

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

privind implementarea proiectului în perioada octombrie 2015 – septembrie 2017

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 Szedlak-Stînean, drd.ing. Constantin Purcaru, drd.ing. Raul-Cristian Roman.

Raportul științific sintetic a fost obținut prin concatenarea următoarelor rapoarte științifice care constituie cele trei părți:

- I. Raport științific privind implementarea proiectului în perioada octombrie 2015 – decembrie 2015.
- II. Raport științific privind implementarea proiectului în perioada ianuarie – decembrie 2016.
- III. Raport științific privind implementarea proiectului în perioada ianuarie – septembrie 2017.

Principalele rezultate științifice obținute în perioada de implementare 2015-2017 (24 luni) sunt:

- **7 lucrări publicate în reviste ISI cu factor de impact**, factor de impact ISI Science Citation Index (SCI) cumulat, calculat conform Thomson Reuters Journal Citation Reports din anii de publicare = **20.766**.
- **1 capitol de carte** publicat la editura Springer.
- **14 lucrări** publicate în volumele unor **conferințe** indexate în baze de date internaționale (INSPEC, IEEE Xplore, Scopus, DBLP).
- **3 rapoarte științifice (două anuale (2015,2016) și cel curent sintetic pe toată activitatea).**

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 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.

Partea I. Raport științific intermediar al contractului privind implementarea proiectului în perioada octombrie – decembrie 2015

A. SINTEZĂ GENERALĂ ASUPRA REZULTATELOR

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 2015 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. **Activitățile** desfășurate pentru atingerea acestui obiectiv se referă la:
 - 1.1. Studiu privind diversele tipuri de funcții de bază ce pot fi folosite pentru aproximare. Sunt prezentate detalii în studiul din secțiunea B.
- (2) Dezvoltarea tehnicilor de acordare a regulatoarelor de tip model-free. **Activitățile** desfășurate pentru atingerea acestui obiectiv se referă la:
 - 2.1. Studiul oportunității folosirii rețelelor neurale pentru îmbunătățirea tehnicilor de acordare de tip model-free a regulatoarelor. Studiul bibliografic este prezentat în secțiunea C.

Pentru anul 2015 raportul de cercetare intermediar prezent este singurul livrabil al proiectului.

B. DEZVOLTAREA 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), este sprijinită de 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 (specificațiilor de performanță).

Acordarea parametrilor regulatoarelor automate în medii cu restricții, în paragigma 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, Halmeavaara 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 reacția perturbațiilor). Necesitatea este indicată clar în (Report, 2011) ca și arie 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, traiectoriile 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 primitivele 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 primitivele sunt raportate în (Schöllig et al., 2011) unde fezabilitatea primitivele este testată pentru drone UAV. Mecanismul de compunere a primitivele 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 primitivele 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 traiectorii 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 neliniare care pot fi bine approximate cu sisteme LTI în vecinătatea unor puncte de funcționare;
- iii) Extensia la SRA de tip MIMO ar putea fi extinsă înținând 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 neliniare 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-ieșirile controlate vor fi tratate ca și perechi de **intrare-ieșire ce vor constitui primitivele de execuție**. Referințele vor fi optimizare 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 eșanțioane 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.

Ieșirile primitive 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 primitiveelor**. 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 approximate în vecinătatea unor puncte de funcționare cu sisteme LTI, tehnica propusă va fi extinsă și la sisteme ușor neliniare. 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 neliniarități 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 prescrisează 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 viteză 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 traectorii 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 cîte 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 atractor stabil pentru ecuația DMP-ului care este modelat ca un sistem de tip masă-resorț-amortizor de ordinul 2. Perturbația f este codificată apoi prin aproximare folosind RBFs prin regresie liniară. Perturbația f care trebuie aproimată 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)-punkte de tip țintă, iar pentru fiecare punct este stocată durata dorită a traiectoriei 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 aceleiași 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 traiectorii 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” noncauze 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), explotând astfel teoria sistemelor LTI. Din acest punct de vedere, poate fi acceptată superioritatea tehniciilor de tip ILC în generalizarea unor soluții optimale.

C. DEZVOLTAREA TEHNICILOR DE ACORDARE A REGULATOARELOR DE TIP MODEL-FREE. STUDIUL OPORTUNITĂȚII FOLOSIRII REȚELELOR NEURALE PENTRU ÎMBUNĂTĂȚIREA TEHNICILOR DE ACORDARE DE TIP MODEL-FREE A REGULATOARELOR

IFT este una dintre cele mai utilizate tehnici DbC și poate fi privită ca o tehnică de optimizare a parametrilor regulatoarelor. Specificațiile de performanță sunt impuse folosind funcții obiectiv (FO) care conțin de obicei termeni integrali iar aceste FO sunt minimizate folosind IFT prin aplicarea unor algoritmi numerici (tipic, de gradient), în care informația de gradient este obținută experimental, fără a folosi modelul procesului condus. Acordarea are loc cu procesul operând în buclă închisă. Cercetările din ultimii 5 ani în domeniul IFT sunt: aplicare în optimizarea unei structuri cu model intern (Rupp and Guzzella, 2010), aplicare în conducerea unor elemente de execuție inteligente folosind gain-scheduling (McDaid et al., 2010, 2012), aplicarea IFT și SPSA la servosisteme (Radac et al., 2011b), aplicații în litografie (Qu et al., 2011), analiza stabilității și a convergenței IFT (Radac et al., 2011a, 2011c; van Heusden et al., 2011), conducerea roboților (Rico et al., 2012), aplicații de conducere a traficului (Chi et al., 2013), sisteme aerodinamice/drone (Prucksakorn et al., 2013; Radac et al., 2013a). În (Radac et al., 2013b, 2014b, 2014c, 2014d) au fost tratate reducerea numărului de experimente folosind rețele neurale, extensiile IFT la procese neliniare și acordarea în medii cu restricții.

VRFT este o alternativă non-iterativă la IFT. Regulatorul este proiectat și acordat astfel încât bucla de reglare să se comporte ca un model de referință impus. VRFT folosește un singur set de date de intrare-ieșire culese din proces în acest scop și nu necesită experimente suplimentare. Unele realizări recente ale VRFT includ: extensia la procese neliniare (Campi et al., 2006), regulatoare PID adaptive și analiza relației VRFT-control bazat pe model intern (Kansha et al., 2008), combinarea cu regulatoare PI-fuzzy (Precup et al., 2007a), extensia la sisteme de fază neminimă (Campestrini et al., 2009), analiza stabilității (van Heusden et al., 2011), combinarea IFT cu VRFT (Radac et al., 2011d) tratarea apelor reziduale (Rojas et al., 2012). Alte aplicații industriale sunt raportate în (Previdi et al., 2012; Formentin et al., 2013). și tehnica VRFT este folosită pentru acordarea unor regulatoare neliniare de tip rețele neurale (Previdi et al., 2004; Esparza et al., 2011) însă direcția este insuficient exploatată și validată.

MFC și MFAC sunt strategii de reglare adaptive considerate model-free deoarece nu necesită o modelare explicită folosind ecuații primare; în schimb, sunt forțate modele ultralocale adapatabile ca descrieri ale procesului pentru momente foarte scurte de timp. Linearizarea dinamică este folosită în MFAC (Hou et al., 2011a, 2011b) iar ecuațiile diferențiale (ecuații recurente) de ordin redus sunt folosite în cadrul MFC pentru a descrie procesul în (Fliess et al., 2009, 2011, 2013). Aplicațiile raportate indică rezultate încurajatoare mai ales pe sisteme multivariabile (Multi Input-Multi Output, MIMO) complexe neliniare atât pentru MFAC (Li et al., 2012; Wang et al., 2012; Radac et al., 2014b) cât și pentru MFC (Radac et al., 2014e). Provocările curente cer proiectarea stabilă a acestor algoritmi adaptivi (Precup et al., 2014), adăugarea unor capabilități de învățare, validarea pe diverse procese și compararea performanțelor cu abordări similare (Roman et al., 2014).

