

Raport științific

privind implementarea proiectului în perioada ianuarie – decembrie 2014

A. SINTEZĂ GENERALĂ ASUPRA PROIECTULUI

Echipa de cercetare care a desfășurat activități de cercetare în cadrul proiectului "Noi tehnici de imbunatatire a performanțelor sistemelor de reglare automata utilizând acordarea parametrilor bazată pe experimente", contract de finanțare nr. 167 / 05.10.2011, codul de depunere PN-II-ID-PCE-2011-3-0109, <http://www.aut.upt.ro/~rprecup/grant2011.html>, este cea nominalizată în cererea de finanțare: prof.dr.ing. Radu-Emil Precup (director de proiect), prof.dr.ing. Stefan Preitl, conf.dr.ing. Florin Drăgan, as.dr.ing. Daniel Iercan, s.l.dr.ing. Mircea-Bogdan Rădac, as.dr.ing. Claudia-Adina Dragoș, dr.ing. Alexandra-Iulia Stînean, drd.ing. Lucian-Ovidiu Fedorovici.

Principalele obiective urmărite în cadrul proiectului au fost îndeplinite conform planului de activitate și sunt grupate în cele ce urmează sub forma următoarelor obiective și **activități**:

- (1) Introducerea tehnicii de acordare optimală a regulatoarelor în structuri neconvenționale de reglare automată. **Activitățile** desfășurate pentru atingerea acestui obiectiv se referă la:
 - 1.1. Utilizarea tehnicii iterative și experimentale în acordarea optimală a unor structuri de reglare automată cu regulatoare fuzzy de tip Mamdani și de tip Takagi-Sugeno. Sunt prezentate detalii în capitolul D și rezultatele aferente sunt prezentate în subcapitolul E.4.
 - 1.2. Implementarea și validarea tehnicii propuse pe echipamentele de laborator. Noile tehnici au fost validate prin simulări și experimente efectuate pe un sistem aerodinamic cu două rotoare din laboratorul în care își desfășoară activitatea echipa de cercetare.
- (2) Exploatarea și diseminarea rezultatelor. **Activitățile** desfășurate pentru atingerea acestui obiectiv, cu rezultatele prezentate în subcapitolul E.4, se referă la:
 - 2.1. Publicarea de lucrări în reviste cu factor de impact ridicat. În 2014 au fost publicate 10 lucrări, [R1],[R2] [P1] - [P7], [F1], în reviste cotate ISI cu factor de impact între 6.500 și 0.0, cu scor relativ de influență între 3.908 și 0.
 - 2.2. Participarea și publicarea de lucrări la manifestări științifice vizibile. În 2014 au fost publicate 8 lucrări științifice [R3]–[R5], [P8] - [P11], în volumele unor conferințe indexate în baze de date internaționale (INSPEC, IEEE Xplore), 2 capitole de carte, [P12], [D1], în editura Springer-Verlag.

Principalele rezultate obținute în 2014 sunt:

- 10 lucrări publicate în reviste ISI cu factor de impact, factor de impact cumulat ISI Science Citation Index (SCI) calculat conform Thomson Reuters 2013 Journal Citation Reports = **13.061**, scor relativ de influență cumulat = **11.498**.
- 8 lucrări publicate în volumele unor conferințe indexate în baze de date internaționale (INSPEC, IEEE Xplore, Scopus).
- 2 capitole de carte publicate în editura Springer-Verlag.
- O teză de doctorat, susținută în februarie 2014 de un membru al echipei, Alexandra-Iulia Stînean, sub conducerea unui alt membru al echipei, prof.dr.ing. Stefan Preitl. Teza include capitole cu rezultate raportate în cadrul proiectului.

Remarci:

1. În acest raport științific figurile și parțial relațiile au fost preluate din lucrările elaborate de echipa de cercetare. Din acest motiv pot apărea adnotări în limba engleză și, în unele cazuri, notații puțin diferite de la capitol la capitol. De fiecare dată sunt aduse însă precizările necesare pentru a face interpretările cât mai clare. Mai mult, din motive de asigurare a unei prezentări coerente a ideilor, sunt prezentate detalii privind unele rezultate din anii anteriori, care au stat la baza construirii ideilor și rezultatelor obținute în acest an.

2. Toate lucrările publicate sau în curs de publicare și care conțin rezultate de cercetare obținute în cadrul acestui proiect au menționat sprijinul CNCS – UEFISCDI în secțiunea de Acknowledgements sau în nota de subsol a primei pagini, alături de specificarea codului de depunere a cererii de finanțare.

3. Rezultatele obținute și în **pagina de web a proiectului**, <http://www.aut.upt.ro/~rprecup/grant2011.html>, unde sunt incluse link-uri către lucrările publicate.

A. ANALIZA STADIULUI ACTUAL PRIVIND CERCETĂRILE TEORETICE ȘI APlicațiile PRACTICE ALE IFT

Cele două direcții de cercetare predominante care au la bază tehnica IFT sunt: dezvoltările teoretice ale tehnicii și validarea experimentală pe procese industriale reale. Aceste direcții au mers în paralel încă de la începutul IFT în 1994.

Pe prima direcție, dacă primii opt ani de preocupări legate de IFT au fost dedicati adaptării IFT pentru o gamă largă de aplicații, perioada 2002-prezent este dedicată îmbunătățirii aspectelor particulare ale tehnicii, combinării cu alte structuri de reglare automată, plasării IFT în contextul mai general al tehniciilor bazate pe experimente pentru a oferi o viziune unificată a acestora. Aceste necesități de abordare au emanat din conștientizarea faptului că efectuarea unei acordări experimentale nu este suficientă ci este adiacentă ca și scop asigurării performanțelor prin prisma asigurării stabilității SRA, a performanțelor robuste, etc. Aceste deziderate nu pot fi îndeplinite fără o anumită cantitate de informație din interiorul buclei de reglare deci automat cunoașterea unor aspecte legate de procesul condus. S-a încercat astfel evitarea unei identificări directe a procesului condus și extragerea informațiilor semnificative prin alte abordări. În sensul definit anterior, în cele ce urmează sunt analizate sintetic câteva lucrări marcante pentru această direcție.

În [D4] se încearcă analiza convergenței algoritmului de căutare specific IFT și largirea domeniului de atracție prin procedura de „cost function shaping”. Această procedură are ca și grade de libertate în proiectare modelul de referință și intrarea de prescriere a SRA. Fără un model aproximativ al funcției de sensibilitate a buclei închise nu se poate asigura unicitatea minimului global în cadrul domeniului de atracție al algoritmului de căutare.

În [D5] stabilitatea de-a lungul iterațiilor IFT este asigurată prin asigurarea condiției suficiente ca distanța Vinnicombe („mu-gap metric”) dintre regulatorul curent și cel viitor să fie mai mică decât rezerva de stabilitate generalizată. Calculul acestor indicatori se face folosind modele neparametrice în domeniul frecvență pentru bucla închisă (deci neidentificând direct procesul condus) obținute prin analiză spectrală de corelație a semnalelor în timp discret.

În [D6] este prezentată o metodă experimentală de a estima norma infinită a unor sisteme, abordare care poate fi folosită la asigurarea stabilității SRA în timpul acordărilor iterative prin tratarea într-un cadru de analiză de stabilitate robustă.

Lucrările [D7] și [D8] sunt dedicate îmbunătățirii convergenței algoritmului de căutare al IFT folosind semnalul de referință ca și grad de libertate în proiectarea unor SRA destinate rejectării perturbațiilor.

Lucrarea [D9] este de asemenea dedicată validării stabilității SRA folosind două tipuri de teste pe bucla închisă, din care se extrag datele necesare: un test folosind răspunsul la semnal treaptă al SRA și un test folosind un criteriu similar cu criteriul Nyquist în domeniul frecvență.

În [D10] este folosit un cadru de analiză de stabilitate robustă pentru tehnici neiterative (sau într-o iterare, în genul VRFT). Sunt găsite condiții suficiente pentru asigurarea stabilității SRA folosind o versiune a teoremei amplificărilor mici, folosind de asemenea o estimare a normei infinite a unui sistem din date experimentale.

