



**ХИМИКОТЕХНОЛОГИЧЕН И МЕТАЛУРГИЧЕН
УНИВЕРСИТЕТ**

**ФАКУЛТЕТ ПО ХИМИЧНО И СИСТЕМНО ИНЖЕНЕРСТВО
КАТЕДРА „АВТОМАТИЗАЦИЯ НА ПРОИЗВОДСТВОТО“**

Ксие Джунхонг

**ИНТЕЛИГЕНТНО МОДЕЛНО-БАЗИРАНО
УПРАВЛЕНИЕ НА НЕЛИНЕЙНИ СИСТЕМИ**

А В Т О Р Е Ф Е Р А Т

на дисертация

за придобиване на образователната и научна степен „доктор“
по научна специалност 5.2. Електротехника, електроника и автоматика
(Теория на автоматичното управление)

Научни ръководители: проф. д-р инж. Александра Грънчарова
проф. д-р инж. Липинг Фан

Научно жури:

1. Проф. д-р инж. Елена Колева - председател
2. Доц. д-р инж. Пламен Василев - рецензент
3. Проф. д-р инж. Петя Копринкова-Христова - рецензент
4. Проф. д-р инж. Вера Ангелова-Димитрова
5. Доц. д-р инж. Аспарух Марковски

София, 2025

Дисертационният труд е написан на 132 страници, съдържа 67 фигури и 5 таблици. Цитирани са 176 източника.

Представеният дисертационен труд е обсъден и приет за защита на заседание на разширен научен съвет на научното звено на катедра „Автоматизация на производството”, състояло се на 19.03.2025 г.

Публичната защита на дисертационния труд ще се проведе на 17.06.2025 г. от 11 часа в зала 301, сграда „А” на ХТМУ.

Материалите са на разположение на интересуващите се на интернет страницата на ХТМУ и в отдел „Научни дейности”, стая 406, етаж 4, сграда „А” на ХТМУ.

ОБЩА ХАРАКТЕРИСТИКА НА ДИСЕРТАЦИОННИЯ ТРУД

Актуалност

Разработването на линейни системи за управление става все по-зряло и се прилага успешно в производствените процеси. Сложността на реалните системи нараства, като те са подложени на смущения и има неопределеност при реалното им функциониране. В този случай е трудно да се постигне необходимата точност на управление с помощта на линейна система за управление. Нелинейността е често срещана характеристика на химичните, физичните, биологичните и други системи. Ето защо проектирането на ефективни управляващи устройства, както и подобряването на тяхното качество на управление са ключови фактори за решаване на проблема с управлението на нелинейните системи, като същевременно така се насърчава индустриалното развитие.

Използването на конвенционалните методи за управление среща редица трудности в практическите приложения, които са свързани с нелинейността и неопределеността на реалните динамични системи и наличието на ограничения върху техните променливи. Алтернативата е да се разработят интелигентни методи за управление, които могат да се справят с проблемите, свързани с управлението на сложни нелинейни системи. Ето защо изследването на интелигентните методи за управление е от голямо теоретично и практическо значение.

Цел и задачи

Целта на тази дисертация е да се разгледат няколко вида сложни нелинейни системи (модел на неврона на Хиндмарш-Роуз, главна система-подчинена система и непрекъснати неизотермични тръбни реактори с идеално изтласкване) и да се разработят интелигентни методи за тяхното оптимално управление. За постигането на тази цел **са формулирани няколко задачи**, които включват разработване на нови интелигентни методи, които съчетават моделното предсказващо управление, управлението в режим на хлъзгане и адаптивното управление с някои от методите за машинно обучение (дълбочинни невронни мрежи, Гаусови процеси), и тяхното прилагане към горепосочените класове сложни нелинейни системи.

Научноизследователски методи

Методите на моделното предсказващо управление, управлението в режим на хлъзгане и адаптивното управление в комбинация с някои от подходите за машинно обучение са приложени за моделиране и управление на сложни системи.