ILC (Bristow et al., 2006; Ahn et al., 2007) este o tehnică deja bine conturată și acceptată care a generat cercetări intense în ultimii 20 de ani și pentru care este aproape imposibil de realizat o analiză completă a contextului științific actual. ILC optimal cu restricții a generat interes semnificativ în ultimii 5 ani (Heertjes et al., 2010; Lupashin et al., 2010; Mishra et al., 2011; Freeman et al., 2013; Janseens et al., 2013; Jiang et al., 2014). Abordarea de tip model-free ILC optimal cu restricții este chiar mai recentă (Chi et al., 2012; Radac et al., 2012a). Abordarea ILC model-free optimal cu restricții este discutată și în (Butcher et al., 2008; Radac et al., 2013c, 2014a). În (Radac et al., 2014d) este propusă combinarea model-free ILC cu IFT pentru structuri de reglare cu două grade de libertate cu restricții. Provocările curente pentru model-free ILC optimal necesită combinarea cu alte tehnici precum și dezvoltarea unor mecanisme de învățare pentru SRA care au la bază ILC. Pentru tehnici de tip ILC model-free, reducerea dimensiunii semnalelor de referință a fost propusă în (Radac and Precup, 2015a; Radac and Precup, 2015b) prin aproximarea folosind funcții polinomiale și funcții radiale de bază, care sunt un caz particular de **rețele neurale**. În plus, atunci când semnalul de referință de la intrarea unui sistem de reglare automată este optimizat folosind tehnici de tip ILC cu scopul de a obține urmărirea unei traectorii de referință a ieșirii controlate, ieșirile controlate pot fi de tipul unor funcții de bază des folosite în aproximarea funcțiilor în general. Spre exemplu, funcții radiale de bază, funcții spline, etc, (Wang et al., 2014; Radac and Precup 2015b). Rezultă astfel aşa-numitele perechi de primitive intrare-ieșire. În acest caz, în cazul urmăririi unei noi traectorii, referința care asigură urmărirea poate fi predictată off-line prin descompunerea traectoriei dorite la ieșire în funcție de ieșirile perechilor de primitive și apoi prin recompunerea intrărilor perechilor de primitive. Și în acest caz se poate discuta despre o abordare care folosește funcții de bază în aproximarea unor funcții mai generale, deci tot despre conceput de aproximare folosind rețele neurale.

D. BIBLIOGRAFIE

D.1. Bibliografie aferentă secțiunilor B și C

- 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.
- Esparza 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. Riachy (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. Savarese (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. Hytönen (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. Dragoș (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. Dragoș (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. Dragoș (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 quadcopter 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.

Partea II. Raport științific intermediar al contractului privind implementarea proiectului în perioada ianuarie – decembrie 2016

A. SINTEZĂ GENERALĂ ASUPRA REZULTATELOR

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: ş.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 2016 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**.

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 tehnologile 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 (specificațiilor de performanță).

Acordarea parametrilor regulațoarelor automate în medii cu restricții, în paradigma data-based control (DbC), întărește 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 reacția perturbațiilor). Necesitatea este indicată clar în (Report, 2011) ca și arie 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), diverși roboți (în particular, mobili) care îmbunătățesc execuțiile sarcinilor prin învățare prin planificare, urmărire, evitarea ciocnirilor și obstacolelor.

În robotică, spre exemplu, traiectoriile 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-ieșire 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 traiectorii prin optimizarea semnalului de referință poate fi rezolvată prin tehnica **model-free** ILC. Perechile intrare de referință-ieșire 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 ținând seama de particularitățile aferente;
- iv) Analiza stabilității buclei de reglare pentru unele dintre tehnici de proiectare model-free poate fi problematică atunci când nu există modele ale proceselor; există doar tehnici indirecte 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 învață 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-iesările 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 traекторii 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 redusă prin aproximarea cu funcții radiale de bază (RBF, spline, polinomiale, Fourier, etc.) astfel încât optimizarea (învățarea) să aibă loc într-un subspațiu de dimensiune redusă.

Iesările primitive vor fi apoi tratate ca **funcții de bază** folosite în aproximarea temporală a noilor traекторii 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 primitiveelor**. 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 aproximărate 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 tehniciilor 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 asemanător 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 ușual ca și o soluție a unei

probleme de conducere optimală care face uz de un model al procesului condus, semnalul este aproximat, 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 viteză 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 accelerările 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, tombă, deplasare point to point), sub anumite restricții pentru stări și pentru capetele traectoriei (initial și final) privind poziția și viteză. 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 cîte 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 modeleză DMP) este învățată astfel încât să asigure o traекторie 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 DMPului. 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 viteză 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.

Remarci:

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), explotând 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 $T(q) \in \mathbb{R}^{2 \times 2}$:

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

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

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

$$\begin{pmatrix} \mathbf{y}_n \\ \mathbf{y}_{n+1} \\ \vdots \\ \mathbf{y}_{N-n} \end{pmatrix} = \begin{pmatrix} \mathbf{t}_1 & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{t}_2 & \mathbf{t}_1 & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{t}_{N-n} & \mathbf{t}_{N-n-1} & \cdots & \mathbf{t}_1 \end{pmatrix} \mathbf{r}_0, \quad (C1.2)$$

In (C1.2), $\mathbf{t}_i \in \mathbb{R}^{2 \times 2}$, $i=1\dots N-n$ reprezintă coeficienții răspunsului la impuls a SRA MIMO notați în forma compactă în matricea $\mathbf{T} \in \mathbb{R}^{2(N-n) \times 2(N-n)}$. Relația (C1.2) se poate scrie ca $\mathbf{Y}=\mathbf{TR}$ notând $\mathbf{Y}=(\mathbf{y}_n^T \dots \mathbf{y}_{N-n}^T)^T$ și $\mathbf{R}=(\mathbf{r}_0^T \dots \mathbf{r}_{N-n}^T)^T$. Sub același formalism de notație avem $\mathbf{Y}^d=[(\mathbf{y}_n^d)^T \dots (\mathbf{y}_{N-n}^d)^T]^T$. Cu $\tilde{\mathbf{W}}_i = \text{diag}(\mathbf{W}_i, \mathbf{W}_i, \dots)$, $\tilde{\mathbf{W}}_i \in \mathbb{R}^{2(N-n) \times 2(N-n)}$, problema de optimizare (PO) de urmărire a unei traiectorii 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

$$r_i^*(t_d) = \arg \min_{r_i(t_d)} J_i \left(\frac{r_i(t_d)}{r_2(t_d)} \right) = \frac{1}{N} \sum_{\tau=0}^{N-n-1} (\|\varepsilon_i(\tau+n)\|_{w_{i1}}^2 + \|r_i(\tau)\|_{w_{i2}}^2), \quad r_2^*(t_d) = \arg \min_{r_2(t_d)} J_2 \left(\frac{r_2(t_d)}{r_1(t_d)} \right) = \frac{1}{N} \sum_{\tau=0}^{N-n-1} (\|\varepsilon_2(\tau+n)\|_{w_{21}}^2 + \|r_2(\tau)\|_{w_{22}}^2). \quad (C1.5)$$

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

$$\mathbf{R}^{(0)} = \arg \min_{\mathbf{R}^{(0)}} J_i(\mathbf{R}^{(0)}, \mathbf{R}^{(0)}) = \frac{1}{N} (\|\mathbf{Y}^{(0)} - \mathbf{Y}^{(0)d}\|_{\tilde{\mathbf{W}}_1^{(0)}}^2 + \|\mathbf{R}^{(0)}\|_{\tilde{\mathbf{W}}_2^{(0)}}^2), \quad (C1.6)$$

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 $\tilde{\mathbf{W}}_1^{(0)} = \text{diag}(W_{i1}, W_{i1}, \dots)$, $\tilde{\mathbf{W}}_1^{(0)} \in \mathbb{R}^{(N-n) \times (N-n)}$, $\tilde{\mathbf{W}}_2^{(0)} = \text{diag}(W_{i2}, W_{i2}, \dots)$, $\tilde{\mathbf{W}}_2^{(0)} \in \mathbb{R}^{(N-n) \times (N-n)}$. Fie $\mathbf{T}^{(0,i)} \in \mathbb{R}^{(N-n) \times (N-n)}$, $i, m \in \{1,2\}$ notațiile liftate a funcțiilor de transfer (f.d.t) $T_m(q)$, $i, m \in \{1,2\}$, construite din coeficienții răspunsului la impuls corespunzători acestor f.d.t. A schemă iterativă de căutare bazată pe informație de gradient pentru rezolvarea PO (C1.6) este

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

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

variabilele $\mathbf{R}^{(0)}$, evaluat la variabilele din iterația curentă, $\tilde{\mathbf{H}}_{j+1}^{-1}$, $i \in \{1,2\}$ 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

$$\left. \frac{\partial J_i}{\partial \mathbf{R}^{(0)}} \right|_{\mathbf{R}=\mathbf{R}_j^{(0)}} = \frac{2}{N} \mathbf{T}^{(0,i)T} \tilde{\mathbf{W}}_1^{(0)} \mathbf{E}_j^{(0)} + \frac{2}{N} \tilde{\mathbf{W}}_2^{(0)} \mathbf{R}_j^{(0)}, \quad (C1.8)$$

Prin aplicarea regulilor de derivare a matricilor în raport cu vectori, $\mathbf{E}_j^{(0)} = \mathbf{T}^{(0,i)T} \mathbf{R}_j^{(0)} + \mathbf{T}^{(0,i)T} \mathbf{R}_j^{(0)} - \mathbf{Y}^{(0)d}$, $m \in \{1,2\}$, $m \neq i$, reprezintă erorile de urmărire ale iterației curente j . Al doilea termen din (C1.8) depinde de valoarea cunoscută a $\mathbf{R}_j^{(0)}$ la iterația curentă, în timp ce primul termen al relației (C1.8) depinde de mărimea necunoscută $\mathbf{T}^{(0,i)}$. 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