Pe direcția de cercetare care vizează aplicarea IFT, sunt amintite câteva dintre lucrările semnificative din ultimii cinci ani. IFT a fost aplicată la servosisteme (hard-disk [D11], mașini unelte [D12], control de poziție/viteză la motoare [D13], industria semiconducătorilor pentru fabricarea integratorilor [D17]), chimie (coloane de distilare [D16],[D19], actuatori de tip „Ionic Polymer Metal Composite” (IPMC) [D15],[D20]), controlul raportului aer/combustibil la motoarele cu ardere internă [D18].

B. ANALIZA STADIULUI ACTUAL PRIVIND CERCETĂRILE TEORETICE ȘI APLICAȚIILE PRACTICE ALE TEHNICILOR EXPERIMENTALE (DATA-BASED CONTROL)

Tehnicile iterative de acordare automată a regulațoarelor prin optimizare bazată pe experimente ajută la îmbunătățirea performanțelor sistemelor de reglare automată (SRA) folosind informație minimă despre procesul condus [1]–[6]. Această îmbunătățire a performanțelor SRA prin tehnici iterative este realizată prin intermediul indicatorilor de performanță care sunt simplu de interpretat de către utilizatorii neexperimentați. Indicatorii sunt specificați de regulă în domeniul timp (spre exemplu, timp de creștere, suprareglaj) și sunt încorporați în funcții obiectiv (funcții de cost sau criteriu) de tip integral sau sumă cum ar fi, de exemplu, criteriul liniar pătratic Gaussian (LQG). Minimizarea acestor funcții obiectiv (FO) formulate în general ca și probleme de optimizare cu restricții ajută la îndeplinirea anumitor obiective cum ar fi urmărirea traiectoriei de referință (sau corespunzător, în regim dynamic, urmărirea unui model de referință), penalizarea efortului comenzii, atenuarea perturbațiilor, etc.

Tehnicile principale care asigură acordarea iterativă a parametrilor regulațoarelor automate sunt Iterative Feedback Tuning (IFT), [7], Correlation-based Tuning (CbT) [8], Frequency Domain Tuning [9], Iterative Regression Tuning [10], Simultaneous Perturbation Stochastic Approximation [11], [12], Pulse Response based Control [13], Markov data-based LQG Control [14], data-driven sau data-based predictive control [15]–[17], LQ data-driven control [18] și cea mai populară tehnică neiterativă, Virtual Reference Feedback Tuning (VRFT) [19]. Aceste tehnici oferă abordări diferite în a asigura îmbunătățirea performanțelor SRA într-un cadru independent de modelul procesului condus (PC). Pe de altă parte, evitarea folosirii modelului PC nu asigură performanțe robuste, limitând analiza. Diverse abordări recente adresează tocmai această problemă încercând în același timp să folosească cât mai puțină informație despre PC. Aceste abordări evită identificarea directă a PC și folosesc informație indirectă despre PC din modele nonparametrice ale sistemului închis corespunzător SRA. Modelele obținute, cum ar fi funcțiile de răspuns în

frecvență sunt relativ ușor de obținut. Chiar și în abordarea identificării parametrice, modele de ordin redus de calitate acceptabilă pot fi folosite datorită comportamentului tipic al SRA (uzual de tip filtru trece jos) [9], [20].

Urmărirea trajectoriei de referință (RTT) reprezintă o problemă foarte des întâlnită și poate fi tratată ca o problemă de optimizare a semnalului de la intrarea de prescriere (referință) a SRA. SRA se consideră a priori acordat pentru asigurarea stabilității, respectiv a comportării în mod favorabil în raport cu perturbațiile. Astfel, problema RTT poate fi tratată ca o problemă de conducere optimală în buclă deschisă. Abordarea uzuală specifică tehnicii IFT constă în aplicarea unei căutări bazate pe informație de gradient, informație care este obținută pur experimental și fără a face uz de modelul PC. Prin similitudine, optimizarea trajectoriei de referință în mod recursive înlocuiește procedura de modificare recurrentă a parametrilor regulatorului și face uz de cadrul de analiză specific tehniciilor de tip Iterative Learning Control (ILC) [21], [22]. Tratări existente ale soluțiilor de tip ILC în problemele de conducere optimală sunt raportate în [23], [24], cu studii privind analiza de convergență în [25], abordarea în cadrul stochastic în [26] și problema RTT în [27].

În raport cu studiul actual al cercetărilor din domeniu, a fost propusă o nouă abordare pentru un algoritm pur experimental pentru asigurarea urmăririi trajectoriei de referință pentru un SRA. Algoritmul rezolvă iterativ problema de conducere optimală într-un cadrul experimental, ținând seama de restricții și de factorii aleatori care afectează rezultatele. În cadrul acestui algoritm, restricțiile de tip inegalitate definite în raport cu limitarea comenzi și în raport cu limitarea derivatei comenzi din interiorul SRA sunt exprimate și înglobate în aşa numita funcție de penalizare prin care problema de optimizare cu restricții este devine problemă de optimizare fără restricții. Avantajele în raport cu soluțiile existente sunt:

- Algoritmul funcționează pe baza experimentelor efectuate asupra SRA real; astfel, el poate compensa incertitudinile de modelare și neliniaritățile PC.
- Algoritmul folosește un număr relativ redus de experimente, soluție atractivă din punct de vedere al costurilor de implementare.

Soluția de tratare a restricțiilor atât pentru optimizarea semnalului de referință cât și pentru optimizarea parametrilor regulatorilor a fost diseminată în lucrările [R1], [R2], [R3] din subcapitolul E.4.

C. TEHNICĂ NOUĂ DE ACORDARE A REGULATOARELOR SRA CU PROCESE NELINIARE UTILIZÂND ABORDARI DE TIP IFT, ILC ȘI REȚELE NEURONALE

În anii 2013 și 2014 au fost studiate diverse probleme legate atât de îmbunătățirea tehnicii iterative cât și de combinarea acestor tehnici cu regulatoare de tip fuzzy. Astfel au fost studiate: aplicarea IFT pentru sisteme de reglare cu reacție după stare [R3], implementarea IFT pe echipament de laborator (sistem cu 3 rezervoare verticale, sistem aerodinamic) [R2],[R3], asigurarea stabilității și convergenței tehnicii IFT folosită pentru acordarea regulatorilor fuzzy [P1] și altele cu rezultate diseminate în 2013.

Fie sistemul de reglare automată (SRA) în timp discret caracterizat de ecuațiile neliniare ale procesului condus și ale regulatorului:

$$\begin{aligned} y(k) &= P(y(k-1), \dots, y(k-n_{y_1}), u(k-1), \dots, u(k-n_{u_1})) + v(k), \\ u(k) &= C(\rho, u(k-1), \dots, u(k-n_{u_2}), y(k), \dots, y(k-n_{y_2}), r(k), \dots, r(k-n_r)), \end{aligned} \quad (1)$$

în care y reprezintă mărimea de ieșire reglată, u este semnalul de intrare de comandă, r este semnalul de referință la intrarea sistemului de reglare automată, v poate fi interpretată ca și o perturbație aleatoare de medie nulă care acționează pe ieșire și poate reprezenta astfel o clasă mare de perturbații pe procesul condus, și $\rho \in \mathbb{R}^{n_p}$ este vectorul de parametri ai regulatorului. Funcțiile neliniare P și C în (1) reprezintă un model tipic neliniar auto regresiv cu intrări exogene(NARX).

Trebuie formulate câteva ipoteze în legătură cu relația (1). SRA în circuit închis se consideră stabil iar funcțiile neliniare P și C se consideră a fi netede. Fie o trajectorie nominală a sistemului de reglare notată ca $\{r_n(k), u_n(k), y_n(k)\}, k = 0 \dots N$, în care N reprezintă lungimea experimentului. Se notează în continuare variațiile în jurul trajectoriei nominale cu $\Delta r(k) = r(k) - r_n(k)$ pentru semnalul de referință, cu $\Delta u(k) = u(k) - u_n(k)$ pentru intrarea de comandă și cu $\Delta y(k) = y(k) - y_n(k)$ pentru ieșirea reglată.

