un set de reguli fuzzy și permite obținerea modelării și convergenței rezultatelor pentru rețeaua fuzzy. Deci aceste rețele încapsulează atât o abordare calitativă cât și una cantitativă, dând posibilitatea informației euristice să fie incorporată și dedusă ca la rețelele neuronale și permițând obținerea regulilor fuzzy prin învățare, reguli pentru care convergența rezultatelor poate fi dovedită. [1]

Ieșirea rețelei B-spline este obținută din combinația liniară a unui set de funcții bază, care sunt definite într-un spațiu n -dimensional. Deoarece suportul fiecărei funcții bază este mărginit, numai un număr mic de ponderi sunt implicate în calcularea ieșirii rețelei, iar rețeaua stochează și învață informația local.

ORMA B-spline își ajustează vectorul de ponderi, în general, utilizând algoritmi instantanei de tipul celor mai mici pătrate (CMMP), în vederea realizării unei mapări particulare, modificând ponderea cu care o funcție bază contribuie la ieșirea rețelei. Reprezentarea internă rară a rețelei simplifică procesul de învățare în sensul că un procentaj mic din totalul de ponderi contribuie la realizarea ieșirii și numai acești parametri sunt modificați de regulile CMMP.

Când rețeaua B-spline este proiectată este necesar a se specifica forma (ordinul) fiecărei funcții

bază univariabilă, ceea ce implicit va determina numărul de funcții bază mapate pentru o intrare a rețelei. De asemenea este necesar a se specifica numărul de intervale în care se divide fiecare intrare a rețelei. Dacă toate funcțiile univariabile B-spline au lățimea k (suportul unei funcții bază este format din k intervale), k^n (n – dimensiunea spațiului de intrare al rețelei) funcții bază contribuie la ieșirea rețelei. Astfel rețeaua B-spline trebuie utilizată numai când numărul de intrări relevante este mic iar funcția dorită este neliniară. [1]

1.4 Regulator neuronal

Un regulator neuronal poate fi ușor construit utilizând o rețea neuronală artificială (RNA).

Rețelele neuronale artificiale sunt constituite dintr-un număr mare de elemente simple de preprocesare numite noduri sau neuroni. Semnalele sunt transmise între noduri de-a lungul conexiunilor ponderate, unde ponderile sunt parametrii ajustabili ai rețelei. Aranjamentul nodurilor și conexiunilor rețelei definesc arhitectura ei, astfel există multe variații posibile ale rețelei. Un aranjament popular este prezentat în Figura 4 unde neuronii sunt aranjați în straturi și fiecare neuron dintr-un strat are conexiuni cu noduri din stratul anterior.

Intrarea este prezentată primului strat și această informație este propagată înainte prin rețea, astfel că semnalul de ieșire a fiecărui nod nu face parte niciodată din propria intrare. Semnalele de la ieșirea ultimului strat reprezintă ieșirea rețelei. [1, 3]

2. Sistemele de reglare automată a iluminatului (SRAI)

În Figurile 5 și 6 sunt prezentate configurațiile sistemelor de reglare automată a iluminatului. Toate cele trei regulatoare au un spațiu de intrare bidimensional și spațiul de ieșire unidimensional. Regulatele pe baza valorilor lui ε (eroarea – diferența dintre semnalul de referință y_r – iluminarea dorită – și ieșirea măsurată a SRAI y – iluminarea măsurată) și a lui $\Delta\varepsilon$ (derivata erorii – diferența dintre eroarea curentă și eroarea anterioară) va genera valoarea cu care se modifică semnalul de comandă notată cu Δu . Semnalul u (unde $u(k) = u(k-1) + \Delta u(k)$) va fi aplicat procesului în scopul menținerii semnalului de ieșire y (iluminarea în planul de lucru) apropiat de valoarea dorită y_r . Semnalul p (perturbația) reprezintă contribuția iluminatului natural. Am considerat ca fluxul luminos al sistemului de iluminat electric este modificat cu ajutorul unui dispozitiv cu triac ce

modifică perioada de conducție a curentului prin lampă. Semnalul u reprezintă timpul de întârziere al amorsării triacului.

3. Rezultate experimentale

Studiul a fost realizat considerând iluminarea de referință în planul de lucru de 500 lx iar perioada de eșantionare a semnalelor de 20 ms. Pentru toate sistemele de reglare am utilizat aceeași traiectorie a contribuției iluminatului natural. Pasul de creștere/descrescere a iluminării naturale a fost setat la 1 lx/eșantion. În practică pentru configurația sistemului de reglare din Figura 6, modelul matematic invers al procesului este obținut printr-o metodă clasică de identificare (de ex. metoda CMMP) sau prin antrenarea unei rețele neuronale sau fuzzy-neuronale. Pentru acest studiu s-a considerat modelul matematic invers exact al procesului (cazul ideal) pentru SRAI neuronal și fuzzy-neuronal.

Pentru intrările și ieșirea regulatorului fuzzy, am preferat seturi fuzzy asemenea cu cel prezentat în Figura 7 (a). Baza de reguli pentru regulatorul fuzzy este prezentată în Figura 7 (b). Din [5] am ales pentru regulatorul fuzzy următoarele setări ale lății semibazei funcției de apartenență: 2 lx pentru ε , 0,5 lx pentru $\Delta\varepsilon$ și 0,02 ms pentru Δu . Regulatorul fuzzy a fost proiectat utilizând metoda Mamdani. [2, 3]

Din [7] am ales pentru intrările regulatorului fuzzy-neuronal seturi fuzzy construite cu funcții bază B-spline de ordinul 5. Figura 8 prezintă forma funcțiilor bază B-spline de ordinul 5. Aceste funcții bază sunt relative intervalului [2, 3].

