

Raport științific intermediar al contractului PN-II-RU-TE-2014-4-0207

privind implementarea proiectului în perioada ianuarie – decembrie 2016

A. SINTEZĂ GENERALĂ ASUPRA PROIECTULUI

Echipa de cercetare care a desfășurat activități de cercetare în cadrul proiectului "Tehnici de învățare pentru îmbunătățirea performanțelor sistemelor de conducere automată folosind abordări de tip model-free", contract de finanțare nr. 130/01.10.2015, codul de depunere PN-II-RU-TE-2014-4-0207, <http://www.mbradac.info/te2015.html>, este cea nominalizată în cererea de finanțare: ș.l.dr.ing. Mircea-Bogdan Rădac (director de proiect), prof.dr.ing. Radu-Emil Precup, as.dr.ing. Alexandra-Iulia Stînean, drd.ing. Constantin Purcaru, drd.ing. Raul-Cristian Roman.

Principalele obiective urmărite în cadrul proiectului în anul 2016 au fost îndeplinite conform planului de activitate și sunt grupate în cele ce urmează sub forma următoarelor obiective și **activități**:

- (1) Dezvoltarea cadrului teoretic necesar implementării mecanismelor de învățare pentru sisteme de reglare automată – continuare an 2015. **Activitățile** desfășurate pentru atingerea acestui obiectiv se referă la:
 - 1.1. Construcția bibliotecilor de primitive ce vor fi optimizate și a planificatorului de sarcini. Sunt prezentate detalii în studiu din secțiunea C.1.
 - 1.2. Validarea abordărilor teoretice prin simulări numerice și experimente pe echipamente de laborator. Cîteva rezultate sunt de asemenea prezentate succint în secțiunea C.1.
 - 1.3. Extinderea tehnicilor propuse la sisteme multivariabile. Rezultatele aferente sunt prezentate în cadrul tehnicilor din secțiunea C.1.
- (2) Dezvoltarea tehnicilor de acordare a regulatoarelor de tip model-free – continuare an 2015. **Activitățile** desfășurate pentru atingerea acestui obiectiv se referă la:
 - 2.1. Formularea a noi tehnici de tip model-free data-based control. Rezultate aferente unei noi tehnici de acordare automată a unor regulatoare de tip model-free adaptive sunt prezentate în secțiunea C.2.
 - 2.2. Validarea tehnicilor propuse prin simulări numerice și experimente pe echipamente de laborator. Rezultatele de validare experimentală sunt prezentate în secțiunea C.2.
- (3) Exploatarea și diseminarea rezultatelor cercetării. Activitățile prevăzute pentru acest obiectiv redate în secțiunea D.2. se referă la:
 - 3.1. Publicarea în reviste cu factor de impact. Au rezultat un număr de 4 lucrări publicate în reviste ISI cu factor de impact, [R1]–[R4] factor de impact cumulat ISI Science Citation Index (SCI) calculat conform Thomson Reuters 2016 Journal Citation Reports = 6.816, scor relativ de influență cumulat = 5.155, precum și 1 capitol de carte la editura Springer [R5].
 - 3.2. Participarea și prezentarea rezultatelor cercetării la conferințe importante din domeniu. Au rezultat 8 lucrări [R6]–[R9], [P1]–[P2], [B1], [H1], publicate în volumele unor conferințe indexate în baze de date internaționale (INSPEC, IEEE Xplore, Scopus, DBLP).

Pentru **anul 2016** livrabilele propuse în cadrul planului de realizare al proiectului sunt: raportul de cercetare intermediar prezent, **2 lucrări** științifice publicate în reviste ISI cu factor de impact, **2 lucrări** publicate în volumele unor conferințe, în reviste sau sub formă de capitole de carte indexate în baze de date internaționale.

Principalele rezultate obținute în 2016 sunt:

- **4 lucrări** publicate în reviste ISI cu factor de impact, factor de impact cumulat ISI Science Citation Index (SCI) calculat conform Thomson Reuters 2014 Journal Citation Reports = **6.816**, scor relativ de influență cumulat = **5.155**.
- **8 lucrări** publicate în volumele unor conferințe indexate în baze de date internaționale (INSPEC, IEEE Xplore, Scopus, DBLP).
- **1 capitol de carte** la editura Springer International Publishing.
- **1 raport științific**.

Remarci:

1. În acest raport științific figurile și partea 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 diferite de la capitol la capitol. De fiecare dată sunt aduse însă precizările necesare pentru a face interpretările cât mai clare. 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 sunt menționate și în pagina de web a proiectului, <http://www.mbradac.info/te2015.html>, unde vor fi incluse toate informațiile legate de desfășurarea proiectului și rezultatele obținute.

B. STUDIU AL CADRULUI TEORETIC NECESAR IMPLEMENTĂRII MECANISMELOR DE ÎNVĂȚARE PENTRU SISTEME DE REGLARE AUTOMATĂ. STUDIU PRIVIND DIVERSELE TIPURI DE FUNCȚII DE BAZĂ CE POT FI FOLOSITE PENTRU APROXIMARE

Progresele recente înregistrate în tehnologiile informatiche de prelucrare a datelor, dezvoltarea capabilităților de stocare a istoriei de funcționare a proceselor industriale, precum și dezvoltarea fără precedent a echipamentelor de măsurare, au oferit un impuls major de dezvoltare a unei noi abordări de proiectare și optimizare a funcționării sistemelor de conducere automată folosind cantități mari de date. Aceste tehnici aparțin unui nou val de abordări care are ca scop înzestrarea sistemelor de conducere automată cu principii și mecanisme specifice inteligenței artificiale. Astfel, principiile învățării automate pot fi aplicate cu succes la metodele clasice de prelucrare a semnalelor și proiectare a sistemelor de reglare automată. Scopul acestor sisteme inteligente de conducere este de a oferi un grad sporit de autonomie și adaptabilitate sistemelor de conducere actuale și astfel de a rezolva probleme precum modelarea imprecisă/incompletă, restricții operaționale de funcționare, nelinearități, probleme de scalabilitate și distribuție, probleme legate de numărul mare de variabile, care pot afecta performanțele acestor sisteme de conducere.

Tehnicile mai sus amintite și denumite mai departe **Data-based** (sau **data-driven**) includ și abordări recente de optimizare iterativă (învățare) a funcționării sistemelor de reglare automată folosind cât mai puține informații despre procesul condus. Aceste abordări sunt etichetate ca și **model-free** și au următoarele particularități: sunt iterative/non-iterative în domeniul experimentelor (altfel spus, nu sunt adaptive în cadrul unui singur experiment), sunt bazate pe date culese de pe procesul real, calculele specifice învățării sunt efectuate offline, nu necesită putere de calcul și nu sunt critice în timp, iar mecanismele acestui tip de învățare pot fi pornite și opuse în orice moment. Câteva situații practice care beneficiază de pe urma acestor tehnici sunt: diferențele dintre model și proces compromit performanțele, perturbațiile parametrice aplicate în timp îndelungat deteriorează de asemenea performanțele, apar modificări ale performanțelor impuse (specificațiile de performanță).

Acordarea parametrilor regulațoarelor automate în medii cu restricții, în paradigma data-based control (DbC), țintește îmbunătățirea performanțelor sistemelor de reglare automată (SRA) atunci când unele mărimi/variabile din sistem sunt supuse restricțiilor. Pot fi amintite aici tehnici precum **Iterative Feedback Tuning** (IFT, Hjalmarsson et al., 1994), **Virtual Reference Feedback Tuning** (VRFT, Campi et al., 2000), **Iterative Regression Tuning** (IRT, Halmevaara and Hyotyniemi, 2006), **Frequency Domain Tuning** (FDT, Kammer et al., 2000), **Correlation-based Tuning** (CbT, Karimi et al., 2004) and **Simultaneous Perturbation Stochastic Approximation** (SPSA, Spall, 1988).

Alte abordări similare DbC sunt **Model-free Control** (MFC, Gedouin et al., 2011), **Model-free Adaptive Control** (MFAC, Hou et al. 2011a, 2011b), **Iterative Learning Control** (ILC, Norloff et al., 2002; Bristow et al., 2006,), **Unfalsified Control** (Safonov et al., 1997), **Pulse Response based Control** (Bennighof et al., 1993), **Model-Free predictive control** (Kadali et al., 2003, Wang et al., 2007), **Reinforcement Learning for control** (Busoniu et al., 2008) sau **Approximate Dynamic Programming** (Al-Tamimi et al., 2008).

Sistemele actuale autonome de conducere necesită să fie înzestrate cu mecanisme ale inteligenței artificiale și trebuie să dețină capabilități de planificare și învățare la nivelul ierarhic superior față de cel aferent funcțiilor de conducere de bază (urmărirea referinței și rejecția perturbațiilor). Necesitatea este indicată clar în (Report, 2011) ca și ară majoră de cercetare.

Importanța inducerii unui comportament de învățare pentru sistemele de reglare este motivată de cercetări recente în domeniul manevrabilității sporite a dronelor (Flying Machine Arena, ETH Zurich), hipermanevrabilitatea elicopterelor (Stanford AI Lab), autoturismul fără pilot uman (Google Driverless Car), diversi roboți (în particular, mobili) care îmbunătățesc execuțiile sarcinilor prin învățare prin planificare, urmărire, evitarea ciocnirilor și obstacolelor.

În robotică, spre exemplu, traectoriile trebuie executate cu mare precizie. Execuția poate fi îmbunătățită, de exemplu, prin ILC. Este indus, astfel, un comportament de învățare specific organismelor vii care funcționează similar. Însă organismele vii extind experiența acumulată prin învățare prin fenomenul de predicție care presupune optimizarea *a priori* a execuției unei sarcini astfel ca încă de la prima execuție organismul o execută foarte aproape de soluția optimală (suboptimală). Este important, însă, că organismele vii nu rezolvă ecuații matematice pentru acest scop ci îmbină experiența execuțiilor anterioare ale unor sarcini de bază numite primitive pe care apoi le

recompun pentru a oferi o execuție suboptimală din prima încercare. Creierul biologic este responsabil pentru soluția de optimizare *a priorică* (Mussa-Ivaldi et al., 2004).