Obiectivul în acordarea automată a regulatorilor este reprezentat de găsirea celor valori pentru parametrii regulatorului care reprezintă soluția unei probleme de optimizare, pornind de valoarea inițială ρ_0 a acestor parametri:

$$\begin{aligned} \rho^* &= \arg \min_{\rho \in D_S} J(\rho), \\ J(\rho) &= \frac{1}{2N} E \left\{ \sum_{k=1}^N [(y(k) - y^d(k))^2 + \lambda u^2(k)] \right\}, \end{aligned} \quad (2)$$

subject to system dynamics (1) and to some operational constraints,

în care D_s reprezintă domeniul parametrilor ρ pentru care sistemul de reglare rămâne stabil. Restricțiile operaționale pot fi introduse de cele mai multe ori sub forma restricțiilor de tip inegalitate pentru mărimile $u(k)$ și $y(k)$, și pentru derivatele acestora în raport cu timpul, $\Delta u(k)$ și respectiv $\Delta y(k)$, iar aceste restricții depind de contextul aplicației. Formularea problemei de optimizare ca în relația (2) țintește urmărirea unei traectorii de referință y^d penalizând în același timp efortul la nivelul comenzi cu o pondere $\lambda \geq 0$ care reprezintă un grad de libertate în proiectare, iar speranța matematică $E\{\dots\}$ este introdusă în raport cu perturbația aleatoare v . Pentru a rezolva această problemă de optimizare specifică relației (2) în cazul în care nu avem restricții, putem folosi un algoritm recursiv de căutare stochastică

$$\rho_{j+1} = \rho_j - \gamma_j \mathbf{R}_j^{-1} \text{est} \left\{ \frac{\partial J}{\partial \rho} \Big|_{\rho=\rho_j} \right\}, \quad (3)$$

în care direcția de căutare este conținută în estimatorul gradientului funcției obiectiv în raport cu parametrii regulatorului. În acest sens, poate fi folosită informație de ordinul doi, reprezentată spre exemplu de o aproximare de tip Gauss-Newton a Hessian-ului funcției obiectiv, în matricea \mathbf{R}_j , $j \in \mathbb{N}$ în (3) reprezintă indexul iterației curente iar $\gamma_j > 0$, reprezintă un coeficient de scalare al pasului algoritmului de căutare.

Inovația principală a IFT [1], este aceea că informația de gradient poate fi obținută din experimente speciale realizate pe bucla de reglare fără a folosi în mod explicit un model al procesului condus. În același timp însă sunt necesare regimuri de experimentare diferite de regimul nominal. Aceste experimente generează gradienții mărimilor y și u în raport cu parametrii regulatorului, adică $\partial y / \partial \rho$ și $\partial u / \partial \rho$, care apoi sunt folosite pentru a reconstituî gradientul funcției obiectiv și eventual matricea \mathbf{R}_j . Deși în tehnica IFT originală este invocată ipoteza de linearitate, aplicațiile dovedesc că tehnica funcționează și în cazul proceselor neliniare. Gradientul funcției obiectiv poate fi estimat conform [1] (subcapitolul E.3), nu prin injectarea unor mărimi în bucla de reglare, nici prin aproximarea derivelor cu diferențe finite prin modificarea parametrilor regulatorului, ci prin perturbarea traectoriei de referință nominală folosind semnale de amplitudine mică. Această abordare permite extinderea tehnicii IFT la SRA neliniare.

Această abordare are două avantaje. În primul rând, bucla de reglare nu este modificată pentru experimentele de gradient. În al doilea rând, experimentele de gradient vor fi foarte apropiate de regimul nominal astfel încât nu se pierde funcționarea cvasi-nominală a sistemului de reglare. Motivarea este reluată conform [2] (subcapitolul E.3). Fie deviațiile în jurul traectoriilor nominale exprimate după dezvoltarea în serie Taylor de forma:

$$\begin{aligned} u(k) &= u_n(k) + \sum_{i=1}^{n_u} \frac{\partial C}{\partial u(k-i)} \Big|_{\{r_n(k), u_n(k), y_n(k), \rho\}} \Delta u(k-i) + \sum_{i=0}^{n_y} \frac{\partial C}{\partial y(k-i)} \Big|_{\{r_n(k), u_n(k), y_n(k), \rho\}} \Delta y(k-i) + \sum_{i=0}^{n_r} \frac{\partial C}{\partial r(k-i)} \Big|_{\{r_n(k), u_n(k), y_n(k), \rho\}} \Delta r(k-i) \\ &+ \sum_{h=1}^{n_p} \frac{\partial C}{\partial \rho_h} \Big|_{\rho} \Delta \rho_h + h.o.t., \\ y(k) &= y_n(k) + \sum_{i=1}^{n_u} \frac{\partial P}{\partial u(k-i)} \Big|_{\{r_n(k), u_n(k), y_n(k)\}} \Delta u(k-i) + \sum_{i=0}^{n_y} \frac{\partial P}{\partial y(k-i)} \Big|_{\{r_n(k), u_n(k), y_n(k)\}} \Delta y(k-i) + h.o.t. \end{aligned} \quad (4)$$

Se presupune că o modificare relativ mică a mărimii de comandă $\{u_n(k)\}$ este generată în jurul traectoriei nominale $\{r_n(k), u_n(k), y_n(k)\}$, $k = 0 \dots N$, odată generată prin modificarea unui parametru al regulatorului ρ_h , $h = 1 \dots n_p$, și altă dată generată prin perturbarea traectoriei nominale a referinței $\{r_n(k)\}$. Dacă există o perturbație a referinței nominale, $\{\Delta r(k)\}$ care generează aceeași modificare în $\{u_n(k)\}$ ca și atunci când se modifică un parametru al regulatorului, atunci aceeași modificare apare și în jurul ieșirii nominalei $\{y_n(k)\}$ și anume $\{\Delta y(k)\}$. Termenii de ordin superior din (4) se neglijeză. Dacă se consideră ultimii doi termeni ai expresiei $u(k)$ din (4) de valoare egală, se poate deduce că:

$$\frac{\partial C}{\partial \rho_h} \Big|_{\{r_n(k), u_n(k), y_n(k), \rho\}} \Delta \rho_h = \sum_{i=0}^{n_r} \frac{\partial C}{\partial r(k-i)} \Big|_{\{r_n(k), u_n(k), y_n(k), \rho\}} \Delta r(k-i), \quad (5)$$

de unde poate fi calculată o variație a referinței nominale $\{\Delta r(k)\}$. Pentru un regulator LTI se poate arăta simplu că $\Delta r(k) = S(k) \Delta \rho_h$, cu $S(k)$ un semnal care depinde de traectoriile nominale și de parametrii regulatorului. Ideea sugerează faptul că putem experimenta sistemul de reglare în jurul traectoriilor nominale și putem obține același efect în modificările $\{u_n(k)\}$ și $\{y_n(k)\}$ ca și atunci când perturbăm un singur parametru al regulatorului.

În literatură au fost tratate două probleme în acest context, și anume numărul experimentelor de gradient care poate fi destul de mare pentru un număr mare al parametrilor regulatorului și introducerea restricțiilor în problema de optimizare originală. Algoritmul propus de echipa de cercetare arată că este posibilă reducerea sau chiar eliminarea experimentelor de gradient dar și introducerea restricțiilor operaționale prin mecanisme simple de implementat care extind tehnica curentă IFT și o fac să fie și mai atractivă pentru aplicațiile industriale.