Научна новост

На базата на дълбочинни невронни мрежи е разработен явен нелинеен предсказващ регулатор за невронния модел на Хиндмарш-Роуз. Предложена е нова схема за управление на синхронизацията на системи от вида главна система-подчинена система с експоненциално смутен невронен регулатор в режим на хлъзгане и е доказана устойчивостта на затворената система. Разработен е нов подход за моделиране и адаптивно оптимално управление на тръбни реактори, основан на Гаусови процеси (GP). Подходът за моделиране с GP се прилага за получаване на набор от нелинейни авторегресионни модели с

външни входни въздействия (NARX модели) на концентрацията и температурата на изход от реактора за няколко стойности на температурата на входящия поток. Идентифицираните модели след това се използват за синтез на адаптивен моделно предсказващ регулатор за постигане на оптимална производителност на реактора въпреки промените във входната температура.

Характер на приносите

Дисертационният труд съдържа научни приноси, свързани с разработването на нови методи за управление на нелинейни системи и научно-приложни приноси, свързани с прилагането на тези методи към конкретни класове такива системи.

Публикации

Получените в дисертацията резултати от научните изследвания са публикувани в 4 доклада, представени на международните конференции: IEEE International Conference on Automatics and Informatics 2023, Varna, Bulgaria, 12th IEEE International Conference on Intelligent Systems, Varna, Bulgaria, 2024, 19th International Conference on Artificial Intelligence: Methodology, Systems, and Applications, Varna, Bulgaria, 2024.

Структура и обем на дисертационния труд

Дисертационният труд се състои от увод, 4 глави, резюме на научните и научно-приложни приноси, списък на публикациите по темата на дисертацията и списък на цитираната литература, включваща 176 източника. Дисертацията е изложена в 132 страници (в това число 67 фигури и 5 таблици). Означенията на уравненията, фигурите и таблиците в автореферата са същите както в дисертационния труд.

УВОД

Сложността на реалните системи нараства, като в същото време те са подложени на смущения и има неопределености при тяхното действително функциониране. В този случай е трудно да се постигне необходимата точност на управление с помощта на линейна система за управление. Нелинейността е една от типичните характеристики на реалните химични, физични, биологични и други системи, включително хаотични системи, невронни системи и модели на химични реактори. Ето защо проектирането на ефективни автоматични регулатори, както и подобряването на тяхното качество на управление е от голямо значение за решаване на проблема с управлението на нелинейните системи.

Освен това, използването на конвенционалните методи за управление среща редица трудности в практическите приложения. Основните от тях са следните: 1) Повечето реални динамични системи се характеризират с нелинейност и неопределеност, което затруднява получаването на добро качество на управлението; 2) Обикновено не е възможно неопределените системи да се опишат с традиционни математически модели; 3) Наличието на ограничения върху променливите на системата усложнява задачата за управление. Сложните задачи за управление трудно се решават с традиционните методи за управление.

Интелигентното управление решава предимно сложните проблеми за управление на нелинейните системи, които са трудни за решаване чрез конвенционалните методи. Той е подходящ метод поради следните причини: 1)

Интелигентното управление може да бъде по-добро решение за съществено нелинейни системи; 2) Интелигентното управление е ефикасно за управление на неопределени системи, тъй като е в състояние да моделира тяхната динамика; 3) То може да се справи със сложността и да позволи прецизно управление на сложни многомерни и многосвързани системи с ограничения. Особено при сложни промишлени процеси, интелигентното управление може да се обучава и адаптира към променящата се динамика на системата и работните условия, като осигурява отлични резултати на управлението в динамични промишлени условия.

Освен това, интелигентното управление притежава функциите за обучение и за оптимизация. Функцията за обучение означава, че то може да се учи от информацията, получена от външния свят, за да подобри ефективността на управлението на системата. Функцията за оптимизация означава, че то може да оптимизира параметрите на управлението, за да постигне цялостната оптимална ефективност на управлението. Ето защо изследването на интелигентното управление на сложни нелинейни системи е от голямо значение за развитието на индустриализацията. Настоящата дисертация е посветена на разработването на методи за интелигентно управление на няколко вида сложни нелинейни системи, а именно хаотични системи от вида главна система-подчинена система, тръбни химически реактори и невронния модел на Хиндмарш-Роуз като частен случай на хаотична система.

ГЛАВА 1 ОБЗОР НА МЕТОДИТЕ ЗА УПРАВЛЕНИЕ НА НЕЛИНЕЙНИ СИСТЕМИ

1.1. Методи за управление на нелинейни системи

Разгледани са основните концепции и методи за управление на нелинейни системи, като например моделно предсказващо управление, управление в режим на хлъзгане, управление чрез линеаризация на затворения контур, управление с обратна стъпка и адаптивно управление.