În literatură, **învățarea folosind primitive** este de trei tipuri: transformări de scară de timp, concatenarea temporală a primitivelor și abordarea bazată pe descompunere temporală. *Transformările de scară de timp* sunt tratate în (Ijspeert et al., 2002; Kawamura et al., 2002). *Concatenările temporale* ale primitivelor sunt raportate în (Schöllig et al., 2011) unde fezabilitatea primitivelor este testată pentru drone UAV. Mecanismul de computare a primitivelor folosește tehnici de descompunere în serii Fourier a semnalelor. Conceptul de bibliotecă de primitive este sugerat în (Hoelzle et al., 2011), unde o pereche de intrare de referință-iesire controlată caracterizează fiecare primitivă iar aceste perechi sunt învățate folosind ILC. Un algoritm de căutare A* pentru concatenarea temporală optimă a primitivelor este propus în (Grymin et al., 2014). *Descompunerea temporală* este analizată în (Wang et al., 2014). Primitivele folosite conțin funcții de tip B-spline.

Obiectivul principal al cercetărilor din cadrul contractului este de a dezvolta uneltele, algoritmii și cadrul teoretic necesar pentru implementarea unui comportament de învățare-predicție pentru SRA, folosind tehnici de tip model-free descrise anterior. Bucile de reglare de la nivelul ierarhic inferior pot fi proiectate folosind tehnici model-free precum IFT, VRFT, MFC. Cu regulatorul fixat, urmărirea unei traectorii prin optimizarea semnalului de referință poate fi rezolvată prin tehnica model-free ILC. Perechile intrare de referință-iesire reglată denumite primitive vor fi memorate într-o bibliotecă. Aceste primitive vor fi apoi folosite în predicția execuției optimale a unei noi sarcini care nu a fost efectuată anterior. Această predicție va utiliza ipoteza de linearitate invariantă în timp (LTI) a sistemelor de reglare implicate. Abordarea va fi validată pe diverse echipamente de laborator.

Au fost identificate următoarele **dificultăți care pot afecta abordarea propusă**:

- i) Mediile cu restricții (de exemplu, restricții de tip inegalitate (RTI) pe comandă și/sau pe derivata comenzi, RTI pe eroarea de reglare, etc.);
- ii) Este de așteptat ca abordarea propusă să funcționeze și pentru sisteme ușor nelineare care pot fi bine aproximărate cu sisteme LTI în vecinătatea unor puncte de funcționare;
- iii) Extensia la SRA de tip MIMO ar putea fi extinsă înănd seama de particularitățile aferente;
- iv) Analiza stabilității buclei de reglare pentru unele dintre tehniciile de proiectare model-free poate fi problematică atunci când nu există modele ale proceselor; există doar tehnici indirekte de asigurare a stabilității acordării.

Tehnicile pentru acordarea iterativă de tip model-free în medii cu restricții sunt dezvoltate de echipa sa de cercetare. Alte tehnici pentru acordarea SRA pe procese nelineare precum și îmbunătățirea celor existente sunt, de asemenea, în curs de dezvoltare de către echipa de cercetare.

Abordările curente în literatura de specialitate **nu folosesc tehnici de tip model-free** pentru mecanisme de învățare bazate pe primitive. Deci tema proiectului propus va beneficia de avantajele utilizării tehniciilor de tip model-free dezvoltate de echipa de cercetare atunci când trebuie îmbunătățită performanța SRA fără modele/cu modele imprecise. Abordarea este puternic motivată de comportamentul organismelor vii care învăță fără a utiliza modele matematice explicite.

Metodologia cercetării având ca și scop dezvoltarea mecanismelor de învățare automată folosind conceptul de primitive:

Tehnicile state-of-the-art de tip iterativ/adaptiv model-free vor fi folosite pentru proiectarea și acordarea regulatoarelor de bază utilizând spre exemplu IFT, VRFT, MFC. În continuare, SRA fixat va fi considerat de tip LTI. Apoi intrările de referință-iesirile controlate vor fi tratate ca și perechi de **intrare-iesire ce vor constitui primitivele de execuție**. Referințele vor fi optimizate folosind tehnica model-free ILC (Radac et al., 2014d). Optimizarea va fi efectuată în contextul unei probleme de urmărire a unei traectorii de referință pentru sisteme LTI și poate fi rezolvată printr-un algoritm de căutare bazat pe informație de gradient, în care gradientul este obținut experimental, fără model al procesului condus (și nici al SRA). Vor fi necesare în acest sens operații de filtrare non-cauzală efectuate offline (experimental) și va fi utilizată notația supervectorială (liftată) specifică ILC. Datorită numărului foarte mare de variabile de optimizare (sute de eșantioane ale intrării de referință per experiment) dimensiunea vectorului de variabile de optimizare va fi redus prin aproximarea cu funcții radiale de bază (RBF, spline, polinomiale, Fourier, etc.) astfel încât optimizarea (învățarea) să aibă loc într-un spațiu de dimensiune redusă.

Iesirile primitivelor vor fi apoi tratate ca **funcții de bază** folosite în aproximarea temporală a noilor traectorii de urmărit denumite **sarcini complexe**. Folosind principiul **superpoziției** care caracterizează sistemele LTI, **intrarea de referință optimală predictată** va fi calculată prin **combinarea intrărilor de referință ale primitivelor**. Aceasta este principala contribuție din propunerea de proiect curentă. Vor fi abordate mai multe studii de caz privind posibilități de aproximare folosind și alte tipuri de funcții de bază (RBF, polinomiale, spline, Fourier, etc.). **Biblioteca de primitive** va fi astfel construită încât să stocheze perechile de primitive amintite mai sus. **Planificatorul de sarcini** va

avea rolul descompunerii sarcinilor complexe și recomponerii referințelor optimale predictate. Mecanismul de învățare-predicție astfel dezvoltat acționează la nivelul ierarhic superior față de cel aferent funcțiilor de conducere de bază (urmărirea referinței și rejecția perturbațiilor).

Tehnica de învățare propusă va fi extinsă și la SRA de tip **MIMO**. Având în vedere că unele procese pot fi bine aproximăte în vecinătatea unor puncte de funcționare cu sisteme LTI, tehnica propusă va fi extinsă și la **sisteme ușor nelineare**. Validarea tehnicii propuse va fi efectuată prima dată pe studii de caz de simulare numerică iar apoi pe echipamente de laborator în diverse aplicații (control al mișcării control al nivelului/presiunii, sisteme aerodinamice, control al temperaturii, macarale 3D etc.).

Dezvoltarea paralelă continuă a tehnicii de acordare a parametrilor regulatoarelor în reacție poate fi urmată fără nicio problemă și fără riscuri. Noile tehnici de tip VRFT, IFT și MFC vor fi dezvoltate astfel încât să poată adresa nelinearități ale proceselor (zone de insensibilitate, histerezis, saturatie) precum și alte restricții operaționale.

În contextul conducerii bazată pe conceptul de primitive, un mecanism asemănător ca și funcționalitate este reprezentat de Dynamic Movement Primitives (DMPs) care este des răspândit în robotică. Acest mecanism are ca și scop primar calculul unui semnal de referință care prescris către un sistem de reglare de bază ar asigura urmărirea traectoriei. Totuși, nici acest mecanism nu este unul de tip-model free, pentru că nu ia în considerare dinamica buclei de reglare de nivel inferior. Deși semnalul de referință al DMP este obținut în mod ușor ca și o soluție a unei probleme de conducere optimală care face uz de un model al procesului condus, semnalul este aproimat, de regulă, prin funcții radiale de bază. Avantajul major al acestui mecanism este acela că poate fi scalat ușor atât în timp cât și în amplitudine (spațiu) astfel că permite execuția unei traectorii învățate într-o gamă diversificată de setări de tip viteza de execuție. Ca și exemplu în acest sens, lucrarea (Tomic et al., 2014) propune o strategie de interpolare între soluții de tip DMP obținute optimal, pentru îmbunătățirea manevrabilității sistemelor de tip quadrocopter (dronă).

Într-o primă fază, pornind de la modelul planar al quadrocopterului și ipotezând că este de tip "differentially flat", rezultă că intrările de comandă pot fi calculate din acceleratiile dorite și pe cale de consecință doar ieșirea controlată (poziție) precum și derivatele acesteia este suficientă pentru reproducerea unei manevre.

Problema de optimizare de bază presupune aflarea comenzi optimale care asigură execuția în timp minim a unui anumit tip de manevră (translație, tumbă, deplasare point to point), sub anumite restricții pentru stări și pentru capetele traectoriei (initial și final) privind poziția și viteza. Problema este rezolvată deci în paradigma model-based folosind un solver GPOPS (care implementează o metodă pseudospectrală de tip Gauss) disponibil ca și toolbox Matlab. Pentru fiecare manevră particulară pentru care sunt găsite astfel comenzi și traectoriile de stare optimale, este codificată apoi primitiva de execuție sub forma unui DMP corespunzător. Pentru fiecare grad de libertate de mișcare (care este și o stare a sistemului dinamic) este învățat căte un DMP. DMP reprezintă astfel un planificator de nivel înalt care codifică traectoriile de referință pentru sistemul de reglare de bază.

În formalismul DMP, o componentă de tip perturbator (ea nu este o perturbație pentru sistemul de comandă al manevrei și pentru procesul condus ci pentru ecuația diferențială care modelează DMP) este învățată astfel încât să asigure o traectorie dorită între un punct initial și un punct final, pe fiecare axă de mișcare. Punctul final (țintă) este un punct atrăctor stabil pentru ecuația DMP-ului care este modelat ca un sistem de tip masă-resort-amortizor de ordinul 2. Perturbația f este codificată apoi prin aproximare folosind RBFs prin regresie liniară. Perturbația f care trebuie aproximată este calculată din ecuația DMP-ului. Codificarea are drept rezultat ponderile RBF-ului (în particular ponderile din stratul de ieșire al acestui tip particular de rețea neurală) denumite în continuare parametrii DMP.

Generalizarea execuției manevrelor este posibilă printr-un mecanism de interpolare. Astfel, pentru fiecare manevră optimală codificată printr-un DMP, este creat un spațiu (rețea) de (hiper)-puncte de tip țintă, iar pentru fiecare punct este stocată durata dorită a traectoriei și parametrii DMP-ului. Prin urmare, se presupune că fiecare tip de manevră a fost efectuată la diferite viteze și parametrii DMP-ului au fost obținuți corespunzător. Astfel pentru orice punct țintă nou, care nu este regăsit între punctele stocate, un DMP corespunzător este obținut prin interpolare biliniară a parametrilor punctelor rețelei. Abordarea este funcțională dacă rețeaua de puncte este fin discretizată și dacă hipersuprafața rețelei de puncte este netedă. Este important însă să fie folosite pentru aproximare aceleasi RBF-uri ca și funcții de bază.