Rețelele neuronale pot fi folosite pentru a genera informația de gradient folosind modele identificate pentru sistemul în buclă închisă deci evitând un model direct al procesului condus. Fie aceste modele de la r la y și de la r la u , exprimate sub forma:

$$y(k) = M_{ry}(y(k-1), \dots, y(n_y), r(k-1), \dots, r(n_{ry})), \quad (6)$$

$$u(k) = M_{ru}(u(k-1), \dots, u(n_u), r(k-1), \dots, r(n_{ru})). \quad (7)$$

Variabilele $\partial y / \partial p_h$ și $\partial u / \partial p_h$ pot fi estimate prin diferențe finite folosind

$$\begin{aligned} \frac{\partial \hat{y}(k)}{\partial p_h} &= \frac{\bar{y}(k, r_n + \mu_h \Delta r_h) - \bar{y}(k, r_n)}{\mu_h \Delta p_h}, \\ \frac{\partial \hat{u}(k)}{\partial p_h} &= \frac{\bar{u}(k, r_n + \mu_h \Delta r_h) - \bar{u}(k, r_n)}{\mu_h \Delta p_h}, \quad h = 1 \dots n_p, k = 0 \dots N, \end{aligned} \quad (8)$$

în care se consideră implicit $\Delta p_h = 1$ și fiecare numărător din relația (8) poate fi obținut din două simulări: una cu parametrii iterației curente a IFT, p , și una cu cel de-al h -lea parametru al regulatorului perturbat cu cantitatea $\mu_h \Delta p_h$. Scalarii μ_h se aleg automat astfel încât să asigure doar perturbații de mică amplitudine în jurul traiectoriei nominale a referinței $\{r_n(k)\}$. Variabilele \bar{y} și \bar{u} se obțin filtrând neliniar referințele nominale și cele perturbate prin aplicațiile neliniare M_{ry} și respectiv M_{ru} .

În continuare este prezentată o problemă de optimizare particulară care ilustrează introducerea restricțiilor și soluția problemei folosind un algoritm de tip Interior-Point Barrier (IPB). Fie problema de optimizare:

$$\mathbf{p}^* = \arg \min_{p \in D_S} J(\mathbf{p}), \quad J(\mathbf{p}) = \frac{1}{2N} \sum_{k=1}^N [r(k) - y(k, \mathbf{p})]^2, \quad (9)$$

$$\text{subject to } u_{\min}(k) \leq u(k, \mathbf{p}) \leq u_{\max}(k), \quad k = 1 \dots N,$$

care penalizează eroarea de urmărire a referinței $e^2(k, \mathbf{p}) = [r(k) - y(k, \mathbf{p})]^2$, cu e reprezentând eroarea de reglare. Restricțiile pot fi codificate în funcția logaritmică specifică IPB și problema devine una de optimizare fără restricții:

$$\begin{aligned} \mathbf{p}^* &= \arg \min_{p \in D_S} \tilde{J}(\mathbf{p}), \quad \tilde{J}(\mathbf{p}) = J(\mathbf{p}) + \kappa \phi(\mathbf{p}), \\ \phi(\mathbf{p}) &= -\sum_{k=1}^N \log[(u_{\max}(k) - u(k, \mathbf{p}))(u(k, \mathbf{p}) - u_{\min}(k))], \end{aligned} \quad (10)$$

cu $\phi(\mathbf{p})$ reprezentând funcția de penalizare a restricțiilor. Gradientul $\tilde{J}(\mathbf{p})$ în raport cu p_h , $h = 1 \dots n_p$, se poate estima astfel:

$$\frac{\partial \tilde{J}}{\partial p_h} = -\frac{1}{N} \sum_{k=1}^N e(k) \frac{\partial \hat{y}(k)}{\partial p_h} + \kappa \left(\sum_{k=1}^N \frac{\partial \hat{u}(k)}{\partial p_h} \cdot \frac{1}{u_{\max}(k) - u(k, \mathbf{p})} - \sum_{k=1}^N \frac{\partial \hat{u}(k)}{\partial p_h} \cdot \frac{1}{u(k, \mathbf{p}) - u_{\min}(k)} \right), \quad (11)$$

și poate fi obținut experimental cu restricțiile evaluate pentru valorile curente ale parametrilor regulatorului. Mai mult decât atât, putem folosi abordarea cu rețelele neuronale pentru a elimina complet și experimentele de gradient.

O aproximare de tip Gauss-Newton a Hessianului funcției obiectiv poate fi de asemenea obținută neglijând derivatele de ordin doi. Elementul (l, m) al matricii \mathbf{R}_j de dimensiune $n_p \times n_p$ este exprimată sub forma

$$\frac{\partial^2 \tilde{J}}{\partial p_m \partial p_l} = \frac{1}{N} \sum_{k=1}^N \frac{\partial \hat{y}(k)}{\partial p_m} \frac{\partial \hat{y}(k)}{\partial p_l} + \kappa \left(\sum_{k=1}^N \frac{\partial \hat{u}(k)}{\partial p_m} \frac{\partial \hat{u}(k)}{\partial p_l} \cdot \frac{1}{(u_{\max}(k) - u(k, \mathbf{p}))^2} + \sum_{k=1}^N \frac{\partial \hat{u}(k)}{\partial p_m} \frac{\partial \hat{u}(k)}{\partial p_l} \cdot \frac{1}{(u(k, \mathbf{p}) - u_{\min}(k))^2} \right). \quad (12)$$

D. TEHNICĂ NOUĂ DE ANTRENARE A REȚELELOR NEURONALE FOLOSIND PRINCIPII ILC

Modelele M_{ry} și M_{ru} din relațiile (6) și (7) pot fi avea structura unor rețele neurale și pot fi identificate din datele de intrare-iesire culese în jurul unei traiectorii nominale de la iterația curentă a algoritmului de optimizare a parametrilor regulatorului.

Pentru antrenarea acestor rețele neurale se poate opta pentru o strategie online (adaptivă) sau offline (de tip batch sau iterativă). Este propusă o nouă tehnică de antrenare a rețelelor neurale folosind o abordare de tip ILC. Această strategie este avantajoasă întrucât pentru optimizarea iterativă a parametrilor regulatorilor, actualizarea valorilor parametrilor se face între iterații, adică offline. Procedând astfel nu este necesară o putere de calcul mare.

Se va considera în continuare o structură de tip feedforward a unei rețele neurale cu un singur strat ascuns în care fiecare neuron este caracterizat de o funcție de activare de tip tangentă hiperbolică iar stratul de ieșire conține un singur neuron cu funcție de activare lineară. Relația între intrările și ieșirea rețelei este:

$$\hat{y}(k+1) = \mathbf{W}^T(k) \sigma(\mathbf{V}(k), \mathbf{x}(k)), \quad (13)$$

în care $\mathbf{W}^T = [w_0 \ w_1 \ \dots \ w_H] \in \mathbf{R}^{H+1}$ este vectorul ponderilor din stratul de ieșire, $\sigma^T = [1 \ \sigma_1(\mathbf{V}_1^T \mathbf{x}) \ \dots \ \sigma_H(\mathbf{V}_H^T \mathbf{x})]$ este vectorul ieșirilor neuronilor din stratul ascuns, caracterizați de funcția de activare de tip tangentă hiperbolică

$\sigma_m(x) = \tanh(x)$, $m=1..H$, iar indicele superior T indică operația de transpunere a unei matrice. Primul element al vectorului coloană σ corespunde bias-ului aferent neuronului din stratul de ieșire. Fiecare neuron din stratul ascuns este la rândul său parametrizat de către ponderile aferente conținute în vectori de tipul $(\mathbf{V}^m)^T = [v_m^0 \ v_m^1 \ ... \ v_m^{nu}] \in \mathbb{R}^{nu+1}$, $m=1..H$, care înmulțesc la rândul lor vectorul intrărilor rețelei $\mathbf{x}^T = [x_0 \ x_1 \ ... \ x_{nu}]$. Fiecare vector \mathbf{V}^m include ponderea v_m^0 aferentă bias-ului celui de-al m -lea neuron. Aici $nu+1$ reprezintă numărul intrărilor în rețea iar H este numărul neuronilor din stratul ascuns. Se consideră timpul discret indexat de $k=0..N$.