1.2. Методи за интелигентно управление, базирани на машинно обучение

Разгледано е развитието на интелигентните методи за управление, базирани на подходите за машинно обучение, като например подходи, използващи дълбочинно обучение, невронни мрежи, Гаусови процеси.

1.3. Методи за управление на специфични класове нелинейни системи

Представени са три специфични класа нелинейни системи: невронния модел на Хиндмарш-Роуз, системите от вида главна система-подчинена система и непрекъснатите неизотермични тръбни реактори с идеално изтласкване. Разгледани са методите за тяхното управление.

1.4. Основни изводи. Цел и задачи на дисертационния труд

Основни изводи от обзора на литературата

1. Конвенционалните методи за управление се основават на точен модел на управляваната система и са подходящи за решаване на сравнително прости

задачи за управление, като например тези, свързани с линейни стационарни динамични системи. В практическите приложения, обаче, задачите на управлението често включват системи със съществено нелинейна динамика, хаотични системи, неопределени системи или системи с разпределени параметри. Тези практически задачи е трудно да бъдат решени с конвенционалните методи за управление, при което да се постигне необходимата точност на управление.

2. Интелигентните системи за управление се характеризират с функциите на обучение, моделиране, оптимизиране, адаптиране. Това им позволява да компенсират недостатъците, характерни за конвенционалните методи за управление. Например, методите за дълбочинно обучение притежават способността за автоматично обучение от данни и могат да се справят със сложни и големи по обем данни. Изкуствените невронни мрежи са универсални апроксиматори, които могат да се използват за апроксимиране на произволни нелинейни функции и по този начин могат да подобрят способността за самоадаптация в дадена система за управление. Гаусовите процеси могат да се прилагат за получаване на непараметрични вероятностни модели на стохастични нелинейни системи.

3. Една от основните цели на изследванията в областта на изкуствените невронни мрежи е да се използват моделите на невроните като инструмент за разбиране на обработката на информацията от биологичните неврони. По отношение на нелинейната динамика е доказано, че моделът на неврона на Хиндмарш-Роуз има множество динамични поведения, като състояние на покой, периодично състояние, периодичен взрив и хаотична динамика при промяна на външния входящ поток, и е силно чувствителен към началните условия. Следователно, изследването на управлението на такъв модел на неврона е от решаващо значение за анализа на сложното поведение на невроните, което може да помогне на лекарите да лекуват по-добре неврологичните разстройства като епилепсия и аутизъм.

4. Системите от вида главна система-подчинена система се използват широко в различни области, като например безопасната комуникация, откриване на неизправности и др. Постигането на тяхното синхронно състояние широко се използва в промишлеността. Например, отклонението от синхронизацията между главната система и подчинената система може да сигнализира за неизправност или аномалия. Ефективното синхронизирано управление на системите от вида главна система-подчинена система полага основите на тяхното практическо приложение.

5. Химическите реактори са основни технологични единици в химикотехнологичните процеси. Типичен пример за това са непрекъснатите неизотермични реактори с идеално изтласкване. Такива реактори са изключително сложни, тъй като представляват нелинейни системи с разпределени параметри, чиято динамика се описва с частни диференциални уравнения, произтичащи от материалните и енергийните баланси в пространството и времето. Ефективното им управление може да подобри качеството на процесите в химическите производства, да намали производствените разходи и потреблението на енергия.

Целта на тази дисертация е да се разгледат няколко вида сложни нелинейни системи (модела на неврона на Хиндмарш-Роуз, системите от вида главна система-подчинена система и непрекъснатите неизотермични тръбни реактори с идеално изтласкване) и да се разработят интелигентни методи за тяхното оптимално управление.