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

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 $\mathbf{E}_j^{(0)} = \mathbf{Y}_j^{(0)} - \mathbf{Y}_j^{(0)d} = \mathbf{T}^{(0,i)T} \mathbf{R}_j^{(0)} + \mathbf{T}^{(0,i)T} \mathbf{R}_j^{(0)} - \mathbf{Y}^{(0)d}$. 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. $\mathbf{R}_j^{(0)}$ este păstrat constant și privit ca și perturbație pentru primul canal de reglare de tip SISO. Atunci $\mu_1 \cdot \text{flp}(\tilde{\mathbf{W}}_1^{(0)} \mathbf{E}_j^{(0)})$, cu μ_1 un scalar nenul, este folosit ca și perturbație de amplitudine mică peste

vectorul r.i. nominal $\mathbf{R}_j^{(1)}$, și ieșirea reglată a SRA MIMO, $\mathbf{Y}_G^{(1)}$, este înregistrată în acest prim experiment de gradient ca fiind definită de relația $\mathbf{Y}_G^{(1)} = \mathbf{T}^{(1,1)}(\mathbf{R}_j^{(1)} + \mu_1 \cdot ffp(\tilde{\mathbf{W}}_1^{(1)}\mathbf{E}_j^{(1)})) + \mathbf{T}^{(2,1)}\mathbf{R}_j^{(2)}$.

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 $\mu_1 \cdot ffp(\tilde{\mathbf{W}}_1^{(2)}\mathbf{E}_j^{(2)})$, cu μ_1 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 $\mathbf{Y}_G^{(2)} = \mathbf{T}^{(2,2)}(\mathbf{R}_j^{(2)} + \mu_2 \cdot ffp(\tilde{\mathbf{W}}_1^{(2)}\mathbf{E}_j^{(2)})) + \mathbf{T}^{(1,2)}\mathbf{R}_j^{(1)}$.

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

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

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 traectorii de referință nemaîntâlnită 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 fiecarei perechi de primitive sunt în continuare denumite ca primitive de intrare, iar ieșirile controlate ale fiecăreia perechi de primitive sunt mai departe referite ca și primitive de ieșire. Fie P perechi de primitive descrise în notația în timp $\{\mathbf{r}_{t_j}^p, \mathbf{y}_{t_{j+k}}^p\}, k=0..N-m-1$ sau $\{\mathbf{R}^p, \mathbf{Y}^p\}, p=1..P$ în forma liftată, fiecare pereche reprezentând soluția PO

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

Considerăm ca fiecare din cele P PO din (C1.11) sunt rezolvate folosind algoritmul de tip model-free ILC descris mai sus. Pentru a rezola PO (C1.3) folosind primitivele $\{\mathbf{R}^p, \mathbf{Y}^p\}, p=1..P$ care rezolvă (C1.11), fie $\mathbf{w} = (w_1 \dots w_P)^T \in \mathfrak{R}^P$ proiecția traectoriei noi dorite spre a fi urmările \mathbf{Y}^d pe spațiul primitivelor de ieșire $\{\mathbf{Y}^p | p=1..P\}$. 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 $\mathbf{Y}^p, p=1..P$, primitivele de ieșire ale PO (C1.11) și proiecția vectorului \mathbf{Y}^d în spațiul primitivelor de ieșire este $\mathbf{w} \in \mathfrak{R}^P$ 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 invarianță în timp a SRA.

Primitivele de ieșire $\mathbf{Y}^p \in \mathfrak{R}^{2(N-m)}$ din (C1.12) sunt considerate ca și funcții de bază folosite în aproximare și proiecția lui $\mathbf{Y}^d \in \mathfrak{R}^{2(N-m)}$ 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 formă $y_i(t_j) = a_i e^{-\alpha_i t_j - \epsilon_i t_j^2 / s_i}$, $i \in \{1,2\}$, atunci fiecare primitivă de ieșire P este construită din ieșirile SRA MIMO $\mathbf{y}_{t_j} = [y_1(t_j) \ y_2(t_j)]^T$ scrise în forma liftată ca și $\mathbf{Y}^p, p=1..P$. Aici a_i, c_i și s_i reprezintă amplitudinea, centru și largimea lui $y_i(t_j)$ (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 $\{\mathbf{R}_{d_p}^n, \mathbf{Y}_{d_p}^n\}, n=1..N$, adică fiecare pereche de primitive

originală indexată de $0=1..N$ 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 $\mathbf{Y}^d = \sum_{p=1}^P w_p \mathbf{Y}_{d_p}^n, n=1..N$, care în notație indexată în timp este

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

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

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

Se poate merge chiar mai departe prin codificarea primitivele de intrare folosind alte funcții radiale de bază (RBF) astfel încât întreaga învățare a acestor primitive de intrare să se desfășoare într-un spațiu 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 $\mathbf{y}(k) = [y_1(k) \ y_2(k)]^T \in \mathbb{R}^{2 \times 1}$ este vectorul ieșirii reglate, $\mathbf{y}(k) = [y_1(k) \ y_2(k)]^T \in \mathbb{R}^{2 \times 1}$ este vectorul de comandă al intrărilor, T reprezintă notația pentru operația de transpunere a matricelor, n_y și n_u reprezintă ordinea 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 $\Delta \mathbf{y}(k+1) = \mathbf{y}(k+1) - \mathbf{y}(k)$, $\Delta \mathbf{u}(k) = \mathbf{u}(k) - \mathbf{u}(k-1)$. Să $b = \text{const} > 0$.

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 $\mathbf{y}^*(k+1) = [\mathbf{y}_1^*(k+1) \ \mathbf{y}_2^*(k+1)]^T$ 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:

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

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 constant și $\mu > 0$ este un alt factor de ponderare, diferit de controlul optim. Condițiile de resetare sunt:

$$\hat{\phi}_{ii}(k) = \hat{\phi}_{ii}(1), \quad \text{if } |\hat{\phi}_{ii}(k)| < b_2 \text{ or } |\hat{\phi}_{ii}(k)| > a b_2 \text{ or } \text{sgn}(\hat{\phi}_{ii}(k)) \neq \text{sgn}(\hat{\phi}_{ii}(1)), \quad (C2.6)$$

$$\hat{\phi}_{ij}(k) = \hat{\phi}_{ij}(1), \quad \text{if } |\hat{\phi}_{ij}(k)| > b_1 \text{ or } \text{sgn}(\hat{\phi}_{ij}(k)) \neq \text{sgn}(\hat{\phi}_{ij}(1)), \quad i \neq j.$$

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

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

în care $\rho > 0$ este o altă constantă de timp cu pas constant. Găsirea parametrilor $\hat{\Phi}(1)$, 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 o 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 a 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:

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

în care $y_s(k+1) = f(y(k), \dots, y(k-n_y), u_0(k), \dots, u_0(k-n_u))$ este vectorul ieșirii a procesului nelinear, $u_0(k) = C_0(\theta, u(k-1), \dots, u(k-n_u), e(k), \dots, e(k-n_e))$ (notăția prescurtată este exprimată ca $u_0(k) = C_0(\theta, u(k-1), e(k))$) este vectorul ieșirii regulatorului nelinear, cu uc și ec – ordinele cunoscute ale structurii fixe ale regulatorului parametrizat de către vectorul θ , $e(k) = r(k) - y_s(k)$ este eroarea de urmărire, $r(k)$ este vectorul intrării referinței aplicat sistemului în buclă închisă, $y^d(k) = m(y^d(k-1), \dots, y^d(k-n_m), r(k-1), \dots, r(k-n_m))$ este ieșirea modelului de referință nelinear m selectat de către utilizator de ordin ym și rm 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 traiectorii similare. Prin impunerea notăției 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:

$$J_{VRFT}(\theta) = \frac{1}{N} \sum_{k=1}^N \|C_0(\theta, \bar{e}(k)) - u(k)\|^2, \quad (C2.9)$$

În cazul VRFT MIMO nu este necesar filtrul variabil în timp pentru a face ca $J_{MR}(\theta)$ și $J_{VRFT}(\theta)$ 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:

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

$$\hat{\Phi}(k) = h(\hat{\Phi}(k-1), u(k-1), u(k-2), y(k), y(k-1), \theta).$$

în care $g, h \in \mathbb{R}^{2x1}$ sunt funcții nelineare de argumentele lor. Prin introducerea unui vector adițional de stare $z(k) = u(k-1)$, se poate arăta că modelul matematic intrare stare ieșire este de forma $\chi(k) = F(\chi(k-1), U(k), \theta)$, unde vectorul stare este $\chi(k) = [u(k)^T \ z(k)^T \ \hat{\Phi}(k)^T]^T$, vectorul intrare este $U(k) = [y^*(k+1)^T \ y(k)^T \ y(k-1)^T]^T$, iar vectorul parametrilor este $\theta = [\rho \ \eta \ \lambda \ \mu]^T$, care este considerat ca și un vector de intrare adițional (adică vectorul perturbator).

