

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

*privind implementarea proiectului în perioada octombrie – decembrie 2015*

### **A. SINTEZĂ GENERALĂ ASUPRA PROIECTULUI**

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

**Principalele obiective** urmărite în cadrul proiectului în anul 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 tehniciilor 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 tehniciilor 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.

#### **Remarci:**

1. În acest raport științific pot apărea adnotări în limba engleză și, în unele cazuri, notații puțin diferite de la capitol la capitol. De fiecare dată sunt aduse însă precizările necesare pentru a face interpretările cât mai clare.
2. 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.

### **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 informatici 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 opsite 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 paradigma data-based control (DbC), întreține îmbunătățirea performanțelor sistemelor de reglare automată (SRA) atunci când unele mărimi/variabile din sistem sunt supuse restricțiilor. Pot fi amintite aici tehnici precum **Iterative Feedback**

Tuning (IFT, Hjalmarsson et al., 1994), Virtual Reference Feedback Tuning (VRFT, Campi et al., 2000), Iterative Regression Tuning (IRT, Halmevaara and Hyotyniemi, 2006), Frequency Domain Tuning (FDT, Kammer et al., 2000), Correlation-based Tuning (CbT, Karimi et al., 2004) and Simultaneous Perturbation Stochastic Approximation (SPSA, Spall, 1988).

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

Sistemele actuale autonome de conducere necesită să fie înzestrate cu mecanisme ale inteligenței artificiale și trebuie să dețină capabilități de planificare și învățare la nivelul ierarhic superior față de cel aferent funcțiilor de conducere de bază (urmărirea referinței și rejecția perturbațiilor). Necesitatea este indicată clar în (Report, 2011) ca și 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 compunere a primitivelor folosește tehnici de descompunere în serii Fourier a semnalelor. Conceptul de bibliotecă de primitive este sugerat în (Hoelzle et al., 2011), unde o pereche de intrare de referință-iesire controlată caracterizează fiecare primitivă iar aceste perechi sunt învățate folosind ILC. Un algoritm de căutare A\* pentru concatenarea temporală optimă a primitivelor este propus în (Grymin et al., 2014). *Descompunerea temporală* este analizată în (Wang et al., 2014). Primitivele folosite conțin funcții de tip B-spline.

**Obiectivul principal al cercetărilor din cadrul contractului este de a dezvolta unelele, 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 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 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 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 optimizare folosind tehnica model-free ILC (Radac et al., 2014d). Optimizarea va fi efectuată în contextul unei probleme de urmărire a unei traiectorii de referință pentru sisteme LTI și poate fi rezolvată printr-un algoritm de căutare bazat pe informație de gradient, în care gradientul este obținut experimental, fără model al procesului condus (și nici al SRA). Vor fi necesare în acest sens operații de filtrare non-cauzală efectuate offline (experimental) și va fi utilizată notația supervectorială (liftată) specifică ILC. Datorită numărului foarte mare de variabile de optimizare (sute de eșantioane ale intrării de referință per experiment) dimensiunea vectorului de variabile de optimizare va fi redus prin aproximarea cu funcții radiale de bază (RBF, spline, polinomiale, Fourier, etc.) astfel încât optimizarea (învățarea) să aibă loc într-un subspațiu de dimensiune redusă.

Iesările primitive vor fi apoi tratate ca **funcții de bază** folosite în aproximarea temporală a noilor traiectorii 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 conducede de bază (urmărirea referinței și rejecția perturbațiilor).

Tehnica de învățare propusă va fi extinsă și la SRA de tip **MIMO**. Având în vedere că unele procese pot fi bine aproximăte în vecinătatea unor puncte de funcționare cu sisteme LTI, tehnica propusă va fi extinsă și la **sisteme ușor 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 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 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 prescris către un sistem de reglare de bază ar asigura urmărirea traiectoriei. 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 conducede 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 traiectorii 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 (drone).

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 accelerăriile 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 comenzii 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 traiectoriei (inițial 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 traiectoriile

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 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 DMP-ului. Codificarea are drept rezultat ponderile RBF-ului (în particular ponderile din stratul de ieșire al acestui tip particular de rețea neurală) denumite în continuare parametrii DMP.