За постигането на тази цел са формулирани следните задачи:

1. Синтез на явен моделно предсказващ регулатор за невронния модел на Хиндмарш-Роуз (HR модел) с помощта на дълбочинни невронни мрежи. Целта е да се постигне оптимално управление на HR модела, като се избегне оптимизацията в онлайн режим. Това ще доведе до оптимална система за управление с намалена изчислителна сложност в реално време.
2. Разработване на нов метод за синтез на интелигентен регулатор в режим на хлъзгане за синхронизиране на системи от вида главна система-подчинена система. Методът ще използва невронна мрежа с радиални базисни функции (RBF-NN) с адаптивни тегла за описване на неопределеността в динамиката на главната и подчинената система.
3. Изследване на оптималното стабилизиране на изходната концентрация на реагента и изходната температура на тръбен реактор с охлаждащ кожух на оптималните зададени стойности чрез проектиране на моделно предсказващ регулатор. Изследване на работата на предсказващия регулатор при наличие на параметрична неопределеност в математичния модел и при наличие на смущения в температурата на охлаждащия агент.
4. Предлагање на нов подход за моделиране и адаптивно оптимално управление на тръбен реактор чрез използване на Гаусови процеси (GP). Получаване на GP модели на динамиката на изходната концентрация и изходната температура на реактора и проектиране на адаптивен моделно предсказващ регулатор за постигане на оптимална работа на реактора.

ГЛАВА 2 НЕЛИНЕЙНО МОДЕЛНО ПРЕДСКАЗВАЩО УПРАВЛЕНИЕ НА НЕВРОННИЯ МОДЕЛ НА ХИНДМАРШ-РОУЗ НА БАЗАТА НА ДЪЛБОЧИННО ОБУЧЕНИЕ


2.1. Задача на управлението

Динамиката на управлявания невронен модел на Хиндмарш и Роуз (HR невронен модел) се описва с:

$$\begin{cases} \dot{x}_1(t) = x_2(t) - ax_1^3(t) + a_2x_1^2(t) - x_3(t) + I_0 + u_1(t) \\ \dot{x}_2(t) = c(t) - a_3x_1^2(t) - x_2(t) + u_2(t) \\ \dot{x}_3(t) = r[a_4(x_1(t) - a_1) - x_3(t)] + u_3(t) \end{cases} \quad (2.1)$$

където $u_1(t)$, $u_2(t)$, $u_3(t)$ са управляващите въздействия, $x_1(t)$, $x_2(t)$, $x_3(t)$ са променливите на състоянието, и t е непрекъснатото време. Тук, $x_1(t)$ е потенциалът на мембраната, $x_2(t)$ е шпайковата променлива (наричана още

променлива на потока), $x_3(t)$ е променливата на избухването (наричана още променлива на адаптирането). Параметърът I_0 е външният поток, a_1 е праговият потенциал за задействане на избухването, a, a_2, c, a_3, a_4 са константи. Траекторията на неуправлявания HR невронен модел ($u_i = 0, i = 1, 2, 3$) за $a = 1, a_1 = -1.6, a_2 = 3, c = 1, a_3 = 5, r = 0.006, a_4 = 4, I_0 = 1.5$ и начално състояние $x(0) = [0.2, 2, 0.1]$ е илюстрирана на Фигура 2.1 и съответства на хаотично поведение. HR невронният модел може да има други поведения за други стойности на параметъра I_0 .



Фигура 2.1 Траектория на неуправлявания HR невронен модел

Показано е, че неуправляваният HR невронен модел (2.1) има само една реална точка на равновесие ($x_e = [-0.7138, -1.5479, 3.5446]$) и тя е неустойчива. Целта е да се подтисне хаотичното поведение на HR модела (2.1) и той да се стабилизира в неустойчивата равновесна точка x_e . Управляваният HR невронен модел се описва с:

$$\dot{x}(t) = f(x(t)) + u(t) \quad (2.2)$$

където $u(t) = [u_1(t), u_2(t), u_3(t)]$ е векторът на управляващите въздействия, $x(t) = [x_1(t), x_2(t), x_3(t)]$ е векторът на състоянието и $f(x(t)) = [f_1(x(t)), f_2(x(t)), f_3(x(t))]$ е вектор-функция, свързана с дясната страна на уравнението (2.1).