Folosind notățile 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:

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

$$z(k) = u(k-1).$$

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

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

$$\begin{aligned}
\hat{\Phi}(2) &= \mathbf{h}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}(2), \mathbf{y}(1), 0), \\
\mathbf{u}(2) &= \mathbf{g}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}(2), \mathbf{y}(1), \mathbf{y}'(3), \theta), \\
\mathbf{u}(3) &= \mathbf{g}(\hat{\Phi}(2), \mathbf{u}(2), \mathbf{u}(1), \mathbf{y}(3), \mathbf{y}(2), \mathbf{y}'(4), 0) = \mathbf{g}(\mathbf{h}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}(2), \\
&\quad \mathbf{y}(1), 0), \mathbf{g}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}(2), \mathbf{y}(1), \mathbf{y}'(3), 0), \mathbf{u}(1), \mathbf{y}(3), \mathbf{y}(2), \mathbf{y}'(4), 0), \\
&= \mathbf{g}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}(3), \mathbf{y}(2), \mathbf{y}(1), \mathbf{y}'(3), \mathbf{y}'(4), 0),
\end{aligned} \tag{C2.13}$$

...

$$\begin{aligned}
\mathbf{u}(k) &= \mathbf{g}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}(k), \mathbf{y}(k-1), \dots, \mathbf{y}(2), \mathbf{y}(1), \mathbf{y}'(k+1), \mathbf{y}'(k), \dots, \\
&\quad \mathbf{y}'(4), \mathbf{y}'(3), 0) = \mathbf{g}(\hat{\Phi}(1), \mathbf{u}(1), \mathbf{u}(0), \mathbf{y}'(k+1) - \mathbf{y}(k), \mathbf{y}'(k) - \mathbf{y}(k-1), \dots, \\
&\quad \mathbf{y}'(3) - \mathbf{y}(2), \mathbf{y}(1), 0).
\end{aligned}$$

Dacă realizăm notația $e(k) = \mathbf{y}'(k+1) - \mathbf{y}(k)$ atunci $\mathbf{u}(k)$ din (C2.13) poate să reiasă din descrierea nelineară recurrentă a intrărilor-ieșirilor de forma $\mathbf{u}_{\theta_c}(k) = C_{\theta_c}(\theta_c, \mathbf{u}(k-1), \dots, \mathbf{u}(k-n_{uc}), e(k), \dots, e(k-n_{uc}))$, cu $\theta_c = \{\hat{\Phi}(1), \theta^T\}$. Dacă $r(k)$ specific tehnicii VRFT este considerat echivalent cu $\mathbf{y}'(k+1)$ de la algoritmul MFAC, atunci structura regulatorului MFAC poate fi considerată în buclă închisă. Figura 1 prezintă structura sistemului de reglare automată cu algoritmul MFAC-VRFT.

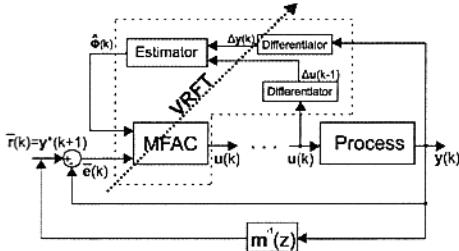


Fig. 1. Structura sistemului de reglare automată cu algoritmul MFAC-VRFT [18]

Alegând modelul de referință $m = I_2$ în proiectarea VRFT-ului nelinear devine echivalent cu minimizarea $J_{MFAC}(\theta) = \sum_{k=1}^N \|y_0(k) - y'(k)\|^2$, 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 $m = I_2$. Prin urmare alegându-l pe $m \neq I_2$ 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 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 ușoară caracterizată prin modelul de referință 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.
- Esparza 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. Dragos (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. Quirgoa (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 influență 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 influență 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 influență 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. Szedlak-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. Szedlak-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.

Partea III. Raport științific intermediar al contractului privind implementarea proiectului în perioada ianuarie – septembrie 2017

A. SINTEZĂ GENERALĂ ASUPRA REZULTATELOR

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 2017 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 2016. **Activitățile** desfășurate pentru atingerea acestui obiectiv se referă la:
 - 1.1. Extinderea tehniciilor propuse la sisteme multivariable – continuare 2016.
 - 1.2. Validarea abordărilor teoretice prin simulări numerice și experimente pe echipamente de laborator. Cîteva rezultate sunt prezentate succint în secțiunea B.
 - 1.3. Extinderea tehniciilor propuse la sisteme multivariable. Rezultatele aferente sunt prezentate în cadrul tehniciilor din secțiunea C.1.
- (2) Dezvoltarea tehniciilor de acordare a regulatoarelor de tip model-free – continuare an 2016. **Activitățile** desfășurate pentru atingerea acestui obiectiv se referă la:
 - 2.1. Formularea a noi tehnici de tip model-free data-based control – continuare an 2016. Rezultate aferente unei noi tehnici de învățare bazată pe compunerea adaptivă de primitive sunt prezentate în secțiunea B.
 - 2.2. Validarea tehniciilor propuse prin simulări numerice și experimente pe echipamente de laborator – continuare an 2016. Rezultatele de validare sunt prezentate în secțiunea B.
- (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 2 lucrări publicate în reviste ISI cu factor de impact, [P1]–[P3] factor de impact cumulat ISI Science Citation Index (SCI) calculat conform Thomson Reuters 2017 Journal Citation Reports = 13.950.
 - 3.2. Participarea și prezentarea rezultatelor cercetării la conferințe importante din domeniu. Au rezultat 7 lucrări [D1], [R1]–[R5], [S1], publicate în volumele unor conferințe indexate în baze de date internaționale (INSPEC, IEEE Xplore, Scopus, DBLP).

Pentru **anul 2017** livrabilele propuse în cadrul planului de realizare al proiectului sunt: raportul de cercetare intermediar prezent, **1 lucrare** științifică publicată în revistă 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 2017 sunt:

- **3 lucrări** publicate în reviste ISI cu factor de impact, factor de impact cumulat ISI Science Citation Index (SCI) calculat conform Thomson Reuters 2017 Journal Citation Reports = **13.950**.
- **6 lucrări** publicate în volumele unor **conferințe** indexate în baze de date internaționale (INSPEC, IEEE Xplore, Scopus, DBLP).
- **1 raport** științific.

B. Reglarea bazată pe învățare de nivel înalt utilizând primitive stocate

Un cadrul ILC pentru formularea problemei de urmărire a traiectoriei de referință este redat în continuare. În acest cadrul, se va face uz de reprezentarea super vectorială (sau liftată). Se are în vedere ca ieșirea Sistemului de reglare automată (SRA) să urmărească din ce în ce mai bine o traiectorie de referință notată $y^d(k)$. Pentru un exces poli-zerouri al SRA de valoare n , reprezentarea liftată pentru un experiment de durata a N pași de eşantionare capătă expresia

$$Y = TR + Y_{\perp}, \quad (B.1)$$

unde

$$\begin{aligned}
\mathbf{Y} &= [y(n) \quad y(n+1) \quad \dots \quad y(N-1)]^T, \\
\mathbf{R} &= [r(0) \quad r(1) \quad \dots \quad r(N-n-1)]^T, \\
\mathbf{Y}_d &= [y_{1,d} \quad y_{2,d} \quad \dots \quad y_{(N-n),d}]^T, \\
\mathbf{T} &= \begin{bmatrix} t_1 & 0 & \dots & 0 \\ t_2 & t_1 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ t_{N-n} & t_{N-n-1} & \dots & t_1 \end{bmatrix}.
\end{aligned} \tag{B.2}$$