Remarcă:

a) Optimizarea execuției unor manevre punct la punct este specifică și tehniciilor de tip ILC la care, totuși, de obicei este pus accentul pe partea de urmărire optimală a unei traectorii prin optimizarea unui semnal de referință la intrarea buclei de reglare. Tehnicile de tip ILC consideră însă dinamica sistemului de reglare de bază (dinamica procesului atunci când conducerea este efectuată în buclă deschisă) și au în plus comportament anticipativ. Acest fapt este datorat comportamentului de natură iterativă a tehniciilor de tip ILC și este caracterizat prin „salturi” noncauzale ale semnalelor de referință ILC.

b) Codificarea semnalelor de referință în tehniciile ILC este posibilă și are drept scop reducerea dimensionalității acestora (Radac and Precup, 2015a; Radac and Precup, 2015b). Cel mai des întâlnită codificare este cea bazată pe

aproximare folosind funcții radiale de bază (RBF), funcții spline, funcții polinomiale, etc. Din acest punct de vedere, comparația cu codificarea termenului perturbator specific DMP este justificată.

c) Există tehnici de tip model-free ILC (Radac et al., 2013c, 2014a, 2014d) dezvoltate în cadrul teoretic al sistemelor liniare invariante în timp (LTI) pentru care poate fi realizată predicția unor soluții optimale de urmărire și prin extrapolare și nu doar prin interpolare (Radac and Precup, 2015b), exploatajând astfel teoria sistemelor LTI. Din acest punct de vedere, poate fi acceptată superioritatea tehniciilor de tip ILC în generalizarea unor soluții optimale.

C.1. SISTEM DE CONDUCERE IERARHIZAT BAZAT PE TEHNICI DE TIP MODEL-FREE ITERATIVE LEARNING CONTROL ȘI TEHNICI DE TIP MODEL-FREE ADAPTIVE CONTROL

Fie un sistem de reglare automată (SRA) în buclă închisă, de tip MIMO pătratic 2x2, cu orientarea de la intrările de referință (r.i.) la ieșirile controlate, descris de operatorul de tip matrice de transfer $T(q) \in \mathbb{R}^{2 \times 2}$:

$$\begin{pmatrix} y_1(t_d) \\ y_2(t_d) \end{pmatrix} = \begin{pmatrix} T_{11}(q) & T_{12}(q) \\ T_{21}(q) & T_{22}(q) \end{pmatrix} \begin{pmatrix} r_1(t_d) \\ r_2(t_d) \end{pmatrix} = T(q) \begin{pmatrix} r_1(t_d) \\ r_2(t_d) \end{pmatrix}, \quad (C1.1)$$

$$y_{t_d} = (y_1(t_d) \dots y_2(k))^T, \quad r_{t_d} = (r_1(t_d) \dots r_2(t_d))^T,$$

cu y_{t_d} ieșirile controlate și r_{t_d} sunt r.i. Condițiile inițiale nenule și perturbațiile repetitive pot fi absorbite în termenii y_1^d, y_2^d fără a afecta generalitatea formulării problemei. Notația în formă liftată specifică ILC a relației (C1.1) este

$$\begin{pmatrix} y_n \\ y_{n+1} \\ \vdots \\ y_{N-n} \end{pmatrix} = \begin{pmatrix} t_1 & 0 & \dots & 0 \\ t_2 & t_1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ t_{N-n} & t_{N-n-1} & \dots & t_1 \end{pmatrix} \begin{pmatrix} r_0 \\ r_1 \\ \vdots \\ r_{N-n-1} \end{pmatrix}, \quad (C1.2)$$

În (C1.2), $t_i \in \mathbb{R}^{2 \times 2}$, $i=1\dots N-n$ reprezintă coeficienții răspunsului la impuls a SRA MIMO notați în forma compactă în matricea $T \in \mathbb{R}^{2(N-n) \times 2(N-n)}$. Relația (C1.2) se poate scrie ca $\mathbf{Y} = \mathbf{TR}$ notând $\mathbf{Y} = (y_n^T \dots y_{N-n}^T)^T$ și $\mathbf{R} = (r_0^T \dots r_{N-n-1}^T)^T$. Sub același formalism de notație avem $\mathbf{Y}^d = [(y_n^d)^T \dots (y_{N-n}^d)^T]^T$. Cu $\tilde{\mathbf{W}}_i = \text{diag}(\mathbf{W}_i, \mathbf{W}_i, \dots)$, $\tilde{\mathbf{W}}_i \in \mathbb{R}^{2(N-n) \times 2(N-n)}$, $i \in \{1,2\}$, problema de optimizare (PO) de urmărire a unei traectorii de referință cu termen de regularizare a amplitudinii referinței se definește ca

$$\mathbf{R}^* = \arg \min_{\mathbf{R}} J(\mathbf{R}) = \frac{1}{N} (\|\mathbf{Y}(\mathbf{R}) - \mathbf{Y}^d\|_{\tilde{\mathbf{W}}_1}^2 + \|\mathbf{R}\|_{\tilde{\mathbf{W}}_2}^2), \quad (C1.3)$$

Funcția obiectiv (FO) din (C1.3) este pătratică și convexă în raport cu \mathbf{R} deci argumentul care o minimizează este

$$\mathbf{R}^* = (\mathbf{T}^T \tilde{\mathbf{W}}_1 \mathbf{T} + \tilde{\mathbf{W}}_2)^{-1} \mathbf{T}^T \tilde{\mathbf{W}}_1 \mathbf{Y}^d, \quad (C1.4)$$

Propunem în continuare o rezolvare experimentală a PO (C1.3) prin acordarea simultană și în paralel a r.i. aferente celor două canale de reglare de tip SISO cu dinamică cuplată. Cele două PO aferente SRA de tip SISO sunt

$$r_1^*(t_d) = \arg \min_{r_1(t_d)} J_1 \left(\begin{pmatrix} r_1(t_d) \\ r_2(t_d) \end{pmatrix} \right) = \frac{1}{N} \sum_{\tau=0}^{N-n-1} (\|\varepsilon_1(\tau+n)\|_{\tilde{\mathbf{W}}_1}^2 + \|r_1(\tau)\|_{\tilde{\mathbf{W}}_2}^2), \quad r_2^*(t_d) = \arg \min_{r_2(t_d)} J_2 \left(\begin{pmatrix} r_1(t_d) \\ r_2(t_d) \end{pmatrix} \right) = \frac{1}{N} \sum_{\tau=0}^{N-n-1} (\|\varepsilon_2(\tau+n)\|_{\tilde{\mathbf{W}}_1}^2 + \|r_2(\tau)\|_{\tilde{\mathbf{W}}_2}^2), \quad (C1.5)$$

Cele două PO (C1.5) pot fi scrise în notație liftată ca

$$\mathbf{R}^{(0)*} = \arg \min_{\mathbf{R}^{(0)}} J_i(\mathbf{R}^{(0)}, \mathbf{R}^{(0)}) = \frac{1}{N} (\|\mathbf{Y}^{(0)} - \mathbf{Y}^{(0)d}\|_{\tilde{\mathbf{W}}_i}^2 + \|\mathbf{R}^{(0)}\|_{\tilde{\mathbf{W}}_i}^2), \quad (C1.6)$$

cu $\mathbf{R}^{(0)} \in \mathbb{R}^{N-n}$, $i \in \{1,2\}$ fiind notațiile liftate pentru $r_i(t_d)$, $i \in \{1,2\}$, $\mathbf{Y}^{(0)} \in \mathbb{R}^{N-n}$, $i \in \{1,2\}$ fiind notațiile liftate pentru $y_i(t_d)$, $i \in \{1,2\}$, $\mathbf{Y}^{(0)d} \in \mathbb{R}^{N-n}$, $i \in \{1,2\}$ fiind notațiile liftate pentru $y_i^d(t_d)$, $i \in \{1,2\}$, cu matricile de ponderare $\tilde{\mathbf{W}}_1^{(0)} = \text{diag}(\mathbf{W}_1, \mathbf{W}_1, \dots)$, $\tilde{\mathbf{W}}_1^{(0)} \in \mathbb{R}^{(N-n) \times (N-n)}$, $\tilde{\mathbf{W}}_2^{(0)} = \text{diag}(\mathbf{W}_2, \mathbf{W}_2, \dots)$, $\tilde{\mathbf{W}}_2^{(0)} \in \mathbb{R}^{(N-n) \times (N-n)}$. Fie $\mathbf{T}^{(m,0)} \in \mathbb{R}^{(N-n) \times (N-n)}$, $i, m \in \{1,2\}$ notățiile liftate a funcțiilor de transfer (f.d.t) $T_m(q)$, $i, m \in \{1,2\}$, construite din coeficienții răspunsului la impuls corespunzător acestor f.d.t. A schemă iterativă de căutare bazată pe informație de gradient pentru rezolvarea PO (C1.6) este

$$\mathbf{R}_{j+1}^{(0)} = \mathbf{R}_j^{(0)} - \gamma_j^{(0)} \tilde{\mathbf{H}}_{y_j}^{-1} \text{est} \left\{ \frac{\partial J_i}{\partial \mathbf{R}^{(0)}} \Bigg|_{\mathbf{R}=\mathbf{R}_j^{(0)}} \right\}. \quad (C1.7)$$

Aici, j este indexul iterației (incercării curente), $\text{est} \left\{ \frac{\partial J_i}{\partial \mathbf{R}^{(0)}} \Bigg|_{\mathbf{R}=\mathbf{R}_j^{(0)}} \right\}$, $i \in \{1,2\}$ este un estimat al gradientului FO în raport cu

variabilele $\mathbf{R}^{(0)}$, evaluat la variabilele din iterația curentă, $\tilde{\mathbf{H}}_{y_j}^{-1}$, $i \in \{1,2\}$ pot fi aproximări de tip Gauss-Newton ale Hessian-ului FO, dar de obicei sunt alese ca matricea unitate pentru considerante de simplitate practică, iar $\gamma_j^{(0)}$ sunt coeficienții de amplitudine a pasului de căutare. O inițializare tipică a algoritmului de căutare (C1.7) poate fi aleasă ca $\mathbf{R}_0^{(0)} = \mathbf{Y}^{(0)d}$, $i \in \{1,2\}$. Gradientii FO J_i , $i \in \{1,2\}$ din (C1.7) sunt exprimabili sub forma

$$\left. \frac{\partial J_j}{\partial \mathbf{R}_j^{(m)}} \right|_{\mathbf{R} = \mathbf{R}_j^{(1)}} = \frac{2}{N} \mathbf{T}^{(l,m)} \tilde{\mathbf{W}}_1^{(m)} \mathbf{E}_j^{(m)} + \frac{2}{N} \tilde{\mathbf{W}}_2^{(m)} \mathbf{R}_j^{(m)}, \quad (C1.8)$$