2.2. Метод за нелинейно моделно предсказващо управление (NMPC), базиран на дълбочинни невронни мрежи, приложен към невронния модел на Хиндмарш-Роуз

2.2.1. Формулиране на задачата за НМПУ на невронния модел на Хиндмарш-Роуз

Първо, моделът (2.2) е дискретизиран с интервал на дискретизация $T_s = 0.01$ [s] и използване на метода на Ойлер за интегриране напред:

$$x(k+1) = f_d(x(k)) + Bu(k) \quad (2.3)$$

където $f_d(x(k)) = x(k) + T_s f(x(k))$, $B = \text{diag}\{T_s, T_s, T_s\}$, а k е дискретното време. На управляващото въздействие е наложено следното ограничение:

$$-12 \leq u(k) \leq 12, \forall k \quad (2.4)$$

За системата (2.3), задачата за оптимално управление се състои в превеждане по оптимален начин на текущото състояние $\bar{x}$ до равновесното състояние $x_e = [-0.7138, -1.5479, 3.5446]$ при спазване на ограничението (2.4). В текущия момент k , NMPC включва решаването на следната задача за оптимизация:

Задача P2.1:

$$V^*(\bar{x}) = \min_U J(U, \bar{x}) \quad (2.5)$$

при известно $x_{k|k} = \bar{x}$ и:

$$-12 \leq u_{k+i} \leq 12, \quad i = 0, 1, \dots, N_p - 1 \quad (2.6)$$

$$x_{k+i+1|k} = f_d(x_{k+i|k}) + Bu_{k+i}, \quad i = 0, 1, \dots, N_p - 1 \quad (2.7)$$

Тук, последователността от управляващи въздействия в рамките на хоризонта на предсказване N_p е означена с $U = [u_k, u_{k+1}, \dots, u_{k+N_p-1}]$, а критерият за оптималност $J(U, \bar{x})$ е дефиниран както следва:

$$J(U, \bar{x}) = \sum_{i=0}^{N_p-1} [\|x_{k+i+1|k} - x_e\|_Q^2 + \|u_{k+i}\|_R^2] \quad (2.8)$$

където $Q \succ 0$ и $R \succ 0$ са симетрични тегловни матрици. Нека оптималното решение на задачата P2.1 е означено с $U^* = [u_k^*, u_{k+1}^*, \dots, u_{k+N_p-1}^*]$. Тогава, в момента k , управляващото въздействие, приложено на системата е $u(k) = u_k^*$.

2.2.2. Синтез на NMPC, базирано на дълбочинни невронни мрежи (NMPC-DNN) за невронния модел на Хиндмарш-Роуз

За нелинейна дискретна система:

$$x(k+1) = h(x(k), u(k)) \quad (2.9)$$

където $x(k) \in \mathbb{R}^{n_x}$ и $u(k) \in \mathbb{R}^{n_u}$ са нейните вектори на състоянието и управлението, функционалното представяне на дълбочинната невронна мрежа на явния нелинеен моделно предсказващ регулатор е от вида $\mathcal{N} : \mathbb{R}^{n_x} \rightarrow \mathbb{R}^{n_u}$. Разглеждаме следния модел на невронна мрежа:

$$\mathcal{N}(x; \theta, M, L) = \begin{cases} q_{L+1} \circ g_L \circ q_L \circ \dots \circ g_1 \circ q_1(x), & L \geq 2 \\ q_{L+1} \circ g_1 \circ q_1(x), & L = 1 \end{cases} \quad (2.10)$$

Тук, композицията на двете функции q_l и g_l е представена като $g_l \circ q_l(\cdot) = g_l(q_l(\cdot))$, M е броят на невроните във всеки скрит слой (широчината на невронната мрежа (NN)), а L е броят на скритите слоеве (дълбочината на NN). Афинната функция q_l на l -тия скрит слой е:

$$q_l(\zeta_{l-1}) = W_l \zeta_{l-1} + b_l \quad (2.11)$$

където $\zeta_{l-1} \in \mathbb{R}^M$ означава изхода на $(l-1)$ -вия слой. Матрицата W_l и векторът b_l съдържат теглата и отместванията на l -тия слой. Нелинейната функция на активация g_l използва ректифициран линеен блок ReLU:

$$g_l(q_l) = \max(0, q_l) \quad (2.12)$$

Параметрите $\theta = \{\theta_1, \dots, \theta_{L+1}\}$ на NN включват всички тегла W_l и отмествания b_l , $l = 1, \dots, L+1$. Обучаването на дълбочинна NN с определена архитектура се състои в определяне на оптималните параметри θ^* , които минимизират функцията на загубите.