Regulatorul fuzzy-neuronal are următoarele setări: spațiul de intrare al rețelei B-spline pentru ε este [-5, 5] lx iar pentru $\Delta\varepsilon$ este [-2,5, 2,5] lx. Pentru ambele spații de intrare am ales 5 intervale.

Pentru regulatorul neuronal am ales o RNA cu trei straturi (strat de intrare, strat ascuns, strat de ieșire). Stratul de intrare are doi neuroni, stratul ascuns are șase neuroni și stratul de ieșire are un neuron. Funcția de activare (notată cu F în Figura 11) pentru neuronii din stratul ascuns este funcția sigmoid unipolară (Figura 9) și pentru neuronii din stratul de ieșire este funcția sigmoid bipolară (Figura 10).

Σ din Figura 11 reprezintă suma a doi termeni. Primul termen reprezintă produsul scalar al vectorului de intrare ($\underline{x}=(x_1 \ x_2 \ \dots \ x_n)$) cu vectorul pondere ($\underline{\omega}=(\omega_1 \ \omega_2 \ \dots \ \omega_n)^t$). Al doilea termen reprezintă produsul $1-\theta$. Ultimul termen poate fi

scris în forma $x_{n+1} \cdot \omega_{n+1}$ unde $x_{n+1}=1$ și $\omega_{n+1}=\theta$. Cu aceste notații Σ devine produsul scalar al vectorilor $\underline{x}=(x_1 \ x_2 \ \dots \ x_n \ x_{n+1})$ și $\underline{\omega}=(\omega_1 \ \omega_2 \ \dots \ \omega_n \ \omega_{n+1})^t$. Ieșirea neuronului (notată cu a în Figura 11) numită activarea neuronului reprezintă evaluarea lui $F(\Sigma)$.

Pentru antrenarea RNA am utilizat regula de învățare Delta generalizată. [2, 3, 8] Rata de învățare are valoarea de 0,95. Valorile de intrare ale RNA sunt scalate. [9]

Comportarea iluminării în spațiul de lucru și eroarea de reglare (diferența dintre iluminarea dorită și iluminarea măsurată) sunt prezentate în:

- Figurile 12, 13, 14 pentru SRAI fuzzy;
- Figurile 15, 16, 17 pentru SRAI fuzzy-neuronal;
- Figurile 18, 19, 20 pentru SRAI neuronal.

În figurile 12, 15, 18 sunt reprezentate patru traiectorii: traiectoria 1 reprezintă iluminarea (E_{daylight}) din planul de lucru datorată luminii naturale, traiectoria 2 reprezintă nivelele iluminării ($E_{\text{artificial}}$) în planul de lucru datorate iluminatului electric, traiectoria 3 reprezintă iluminarea totală (E_{measured}) din planul de lucru (suma iluminării naturale și a iluminării datorate iluminatului electric) și traiectoria 4 care reprezintă nivelul iluminare dorit (E_{desired}) în planul de lucru (o linie orizontală situată la 500lx). Traiectoria lui E_{daylight} prezintă multiple paliere situate la diferite nivele ale iluminării (500lx, 0lx, valori intermediare în intervalul (0,500)lx) și multiple fronturi crescătoare/descrescătoare. Traiectoria lui $E_{\text{artificial}}$ încearcă să aproximeze traiectoria complementară lui E_{daylight} . Suma traiectoriilor lui E_{daylight} și $E_{\text{artificial}}$, care reprezintă E_{measured} , încearcă să aproximeze traiectoria lui E_{desired} .

4. Concluzii

Când contribuția iluminării naturale descrește de la valoarea constantă maximă (500 lx) spre valori minime, eroarea de reglare va crește de-a lungul a unui număr de eșantioane. Apoi, eroarea de reglare va scădea datorită acțiunii regulatorului. Astfel vom avea o eroare maximă de reglare (un subreglaj). Așa cum se poate vedea în Figurile 14, 17 și 20, subreglajul va avea valoare mai mare pentru SRAI fuzzy-neuronal și neuronal decât pentru SRAI fuzzy. Așa cum se poate vedea în Figura 17, eroarea staționară pentru SRAI fuzzy-neuronal are o comportare oscilatorie pentru un număr de eșantioane. Din punct de vedere al teoriei automatizării, SRAI fuzzy are o comportare mai bună decât SRAI fuzzy-neuronal și neuronal deoarece eroarea de reglare nu este

oscilatorie subreglajul este mai mic. Dar din punct de vedere al percepției ochiului uman, toate SRAI au aceeași comportare, deoarece aceste comportări ale erorii de reglare nu sunt percepute. Astfel, aceste trei tipuri de SRAI cu setările prezentate în subcapitolul anterior sunt recomandate pentru acele aplicații în care din punct de vedere al percepției ochiului uman iluminarea trebuie să fie constantă la nivelul dorit în planul de lucru (ex. laboratoare de proiectare). Pentru acele aplicații în care utilizatorii doresc să simtă schimbările iluminării naturale chiar dacă este necesară menținerea nivelului dorit al iluminării în planul de lucru (ex. birouri) trebuie să

schimbați setările reguletoarelor. Pentru regulatorul fuzzy descreșteți lățimea semi-bazei funcției de apartenență pentru Δu , pentru regulatorul fuzzy-neural creșteți ordinul funcțiilor bază B-spline și pentru regulatorul neuronal descreșteți rata de învățare.

Performanța SRAI fuzzy-neural și neuronal va fi influențată de exactitatea modelului matematic invers al procesului. Astfel, pentru aceste configurații ale sistemelor de reglare automată a iluminatului SRAI fuzzy are o comportare mai bună decât celelalte două SRAI.