Rețeaua neurală este privită ca un sistem dinamic nelinear multivariabil la intrare și la ieșire care evoluează în domeniul iterațiilor

$$\begin{aligned} \mathbf{W}_{j+1} &= \mathbf{W}_j + \mathbf{u}_j^w, \\ \mathbf{V}_{j+1}^i &= \mathbf{V}_j^i + \mathbf{u}_j^{v^i}, i = 1..H, \\ \mathbf{Y}_j(k+1) &= \mathbf{W}_j^T \sigma(\mathbf{V}_j^i, \mathbf{x}(k)), k = 0..N, \end{aligned} \quad (14)$$

unde

$$\begin{aligned} \mathbf{u}_j^w &= [u_j^{w0} \ ... \ u_j^{wH}]^T \in \mathbb{R}^{H+1}, \\ \mathbf{u}_j^{v^i} &= [u_j^{v^i0} \ ... \ u_j^{v^{iu}}]^T \in \mathbb{R}^{nu+1}, \\ \mathbf{Y}_j &= [y_j(1) \ ... \ y_j(N+1)]^T \in \mathbb{R}^{N+1}, \\ \mathbf{X}_j &= [\mathbf{x}_j^T(0) \ ... \ \mathbf{x}_j^T(N)]^T \in \mathbb{R}^{(N+1)(nu+1)}, \end{aligned} \quad (15)$$

unde j este indicele iterației, $\mathbf{u}_j^w, \mathbf{u}_j^{v^i}$ sunt vectorii variabilor de intrare, iar vectorii ponderilor $\mathbf{W}_j, \mathbf{V}_j^i$ definiți anterior sunt priviți ca mărimi de stare ale sistemului dinamic (14). Vectorul \mathbf{X}_j poate fi tratat ca o perturbație repetitivă la fiecare iterație însă poate fi tratat și ca un parametru variabil în timp al sistemului nelinear (14). Vectorul \mathbf{Y}_j reprezintă ieșirea sistemului nelinear (14) la fiecare iterație.

Folosind cadrul de analiză oferit de tehnicele de tip ILC, sistemul dinamic (14) este privit în continuare ca și o aplicație statică dinspre intrări spre ieșiri. ILC are ca și obiectiv minimizarea erorii de urmărire dintre ieșirea de la iterația curentă și o ieșire dorită iar acest lucru se poate obține modificând intrarea în mod corespunzător, la fiecare iterație. Vectorul ieșirii dorite poate fi descris ca $\mathbf{Y}_d = [y_d(1) \ ... \ y_d(N+1)]^T \in \mathbb{R}^{N+1}$, cu $y_d(k)$ – reprezentând eșantioanele dorite ale ieșirii pentru momentele de timp $k=1..N+1$. Astfel, antrenarea de tip batch a rețelei neurale poate fi privită ca o învățare supervizată care are ca și scop minimizarea erorii de urmărire exprimată ca $\mathbf{E}_j = \mathbf{Y}_j - \mathbf{Y}_d$ și numită și eroare de antrenare. Intrarea sistemului nelinear (14) la fiecare iterație poate fi găsită ca și soluție a unei probleme de optimizare specifică ILC

$$(\mathbf{u}_j^{w*}, \mathbf{u}_j^{v^i*}) = \arg \min_{\mathbf{u}_j^w, \mathbf{u}_j^{v^i}} \|\mathbf{E}_{j+1}^T \mathbf{R} \mathbf{E}_{j+1} + \mathbf{U}_j^T \mathbf{Q} \mathbf{U}_j\|_2^2, \quad (16)$$

unde $\mathbf{U}_j = [(\mathbf{u}_j^w)^T \ (\mathbf{u}_j^{v^1})^T \ ... \ (\mathbf{u}_j^{v^H})^T]^T \in \mathbb{R}^{H+1+H(nu+1)}$ reprezintă super-vectorul tuturor intrărilor, $\mathbf{R} = \mathbf{R}^T > 0$ și $\mathbf{Q} = \mathbf{Q}^T > 0$ de dimensiuni corespunzătoare sunt matrici diagonale simetrice și pozitiv definite, $\mathbf{E}_{j+1} = \mathbf{Y}_{j+1} - \mathbf{Y}_d$ este eroarea de urmărire la iterația $j+1$, iar $\|\bullet\|$ este norma Euclideană a vectorului \bullet . Penalizarea vectorului intrărilor \mathbf{U}_j în (16) are rolul de a preveni efectul de over-fitting în antrenarea rețelei.

Abordarea clasică specifică algoritmului celor mai mici pătrate nelineare este aplicată pentru a obține soluția analitică a problemei de optimizare (9). Linearizarea ieșirilor de la iterația următoare $y_{j+1}(k+1) = \mathbf{W}_{j+1}^T \sigma(\mathbf{V}_{j+1}^i, \mathbf{x}(k))$, $k=0..N$, este efectuată în jurul valorilor stărilor/ponderilor de la iterația curentă $\mathbf{W}_j, \mathbf{V}_j^i$ pentru variații de mică amplitudine $\mathbf{u}_j^w, \mathbf{u}_j^{v^i}$ considerând ieșirea ca o funcție nelineară de ponderi $y_{j+1}(k+1) = f(\mathbf{W}_{j+1}, \mathbf{V}_{j+1}^i, \mathbf{x}(k))$, $k=0..N$, și vectorul $\mathbf{x}(k)$ ca și un vector de parametri de variație cunoscută. Dezvoltarea în serie Taylor se scrie

$$\begin{aligned} y_{j+1}(k+1) &= \mathbf{W}_j^T \sigma(\mathbf{V}_j^i, \mathbf{x}(k)) + \\ &[1 \ \tanh(\mathbf{V}_j^{1T} \mathbf{x}(k)) \ ... \ \tanh(\mathbf{V}_j^{H^T} \mathbf{x}(k))] \mathbf{u}_j^w \\ &+ w_j^1 \frac{4}{(e^{\mathbf{V}_j^{1T} \mathbf{x}(k)} + e^{-\mathbf{V}_j^{1T} \mathbf{x}(k)})^2} \mathbf{x}^T(k) \mathbf{u}_j^{v^1} + ... \\ &+ w_j^H \frac{4}{(e^{\mathbf{V}_j^{HT} \mathbf{x}(k)} + e^{-\mathbf{V}_j^{HT} \mathbf{x}(k)})^2} \mathbf{x}^T(k) \mathbf{u}_j^{v^H} + h.o.t. \end{aligned} \quad (17)$$

Întrucât $y_j(k+1) = \mathbf{W}_j^T \boldsymbol{\sigma}(\mathbf{V}_j^i, \mathbf{x}(k))$, și introducând notațiile $g_i(k) = 4/(e^{\mathbf{V}_j^{iT} \mathbf{x}(k)} + e^{-\mathbf{V}_j^{iT} \mathbf{x}(k)})^2$ și $\boldsymbol{\sigma}_j(k) = [1 \ \tanh(\mathbf{V}_j^{1T} \mathbf{x}(k)) \ \dots \ \tanh(\mathbf{V}_j^{H^T} \mathbf{x}(k))]^T$, și neglijând termenii de ordin superior din dezvoltarea (17), rezultatul este:

$$y_{j+1}(k+1) = y_j(k+1) + \boldsymbol{\sigma}_j^T(\mathbf{x}(k)) \mathbf{u}_j^w + w_j^1 g_1(k) \mathbf{x}^T(k) \mathbf{u}_j^v + \dots + w_j^H g_H(k) \mathbf{x}^T(k) \mathbf{u}_j^H. \quad (18)$$