Разглежда се моделът (2.10) - (2.12) на NN и е използван инкременталният подход при избора на структурата на NN. Това означава, че трябва да се започне с по-малко скрити слоеве и брой на невроните в тях, като постепенно се добавят още, докато грешката на предсказване престане да се променя съществено. За да се генерира обучаваща извадка от данни, задачата P2.1 е решена за N_s на брой начални състояния на HR модела $\bar{x}_i$, $i = 1, \dots, N_s$ и са получени съответните оптимални стойности $u^*(\bar{x}_i)$, $i = 1, \dots, N_s$ на управляващите въздействия. Функцията на загубите при обучаването на NN е избрана да бъде средната сумарно-квадратична грешка на предсказване (MSE), което налага решаването на следната оптимизационна задача:


$$\theta^* = \arg \min_{\theta} \frac{1}{N_s} \sum_{i=1}^{N_s} (u^*(\bar{x}_i) - \mathcal{N}(\bar{x}_i; \theta))^2 \quad (2.13)$$

Тук, $u^*(\bar{x}_i)$ е оптималната стойност на управляващото въздействие, а $\mathcal{N}(\bar{x}_i; \theta)$ е генерираният от NN изход. Законът за управление, реализиран от дълбочинната NN е $u(x(k)) = \mathcal{N}(x(k); \theta^*)$. В задачата за NMPC P2.1, $N_p = 30$, $Q = \text{diag}\{300, 300, 300\}$, $R = \text{diag}\{0.01, 0.01, 0.01\}$. В HR невронния модел, $I_0 = 3.2$, което съответства сложна хаотична динамика.


2.3. Симулационни резултати

2.3.1. NMPC, базирано на дълбочинни невронни мрежи (NMPC-DNN)


Задачата за NMPC P2.1 е решена за различни начални състояния на HR модела чрез използване на CasADi тулбокса. По този начин са генерирани извадките от данни за обучение и валидиране на невронната мрежа на регулатора. Дълбочинната NN има $L = 4$ и $M = 5$. Траекториите, получени при използването на NMPC-DNN регулатор са показани на Фигури 2.2 до 2.7. На тези фигури, действието на явното NMPC-DNN е сравнено с това на NMPC, базирано на решаване във всеки дискретен момент от време на оптимизационната задача P2.1.




Фигура 2.2 Управлящо въздействие u_1




Фигура 2.3 Управлящо въздействие u_2




Фигура 2.4 Управлящо въздействие u_3



Фигура 2.5 Променлива на състоянието x_1




Фигура 2.6 Променлива на състоянието x_2



Фигура 2.7 Променлива на състоянието x_3

Фигури 2.2 до 2.7 показват, че дълбочинната невронна мрежа на NMPC-DNN постига висока точност на апроксимация на оптималното управляващо въздействие, а получените траектории на състоянието с двата предсказващи регулатора са почти неразличими.


Освен това е важно да се вземе предвид стойността на функцията на загубите (2.13), тъй като тя е важен показател за оценка на ефективността на NN. Колкото по-малка е нейната стойност, толкова по-малка е грешката на предсказване на NN. Стойността на тази функция по време на епохите на обучение е представена на Фигура 2.8. Процесът на обучение приключва за 17 епохи при стойност на $MSE \approx 1,10^{-5}$.




Фигура 2.8 Грешки при обучение и валидиране

2.3.2. NMPC, базирано на плитки невронни мрежи


За сравнение е синтезирано явно NMPC, базирано на плитка невронна мрежа, чиято структура има $L = 1, M = 7$. Съответните траектории на затворения контур са дадени на Фигури 2.9 до 2.14, където са показани и траекториите, получени с NMPC-DNN.




Фигура 2.9 Управлящо въздействие u_1




Фигура 2.10 Управлящо въздействие u_2




Фигура 2.11 Управлящо въздействие u_3



Фигура 2.12 Променлива на състоянието x_1




Фигура 2.13 Променлива на състоянието x_2



Фигура 2.14 Променлива на състоянието x_3

От Фигури 2.9 до 2.14 се вижда, че NMPC, базирано на плитка невронна мрежа, не апроксимира толкова добре оптималната динамика на затворения контур, колкото се постига с NMPC-DNN. Стойността на функцията на загубите (MSE) по време на епохите на обучение на плитката NN е представена на Фигура 2.15. Минималната стойност на функцията на загубите е $MSE \approx 1,10^{-3}$.