Prin aplicarea regulilor de derivare a matricilor în raport cu vectori, $\mathbf{E}_j^{(m)} = \mathbf{T}^{(l,m)} \mathbf{R}_j^{(m)} + \mathbf{T}^{(l,m)} \mathbf{R}_j^{(m)} - \mathbf{Y}_j^{(l,m)}$, $m \in \{1,2\}$, $m \neq l$, reprezintă erorile de urmărire ale iterației curente j . Al doilea termen din (C1.8) depinde de valoarea cunoscută a $\mathbf{R}_j^{(m)}$ la iterația curentă, în timp ce primul termen al relației (C1.8) depinde de mărimea necunoscută $\mathbf{T}^{(l,m)}$. O soluție pentru calculul acestui prim termen al relației (C1.8) este redată în continuare. Soluția folosește o operație de filtrare noncauzală. Fie operația de inversare a unui vector $\Psi \in \mathbb{R}^{N-n}$ definită ca

$$fip(\Psi) = fip([\Psi(0) \dots \Psi(N-n-1)]^T) = [\Psi(N-n-1) \dots \Psi(0)]^T. \quad (C1.9)$$

Următorii pași trebuie efectuați la fiecare iterație a algoritmului de căutare de mai sus:

Pasul 1. Un experiment normal (nominal) este efectuat la iterația curentă j , cu r.i. $\mathbf{R}_j^{(0)}$, înregistrând erorile de urmărire $\mathbf{E}_j^{(0)} = \mathbf{Y}_j^{(0)} - \mathbf{Y}_j^{(0,d)} = \mathbf{T}^{(l,0)} \mathbf{R}_j^{(0)} + \mathbf{T}^{(l,m,0)} \mathbf{R}_j^{(m,0)} - \mathbf{Y}_j^{(l,0)}$. Termenul $\tilde{\mathbf{W}}_1^{(0)} \mathbf{E}_j^{(0)}$ este apoi direct obținut pentru fiecare $i \in \{1,2\}$, $m \in \{1,2\}$, $m \neq i$.

Pasul 2. Cel de-al doilea vector r.i. $\mathbf{R}_j^{(1)}$ este păstrat constant și privit ca și perturbație pentru primul canal de reglare de tip SISO. Atunci $\mu_1 \cdot fip(\tilde{\mathbf{W}}_1^{(0)} \mathbf{E}_j^{(0)})$, cu μ_1 un scalar nenul, este folosit ca și perturbație de amplitudine mică peste vectorul r.i. nominal $\mathbf{R}_j^{(0)}$, și ieșirea reglată a SRA MIMO, $\mathbf{Y}_G^{(1)}$, este înregistrată în acest prim experiment de gradient ca fiind definită de relația $\mathbf{Y}_G^{(1)} = \mathbf{T}^{(1,0)} (\mathbf{R}_j^{(0)} + \mu_1 \cdot fip(\tilde{\mathbf{W}}_1^{(0)} \mathbf{E}_j^{(0)})) + \mathbf{T}^{(2,0)} \mathbf{R}_j^{(1)}$.

Step 3. Primul vector r.i. $\mathbf{R}_j^{(1)}$ este păstră constant și tratat ca și perturbație pentru cel de-al doilea canal de reglare de tip SISO. Atunci $\mu_2 \cdot fip(\tilde{\mathbf{W}}_1^{(2)} \mathbf{E}_j^{(2)})$, cu μ_2 scalar nenul, este folosit ca și perturbație de mică amplitudine peste vectorul r.i. nominal $\mathbf{R}_j^{(2)}$, și ieșirea reglată a SRA MIMO $\mathbf{Y}_G^{(2)}$, este înregistrată în acest al doilea experiment de gradient ca fiind complet definit de relația $\mathbf{Y}_G^{(2)} = \mathbf{T}^{(2,2)} (\mathbf{R}_j^{(2)} + \mu_2 \cdot fip(\tilde{\mathbf{W}}_1^{(2)} \mathbf{E}_j^{(2)})) + \mathbf{T}^{(1,2)} \mathbf{R}_j^{(1)}$.

Pasul 4. Termenii $\mathbf{T}^{(1,0)^T} \tilde{\mathbf{W}}_1^{(0)} \mathbf{E}_j^{(0)}$ și $\mathbf{T}^{(2,2)^T} \tilde{\mathbf{W}}_1^{(2)} \mathbf{E}_j^{(2)}$ sunt calculați ca

$$\begin{aligned} \mathbf{T}^{(1,0)^T} \tilde{\mathbf{W}}_1^{(0)} \mathbf{E}_j^{(0)} &= (1/\mu_1) \cdot fip(\mathbf{Y}_G^{(1)} - \mathbf{Y}_j^{(0)}), \\ \mathbf{T}^{(2,2)^T} \tilde{\mathbf{W}}_1^{(2)} \mathbf{E}_j^{(2)} &= (1/\mu_2) \cdot fip(\mathbf{Y}_G^{(2)} - \mathbf{Y}_j^{(2)}). \end{aligned} \quad (C1.10)$$

Termenii (C1.10) sunt folosiți pentru a reconstrui gradienții (C1.8) care apoi folosesc în relațiile iterative (C1.7). Soluțiile PO independente (C1.6) vor constitui soluția PO MIMO originală (C1.3). Astfel perechile r.i.-ieșiri controlate vor putea fi stocate în memorie ca și comportamente optimizate. Termenul de regulaizare în FO (C1.3) este deosebit de util în cazul în care procesul condus sau SRA au caracter de fată neminimă.

Mai departe, comportamentul optimal de urmărire a unei noi traiectorii de referință nemaiîntâlnită în raport cu PO (C1.3) este obținut prin extrapolarea comportamentelor aferente perechilor de primitive sotcate în memorie, referinte mai departe simplu ca și primitive. R.i. ale fiecărei perechi de primitive sunt în continuare denumite ca primitive de intrare, iar ieșirile controlate ale fiecărei perechi de primitive sunt mai departe referite ca și primitive de ieșire. Fie P perechi de primitive descrise în notația în timp $\{\mathbf{r}_{t_d}^p, \mathbf{y}_{t_d \rightarrow n}^p\}_{t_d=0 \dots N-n-1}$ sau $\{\mathbf{R}^p, \mathbf{Y}^p\}$, $p=1 \dots P$ în forma liftată,

fiecare pereche reprezentând soluția PO

$$\mathbf{R}^p = \arg \min_{\mathbf{R}} J(\mathbf{R}) = \frac{1}{N} (\|\mathbf{T} \mathbf{R} - \mathbf{Y}^p\|_{\tilde{\mathbf{W}}_1}^2 + \|\mathbf{R}\|_{\tilde{\mathbf{W}}_2}^2), \quad p=1 \dots P. \quad (C1.11)$$

Considerăm ca fiecare din cele P PO în (C1.11) sunt rezolvate folosind algoritmul de tip model-free ILC descris mai sus. Pentru a rezola PO (C1.3) folosind primitivele $\{\mathbf{R}^p, \mathbf{Y}^p\}$, $p=1 \dots P$ care rezolvă (C1.11), fie $\mathbf{w} = (w_1 \dots w_p)^T \in \mathbb{R}^P$ proiecția traiectoriei noi dorite spre a fi urmărite \mathbf{Y}^d pe spațiul primitelor de ieșire $\{\mathbf{Y}^p | p=1 \dots P\}$. Atunci

$$\mathbf{Y}^d = \sum_{p=1}^P w_p \mathbf{Y}^p = (\mathbf{Y}^1 \ \mathbf{Y}^2 \ \dots \ \mathbf{Y}^P) \mathbf{w}. \quad (C1.12)$$

Teorema 1. Fie \mathbf{Y}^p , $p=1 \dots P$, primitivele de ieșire ale PO (C1.11) și proiecția vectorului \mathbf{Y}^d în spațiul primitelor de ieșire este $\mathbf{w} \in \mathbb{R}^P$ din (C1.12). Atunci soluția PO (C1.3) este

$$\mathbf{R}^+ = \sum_{p=1}^P w_p \mathbf{R}^p. \quad (C1.13)$$

Demonstrație: Deoarece este oferită în [R7], și folosește ipoteza de liniar invariante în timp a SRA.

Primitivele de ieșire $\mathbf{Y}^p \in \mathbb{R}^{2(N-n)}$ din (C1.12) sunt considerate ca și funcții de bază folosite în aproximare și proiecția lui $\mathbf{Y}^d \in \mathbb{R}^{2(N-n)}$ în spațiul vectorilor \mathbf{Y}^p este \mathbf{w} . Dacă primitivele de ieșire ale SRA MIMO sunt exprimate ca și funcții radiale de bază de forma $y_i(t_d) = a_i e^{-j\omega_d t_d - j\phi_i t_d^2 / 2}$, $i \in \{1,2\}$, atunci fiecare primitivă de ieșire P este construită din ieșirile

SRA MIMO $\mathbf{y}_{t_s} = [y_1(t_s) \ y_2(t_s)]^T$ scrisă în forma liftată ca și \mathbf{Y}^p , $p=1..P$. Aici a_i , c_i și s_i reprezintă amplitudinea, centrul și lărgimea lui $y_i(t_s)$ (adică a celei de-a i^{th} -a ieșire reglată), și T_s este perioada de eşantionare. Se presupune că primitivele de intrare \mathbf{R}^p , $p=1..P$ rezolvă PO (C1.11), oferind perechile de primitive $\{\mathbf{R}^p, \mathbf{Y}^p\}$, $p=1..P$.

Notația pentru o pereche de primitive deplasată în timp este $\{\mathbf{R}_{d_p}^0, \mathbf{Y}_{d_p}^0\}_{p=1..P}^{0=1..Q}$, adică fiecare pereche de primitive originală indexată de $0=1..Q$ este deplasată în timp cu d_p , cu $p=1..P$ indexând de fapt numărul total de primitive folosite în aproximare. Atunci (C1.12) se scrie $\mathbf{Y}^d = \sum_{p=1}^P w_p \mathbf{Y}_{d_p}^0 \}_{p=1..P}^{0=1..Q}$, care în notație indexată în timp este

$$\mathbf{y}_{t_d}^d = \sum_{p=1}^P w_p \mathbf{y}_{t_d-d_p}^0 = \sum_{p=1}^P w_p q^{-d_p} \mathbf{y}_{t_s}^0 = \sum_{p=1}^P w_p q^{-d_p} \mathbf{T}(q) \mathbf{r}_{t_s}^0 = \mathbf{T}(q) \sum_{p=1}^P w_p q^{-d_p} \mathbf{r}_{t_s}^0 = \mathbf{T}(q) \sum_{p=1}^P w_p \mathbf{r}_{t_d-d_p}^0 = \mathbf{T}(q) \mathbf{r}_{t_d}^0, \quad 0=1..Q, \quad p=1..P, \quad (C1.14)$$

cu $\{\mathbf{r}_{t_s}^*, \mathbf{y}_{t_d}^d\}$ reprezentând notația temporală pentru $\{\mathbf{R}^*, \mathbf{Y}^d\}$.