Rescrierea relației (18) în formă vectorială prin stivuirea eșantioanelor celor $N+1$ ieșiri duce la:

$$\mathbf{Y}_{j+1} = \mathbf{Y}_j + \boldsymbol{\Psi}_j \mathbf{U}_j, \quad \boldsymbol{\Psi}_j \in \mathbb{R}^{(N+1) \times (H+1+H(nu+1))},$$

$$\boldsymbol{\Psi}_j = \begin{bmatrix} \boldsymbol{\sigma}_j^T(\mathbf{x}(0)) & w_j^1 g_1(0) \mathbf{x}^T(0) & \dots & w_j^H g_H(0) \mathbf{x}^T(0) \\ \boldsymbol{\sigma}_j^T(\mathbf{x}(1)) & w_j^1 g_1(1) \mathbf{x}^T(1) & \dots & w_j^H g_H(1) \mathbf{x}^T(1) \\ \vdots & \vdots & \vdots & \vdots \\ \boldsymbol{\sigma}_j^T(\mathbf{x}(N)) & w_j^1 g_1(N) \mathbf{x}^T(N) & \dots & w_j^H g_H(N) \mathbf{x}^T(N) \end{bmatrix}. \quad (19)$$

Întrucât $\mathbf{E}_{j+1} = \mathbf{Y}_{j+1} - \mathbf{Y}_d = \mathbf{Y}_j + \boldsymbol{\Psi}_j \mathbf{U}_j - \mathbf{Y}_d = \mathbf{E}_j + \boldsymbol{\Psi}_j \mathbf{U}_j$, problema de optimizare (16) se rescrie sub forma:

$$\mathbf{U}_j^* = \arg \min_{\mathbf{U}_j} \left\| \mathbf{U}_j^T \mathbf{X} \mathbf{U}_j + 2 \mathbf{Z} \mathbf{U}_j + \mathbf{E}_j^T \mathbf{R} \mathbf{E}_j \right\|_2^2, \quad (20)$$

$$\mathbf{X} = \boldsymbol{\Psi}_j^T \mathbf{R} \boldsymbol{\Psi}_j + \mathbf{Q}, \quad \mathbf{Z} = \mathbf{E}_j^T \mathbf{R} \boldsymbol{\Psi}_j.$$

Folosind regulile de derivare ale matricelor în raport cu vectori și observând că \mathbf{X} este o matrice simetrică deoarece matricile \mathbf{R} și \mathbf{Q} sunt simetrice, rezultă mai departe că soluția analitică a problemei de optimizare (20) este:

$$\mathbf{U}_j^* = -(\mathbf{X}^T)^{-1} \mathbf{Z}^T = -(\boldsymbol{\Psi}_j^T \mathbf{R} \boldsymbol{\Psi}_j + \mathbf{Q})^{-1} \boldsymbol{\Psi}_j^T \mathbf{R} \mathbf{E}_j = -\mathbf{K}_j \mathbf{E}_j. \quad (21)$$

Matricea \mathbf{K}_j poate fi obținută relativ ușor deoarece matricile $\boldsymbol{\Psi}_j, \mathbf{E}_j$ pot fi calculate la fiecare iterare.

Vectorul intrărilor optimale conține de fapt corecțiile aplicate ponderilor rețelei neurale. Folosind partitioarea $\mathbf{K}_j = [\mathbf{K}_j^{wT} \ \mathbf{K}_j^{v^T} \ \dots \ \mathbf{K}_j^{H^T}]^T$ cu dimensiunile matricilor $\mathbf{K}_j^w \in \mathbb{R}^{(H+1) \times (N+1)}$, $\mathbf{K}_j^{v^i} \in \mathbb{R}^{(nu+1) \times (N+1)}$, primele două ecuații de stare din (14) pot fi recrise, utilizând (21), sub forma:

$$\mathbf{W}_{j+1} = \mathbf{W}_j - \mathbf{K}_j^w \mathbf{E}_j, \quad (22)$$

$$\mathbf{V}_{j+1}^i = \mathbf{V}_j^i - \mathbf{K}_j^{v^i} \mathbf{E}_j.$$

Legile de actualizare (22) sunt de tip ILC deoarece depind de eroarea de la iterarea curentă. Rezolvând problema de optimizare (16) la fiecare iterare corespunzătoare antrenării rețelei, schema de învățare este privită ca și o problema de tip ILC. Formularea problemei de optimizare (16) specifică ILC este foarte generală permitând penalizarea unor corecții de amplitudine mare aplicate ponderilor rețelei și astfel oferă un grad de libertate suplimentar în antrenarea rețelei.

Rezultatele acestei noi abordări în antrenarea rețelelor neurale a fost diseminat în cadrul lucrărilor [R1] și [R2] din subcapitolul E.4.

E. BIBLIOGRAFIE

E.1. Bibliografie aferentă capitolului A

- [D1] H. Kwakernaak "Robust control and H_∞ optimization - Tutorial paper," Automatica, vol. 29, pp. 255–273, March 1993.
- [D2] H. Bourlés "A local small gain theorem for discrete-time systems," in Proc. 33rd IEEE Conf. Decision and Control, Lake Buena Vista, FL, USA, 1994, vol. 3, pp. 2137–2138.
- [D3] M.-B. Rădac, R.-E. Precup, E. M. Petriu, St. Preitl, and R.-C. David, "Stable Iterative Feedback Tuning method for servo systems," in Proc. 20th IEEE International Symposium on Industrial Electronics (ISIE 2011), Gdansk, Poland, 2011, pp. 1943–1948.
- [D4] A.S. Bazanella, M. Gevers, L. Miskovic, and B.D.O. Anderson, "Iterative minimization of H_2 control performance criteria," Automatica, vol. 44, pp. 2549–2559, Oct. 2008.
- [D5] L.C. Kammer, "Stability assessment for cautious iterative controller tuning," Automatica, vol. 41, pp. 1829–1834, Oct. 2005.
- [D6] B. Wahlberg, M. Barenthin Syberg, and H. Hjalmarsson, "Non-parametric methods for L_2 -gain estimation using iterative experiments," Automatica, vol. 46, pp. 1376–1381, Aug. 2010.
- [D7] J. K. Huusom, H. Hjalmarsson, N.K. Poulsen, and S.B. Jørgensen, "A design algorithm using external perturbation to improve Iterative Feedback Tuning convergence," Automatica, vol. 47, pp. 2665–2670, 2011.
- [D8] J.K. Huusom, N.K. Poulsen, and S.B. Jørgensen, "Improving convergence of Iterative Feedback Tuning," Journal of Process Control, vol. 19, pp. 570–578, Apr. 2009.

- [D9] A. Dehghani, A. Lecchini-Visintini, A. Lanzon, and B.D.O. Anderson, "Validating Controllers for Internal Stability Utilizing Closed-Loop Data," *IEEE Trans. on Automatic Control*, vol. 54(11), pp. 2719-2725, 2009.
- [D10] K. van Heusden, A. Karimi, D. Bonvin, "Data-driven model reference control with asymptotically guaranteed stability," *International Journal of Adaptive Control and Signal Processing*, vol. 25(4), pp. 331-351, 2011.
- [D11] A. Al Mamun, W.Y. Ho, W.E. Wang, and T.H. Lee, "Iterative Feedback Tuning (IFT) of hard disk drive head positioning servomechanism," in Proc. 33rd Annual Conference of the IEEE Industrial Electronics Society (IECON 2007), Taipei, Taiwan, 2007, pp. 769-774.
- [D12] A.E. Graham, A.J. Young, and S.Q. Xie, "Rapid tuning of controllers by IFT for profile cutting machines," *Mechatronics*, vol. 17, pp. 121-128, Mar.-Apr. 2007.
- [D13] S. Kissling, Ph. Blanc, P. Myszkowski and I. Vaclavik, "Application of Iterative Feedback Tuning (IFT) to speed and position control of a servo drive," *Control Engineering Practice*, vol. 17, pp. 834-840, Jul. 2009.
- [D14] F.N. Koumboulis, M.P. Tzamtzi, and C.E. Economakos, "Control of a constant turning force system via step-wise safe switching Iterative Feedback Tuning," in Proc. 2008 IEEE International Conference on Emerging Technologies and Factory Automation (ETFA 2008), Hamburg, Germany, 2008, pp. 1416-1424.
- [D15] A.J. McDaid, K.C. Aw, S.Q. Xie, and E. Haemmerle, "Gain scheduled control of IPMC actuators with 'model-free' Iterative Feedback Tuning," *Sensors and Actuators A: Physical*, vol. 164, pp. 137-147, Dec. 2010.
- [D16] J.K. Huusom, N.K. Poulsen, and S.B. Jørgensen, "Iterative feedback tuning of uncertain state space systems," *Brazilian Journal of Chemical Engineering*, vol. 27, pp. 461-472, Sep. 2010.
- [D17] M. Heertjes, D. Hennekens, and M. Steinbuch, „MIMO feed-forward design in wafer scanners using a gradient approximation-based algorithm," *Control Engineering Practice*, vol. 18(5), pp. 495-506, 2010.
- [D18] D. Rupp and L. Guzzella, "Iterative Tuning of Internal Model Controllers With Application to Air/Fuel Ratio Control," *IEEE Transactions on Control Systems Technology*, vol. 18(1), pp. 177-184, 2010.
- [D19] S. Sommer, P. Muller, and A. Kienle, "Iterative Feedback Tuning of PID Controllers for Reactive Distillation Processes: a Comparison with Relay Feedback Tuning," *Industrial and Engineering Chemistry Research*, vol. 50(16), pp. 9821-9828, 2011.
- [D20] D. Liu, A.J. McDaid, K.C. Aw, and S.Q. Xie, "Position control of an Ionic Polymer Metal Composite actuated rotary joint using Iterative Feedback Tuning," *Mechatronics*, vol. 21(1), pp. 315-328, 2011.