Фигура 2.15 Грешки при обучение и валидиране

2.3.3. NMPC-DNN, сравнено с управлението чрез регулатор в режим на хлъзгане

Тук за HR модела (2.1) е синтезиран регулатор в режим на хлъзгане (SMC). Действието на нелинейния моделно предсказващ регулатор, основан на дълбочинни невронни мрежи (NMPC-DNN) е сравнено с това на SMC.

Първо, задава се следната функция на повърхнината на превключване:

$$s_i = k \int_0^t |e_i|^n \operatorname{sgn}(e_i) dt, i = 1, 2, 3 \quad (2.14)$$

където $e_i(t) = x_{r_i} - x_i(t)$, $i = 1, 2, 3$ са грешките на регулиране, а x_{r_i} , $i = 1, 2, 3$ са зададените стойности. Производната на функцията (2.14) е:

$$\dot{s}_i = k |e_i|^n \operatorname{sgn}(e_i), i = 1, 2, 3 \quad (2.15)$$


Законът на регулиране в режим на хлъзгане се дефинира както следва:

$$u_i = \dot{s}_i - f_i(x) \quad (2.16)$$


$$-12 \leq u_i \leq 12, i=1,2,3 \quad (2.17)$$

където k е коефициентът на усилване, $k > 0$, $0 < n < 1$. Функциите $f_i(x), i=1,2,3$ са $f_1(x) = x_2 - ax_1^3 + a_2x_1^2 - x_3 + I_0$, $f_2(x) = c - a_3x_1^2 - x_2$, $f_3(x) = r[a_4(x_1 - a_1) - x_3]$, съответно. Параметрите са $a = 1, a_1 = -1.6, a_2 = 3, c = 1, a_3 = 5, r = 0.006, a_4 = 4, I_0 = 1.5$.


Симулацията е направена за начално състояние $x(0) = [0.3, 0.3, 3]$ на HR модела. Векторът от зададени стойности е $x_r = [-0.7138, -1.5479, 3.5446]$, който съответства на неустойчивото равновесно състояние на HR модела (2.1), а коефициентът на усилване на регулатора е $k = 12$. На Фигури 2.16-2.21 е сравнено действието на предсказващия регулатор, базиран на дълбочинни невронни мрежи (NMPC-DNN), с това на регулатора в режим на хлъзгане (SMC).



Фигура 2.16 Управляващо въздействие u_1




Фигура 2.17 Управляващо въздействие u_2




Фигура 2.18 Управляващо въздействие u_3


Фигури 2.16-2.18 показват, че траекториите на управляващите въздействия, получени с предсказващия регулатор (NMPC-DNN) достигат стойност нула по-бързо от тези с регулатора в режим на хлъзгане (SMC). Траекториите на променливите на състоянието са дадени на Фигури 2.19-2.21.



Фигура 2.19 Променлива на състоянието x_1



Фигура 2.20 Променлива на състоянието x_2



Фигура 2.21 Променлива на състоянието x_3

От Фигури 2.19-2.21 се вижда, че траекториите на състоянието за NMPC-DNN се установяват на зададените стойности много по-бързо отколкото тези за SMC.

В Таблица 2.1 е дадено сравнение на качеството на управление с NMPC-DNN и с SMC.

Таблица 2.1 Сравнение на ключовите индикатори за качеството на управление с NMPC-DNN и с SMC.

Метод за управление	Променлива на състоянието	Време на регулиране	Пререгулиране	Интегрално-квадратична грешка на регулиране
NMPC-DNN	x_1	0.15 s	12%	0.02
	x_2	0.16 s	0%	0.18
	x_3	0.12 s	0.12%	0.004
SMC	x_1	0.33 s	0%	0.04
	x_2	0.36 s	0%	0.15
	x_3	0.32 s	0%	0.01

Резултатите в таблицата показват, че с NMPC-DNN регулатора се постига по-добро качество, характеризиращо се с по-малко време на регулиране и по-малки интегрално-квадратични грешки на регулиране, което го прави идеален за приложения, изискващи бързо и прецизно управление. За разлика от него, SMC методът води до по-големи времена на регулиране, но с него няма пререгулиране. Като цяло подходът NMPC-DNN предлага по-добро качество на управление за HR невронния модел.