Relația (C1.14) sugerează că soluția PO (C1.3) rezulă prin combinarea primitivelor de intrare originale întârziate, prin combinație liniară folosind ponderile $\mathbf{w} = [w_1 \ w_2 \ ... \ w_P]^T$. $\mathbf{r}_{t_d}^* = \sum_{p=1}^P w_p \mathbf{r}_{t_d-d_p}^0$ în (C1.14) este notația în timp a soluției PO (C1.3).

Se poate merge chiar mai departe prin codificarea primitiveelor de intrare folosind alte funcții radiale de bază (RBF) astfel încât întreaga învățare a acestor primitive de intrare să se desfășoare într-un subspațiu mai restrâns.

C.2. TEHNICĂ DE ACORDARE AUTOMATĂ A PARAMETRILOR UNUI REGULATOR DE TIP MODEL-FREE ADAPTIV FOLOSIND TEHNICA VIRTUAL REFERENCE FEEDBACK TUNING

MFAC este proiectat folosind modelul nelinear al procesului în timp discret:

$$\mathbf{y}(k+1) = \mathbf{f}(\mathbf{y}(k), \dots, \mathbf{y}(k-n_y), \mathbf{u}(k), \dots, \mathbf{u}(k-n_u)), \quad (C2.1)$$

unde $\mathbf{y}(k) = [y_1(k) \ y_2(k)]^T \in \mathbb{R}^{2x1}$ este vectorul ieșirii regulate, $\mathbf{y}(k) = [y_1(k) \ y_2(k)]^T \in \mathbb{R}^{2x1}$ este vectorul de comandă al intrărilor, T reprezintă notația pentru operația de transpunerea a matricelor, n_y și n_u reprezintă ordinele necunoscute ale procesului iar \mathbf{f} este o funcție vectorială nelineară, $\mathbf{f}: \mathbb{R}^{2(n_y+n_u+2)} \rightarrow \mathbb{R}^2$. Derivatele parțiale ale lui \mathbf{f} , în ceea ce privește elementele vectorului $\mathbf{u}(k)$ (adică intrările comenzi) sunt presupuse ca fiind continue.

Întrucât Compact Form Dynamic Linearization (CFDL) este cel cea mai populară versiune a MFAC, în această lucrare este abordată doar versiunea CFDL. Rezultatele pot fi extinse și pentru alte versiuni de asemenea. Matricea PPD $\Phi(k)$ există astfel încât (C2.1) poate fi transformat în următorul model de date CFDL-MFAC:

$$\Delta \mathbf{y}(k+1) = \Phi(k) \Delta \mathbf{u}(k), \quad (C2.2)$$

în care $\Phi(k) = [\phi_{ij}(k)]_{i,j \in \{1,2\}}$, $\|\Phi(k)\| \leq b$. Aceste condiții privind $\Phi(k)$ sunt îndeplinite doar dacă modelul din (C2.1) este generalizat Lipschitz, adică, $\|\Delta \mathbf{y}(k+1)\| \leq b \|\Delta \mathbf{u}(k)\|$ pentru fiecare moment de timp discret k fix, și $\|\Delta \mathbf{u}(k)\| \neq 0$, cu $\Delta \mathbf{y}(k+1) = \mathbf{y}(k+1) - \mathbf{y}(k)$, $\Delta \mathbf{u}(k) = \mathbf{u}(k) - \mathbf{u}(k-1)$ și $b = \text{const} > 0$.

Obiectivul MFAC este rezolvarea problemei de optimizare:

$$\mathbf{u}^*(k) = \arg \min_{\mathbf{u}(k)} J_{MFAC}(\mathbf{u}(k)), \quad (C2.3)$$

$$J_{MFAC}(\mathbf{u}(k)) = \|\mathbf{y}^*(k+1) - \mathbf{y}(k+1)\|^2 + \lambda \|\Delta \mathbf{u}(k)\|^2,$$

unde $\mathbf{y}^*(k+1) = [y_1^*(k+1) \ y_2^*(k+1)]^T$ este vectorul semnalului de referință iar $\lambda \geq 0$ este un coeficient de ponderare. Această estimată a lui $\Phi(k)$ este calculată folosind datele de intrare/ieșire ale procesului, această matrice ar trebui să fie diagonal dominantă și mărginită:

$$|\phi_{ij}(k)| \leq b_1, \quad b_2 \leq |\phi_{ij}(k)| \leq a b_2, \quad i, j \in \{1, 2\}, \quad i \neq j, \quad a \geq 1, \quad b_2 > b_1(2a+1), \quad (C2.4)$$

în care semnul tuturor elementelor ale lui $\Phi(k)$ ar trebui să rămână neschimbate.

Estimata $\hat{\Phi}(k)$ a matricei PPD $\Phi(k)$ este:

$$\hat{\Phi}(k) = \hat{\Phi}(k-1) + \frac{\eta [\Delta \mathbf{y}(k) - \hat{\Phi}(k-1) \Delta \mathbf{u}(k-1)] \Delta \mathbf{u}^T(k-1)}{\mu + \|\Delta \mathbf{u}(k-1)\|^2}, \quad (C2.5)$$

în care $0 < \eta < 1$ este o constantă de timp pas contant și $\mu > 0$ este un alt factor de ponderare, diferit de controlul optim. Condițiile de resetare sunt:

$$\begin{aligned} \hat{\phi}_a(k) &= \hat{\phi}_a(1), \text{ if } |\hat{\phi}_a(k)| < b_2 \text{ or } |\hat{\phi}_a(k)| > a b_2 \text{ or } \text{sgn}(\hat{\phi}_a(k)) \neq \text{sgn}(\hat{\phi}_a(1)), \\ \hat{\phi}_b(k) &= \hat{\phi}_b(1), \text{ if } |\hat{\phi}_b(k)| > b_1 \text{ or } \text{sgn}(\hat{\phi}_b(k)) \neq \text{sgn}(\hat{\phi}_b(1)), \quad i \neq j, \end{aligned} \quad (C2.6)$$

în care $\hat{\phi}_y(I)$ reprezintă valoarea inițială a lui $\hat{\phi}_y(k)$, $i \in \{1,2\}$, $j \in \{1,2\}$. Înlocuirea lui $y(k+1) = y(k) + \Phi(k)\Delta u(k)$ în (C2.3) rezultă în legea de comandă specifică algoritmului MFAC:

$$u(k) = u(k-1) + \frac{\rho \hat{\Phi}^T(k)[y^*(k+1) - y(k)]}{\lambda + \|\hat{\Phi}(k)\|^2}, \quad (C2.7)$$

în care $\rho > 0$ este o altă constantă de timp cu pas constant. Găsirea parametrilor $\hat{\Phi}(I)$, ρ , η , λ , μ ai algoritmului MFAC reprezintă o sarcină dificilă, fără un model al procesului controlat iar instrucțiuni pentru o selecție adecvată nu există conform cunoștințelor autorilor. Procedura care implică un model al procesului este de regulă o problemă de optimizare, care este rezolvată pentru un scenariu de control. Totuși, aceasta definește scopul algoritmului MFAC și împiedică să fie cu adevărat o abordare model-free. Parametrii MFAC-ului sunt obținuți prin cadrul VRFT-ului nelinear care va fi introdus în Secțiunea 4-a.

Tehnica VRFT aplicată proceselor nelineare

Tehnica VRFT nelineară folosește un model de referință liniar sau nelinear, care în cele din urmă trebuie să fie urmărit de către procesul condus în buclă închisă. Tehnica VRFTnelineară folosește un singur experiment în buclă deschisă, în care un semnal bogat în spectrul de frecvență este aplicat ca și intrare pentru procesul nelinear stabil, apoi semnalele de intrare/ieșire sunt colectate, iar apoi sunt folosite în calculul parametrilor regulatorului. Funcția obiectiv a modelului de referință folosită în cadrul tehnicii VRFT nelineare este:

$$J_{AR}(\theta) = \sum_{k=1}^N \|y_a(k) - y^d(k)\|^2, \quad (C2.8)$$

în care $y_a(k+1) = f(y(k), \dots, y(k-n_y), u_a(k), \dots, u_a(k-n_u))$ este vectorul ieșirii a procesului nelinear, $u_a(k) = C_a(\theta, u(k-1), \dots, u(k-n_u), e(k), \dots, e(k-n_e))$ (notația prescurtată este exprimată ca $u_a(k) = C_a(\theta, u(k-1), e(k))$) este vectorul ieșirii regulatorului nelinear, cu ue și ec – ordinele cunoscute ale structurii fixe ale regulatorului parametrizat de către vectorul θ , $e(k) = r(k) - y_a(k)$ este eroarea de urmărire, $r(k)$ este vectorul intrării referinței aplicat sistemului în buclă închisă, $y^d(k) = m(y^d(k-1), \dots, y^d(k-n_m), r(k-1), \dots, r(k-n_r))$ este ieșirea modelului de referință nelinear m selectat de către utilizator de ordin y_m și r_m acceptând că intrarea este setată ca $r(k)$. Se presupune că m este nesingular.

VRFT admite că o pereche de date de intrare/ieșire $\{u(k), y(k)\}$, $k = 0 \dots N$, sunt disponibile de la procesul în buclă deschisă. Apoi vectorul intrare a referinței virtuale $\bar{r}(k)$ este calculat ca $\bar{r}(k) = m^{-1}(y(k))$, astfel încât ieșirea modelului de referință și ieșirea procesului în buclă închisă au traectorii similare. Prin impunerea notației a lui $m^{-1}(y(k))$ rezultată în $\bar{r}(k)$, care este setat ca intrare lui m și rezultă $y(k)$. Eroarea de urmărire este $\bar{e}(k) = \bar{r}(k) - y(k)$. Regulatorul îl realizează pe $u(k)$ dacă $\bar{e}(k)$ este aplicat ca și proprie intrare este cel care obține urmărirea modelului de referință. Parametrii acestui regulator sunt calculați minimizând funcția obiectiv:

$$J_{IRF}(\theta) = \frac{1}{N} \sum_{k=1}^N \|C_a(\theta, \bar{e}(k)) - u(k)\|^2, \quad (C2.9)$$

În cazul VRFT MIMO nu este necesar filtrul variabil în timp pentru a face ca $J_{AR}(\theta)$ și $J_{IR}(\theta)$ să fie aproximativ egale, precum se întâmplă în cazul VRFT-ului clasic. Cele două funcții obiectiv pot să fie aproximativ egale pentru un regulator bogat în parametri, care poate să fie, de exemplu o rețea neuronală. Aceeași teorie a tehnicii VRFT nelineare poate să fie folosită și pentru cazul particular când se dorește controlul unui proces detip SISO.