\mathbf{R} este vectorul intrare de referință care conține secvența eșantioanelor semnalului de referință pe intervalul de timp discret $0 \leq k \leq N-n-1$, \mathbf{Y} este ieșirea procesului condus și totodată ieșirea SRA, t_i este al i -lea coefficient de răsuns la impuls al funcției de transfer (f.d.t) a SRA $T(q)$, \mathbf{T} este o matrice Toeplitz inferior triunghiulară, \mathbf{Y}_d este răspunsul liber al SRA datorat condițiilor inițiale nenule și perturbațiilor identic-repetitive la fiecare iterație, și indicele superior T indică transpusa matricei. În continuare se presupune condiții inițiale nule deoarece \mathbf{Y}_d poate fi absorbit cu ușurință în \mathbf{Y}^d - vectorul traectoriei de referință generat din $y^d(k)$. Vectorul erorii de urmărire $\mathbf{E}(\mathbf{R})$ se exprimă ca

$$\mathbf{E}(\mathbf{R}) = [e(0) \quad \dots \quad e(N-n-1)]^T = \mathbf{Y}(\mathbf{R}) - \mathbf{Y}^d = \mathbf{T}\mathbf{R} - \mathbf{Y}^d. \tag{B.3}$$

$$\mathbf{Y}^d = [y^d(n) \quad \dots \quad y^d(N-1)]^T.$$

Cunoașterea lui \mathbf{T} ar genera referință optimală care ar duce la eroare de urmărire zero: $\mathbf{R} = \mathbf{T}^{-1}\mathbf{Y}^d$. Totuși, \mathbf{T} poate fi slab condiționată, de dimensiune foarte mare și predispusă la erori de măsurarea a coeficienților de răsuns la impuls care o caracterizează, deci folosirea \mathbf{T}^{-1} tebuie evitată. Fie obiectivul de urmărire a traectoriei de referință formulat ca o problema de optimizare (PO)

$$\mathbf{R}^* = \arg \min_{\mathbf{R}} J(\mathbf{R}) = \frac{1}{N} (\|\mathbf{E}(\mathbf{R})\|_{\mathbf{W}_L}^2 + \|\mathbf{R}\|_{\mathbf{W}_R}^2). \tag{B.4}$$

unde $\mathbf{W}_L \in \mathbb{R}^{(N-n) \times (N-n)}$ și $\mathbf{W}_R \in \mathbb{R}^{(N-n) \times (N-n)}$ sunt matrici pozitiv-definite și diagonale, iar notația generală $\|\mathbf{X}\|_P = \sqrt{\mathbf{X}^T \mathbf{P} \mathbf{X}}$ indică norma P -ponderată a unui vector \mathbf{X} , unde \mathbf{P} este o matrice simetrică pozitiv-definită, de asemenea: $\mathbf{P} = \mathbf{P}^T > 0$. Termenul de regularizare $\frac{1}{N} \|\mathbf{R}\|_{\mathbf{W}_R}^2$ în (B.4) poate fi folosit în diverse scopuri pentru a negocia precizia execuției cu efortul necesar atingerii acesteia.

Dacă $\mathbf{W}_L = \mathbf{I}_{N-n}$, unde $\mathbf{I}_{N-n} = \text{diag}(1, 1, \dots, 1) \in \mathbb{R}^{(N-n) \times (N-n)}$ este matricea identitate de ordin $(N-n)^{th}$, și $\mathbf{W}_R = \mathbf{0}_{N-n}$, unde $\mathbf{0}_{N-n} = \text{diag}(0, 0, \dots, 0) \in \mathbb{R}^{(N-n) \times (N-n)}$, PO (B.4) dorește urmărirea perfectă a traectoriei de referință dorite, și soluția la PO (B.4) va fi exact $\mathbf{R} = \mathbf{T}^{-1}\mathbf{Y}^d$. Eroarea de urmărire când $\mathbf{R} = \mathbf{Y}^d$ este setat ca și intrare de referință este $\mathbf{E}(\mathbf{R}) = \mathbf{Y} - \mathbf{Y}^d = (\mathbf{T} - \mathbf{I}_{N-n})\mathbf{Y}^d$, care în domeniul timp corespunde la $e(k) = (T(q) - I)y^d(k)$. Uzual, $e(k) = 0$ doar dacă $T(q) = I$, acest deziderat având loc la frecvențe reduse (de tip filtru trece-jos) ale SRA. Deci $\mathbf{R} = \mathbf{T}^{-1}\mathbf{Y}^d$ conduce la $e(k) = 0$, aceasta corespunzând la $r(k) = T(q)^{-1}y^d(k)$, adică, inversarea perfectă a SRA.

Fie soluția analitică la PO (B.4)

$$\mathbf{R}^* = (\mathbf{T}^T \mathbf{W}_L \mathbf{T} + \mathbf{W}_R)^{-1} \mathbf{T}^T \mathbf{W}_L \mathbf{Y}^d, \tag{B.5}$$

care poate fi obținută relativ simplu prin diferențierea funcției obiectiv din (B.4) în raport cu \mathbf{R} , egalând cu zero ecuația obținută și apoi rezolvând-o. Această soluție nu a fost aplicată în secțiunea precedentă deoarece nu s-a dorit cunoașterea matricei \mathbf{T} și soluția \mathbf{R}^* a fost calculată cu o abordare iterativă folosind cu o tehnică model-free ILC. Această abordare este similară ca și comportament sistemelor biologice ce își îmbunătățesc execuția sarcinilor prin repetiție, bazat doar pe reacția erorii. Această reacție a erorii este obținută prin acumularea informațiilor primite din partea senzorilor vizuali, tactili, auditivi și olfactivi.

Soluția (B.5) dezvăluie de asemenea faptul că în cazul particular $\mathbf{W}_R = \mathbf{0}_{N-n}$ și $\mathbf{W}_L = \mathbf{I}_{N-n}$ soluția este necauzală deoarece $(\mathbf{T}^T \mathbf{T})^{-1} \mathbf{T}^T$ nu mai este inferior triunghiulară. Fiecare eșantion al vectorului soluțiilor optime \mathbf{R}^* poate fi exprimat ca o combinație liniară a tuturor eșantioanelor trecute sau viitoare ale ieșirilor dorite:

$$\begin{aligned}
r^*(k) &= \dots + \alpha_{-NP} y^d(k-NP) + \dots + \alpha_{-1} y^d(k-1) + \alpha_0 y^d(k) \\
&\quad + \alpha_1 y^d(k+1) + \dots + \alpha_{NF} y^d(k+NF) + \dots, \quad 0 \leq k \leq N-n-1,
\end{aligned} \tag{B.6}$$

unde NP și NF reprezintă numărul de eșantioane trecute și viitoare ale lui $y^d(k)$. Valorile NP și NF sunt infinite pentru sisteme cu răsuns infinit la impuls (IIR). Din punct de vedere practic, aceste valori vor fi considerate finite; prin urmare vor fi folosite trunchieri.

Ecuția (B.6) poate fi interpretată astfel încât pentru planificatorul de nivel înalt, pentru a putea calcula acțiunea optimă la momentul eșantionului curent k , este necesară cunoașterea variabilelor de ieșire din trecut și a variabilelor de ieșire viitoare dorite. Cunoașterea ieșirii viitoare dorite necesită din partea planificatorului de nivel

înaltă abilității de proiecție a obiectivelor. O compensare corespunzătoare a lui $y^d(k)$ poate fi luată în considerare atunci când k necesită cunoașterea lui $y^d(k)$ în afara domeniului de testare $0 \leq k \leq N-n-1$. Ecuția (B.6) prezintă similarități cu reglarea adaptivă neuronală inversă (Narendra and Mukhopadhyay, 1997), unde pe de o parte se folosește în legea de reglare doar un eșantion one-step-ahead al lui $y^d(k)$ ca și criteriu one-step-ahead care este apoi minimizat și pe de altă parte eșantioanele trecute ale lui $y^d(k)$ sunt înlocuite cu eșantioanele de ieșire reglate efectiv $y(k)$ pentru a obține avantaje ale reglării cu reacție cum ar fi compensarea incertitudinilor procesului și rejectarea perturbațiilor exogene.

Coefficienții din (B.6) sunt aceiași pentru fiecare pereche de ieșiri de referință controlate de intrare ce este învățată prin repetări. Aceste perechi vor fi denumite de acum încolo perechi de primitive, sau și mai simplu, primitive. Dacă unele perechi de primitive sunt învățate, cu notația $\{r_i^*(k), y^d(k)\}$, $i = 1 \dots P$ (sau $\{R_i^*, Y^d\}$, în notație vectorială), ca și soluții pentru PO

$$R_i^* = \arg \min_{R_i} \frac{1}{N} (\| \mathbf{T} R_i - Y^d \|_{W_d}^2 + \| R_i \|_{W_R}^2), i = 1 \dots P, \quad (B.7)$$

atunci coeficienții din (C3.2) pot fi obținuți în mod analitic din perechi de primitive memorate folosind, de exemplu, metoda liniară a celor mai mici pătrate. În acest fel de fiecare dată când predictorul de nivel înalt furnizează o traiectorie de urmărit nema întâlnită, intrarea de referință optimă poate fi calculată în mod adaptiv folosind cunoștințele stărilor din trecut și stările dorite viitoare. În orice caz, acest mecanism explicit bazat pe identificare nu pare a fi specific sistemelor biologice care în practică sunt mai susceptibile de a fuziona, folosind diferite mecanisme, perechile de primitive optime de reglare învățate. Considerând o situație în care un om, de exemplu, este capabil să imite anumite mișcări/acțiuni ale altui individ. Cu toate că nu au fost exersate anterior, omul este capabil să realizeze, să execute sarcina într-un mod aproape optim din prima încercare. Prin urmare se presupune în mod implicit faptul că creierul planifică/prezice în prealabil o traiectorie de executat pentru sistemul de reglare motor, realizat în afara conștiinței. (Gallivan et al., 2015), și reușește într-un fel să contopească cunoștințele diferitelor sarcini realizate anterior stocate în sistemul neuromuscular. Cu toate că mecanismele exacte utilizate pentru dobândirea acestei capacitați nu sunt formalizate complet, este acceptat faptul că sistemele biologice nu rezolvă ecuații matematice explicite și nu folosesc modele matematice explicite pentru astfel de probleme de învățare și predicție, de aici derivând motivația pentru abordarea propusă în această lucrare.