E.2. Bibliografie aferentă capitolului B

- [1] M. Ikeda, Y. Fujisaki, and N. Hayashi, "A model-less algorithm for tracking control based on input-output data," *Nonlinear Anal. Theory Methods Appl.*, vol. 47, pp. 1953–1960, Aug. 2001.
- [2] I. Markovsky and P. Rapisarda, "Data-driven simulation and control," *Int. J. Control*, vol. 81, pp. 1946–1959, Dec. 2008.
- [3] M. Helle and H. Saxén, "Data-driven analysis of sulfur flows and behavior in the blast furnace," *Steel Res. Int.*, vol. 79, pp. 671–677, Sep. 2008.
- [4] J. Zeng, C. Gao, and H. Su, "Data-driven predictive control for blast furnace ironmaking process," *Comput. Chem. Eng.*, vol. 34, pp. 1854–1862, Nov. 2010.
- [5] D. Wang, "Robust data-driven modeling approach for real-time final product quality prediction in batch process operation," *IEEE Trans. Ind. Informat.*, vol. 7, pp. 371–377, May 2011.
- [6] C. Gao, L. Jian, X. Liu, and J. Chen, "Data-driven modeling based on Volterra series for multidimensional blast furnace system," *IEEE Trans. Neural Netw.*, vol. 22, pp. 2272–2283, Dec. 2011.
- [7] H. Hjalmarsson, M. Gevers, S. Gunnarsson, and O. Lequin, "Iterative feedback tuning: theory and applications," *IEEE Control Syst. Mag.*, vol. 18, pp. 26–41, Aug. 1998.
- [8] A. Karimi, L. Miskovic, and D. Bonvin, "Iterative correlation-based controller tuning," *Int. J. Adapt. Control Signal Process.*, vol. 18, pp. 645–664, Oct. 2004.
- [9] L. C. Kammer, "Stability assessment for cautious iterative controller tuning," *Automatica*, vol. 41, pp. 1829–1834, Oct. 2005.
- [10] R.-E. Precup, C. Borchescu, M.-B. Rădac, S. Preitl, C.-A. Dragoş, E. M. Petriu, and J. K. Tar, "Implementation and signal processing aspects of iterative regression tuning," in Proc. 2010 IEEE International Symposium on Industrial Electronics (ISIE 2010), Bari, Italy, 2010, pp. 1657–1662.
- [11] J. C. Spall and J. A. Cristion, "Model-free control of nonlinear stochastic systems with discrete-time measurements," *IEEE Trans. Autom. Control*, vol. 43, pp. 1198–1210, Sep. 1998.
- [12] M.-B. Rădac, R.-E. Precup, E. M. Petriu, and S. Preitl, "Application of IFT and SPSA to servo system control," *IEEE Trans. Neural Netw.*, vol. 22, pp. 2363–2375, Dec. 2011.
- [13] J. K. Bennighof, S.-H. Chang, and M. Subramaniam, "Minimum time pulse response based control of flexible structure," *J. Guid. Control Dyn.*, vol. 16, pp. 874–881, Oct. 1993.
- [14] G. Shi and R. E. Skelton, "Markov data-based LQG control," *J. Dyn. Syst. Meas. Control*, vol. 122, pp. 551–559, Sep. 2000.

- [15] R. Kadali, B. Huang, and A. Rossiter, "A data driven subspace approach to predictive controller design," *Control Eng. Pract.*, vol. 11, pp. 261–278, Mar. 2003.
- [16] X. Wang, B. Huang, and T. Chen, "Data-driven predictive control for solid oxide fuel cells," *J. Process Control*, vol. 17, pp. 103–114, Feb. 2007.
- [17] X. Lu, H. Chen, P. Wang, and B. Gao, "Design of a data-driven predictive controller for start-up process of AMT vehicles," *IEEE Trans. Neural Netw.*, vol. 22, pp. 2201–2212, Dec. 2011.
- [18] W. Favoreel, B. De Moor, P. van Overschee, and M. Gevers, "Model-free subspace-based LQG-design," in *Proc. 1999 American Control Conference*, San Diego, CA, USA, 1999, vol. 5, pp. 3372–3376.
- [19] M. C. Campi, A. Lecchini, and S. M. Savarese, "Virtual reference feedback tuning: a direct method for the design of feedback controllers," *Automatica*, vol. 38, pp. 1337–1346, Aug. 2002.
- [20] M.-B. Rădac, R.-E. Precup, E. M. Petriu, S. Preitl, and R.-C. David, "Stable iterative feedback tuning method for servo systems," in *Proc. 20th IEEE International Symposium on Industrial Electronics (ISIE 2011)*, Gdansk, Poland, 2011, pp. 1943–1948.
- [21] D. A. Bristow, M. Tharayil, and A. G. Alleyne, "A survey of iterative learning control," *IEEE Control Syst. Mag.*, vol. 26, pp. 96–114, Jun. 2006.
- [22] H.-S. Ahn, Y. Chen, and K. L. Moore, "Iterative learning control: brief survey and categorization," *IEEE Trans. Syst., Man, Cybern. C, Appl. Rev.*, vol. 37, pp. 1109–1121, Nov. 2007.
- [23] D. H. Owens and J. Hätönen, "Iterative learning control – an optimization paradigm," *Annu. Rev. Control*, vol. 29, pp. 57–70, Apr. 2005.
- [24] S. Gunnarsson and M. Norrlöf, "On the design of ILC algorithms using optimization," *Automatica*, vol. 37, pp. 2011–2016, Dec. 2001.
- [25] M. Norrlöf and S. Gunnarsson, "Time and frequency domain convergence properties in iterative learning control," *Int. J. Control*, vol. 75, pp. 1114–1126, Sep. 2002.
- [26] M. Butcher, A. Karimi, and R. Longchamp, "Iterative learning control based on stochastic approximation," in *Proc. 17th IFAC World Congress*, Seoul, Korea, 2008, pp. 1478–1483.
- [27] H.-F. Chen and H.-T. Fang, "Output tracking for nonlinear stochastic systems by iterative learning control," *IEEE Trans. Autom. Control*, vol. 49, pp. 583–588, Apr. 2004.

E.3. Bibliografie aferentă capitolului C

- [1] J. Sjöberg, F. De Bruyne, M. Agarwal, B.D.O. Anderson, M. Gevers, F. J. Kraus, and N. Linard, "Iterative controller optimization for nonlinear systems," *Control Eng. Pract.*, vol. 11, pp. 1079–1086, Sep. 2003.
- [2] J. Sjöberg, P.-O. Gutman, M. Agarwal, and M. Bax, "Nonlinear controller tuning based on a sequence of identifications of linearized timevarying models," *Control Eng. Pract.*, vol. 17, no. 2, pp. 311–321, Feb. 2009.