Folosirea tehnicii VRFT pentru acordarea parametrilor unui regulator de tip MFAC

Această secțiune ne arată că tehnica VRFT poate să fie folosită în determinarea parametrilor algoritmului MFAC. În primul rând, se va arăta că algoritmul MFAC general compus din mecanismul de estimare (C2.5) și legea de comandă (C2.7) poate să fie exprimat ca și un model matematic intrare stare ieșire nelinear iar intrările/ieșirile ca și recurențe nelineare. Fie modelul matematic intrare stare ieșire al regulatorului MFAC:

$$\begin{aligned} u(k) &= u(k-1) + \frac{\rho \hat{\Phi}^T(k)[y^*(k+1) - y(k)]}{\lambda + \|\hat{\Phi}(k)\|^2}, \\ \hat{\Phi}(k) &= \hat{\Phi}(k-1) + \frac{\eta [\Delta y(k) - \hat{\Phi}(k-1)(u(k-1) - u(k-2))] (u^T(k-1) - u^T(k-2))}{\mu + \|u(k-1) - u(k-2)\|^2}, \end{aligned} \quad (C2.10)$$

echivalent cu:

$$\begin{aligned} u(k) &= g(\hat{\Phi}(k), u(k-1), y^*(k+1), y(k), \theta), \\ \hat{\Phi}(k) &= h(\hat{\Phi}(k-1), u(k-1), u(k-2), y(k), y(k-1), \theta), \end{aligned} \quad (C2.11)$$

în care $\mathbf{g}, \mathbf{h} \in \mathbb{R}^{2 \times 1}$ sunt funcții nelineare de argumentele lor. Prin introducerea unui vector adițional de stare $\mathbf{z}(k) = \mathbf{u}(k-1)$, se poate arăta că modelul matematic intrare stare ieșire este de forma $\mathbf{z}(k) = \mathbf{F}(\mathbf{z}(k-1), \mathbf{U}(k), \mathbf{0})$, unde vectorul stare este $\mathbf{z}(k) = [\mathbf{u}(k)^T \ \mathbf{z}(k)^T \ \hat{\Phi}(k)^T]^T$, vectorul intrare este $\mathbf{U}(k) = [\mathbf{y}^*(k+1)^T \ \mathbf{y}(k)^T \ \mathbf{y}(k-1)^T]^T$, iar vectorul parametrilor este $\mathbf{0} = [\rho \ \eta \ \lambda \ \mu]^T$, care este considerat ca și un vector de intrare adițional (adică vectorul perturbator).

Folosind notațiile de mai sus și înlocuindu-l pe $\hat{\Phi}(k)$ din prima ecuație în (C2.11) cu al doilea, următoarea formă a modelului matematic intrare stare ieșire a algoritmului MFAC MIMO este obținută:

$$\mathbf{u}(k) = \mathbf{g}(\hat{\Phi}(k-1), \mathbf{u}(k-1), \mathbf{z}(k-1), \mathbf{y}(k), \mathbf{y}(k-1), \mathbf{y}^*(k+1), \mathbf{0}), \quad (\text{C2.12})$$

$$\mathbf{z}(k) = \mathbf{u}(k-1),$$

$$\hat{\Phi}(k) = \mathbf{h}(\hat{\Phi}(k-1), \mathbf{z}(k), \mathbf{z}(k-1), \mathbf{y}(k), \mathbf{y}(k-1), \mathbf{0}).$$

Pornind cu condițiile inițiale $\hat{\Phi}(1), \mathbf{u}(1), \mathbf{z}(1) = \mathbf{u}(0)$ aplicate modelului intrare stare ieșire din (C2.12), vectorul de comandă $\mathbf{u}(k)$ este exprimat recurrent:

$$\hat{\Phi}(2) = \mathbf{h}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}(2), \mathbf{y}(1), \mathbf{0}),$$

$$\mathbf{u}(2) = \mathbf{g}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}(2), \mathbf{y}(1), \mathbf{y}^*(3), \mathbf{0}),$$

$$\mathbf{u}(3) = \mathbf{g}(\hat{\Phi}(2), \mathbf{u}(2), \mathbf{u}(1), \mathbf{y}(3), \mathbf{y}(2), \mathbf{y}^*(4), \mathbf{0}) = \mathbf{g}(\mathbf{h}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}(2),$$

$$y(1), \mathbf{0}), \mathbf{g}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}(2), \mathbf{y}(1), \mathbf{y}^*(3), \mathbf{0}), \mathbf{u}(1), \mathbf{y}(3), \mathbf{y}(2), \mathbf{y}^*(4), \mathbf{0}) \quad , \quad (\text{C2.13})$$

$$= \mathbf{g}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}(3), \mathbf{y}(2), \mathbf{y}(1), \mathbf{y}^*(3), \mathbf{y}^*(4), \mathbf{0}),$$

...

$$\mathbf{u}(k) = \mathbf{g}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}(k), \mathbf{y}(k-1), \dots, \mathbf{y}(2), \mathbf{y}(1), \mathbf{y}^*(k+1), \mathbf{y}^*(k), \dots,$$

$$\mathbf{y}^*(4), \mathbf{y}^*(3), \mathbf{0}) = \mathbf{g}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}^*(k+1) - \mathbf{y}(k), \mathbf{y}^*(k) - \mathbf{y}(k-1), \dots,$$

$$\mathbf{y}^*(3) - \mathbf{y}(2), \mathbf{y}(1), \mathbf{0}).$$

Dacă realizăm notația $\mathbf{e}(k) = \mathbf{y}^*(k+1) - \mathbf{y}(k)$ atunci $\mathbf{u}(k)$ din (C2.13) poate să reiasă din descrierea nelineară recurrentă a intrărilor-iesărilelor de forma $\mathbf{u}_{\theta_e}(k) = \mathbf{C}_{\theta_e}(\theta_e, \mathbf{u}(k-1), \dots, \mathbf{u}(k-n_{ue}), \mathbf{e}(k), \dots, \mathbf{e}(k-n_{ee}))$, cu $\theta_e = \{\hat{\Phi}(1), \theta^T\}$. Dacă $\mathbf{r}(k)$ specific tehnicii VRFT este considerat echivalent cu $\mathbf{y}^*(k+1)$ de la algoritm MFAC, atunci structura regulatorului MFAC poate fi considerată în buclă închisă. Figura 1 prezintă structura sistemului de reglare automată cu algoritm MFAC-VRFT.

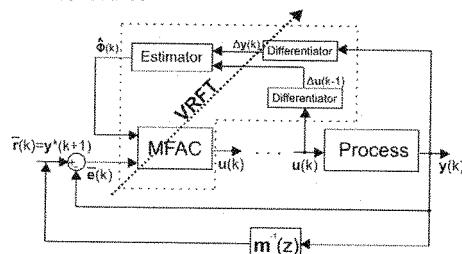


Fig. 1. Structura sistemului de reglare automată cu algoritmul MFAC-VRFT [18].

Alegând modelul de referință $\mathbf{m} = \mathbf{I}_2$ în proiectarea VRFT-ului nelinear devine echivalent cu minimizarea $J_{MR}(\theta) = \sum_{k=1}^N \|\mathbf{y}_0(k) - \mathbf{y}^*(k)\|^2$, care este versiunea discontinuă a funcției obiectiv MFAC J_{MFAC} din (5) cu $\lambda = 0$. Totuși, nici un regulator cauzal nu poate realiza în practică ca $\mathbf{m} = \mathbf{I}_2$. Prin urmare alegându-l pe $\mathbf{m} \neq \mathbf{I}_2$ în VRFT este echivalent cu $\lambda \neq 0$ în MFAC. Parametrul λ este crucial întrucât influențează stabilitatea MFAC-ului în sensul că un λ cu o valoare mare îmbunătățește stabilitatea care pur și simplu înseamnă adăugarea ponderii incrementului de comandă. În termenii VRFT-ului, aceasta înseamnă alegerea modelului de referință \mathbf{m} cu o lățime de bandă care îmbunătățește timpul de răspuns al sistemului de reglare automată dar de asemenea crește pe ansamblu robustețea sistemului de reglare automată. De aceea regulatorul MFAC-VRFT propus transpune proiectarea parametrilor MFAC (precum $\hat{\Phi}(1)$ și $\theta = [\rho \ \eta \ \lambda \ \mu]^T$) într-o buclă închisă de reglare automată mai usoară caracterizată prin modelul de referință \mathbf{m} .

D. BIBLIOGRAFIE

D.1. Bibliografie aferentă secțiunii B

- Ahn, H.-S., Y. Chen, and K. L. Moore (2007). Iterative learning control: brief survey and categorization, IEEE Transactions on Systems, Man and Cybernetics, Part C: Applications and Reviews, vol. 37, no. 6, pp. 1109-1121.