În cele ce urmează este prezentat un nou mecanism de reglare adaptivă combinând cunoștințele acumulate folosind o măsură a similarității în raport cu situații precedente la care sistemul de reglare a fost expus și un criteriu de selecție în ceea ce privește cele mai asemănătoare dintre aceste situații. Abordarea propusă în această lucrare este tot o abordare computațională chiar dacă sistemele biologice nu utilizează una explicită. Cu toate acestea, reunesc reprezentări comportamentale memorate, ceea ce nu este modelat explicit și este capabil de a folosi acest comportament pentru a îmbunătății performanța în situații noi, în timpul unor noi sarcini de urmărire.

Să considerăm că o bază de date de modele $\{x(k), r^*(k)\}$ de lungime N_{DB} , cu condiția $0 \leq k \leq N_{DB}$, este disponibilă, unde $x(k) = [y^d(k-NP) \dots y^d(k-NF)]^T$. Aici $r^*(k)$ este privit ca ieșirea modelului, și $x(k)$ este intrarea modelului liniar. Această bază de date este creată offline prin intermediul perechilor de primitive învățate și stocate $\{R_i^*, Y^d\}$, $i = 1 \dots P$. Ponderarea directă a datelor, folosită în învățarea bazată pe regresie ponderată la nivel local oferă în (Atkeson et al., 1997) o soluție de replicare a modelelor similare și de eliminare a celor mai puțin similare prin intermediul unui mecanism de mediere ponderat astfel încât la fiecare moment k , intrarea de referință este dată de

$$r(k) = \sum_{i=1}^S w_i(x(k)) r^*(i), \quad (B.8)$$

unde S este numărul modelelor similare luate în considerare corespunzător mecanismului de selecție,

$$w_i(x(k)) = K(x(i), x(k)) / \sum_{i=1}^S K(x(i), x(k)) \quad (B.9)$$

este factorul de ponderare normat astfel încât $\sum_{i=1}^S w_i = 1$, $K(x(i), x(k)) = \exp(-\|x(i) - x(k)\|^2)$ este o funcție de ponderare, și $x(k) = [y(k-NP) \dots y(k-NF)]^T$ este punctul de interogare curent.

Toate modelele din baza de date pot fi luate în considerare când $S = N_{DB}$ sau doar cele mai similare din punct de vedere al distanței dintre $x(i)$ și $x(k)$ ca în cazul $S < N_{DB}$ și trebuie aplicat un mecanism de sortare în fiecare moment de eșantionare.

Legea de reglare în buclă deschisă propusă (B.8) nu mai este optimă din moment ce unifică diferite soluții optime prin intermediul mecanismului de mediere ponderat. În al doilea rând, prin implementarea mecanismului de calcul adaptiv parametrii ce pot afecta performanța de reglare sunt NP și NF , numărul S , funcția de ponderare și numărul și diversitatea modelelor din baza de date inițială.

Baza de date poate să crească în dimensiune pentru a îmbogăți experiența sistemului de reglare prin adăugarea modelelor nemaiîntâlnite. Această operație poate fi realizată prin compararea similarităților dintre noile modele și cele stocate în baza de date folosind aceeași metrică.

Algoritm pentru calculul intrării de referință

Să presupunem că traекторia de urmărit este specificată ca $\mathbf{y}^d(k)$. Biblioteca de primitive învățate $\{\mathbf{r}_i^*(k), \mathbf{y}^d(k)\}$, $i = 1 \dots P$ este disponibilă și stocată în memorie. Aceste primitive sunt optimizate prin intermediul unei funcții obiectiv specifice dedicată urmăririi traectoriei petru matricile date \mathbf{W}_L și \mathbf{W}_R alese de proiectant. NP și NF sunt selectate și baza de date a modelelor $\{\mathbf{x}(k), \mathbf{r}^*(k)\}$ de lungime N_{DB} este constituită. Numărul de modele similare luate în considerare pentru alcătuirea soluțiilor, $S \leq N_{DB}$, este selectat. Apoi, la fiecare pas k sunt efectuate următoarele operații:

Algoritm 2:

- O1. Folosește ieșirile trecute și ieșirile viitoare dorite pentru alcătuirea $\mathbf{x}(k) = [y(k-NP) \dots y(k), y^d(k+1) \dots y^d(k+NF)]^T$. Compensează cu $y(0)$ în partea stângă și cu $y^d(N-n-1)$ în partea dreaptă dacă sunt necesare eșantioane din afara domeniului $0 \leq k \leq N-n-1$.
- O2. Evaluatează funcția de ponderare $K(\mathbf{x}(i), \mathbf{x}(k)) = \exp(-\|\mathbf{x}(i) - \mathbf{x}(k)\|^2)$ a tuturor distanțelor dintre $\mathbf{x}(k)$ și toate modelele de intrare $\mathbf{x}(i)$, $1 \leq i \leq N_{DB}$, în baza de date. Sortează și selectează valorile cele mai ridicate S ale funcției de ponderare.
- O3. Calculează $w_i(\mathbf{x}(k))$, $1 \leq i \leq S$ și apoi evaluatează $\mathbf{r}(k)$ folosind (C3.5) cu $\mathbf{r}^*(i)$, $1 \leq i \leq S$ corespunzător celor mai asemănătoare modele din baza de date gasite în O2.
- O4. Aplică $\mathbf{r}(k)$ intrării sistemului de reglare, setează $k = k + 1$ și sare (merge) la operația O1.

Reglare bazată pe învățare de nivel intermediar folosind primitive

Cu ajutorul regulatorului Neural network-Virtual Reference Feedback Tuning (NN-VRFT) proiectat anterior, se execută o tehnică de învățare iterativă model-free a opt perechi de primitive. Pentru perioada de eșantionare $T_s = 0.1s$, primitivele de ieșire sunt

$$\begin{aligned} y^{d1}(k) &= 0.2e^{-(0.1k-20)^2/5}, \quad y^{d2}(k) = -0.2e^{-(0.1k-20)^2/5}, \\ y^{d3}(k) &= 0.2e^{-(0.1k-20)^2/20}, \quad y^{d4}(k) = -0.2e^{-(0.1k-20)^2/20}, \\ y^{d5}(k) &= 0.05e^{-(0.1k-20)^2/5}, \quad y^{d6}(k) = -0.05e^{-(0.1k-20)^2/5}, \\ y^{d7}(k) &= 0.05e^{-(0.1k-20)^2/20}, \quad y^{d8}(k) = -0.05e^{-(0.1k-20)^2/20}, \end{aligned} \quad (B.10)$$

și sunt alese ca ieșirile dorite pentru a fi urmărite prin optimizarea intrărilor de referință corespunzătoare $\mathbf{r}_i(k)$, $1 \leq i \leq 8$. Aceste primitive de ieșire implică diferite domenii de funcționare și diferite viteze de execuție. Valorile inițiale ale intrărilor de referință sunt $\mathbf{r}_i(k) = \mathbf{y}^d(k)$. Optimizarea lui $\mathbf{r}_i(k)$ conduce la perechile de primitive $\{\mathbf{r}_i^*(k), \mathbf{y}^d(k)\}$. În Fig. 2 este prezentat doar procesul de învățare pentru primul primitiv. Celălalte 7 perechi de primitive sunt ilustrate în Fig. 3. Gradul relativ al structurii de reglare este $n=1$, prin urmare, dimensiunea vectorilor de intrare de referință optimizați este de $N=399$ eșantioane pe parcursul celor 40 s ale experimentului. Matricea hessiană din algoritmul iterativ de căuare este aleasă ca $\tilde{\mathbf{H}} = \mathbf{I}_{399}$, și matricile de ponderare ale funcției obiectiv din (B.4) sunt $\mathbf{W}_L = \mathbf{I}_{399}$ și $\mathbf{W}_R = \mathbf{0}_{399}$. Coeficientul de învățare γ_j al algoritmului MFILC poate fi găsit ca soluție a PO (B.11)

$$\gamma_j = \arg \max_{\gamma_j} (\gamma_j) \quad (B.11)$$

supusă la RTI $\gamma_j > 0$ și la RTI $\left\| \mathbf{I} - \frac{2\gamma_j}{N} \mathbf{T}(q) \mathbf{T}^*(q) \right\|_2 < 1$.