Generalizarea execuției manevrelor este posibilă printr-un mecanism de interpolare. Astfel, pentru fiecare manevră optimală codificată printr-un DMP, este creat un spațiu (rețea) de (hiper)-puncte de tip țintă, iar pentru fiecare punct este stocată durata dorită a traectoriei și parametrii DMP-ului. Prin urmare, se presupune că fiecare tip de manevră a fost efectuată la diferite viteze și parametrii DMP-ului au fost obținuți corespunzător. Astfel pentru orice punct țintă nou, care nu este regăsit între punctele stocate, un DMP corespunzător este obținut prin interpolare biliniară a parametrilor punctelor rețelei. Abordarea este funcțională dacă rețeaua de puncte este fin discretizată și dacă hipersuprafața rețelei de puncte este netedă. Este important însă să fie folosite pentru aproximare aceleași 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” 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 minimezate 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 **rețelele neurale**, extensia 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 regulație 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 regulațoare neliniare de tip **rețele neurale** (Previdi et al., 2004; Esparza et al., 2011) însă direcția este insuficient explloatată 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 adapataibile 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. Si 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 17<sup>th</sup> 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. 39<sup>th</sup> 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 15<sup>th</sup> 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 18<sup>th</sup> 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.
- Halmivaara, K. and H. Hytyniemi (2006). Data-based parameter optimization of dynamic simulation models, Proceedings of 47<sup>th</sup> 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 33<sup>rd</sup> 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 31<sup>st</sup> 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 8<sup>th</sup> 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 10<sup>th</sup> 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 20<sup>th</sup> 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 20<sup>th</sup> 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 39<sup>th</sup> Annual Conference of the IEEE Industrial Electronics Society (IECON 2013), Vienna, Austria, pp. 3402-3407.

- Radac, M.-B., R.-E. Precup, E. M. Petriu, S. Preitl, and C.-A. Dragos (2013c). Data-driven reference trajectory tracking algorithm and experimental validation, *IEEE Transactions on Industrial Informatics*, vol. 9, no. 4, pp. 2327-2336.
- Radac, M.-B., R.-E. Precup, and E. M. Petriu (2014a). Design and testing of a constrained data-driven iterative reference input tuning algorithm, *Proceedings of 2014 European Control Conference (ECC 2014)*, Strasbourg, France, pp. 2034-2039.
- Radac, M.-B., R.-E. Precup, E. M. Petriu, and S. Preitl, (2014b). Iterative data-driven controller tuning with actuator constraints and reduced sensitivity, *Journal of Aerospace Information Systems*, vol. 11, no. 9, pp. 551-564.
- Radac, M.-B., R.-E. Precup, E. M. Petriu, and S. Preitl (2014c). Iterative data-driven tuning of controllers for nonlinear systems with constraints, *IEEE Transactions on Industrial Electronics*, vol. 61, no. 4, pp. 6360-6368.
- Radac, M.-B. and R.-E. Precup (2014d). Data-based two-degree-of-freedom iterative control approach to constrained non-linear systems, *IET Control Theory & Applications*, DOI: 10.1049/iet-cta.2014.0187, Oct. 2014.
- Radac, M.-B., R.-C. Roman, R.-E. Precup, and E. M. Petriu (2014e). Data-driven model-free control of twin rotor aerodynamic systems: algorithms and experiments, *Proceedings of 2014 IEEE International Symposium on Intelligent Control (ISIC 2014)*, Part of 2014 IEEE Multi-Conference on Systems and Control (IEEE MSC 2014), Antibes, France, pp. 1889-1894.
- Radac, M-B, and Precup R-E. (2015a). Constrained Data-Driven Model-Free ILC-based Reference Input Tuning Algorithm, *Acta Polytechnica Hungarica*, vol. 12, no. 1, pp. 137-160.
- Radac, M-B. and Precup R-E. (2015b). Optimal behaviour prediction using a primitive-based data-driven model-free iterative learning control approach, *Computers in Industry*, vol. 74, pp. 95-109.
- Report (2011). The impact of control technology, IEEE Control Systems Society.
- Rico, Z. P., A. Lecchini-Visintini, and R. Q. Quiroga (2012). Iterative feedback tuning for the joint controllers of a 7-DOF whole arm manipulator, *Proceedings of 2012 IEEE Annual Conference on Decision and Control (CDC 2012)*, Maui, HI, USA, pp. 544-549.
- Rojas, J. D., X. Flores-Alsina, U. Jeppson, and R. Vilanova (2012). Application of multivariate virtual reference feedback tuning for wastewater treatment plant control, *Control Engineering Practice*, vol. 20, no. 5, pp. 499-510.
- Roman, R.-C., M.-B. Radac, and R.-E. Precup (2014). Data-driven model-free adaptive control of twin rotor aerodynamic systems, *Proceedings of IEEE 9<sup>th</sup> 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 27<sup>th</sup> 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 31<sup>st</sup> 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.

Director de proiect,  
§.l.dr.ing. Mircea-Bogdan Rădac