- Al-Tamimi, A., F. L. Lewis, and M. Abu-Khalaf (2008). Discrete-time nonlinear HJB solution using approximate dynamic programming: Convergence proof, *IEEE Transactions on Systems, Man and Cybernetics, Part B: Cybernetics*, vol. 38, no.4, pp. 943-949.
- Bennighof, J. K., S.-H. Chang, and M. Subramaniam (1993). Minimum time pulse response based control of flexible structure, *J. Guid. Control Dyn.*, vol. 16, pp. 874-881.
- Bristow, D. A., M. Tharayil, and A. G. Alleyne (2006). A survey of iterative learning control, *IEEE Control Systems Magazine*, vol. 26, no. 3, pp. 96-114.
- Busoniu, L., R. Babuska, and B. de Schutter (2008). A comprehensive survey of multiagent reinforcement learning, *IEEE Transactions on Systems, Man and Cybernetics, Part C: Applications and Reviews*, vol. 38, no. 2, pp. 156-172.
- Butcher M., A. Karimi, and R. Longchamp (2008). Iterative learning control based on stochastic approximation, *Proceedings of 17th IFAC World Congress*, Seoul, Korea, pp. 1478-1483.
- Campestrini L., D. Eckhard, M. Gevers, and A. S. Bazanella (2009). Virtual reference feedback tuning for non minimum phase plants, *Proceedings of European Control Conference 2009 (ECC '09)*, Budapest, Hungary, pp. 1955-1960.
- Campi, M. C., A. Lecchini, and S. M. Savaresi (2000). Virtual reference feedback tuning (VRFT): a new direct approach to the design of feedback controllers, *Proc. 39th Conference on Decision and Control*, Sydney, Australia, pp. 623-628.
- Campi, M. C. and S.M. Savaresi (2006). Direct nonlinear control design: the virtual reference feedback tuning (VRFT) approach, *IEEE Transactions on Automatic Control*, vol. 51, no. 1, pp. 14-27.
- Chi, R., D. Wang, Z.-S. Hou, and S. Jin (2012). Data-driven optimal terminal iterative learning control, *Journal of Process Control*, vol. 22, no. 10, pp. 2026-2037.
- Chi, R., Z. Hou, S. Jin, and D. Wang (2013). A data-driven iterative feedback tuning approach of ALINEA for freeway traffic ramp metering with PARAMICS simulations, *IEEE Transactions on Industrial Informatics*, vol. 8, no. 4, pp. 2310-2317.
- Esparraga, A., Sala A., and P. Albertos (2011). Neural networks in virtual reference tuning, *Engineering Applications of Artificial Intelligence*, vol. 24, no. 6, pp. 983-995.
- Fliess, M., and C. Join (2009). Model-free control and intelligent PID controllers: Towards a possible trivialization of nonlinear control?, *Proceedings of 15th IFAC Symposium on System Identification (SYSID 2009)*, Saint-Malo, France, pp. 1531-1550.
- Fliess, M., C. Join, and S. Riachi (2011). Revisiting some practical issues in the implementation of model-free control, *Proceedings of 18th IFAC World Congress*, Milano, Italy, pp. 8589-8594.
- Fliess, M. and C. Join (2013). Model-free control, *International Journal of Control*, vol. 86, no. 12, pp. 2228-2252.
- Formentin, S., P. De Filippi, M. Corno, M. Tanelli, and S. M. Savaresi (2013). Data-driven design of braking control systems, *IEEE Transactions on Control Systems Technology*, vol. 21, no. 1, pp. 186-193.
- Freeman, C. T. and Y. Tan (2013). Iterative learning control with mixed constraints for point-to-point tracking, *IEEE Transactions on Control Systems Technology*, vol. 21, no. 3, pp. 604-616.
- Gedouin, P.-A., E. Delaleau, J. M. Bourgeot, C. Join, S. A. Chirani, and S. Calloch (2011). Experimental comparison of classical PID and model-free control: position control of a shape memory alloy active spring, *Control Engineering Practice*, vol. 19, no. 5, pp. 433-441.
- Grymin, D. J., C. B. Neas, and M. Farhood (2014). A hierarchical approach for primitive-based motion planning and control of autonomous vehicles, *Robotics and Autonomous Systems*, vol. 62, no. 2, pp. 214-228.
- Halmevaara, K. and H. Hyotyniemi (2006). Data-based parameter optimization of dynamic simulation models, *Proceedings of 47th Conference on Simulation and Modelling (SIMS 2006)*, Helsinki, Finland, pp. 68-73.
- Heertjes, M., D. Hennekens, and M. Steinbuch (2010). MIMO feed-forward design in wafer scanners using a gradient approximation-based algorithm, *Control Engineering Practice*, vol. 18, no. 5, pp. 495-506.
- Hjalmarsson, H., S. Gunnarsson and M. Gevers (1994). A convergent iterative restricted complexity control design scheme, *Proceedings of 33rd IEEE Conference on Decision and Control*, Orlando, FL, USA, pp. 1735-1740.
- Hoelzle, D. J., A. G. Alleyne, and A. J. W. Johnson (2011). Bumpless transfer for a flexible adaptation of iterative learning control, *Proceedings of 2011 American Control Conference*, San Francisco, CA, USA, pp. 4305-4311.
- Hou, Z. S. and S. Jin (2011a). A novel data-driven control approach for a class of discrete-time nonlinear systems, *IEEE Transactions on Control Systems Technology*, vol. 19, no. 6, pp. 1549-1558.
- Hou, Z. S. and S. Jin (2011b). Data-driven model-free adaptive control for a class of MIMO nonlinear discrete-time systems, *IEEE Transactions on Neural Networks*, vol. 22, no. 12, pp. 2173-2188.
- Ijspeert, A. J., J. Nakanishi, and S. Schaal (2002). Movement imitation with nonlinear dynamical systems in humanoid robots, *Proceedings of 2002 IEEE International Conference on Robotics and Automation*, Washington, DC, USA, vol. 2, pp. 1398-1403.

- Janseens, P., G. Pipeleers, and J. Swevers (2013). A data-driven constrained norm-optimal iterative learning control framework for LTI systems, *IEEE Transactions on Control Systems Technology*, vol. 21, no. 2, pp. 546-551.
- Jiang, Y., Y. Zhu, K. Yang, C. Hu, and D. Yu (2014). A data-driven iterative decoupling feed-forward control strategy with application to an ultra-precision motion stage, *IEEE Transactions on Industrial Electronics*, DOI: 10.1109/TIE.2014.2327559, May 2014.
- Kadali, R., B. Huang, and A. Rossiter (2003). A data driven subspace approach to predictive controller design, *Control Engineering Practice*, vol. 11, no. 3, pp. 261-278.
- Kammer, L. C., R. R. Bitmead, and P. L. Bartlett (2000). Direct iterative tuning via spectral analysis, *Automatica*, vol. 36, no. 9, pp. 1301-1307.
- Karimi, A., L. Miskovic, and D. Bonvin (2004). Iterative correlation-based controller tuning, *International Journal of Adaptive Control and Signal Processing*, vol. 18, no. 8, pp. 645-664.
- Kansha, Y., Y. Hashimoto, and M.-S. Chiu (2008). New results on VRFT design of PID controller, *Chemical Engineering Research and Design*, vol. 86, no. 8, pp. 925-931.
- Kawamura, S. and N. Sakagami (2002). Analysis on dynamics of underwater robot manipulators based on iterative learning control and time-scale transformation, *Proceedings of 2002 IEEE International Conference on Robotics and Automation*, Washington, DC, USA, vol. 2, pp. 1088-1094.
- Li, X., Z. S. Hou, and S. T. Jin (2012). Model-free adaptive control for magnetic levitation ball system, *Proceedings of 31st Chinese Control Conference*, Hefei, China, pp. 7071-7075.
- Lupashin, S., A. Schöllig, M. Sherback, and R. D'Andrea (2010). A simple learning strategy for high-speed quadrocopter multi-flips, *Proceedings of 2010 IEEE International Conference on Robotics and Automation (ICRA 2010)*, Anchorage, AK, USA, pp. 1642-1648.
- McDaid, A. J., K. C. Aw, S. Q. Xie, and E. Haemmerle (2010). Gain scheduled control of IPMC actuators with 'model-free' iterative feedback tuning, *Sensors and Actuators A: Physical*, vol. 164, no. 1-2, pp. 137-147.
- McDaid, A. J., K. C. Aw, E. Haemmerle, and S. Q. Xie (2012). Control of IPMC actuators for microfluidics with adaptive "online" iterative feedback tuning, *IEEE/ASME Transactions on Mechatronics*, vol. 17, no. 4, pp. 789-797.
- Mishra, S., U. Topcu, and M. Tomizuka (2011). Optimization-based constrained iterative learning control, *IEEE Transactions on Control Systems Technology*, vol. 19, no. 6, pp. 1613-1621.
- Mussa-Ivaldi, F. A. and S. A. Solla (2004). Neural primitives for motion control, *IEEE Journal of Ocean. Engineering*, vol. 29, no. 3, pp. 640-650.
- Norrlöf, M. and S. Gunnarsson (2002). Time and frequency domain convergence properties in iterative learning control, *International Journal of Control*, vol. 75, no. 4, pp. 1114-1126.
- Precup, R.-E., S. Preitl, and E. M. Petriu (2007a). PI-fuzzy controller design based on an optimization approach, *Proceedings of Third IFAC Workshop on Advanced Fuzzy and Neural Control (AFNC 07)*, Valenciennes, France, pp. 133-138.
- Precup, R.-E., M.-B. Radac, C.-A. Dragoș, S. Preitl, and E. M. Petriu (2014). 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.
- Previdi F., Schauer T., Savaresi S.M., and K.J. Junt (2004). Data-driven control design for neuroprostheses: a virtual reference feedback tuning (VRFT) approach, *IEEE Transactions on Control Systems Technology*, vol. 12, no. 1, pp. 176-182.
- Previdi, F., F. Fico, S. M. Savaresi, D. Belloli, and I. Pesenti (2012). Direct design of a velocity controller and load disturbance estimation for a self-balancing industrial manual manipulator, *Mechatronics*, vol. 22, no. 8, pp. 1177-1186.
- Prucksakorn, T., K. Wachirarattanakornkul, and I. Nilkhamhang (2013). Unmanned aerial vehicle for observing landslide with iterative feedback tuning, *Proceedings of 10th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON 2013)*, Krabi, Thailand, pp. 1-5.
- Qu, Y., A. Tay, and H. L. Tong (2011). Iterative feedback tuning of optical proximity correction mask in lithography, *Proceedings of IEEE/SICE International Symposium on System Integration (SII 2011)*, Kyoto, Japan, pp. 851-856.
- Radac, M.-B., R.-E. Precup, E. M. Petriu, S. Preitl, and C.-A. Dragoș (2011a). Convergent iterative feedback tuning of state feedback-controlled servo systems, in: *Informatics in Control Automation and Robotics*, J. Andrade Cetto, J. Filipe, and J.-L. Ferrier, Eds., Springer-Verlag, Berlin, Heidelberg, pp. 99-111.
- Radac, M.-B., R.-E. Precup, E. M. Petriu, and S. Preitl (2011b). Application of IFT and SPSA to servo system control, *IEEE Transactions on Neural Networks*, vol. 22, no 12, pp. 2363-2375.
- Radac, M.-B., R.-E. Precup, E. M. Petriu, S. Preitl, and R.-C. David (2011c). Stable iterative feedback tuning method for servo systems, *Proceedings of 20th IEEE International Symposium on Industrial Electronics (ISIE 2011)*, Gdansk, Poland, pp. 1943-1948.