Pentru $N=399$ și este egal cu $\gamma_j = 396.55$. PO (B.11) asigură convergența condițiilor Teoremei 1 cu ajutorul optimizatorului metaheuristic Gravitational Search Algorithm (Precup et al., 2011; Precup et al., 2013a) deoarece metode numerice standard nu au reușit să găsească o soluție. Pasul coeficientului de învățare $\gamma_j = 150$ a fost stabilit pentru a determina incertitudinea în potrivirea modelului de referință obținut cu ajutorul abordării NN-VRFT.

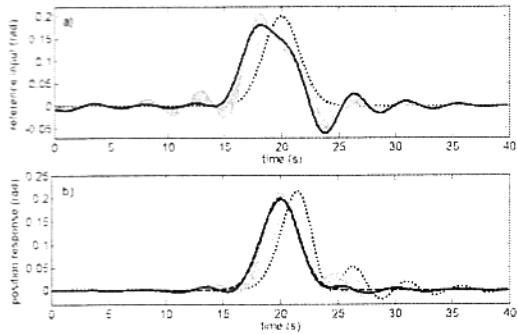


Fig. 2. Învățarea primei perechi de primitive $\{r_i^*(k), y^{d1}(k)\}$: a) evoluția intrării de referință în timpul procesului de învățare (intrarea initială de referință este ilustrată cu linie punctată neagră, cea finală este albastră, cele intermedii sunt gri); b) ieșirea reglată în timpul procesului de învățare (răspunsul inițial este ilustrat cu linie punctată neagră, ultima este albastră, primitiva de ieșire vizată $y^{d1}(k)$ este reprezentată cu linie întreruptă neagră, primitivele intermedii sunt gri).

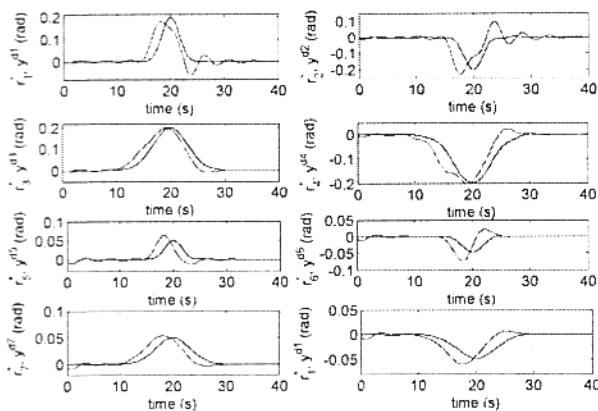


Fig. 3. Perechile de primitive învățate $\{r_i^*(k), y^{di}(k)\}$ care formează **biblioteca de primitive**: primitivele de ieșire vizate $y^{di}(k)$ sunt de culoare neagră, intrările de referință optimizate $r_i^*(k)$ sunt de culoare albastră.

Gradientul funcției obiectiv din PO (B.4) a fost estimat utilizând pașii specifici tehnicii model-free ILC dezvoltată de autori. Coeficientul de scalare μ este ales în mod automat astfel încât mărimea termenului de perturbare în fiecare experiment al gradientului este de zece ori mai mică decât mărimea intrării de referință nominale care este perturbată.

Rezultatele arată că performanța învățării este foarte bună pentru ambele primitive în ceea ce privește performanța de urmărire. De exemplu, 30 de iterații sunt utilizate pentru învățarea primei perechi de primitive și nu este utilizat niciun model al structurii de reglare în buclă închisă. Au fost efectuate 30 de experimente normale (și implicit 30 măsurători) și 30 de experimente de gradient.

Pentru perechile de primitive învățate care formează **biblioteca de primitive**, intrările de referință finale prezintă salturi la începutul sechantei temporale. Aceste salturi arată că a fost efectuată filtrarea non-cauzală.

Din alt punct de vedere, învățarea este oprită la un moment dat, convergența teoretică fiind doar la infinit. Soluțiile sunt, prin urmare, suboptimale. Așa cum se arată în Fig. 2, ieșirea dorită nu este perfect urmărită, dar destul de aproape. Schema propusă de MFILC este superioară altor scheme de învățare model-free, cum ar fi SPSA (Radac and Precup, 2016).

Urmărire de nivel înalt a noii traectorii dorite prin combinarea unor modele similare de execuție optimă

Noua traectorie care urmează să fie urmărită este descrisă ca $y^d(k) = \sin(0.5 \cdot k \cdot 0.1) \cdot 0.2 \cdot e^{-(0.1k-20)^2/20}$. Această traectorie este eșantionată în $N=400$ puncte folosind o perioadă de eșantionare de $T_s = 0.1s$ în domeniul de timp de $[0, 40]$ s.

În continuare se creează o bază de date (bibliotecă de primitive) de $N_{DB} = 3200$ puncte (corespunzătoare la 8 primitive de căte 400 de puncte fiecare) în formatul $\{x(k), r^*(k)\}$ cu $x(k) = [y^{d^*}(k-NP) \dots y^{d^*}(k) y^{d^*}(k+1) \dots y^{d^*}(k+NF)]^T$ pentru $NP = 10$ și $NF = 55$.

Valorile folosite pentru a popula baza de date sunt deci luate din perechile de primitive învățate $\{r_i^*(k), y^{d^*}(k)\}$. Intrarea de referință este în continuare calculată adaptiv prin construirea la fiecare iteratie a lui $x(k) = [y(k-NP) \dots y(k) y^d(k+1) \dots y^d(k+NF)]^T$ și folosind mecanismul de selecție și combinare din algoritm 2 dat în subsecțiunea precedentă, pentru $S = 5$. Valorile trecute ale ieșirii în $x(k)$ sunt aici eșantioanele efective ale ieșirii și nu eșantioanele trecute ale lui $y^d(k)$. Aceasta ar trebui să realizeze o adaptare în raport cu traectoriile perturbate. Intrarea finală de referință este afișată în Fig. 4 a). Ieșirea reglată a poziției este prezentată cu linie albastră în Fig. 4 b), unde $y^d(k)$ este cu linie punctată neagră. Norma erorii de urmărire este $\|y^d(k) - y(k)\|_2 = 0.6335$.

Pentru analize comparative, ieșirea reglată când $r(k) = y^d(k)$ este setată ca intrare de referință și de asemenea este prezentată cu linie roșie în Fig. 4 b). Norma erorii de urmărire este în acest caz 1.1179.

În cele din urmă, pentru problema de urmărire este oferită și o soluție model-based. Din acest punct de vedere, vectorul coeficientilor $\alpha \in \mathbb{R}^{N_p}$ rezultă din baza de date stocată utilizând metoda liniară a celor mai mici pătrate. Intrarea de referință este în continuare calculată adaptiv ca

$$r(k) = \alpha^T x(k), \quad (B.12)$$

unde

$$x(k) = [y^d(k-NP) \dots y^d(k) y^d(k+1) \dots y^d(k+NF)]^T. \quad (B.13)$$

Ieșirea reglată este evidențiată cu linie neagră solidă în Fig. 4 b). Norma erorii de urmărire este de data aceasta 0.5478.

Din compararea celor trei situații, se pare că soluția model-based oferă cea mai bună performanță de urmărire, dar soluția alcătuită din modelele de execuție optime oferă o soluție apropiată, ambele fiind mult mai bune decât atunci când $y^d(k)$ este utilizat ca intrare de referință. Așa cum este prezentat în Fig. 4 a), intrarea de referință calculată învăță comportamentul anticipativ din primitivele stocate în baza de date, deoarece în acest caz ieșirea reglată (linia albastră din Fig. 4 b)) urmărește mai bine $y^d(k)$ decât în cazul când $y^d(k)$ este setată ca intrare de referință (ieșirea reglată este redată cu linie roșie în Fig. 4 b)).

Într-un alt scenariu repetat, traекторia dorită este ușor modificată

$$y^d(k) = \sin(0.5 \cdot k \cdot 0.1) \cdot 0.2 \cdot e^{-(0.1k-20)^2/20} + k/4000. \quad (B.14)$$

Care are sfârșit de traекторie nenuă. În aceleași setări ca înainte, rezultatele sunt prezentate în Fig. 5 și arată că norma erorilor de urmărire este acum 0.7637 atunci când intrarea de referință adaptivă este aplicată structurii de reglare și 1.0354 atunci când intrarea de referință este setată ca $r(k) = y^d(k)$. Deși diferența dintre cele două strategii este acum mai mică, performanța de urmărire în abordarea adaptivă se deteriorează în ultimele 10 secunde, unde $y^d(k)$ este în principiu o rampă. Motivul este că acest model nu a fost văzut înainte, ceea ce subliniază dependența puternică a abordării propuse de experiența bogată stocată în baza de date. Prin urmare, este de așteptat ca atunci când $y^d(k)$ nu este compusă din forme asemănătoare primitivelor, abordarea adaptivă devine mai puțin exactă decât în cazul $r(k) = y^d(k)$.