E.4. BIBLIOGRAFIE PROPIE (în 2014)

- lucrări publicate în reviste ISI cu factor de impact:

- [R1] M.-B. Rădac, R.-E. Precup (corresponding author), E. M. Petriu and St. Preitl, Iterative Data-Driven Tuning of Controllers for Nonlinear Systems with Constraints, *IEEE Transactions on Industrial Electronics*, vol. 61, no. 4, pp. 6360-6368, 2014, impact factor (IF) = 6.500, relative influence score = 3.908.
- [P1] R.-E. Precup, R.-C. David, E. M. Petriu, M.-B. Rădac and St. Preitl, Adaptive GSA-Based Optimal Tuning of PI Controlled Servo Systems With Reduced Process Parametric Sensitivity, Robust Stability and Controller Robustness, *IEEE Transactions on Cybernetics*, vol. 44, no. 11, pp. 1997-2009, 2014, impact factor (IF) = 0.000, relative influence score = 3.240, which corresponds to the previous name of the journal, *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*.
- [P2] R.-E. Precup, R.-C. David, E. M. Petriu, St. Preitl and M.-B. Rădac, Novel Adaptive Charged System Search Algorithm for Optimal Tuning of Fuzzy Controllers, *Expert Systems with Applications* (Elsevier Science), vol. 41, no. 4, part 1, pp. 1168-1175, 2014, impact factor (IF) = 1.965, relative influence score = 1.250.
- [P3] Cl. Pozna, R.-E. Precup (corresponding author) and P. Földesi, A novel pose estimation algorithm for robotic navigation, *Robotics and Autonomous Systems* (Elsevier Science), DOI: 10.1016/j.robot.2014.09.034, 2014, impact factor (IF) = 1.105, relative influence score = 1.597.
- [P4] R.-E. Precup, E. M. Petriu, M.-B. Rădac, St. Preitl, L.-O. Fedorovici and C.-A. Dragoş, Cascade control system-based cost effective combination of tensor product model transformation and fuzzy control, *Asian Journal of Control* (John Wiley and Sons), DOI: 10.1002/asjc.855, 2014, impact factor (IF) = 0.000, relative influence score = 0.000.
- [P5] R.-E. Precup and M. L. Tomescu, Stable fuzzy logic control of a general class of chaotic systems, *Neural Computing and Applications* (Springer-Verlag), DOI: 10.1007/s00521-014-1644-7, 2014, impact factor (IF) = 1.763, relative influence score = 0.511.

- [P6] R.-E. Precup, M.-L. Tomescu and C.-A. Dragoş, Stabilization of Rössler chaotic dynamical system using fuzzy logic control algorithm, International Journal of General Systems (Taylor & Francis), vol. 43, no. 5, pp. 413-433, 2014, impact factor (IF) = 0.786, relative influence score = 0.464.
- [P7] Cl. Pozna and R.-E. Precup, Applications of Signatures to Expert Systems Modelling, Acta Polytechnica Hungarica (Óbuda University), vol. 11, no. 2, pp. 21-39, 2014, impact factor (IF) = 0.471, relative influence score = 0.264.
- [F1] R. S. Fantana, N. Minculete and R.-E. Precup, Extension of Liskov Substitution Principle and Application to Curriculum Management, Acta Polytechnica Hungarica (Óbuda University), vol. 11, no. 7, pp. 25-42, 2014, impact factor (IF) = 0.471, relative influence score = 0.264.
- [R2] M.-B. Rădac, R.-E. Precup (corresponding author), E. M. Petriu and St. Preitl, Iterative Data-Driven Controller Tuning with Actuator Constraints and Reduced Sensitivity, Journal of Aerospace Information Systems (The American Institute of Aeronautics and Astronautics), vol. 11, no. 9, pp. 551-564, 2014, impact factor (IF) = 0.000, relative influence score = 0.000.

- lucrări publicate în volumele unor conferințe indexate în baze de date internaționale:

- [P8] R.-E. Precup, M.-B. Rădac, C.-A. Dragoş, St. Preitl and E. M. Petriu, Model-Free Tuning Solution for Sliding Mode Control of Servo Systems, Proceedings of 8th Annual IEEE International Systems Conference SysCon 2014, Ottawa, ON, Canada, pp. 30-35, 2014, ISI Proceedings.
- [R3] M.-B. Rădac, R.-E. Precup and E. M. Petriu, Design and Testing of a Constrained Data-Driven Iterative Reference Input Tuning Algorithm, Proceedings of 2014 European Control Conference ECC 2014, Strasbourg, France, pp. 2034-2039, 2014, INSPEC.
- [P9] R.-E. Precup, A.-L. Borza, M.-B. Rădac and E. M. Petriu, Bacterial Foraging Optimization Approach to the Controller Tuning for Automotive Torque Motors, Proceedings of IEEE 23rd International Symposium on Industrial Electronics ISIE 2014, Istanbul, Turkey, pp. 972-977, 2014, INSPEC.
- [P10] R.-E. Precup, A.-L. Borza, M.-B. Rădac and E. M. Petriu, Performance Analysis of Torque Motor Systems with PID Controllers Tuned by Bacterial Foraging Optimization Algorithms, Proceedings of 2014 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications CIVEMSA 2014, Ottawa, ON, Canada, pp. 141-146, 2014, INSPEC.
- [P11] R.-E. Precup, R.-C. David, A.-I. Stînean, M.-B. Rădac and E. M. Petriu, Adaptive Hybrid Particle Swarm Optimization-Gravitational Search Algorithm for Fuzzy Controller Tuning, Proceedings of 2014 IEEE International Symposium on Innovations in Intelligent Systems and Applications INISTA 2014, Alberobello, Italy, pp. 14-20, 2014, INSPEC.
- [R4] R.-C. Roman, M.-B. Rădac and R.-E. Precup, Data-Driven Model-Free Adaptive Control of Twin Rotor Aerodynamic Systems, Proceedings of IEEE 9th International Symposium on Applied Computational Intelligence and Informatics SACI 2014, Timisoara, Romania, 2014, pp. 25-30, INSPEC.
- [S1] A.-I. Stînean, St. Preitl, R.-E. Precup and M. Crainic, Study on Experimental Plant of Positioning Control Solutions for Processes with Variable Moment of Inertia, Proceedings of IEEE 9th International Symposium on Applied Computational Intelligence and Informatics SACI 2014, Timisoara, Romania, 2014, pp. 37-42, INSPEC.
- [R5] M.-B. Rădac, R.-C. Roman, R.-E. Precup and E. M. Petriu, Data-Driven Model-Free Control of Twin Rotor Aerodynamic Systems: Algorithms and Experiments, Proceedings of 2014 IEEE International Symposium on Intelligent Control ISIC 2014 Part of 2014 IEEE Multi-conference on Systems and Control IEEE MSC 2014, Antibes, France, pp. 1889-1894, 2014, IEEE Catalog Number (ISIC): CFP14INS-USB, to be indexed in INSPEC.

- capitole de carte publicate în editura Springer-Verlag:

- [P12] St. Preitl, R.-E. Precup, Z. Preitl, A.-I. Stînean, M.-B. Rădac and C.-A. Dragoş, Control Algorithms for Plants Operating Under Variable Conditions, Applications, in: Advances in Soft Computing, Intelligent Robotics and Control, J. Fodor and R. Fuller, Eds., Topics in Intelligent Engineering and Informatics, vol. 8 (Springer-Verlag), pp. 3-39, 2014.
- [D1] R.-C. David, R.-E. Precup, E. M. Petriu, St. Preitl, M.-B. Rădac and L.-O. Fedorovici, Adaptive Evolutionary Optimization Algorithms for Simple Fuzzy Controller Tuning Dedicated to Servo Systems, in: Fuzzy Modeling and Control: Theory and Applications, F. Matia, G. N. Marichal and E. Jimenez, Eds., Atlantis Computational Intelligence Systems, vol. 9 (Atlantis Press and Springer-Verlag), pp. 159-173, 2014.