- Radac, M.-B., R.-E. Precup, E. M. Petriu, S. Preitl, and R.-C. David (2011d). Mixed virtual reference feedback tuning - iterative feedback tuning: method and laboratory assessment, Proceedings of 20th IEEE International Symposium on Industrial Electronics (ISIE 2011), Gdansk, Poland, pp. 649-654.
- Radac, M.-B., R.-E. Precup, E. M. Petriu, S. Preitl, and C.-A. Dragos (2012a). Experiment-based approach to reference trajectory tracking, Proceedings of 2012 IEEE International Conference on Control Applications (CCA 2012), Part of 2012 IEEE Multi-Conference on Systems and Control, Dubrovnik, Croatia, pp. 470-475.
- Radac, M.-B., R.-C. Roman, R.-E. Precup, E. M. Petriu, C.-A. Dragoș and St. Preitl (2013a). Data-based tuning of linear controllers for MIMO twin rotor systems, Proceedings of IEEE Region 8 EuroCon 2013 Conference, Zagreb, Croatia, pp. 1915-1920.
- Radac, M.-B., R.-E. Precup, E. M. Petriu, S. Preitl, and C.-A. Dragos (2013b). Constrained data-driven controller tuning for nonlinear systems, Proceedings of 39th Annual Conference of the IEEE Industrial Electronics Society (IECON 2013), Vienna, Austria, pp. 3402-3407.
- Radac, M.-B., R.-E. Precup, E. M. Petriu, S. Preitl, and C.-A. Dragos (2013c). Data-driven reference trajectory tracking algorithm and experimental validation, IEEE Transactions on Industrial Informatics, vol. 9, no. 4, pp. 2327-2336.
- Radac, M.-B., R.-E. Precup, and E. M. Petriu (2014a). 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.
- Radac, M.-B., R.-E. Precup, E. M. Petriu, and S. Preitl, (2014b). Iterative data-driven controller tuning with actuator constraints and reduced sensitivity, Journal of Aerospace Information Systems, vol. 11, no. 9, pp. 551-564.
- Radac, M.-B., R.-E. Precup, E. M. Petriu, and S. Preitl (2014c). Iterative data-driven tuning of controllers for nonlinear systems with constraints, IEEE Transactions on Industrial Electronics, vol. 61, no. 4, pp. 6360-6368.
- Radac, M.-B. and R.-E. Precup (2014d). Data-based two-degree-of-freedom iterative control approach to constrained non-linear systems, IET Control Theory & Applications, DOI: 10.1049/iet-cta.2014.0187, Oct. 2014.
- Radac, M.-B., R.-C. Roman, R.-E. Precup, and E. M. Petriu (2014e). 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.
- Radac, M-B, and Precup R.-E. (2015a), Constrained Data-Driven Model-Free ILC-based Reference Input Tuning Algorithm, Acta Polytechnica Hungarica, vol. 12, no. 1, pp. 137-160.
- Radac, M-B. and Precup R.-E. (2015b). Optimal behaviour prediction using a primitive-based data-driven model-free iterative learning control approach, Computers in Industry, vol. 74, pp. 95-109.
- Report (2011). The impact of control technology, IEEE Control Systems Society.
- Rico, Z. P., A. Lecchini-Visintini, and R. Q. Quiroga (2012). Iterative feedback tuning for the joint controllers of a 7-DOF whole arm manipulator, Proceedings of 2012 IEEE Annual Conference on Decision and Control (CDC 2012), Maui, HI, USA, pp. 544-549.
- Rojas, J. D., X. Flores-Alsina, U. Jeppson, and R. Vilanova (2012). Application of multivariate virtual reference feedback tuning for wastewater treatment plant control, Control Engineering Practice, vol. 20, no. 5, pp. 499-510.
- Roman, R.-C., M.-B. Radac, and R.-E. Precup (2014). 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, pp. 25-30.
- Rupp, D. and L. Guzzella (2010). Iterative tuning of internal model controllers with application to air/fuel ratio control, IEEE Transactions on Control Systems Technology, vol. 18, no. 1, pp. 177-184.
- Safonov, M. G. and Tsao T. C. (1997). The unfalsified control concept and learning, IEEE Transactions on Automatic Control, vol. 42, no. 6, pp. 843-847.
- Schöllig, A., M. Hehn, S. Lupashin, and R. D'Andrea (2011). Feasibility of motion primitives for choreographed quadrocopter flight, in Proc. 2011 American Control Conference, San Francisco, CA, USA, pp. 3843-3849.
- Spall, J. C. (1988). A stochastic approximation algorithm for large-dimensional systems in the Kiefer-Wolfowitz setting, Proceedings of 27th IEEE Conference on Decision and Control, Austin, TX, USA, vol. 2, pp. 1544-1548.
- Van Heusden, K., A. Karimi, and D. Bonvin (2011). Data-driven model reference control with asymptotically guaranteed stability, International Journal of Adaptive Control and Signal Processing, vol. 25, no. 4, pp. 331-351.
- Wang, J., C. Ji, L. Cao, and Q. Jin (2012). Application of improved model-free adaptive control in an industrial boiler system, Proceedings of 31st Chinese Control Conference, Hefei, China, pp. 7014-7019.
- Wang, H. and Q. Zou (2014). B-spline-decomposition-based approach to multiaxis trajectory tracking: Nanomanipulation example, IEEE Transactions on Control Systems Technology, vol. 22, no. 4, pp. 1573-1580.
- Wang, X., B. Huang, and T. Chen (2007). Data-driven predictive control for solid oxide fuel cells, Journal of Process Control, vol. 17, no. 2, pp. 103-114.

D.2. Bibliografie proprie (2016)

- lucrări publicate în reviste ISI cu factor de impact:

- [R1] M.-B. Rădac and R.-E. Precup, Three-level hierarchical model-free learning approach to trajectory tracking control, *Engineering Applications of Artificial Intelligence* (Elsevier Science), vol. 55, pp. 103-118, 2016, impact factor (IF) = 2.368, scor relativ de influenta 2.116.
- [R2] R.-C. Roman, M.-B. Rădac and R.-E. Precup, Multi-input-multi-output system experimental validation of model-free control and virtual reference feedback tuning techniques, *IET Control Theory & Applications*, vol. 10, no. 12, pp. 1395-1403, 2016, impact factor (IF) = 1.957, scor relativ de influenta 1.856.
- [R3] M.-B. Rădac, R.-E. Precup, and R.-C. Roman, Model-Free control performance improvement using virtual reference feedback tuning and reinforcement Q-learning, *International Journal of Systems Science* (Taylor & Francis), vol. pp. no. 1, pp. 1-13, 2016, impact factor (IF) = 1.947, scor relativ de influenta 0.87.
- [R4] R.-C. Roman, M.-B. Rădac, R.-E. Precup and E. M. Petriu, Data-driven Model-Free Adaptive Control Tuned by Virtual Reference Feedback Tuning, *Acta Polytechnica Hungarica*, vol. 13, no. 1, pp. 83-96, 2016, impact factor (IF) = 0.544, scor relativ de influenta 0.313.

- capitole de carte:

- [R5] R.-C. Roman, M.-B. Rădac, R.-E. Precup and E. M. Petriu, Virtual Reference Feedback Tuning of MIMO Data-Driven Model-Free Adaptive Control Algorithms, in: *Technological Innovation for Cyber-Physical Systems*, L. M. Camarinha-Matos, A. J. Falcao, N. Vafaei and S. Najdi, Eds., *IFIP Advances in Information and Communication Technology*, vol. 470 (Springer International Publishing), pp. 253-260, 2016, indexed in Scopus, DBLP.

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

- [R6] M.-B. Radac and R.-E. Precup, Improving Model Reference Control Performance Using Model-Free VRFT and Q-Learning, Proceedings of 2016 20th International Conference on System Theory, Control and Computing (ICSTCC 2016), Sinaia, Romania, pp. 7-13, 2016, to be indexed in IEEE Xplore, INSPEC.
- [R7] M.-B. Radac, and R.-E. Precup, Hierarchical Data-Driven Model-Free Iterative Learning Control Using Primitives, Proceedings of 2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC 2016), Budapest, Hungary, pp. 2785-2790, 2016, to be indexed in IEEE Xplore, INSPEC.
- [R8] R.-C. Roman, M.-B. Radac and R.-E. Precup, Mixed MFC-VRFT Approach for a Multivariable Aerodynamic System Position Control, Proceedings of 2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC 2016), Budapest, Hungary, pp. 2615-2620, 2016, indexed in IEEE Xplore, INSPEC.
- [R9] M.-B. Radac, R.-E. Precup and R.-C. Roman, Data-Driven Virtual Reference Feedback Tuning and Reinforcement Q-learning for Model-Free Position Control of an Aerodynamic System, Proceedings of 24th Mediterranean Conference on Control and Automation MED'2016, Athens, Greece, pp. 1126-1132, 2016, indexed in IEEE Xplore, INSPEC.
- [B1] C.-A. Bojan-Dragoș, R.-E. Precup, S. Preitl, A.-I. Szndlak-Stînean and E. M. Petriu, Particle Swarm Optimization of Fuzzy Models for Electromagnetic Actuated Clutch Systems, Proceedings of 18th Mediterranean Electromechanical Conference MELECON 2016, Limassol, Cyprus, pp. 1-6, 2016, indexed in IEEE Xplore, INSPEC, Scopus.
- [P1] R.-E. Precup, R.-C. David, E. M. Petriu, M.-B. Rădac and E.-I. Voîsan, Experiment-Based Comparison of Nature-Inspired Algorithms for Optimal Tuning of PI-Fuzzy Controlled Nonlinear DC Servo Systems, Proceedings of 2016 International Symposium on Power Electronics, Electrical Drives, Automation and Motion SPEEDAM 2016, Capri, Italy, pp. 1261-1266, 2016, indexed in IEEE Xplore, INSPEC.
- [H1] E.-L. Hedrea, M.-B. Rădac and R.-E. Precup, Virtual Reference Feedback Tuning for Position Control of a Twin Rotor Aerodynamic System, Proceedings of 11th IEEE International Symposium on Applied Computational Intelligence and Informatics SACI 2016, Timisoara, Romania, pp. 57-62, 2016, indexed in IEEE Xplore, INSPEC, Scopus.
- [P2] R.-E. Precup, R.-C. David, E. M. Petriu, A.-I. Szndlak-Stînean and C.-A. Bojan-Dragoș, Grey Wolf Optimizer-Based Approach to the Tuning of PI-Fuzzy Controllers with a Reduced Process Parametric Sensitivity, Proceedings of 4th IFAC International Conference on Intelligent Control and Automation Sciences ICONS 2016, Reims, France, 2016, IFAC-PapersOnLine, vol. 48, no. 5, pp. 55-60, 2016, indexed in Scopus.

Director de proiect,
ș.i.dr.ing. Mircea-Bogdan Rădac