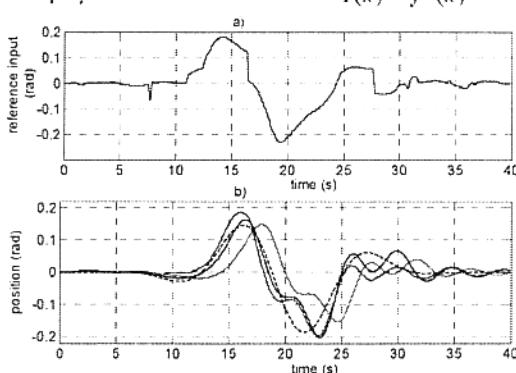


Fig. 4. a) $r(k)$ calculat folosind abordarea propusă prin amestecarea modelelor similare. b) traectoria dorită $y^d(k)$ (linie interrupță neagră), ieșirea când $r(k)$ este setat ca intrare de referință (linie continuă albastră), ieșirea când $y^d(k)$ este utilizat ca intrare de referință (linie continuă roșie) și soluția model-based (linie continuă neagră).

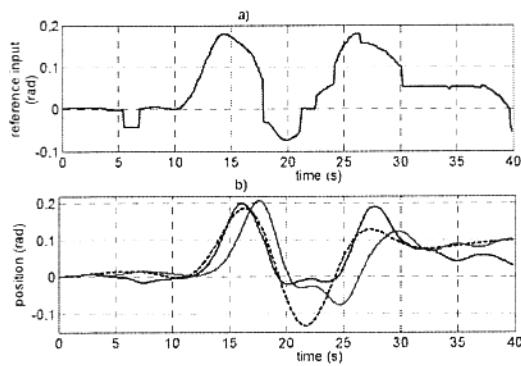


Fig. 5. a) $r(k)$ calculat folosind abordarea propusă prin amestecarea modelelor similare, b) traectoria dorită $y^d(k)$ (linie întretreruptă neagră), ieșirea când $r(k)$ este setat ca intrare de referință (linie continuă albastră), ieșirea când $y^d(k)$ este utilizat ca intrare de referință (linie continuă roșie)

Câteva experimente efectuate pentru acest studiu de caz au arătat că valoarea lui NP nu are o influență semnificativă asupra performanței ca valoarea lui NF . Cu toate acestea, pentru valori ale lui NF mai mari de 60 nu are loc nici o îmbunătățire a performanței. Adăugarea parametrului S (mai degrabă decât valoarea sa) în mecanismul de selecție a similitudinii are o influență puternică asupra performanței de urmărire. Dacă s-ar utiliza $S = N_{D_B}$, atunci referința calculată ar fi media între toate modelele din baza de date, ceea ce pierde avantajul utilizării doar a modelelor celor mai asemănătoare. În orice caz, deși modelele din baza de date aparțin primitivelor învățate în mod optim, calculul adaptiv al intrărilor de referință prin combinarea unor modele asemănătoare nu mai este optim și performanța de urmărire pentru noua traectorie nu este la fel de bună ca atunci când este învățată prin repetări utilizând tehnica ILC. Dar, după cum sugerează rezultatele, abordarea este în continuare capabilă să păstreze comportamentul anticipativ specific tehnicii ILC, de aceea considerăm că este utilă pentru generarea unei performanțe bune de urmărire pentru noi traекторii.

Mecanismul de învățare este capabil să interpoleze, la un alt nivel, între situațiile care au fost experimentate înainte, dar nu este de așteptat să funcționeze bine în afara domeniului cunoașterii. Acesta este un neajuns față de abordarea primitivă folosită în (Radac și Precup, 2015a), unde, în comparație, combinarea offline a primitivelor utilizând contextul LTI are proprietăți de generalizare și extrapolare mai bune. Abordarea offline bazată pe primitive din (Radac și Precup, 2015a) nu se poate adapta la perturbări, ceea ce reprezintă un neajuns față de abordarea propusă aici. Cu toate acestea, intrarea de referință calculată poate fi folosită ca punct de plecare pentru a afla un comportament optimizat în raport față de noua traectorie dorită $y^d(k)$, după care această nouă primitivă poate fi adăugată la baza de date pentru a îmbogăți experiența structurii de reglare de nivel înalt.

D. BIBLIOGRAFIE

D.1. Bibliografie aferentă secțiunii B

- Atkeson, C.G., Moore, A.W., Schaal, S., 1997. Locally weighted learning. *Artificial Intelligence Reviews* 11 (1–5), 11–73.
 Gallivan, J.P., Barton, K.S., Chapman, C. S., Wolpert, D.M., Flanagan, J.R., 2015. Action plan co-optimization reveals the parallel encoding of competing reach movements. *Nature Communications* 6, article number 7428.
 Narendra, K., Mukhopadhyay, S., 1997. Adaptive control using neural networks and approximate models. *IEEE Transactions on Neural Networks* 8 (3), 475–485.
 Precup, R.-E., David, R.-C., Petriu, E.M., Preitl, S., Radac, M.-B., 2011. Gravitational search algorithms in fuzzy control systems tuning. In: *Proceedings of 18th IFAC World Congress*, Milano, Italy, pp. 13624–13629.
 Precup, R.-E., David, R.-C., Petriu, E.M., Preitl, S., Radac, M.-B., 2013a. Fuzzy logic-based adaptive gravitational search algorithm for optimal tuning of fuzzy controlled servo systems. *IET Control Theory and Applications* 7 (1), 99–107.
 Radac, M.-B., Precup, R.-E., 2016. Model-free constrained data-driven iterative reference input tuning algorithm with experimental validation. *International Journal of General Systems* 45 (4), 455–476.

D.2. Bibliografie proprie (2017)

- lucrări publicate în reviste ISI cu factor de impact:

- [P1] R.-E. Precup, M.-B. Rădac, R.-C. Roman, and E. M. Petriu, Model-free sliding mode control of nonlinear systems: Algorithms and experiments, *Information Sciences*, vol. 381, no. 3, pp. 176-192, 2017, impact factor (IF) = 4.832.

- [P2] R.-E. Precup, R.-C. David, and E. M. Petriu, Grey Wolf Optimizer algorithm-based tuning of fuzzy control systems with reduced parametric sensitivity, *IEEE Transactions on Industrial Electronics*, vol. 64, no. 1, pp. 527-534, 2017, impact factor (IF) = 7.168.
- [P3] C. Pozna and R.-E. Precup, On a translated frame-based approach to geometric modeling of robots, *Robotics and Autonomous Systems*, vol. 91, pp. 49-58, May 2017, impact factor (IF) = 1.950.
- lucrări publicate în volumele unor conferințe indexate în baze de date internaționale:**
- [D1] D.-A. Duteșcu, M.-B. Radac and R.-E. Precup, Model Predictive Control of a Nonlinear Laboratory Twin Rotor Aero-dynamical System, *Proceedings of 15th IEEE International Symposium on Applied Machine Intelligence and Informatics (SAMI 2017)*, Herl'any, Slovakia, pp. 37-42, 2017, indexed in IEEE Xplore, INSPEC, Scopus.
- [R1] M.-B. Radac, R.-E. Precup, and R.-C. Roman, Anti-lock Braking Systems Data-Driven Control Using Q-Learning, *Proceedings of the 2017 IEEE International Symposium on Industrial Electronics (ISIE 2017)*, Edinborough, UK, pp. 418-423, 2017, indexed in IEEE Xplore, INSPEC.
- [R2] M.-B. Radac, R.-E. Precup, and R.-C. Roman, Multi Input-Multi Output Tank System Data-Driven Model Reference Control, *Proceedings of the 13th IEEE International Conference on Control & Automation (ICCA 2017)*, Ohrid, Macedonia, pp. 1078-1083, 2017, indexed in IEEE Xplore, INSPEC.
- [R4] R.-C. Roman, R.-E. Precup, and M.-B. Radac, Model-Free Fuzzy Control of Twin Rotor Aerodynamic Systems, *Proceedings of the 25th Mediterranean Conference on Control and Automation (MED 2017)*, Valletta, Malta, pp. 559-564, 2017, indexed in IEEE Xplore, INSPEC.
- [R5] R.-C. Roman, R.-E. Precup, M.-B. Rădac and E. M. Petriu, Takagi-Sugeno Fuzzy Controller Structures for Twin Rotor Aerodynamic Systems, *Proceedings of the 2017 IEEE International Conference on Fuzzy Systems (FUZZIEEE 2017)*, Napoli, Italy, pp. 1-6, 2017, indexed in IEEE Xplore, INSPEC.
- [S1] A.-I. Szedlak-Stinean, R.-E. Precup, and E. M. Petriu, Fuzzy and 2-DOF Controllers for Processes with a Discontinuously Variable Parameter, *Proceedings of 14th International Conference on Informatics in Control, Automation and Robotics (ICINCO 2017)*, Madrid, Spania, pp. 431-438, 2017, to be indexed in IEEE Xplore, INSPEC, Scopus.

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