2.4. Изводи

В тази глава е проектиран явен НМПУ регулатор, базиран на дълбочинни невронни мрежи (NMPC-DNN) за оптимално управление на невронния модел на Хиндмарш-Роуз. Дълбочинната НМ на регулатора е обучена офлайн чрез използване на оптималните траектории на управлението, получени за различни начални състояния на HR невронния модел. Симулационните експерименти показват, че NMPC-DNN регулатора има високо качество на апроксимация на оптималното управление. Предимствата на NMPC-DNN в сравнение с NMPC, базиран на онлайн оптимизация, са намалената сложност на онлайн изчисленията и лесната софтуерна реализация. Това би направило NMPC-DNN за HR невронния модел много подходящ за проектиране на вградена система за управление. Освен това, подходът NMPC-DNN е сравнен с регулатор в режим на хлъзгане. Резултатите показват, че регулаторът NMPC-DNN има по-добро качество на управление.

ГЛАВА 3 СИНХРОНИЗАЦИЯ НА ХАОТИЧНИ СИСТЕМИ С ПОМОЩТА НА НОВ РЕГУЛАТОР В РЕЖИМ НА ХЛЪЗГАНЕ, БАЗИРАН НА НЕВРОННА МРЕЖА

3.1. Описание на системите от вида главна система-подчинена система

Най-общо, динамиката на главната система, отчитаща общия хаос, се описва с:

$$\dot{x}_i = g_{m_i}(x(t)), \quad i = 1, 2, \dots, n \quad (3.1)$$

където $x = [x_1, x_2, \dots, x_n] \in \mathbb{R}^n$ е векторът на състоянието на системата, а $g_{m_i}: \mathbb{R}^n \rightarrow \mathbb{R}, i = 1, 2, \dots, n$ са нелинейни непрекъснати функции. Предполага се, че съответната подчинена система има следната динамика:

$$\dot{y}_i = g_{s_i}(y(t)) + u_i + d_i(t), \quad i = 1, 2, \dots, n \quad (3.2)$$

където $y = [y_1, y_2, \dots, y_n] \in \mathbb{R}^n$ е векторът на състоянието на системата, $g_{s_i}: \mathbb{R}^n \rightarrow \mathbb{R}, i = 1, 2, \dots, n$ са нелинейни непрекъснати функции, $u_i \in \mathbb{R}, i = 1, 2, \dots, n$ са управляващи въздействия и $d_i(t) \in \mathbb{R}, i = 1, 2, \dots, n$ са външни смущения. Грешката от синхронизация между (3.1) и (3.2) е:

$$e_i = y_i - x_i, \quad i = 1, 2, \dots, n \quad (3.3)$$

Чрез заместване с (3.1) и (3.2) в (3.3) и определяйки производната, получаваме следната динамика на грешката от синхронизация:

$$\dot{e}_i = g_{s_i}(y(t)) - g_{m_i}(x(t)) + u_i + d_i(t), \quad i = 1, 2, \dots, n \quad (3.4)$$

Целта на синхронизацията ще бъде постигната, когато грешката между главната система и подчинената системи стане равна на нула.

3.2. Метод за управление в режим на хлъзгане, базиран на невронни мрежи

3.2.1. Синтез на експоненциално смутен регулатор в режим на хлъзгане, базиран на невронни мрежи

Най-напред синтезираме експоненциален наблюдател на смущението с цел компенсиране на смущението и намаляване на усилването на превключването при управлението в режим на хлъзгане (SMC).

Синтезирани са нови функции на повърхнината на превключване и на регулатора. Предложена е нова експоненциална функция на повърхнината на превключване:

$$s_i = e_i + k_1 \int_0^t |e_i|^\mu \text{sign}(e_i) dt \quad (3.17)$$

Нейната производна е:

$$\dot{s}_i = \dot{e}_i + k_1 |e_i|^\mu \text{sign}(e_i) \quad (3.18)$$

където $k_1 > 0, 0 < \mu < 1$.

Забележка 3.1 Непрекъснатата функция $g_i(x(t), y(t))$ е представена като $g_i(z(t))$, където $z(t) = [x^T(t), y^T(t)]^T \in \mathbb{R}^{2n}$, и може да бъде идентифицирана чрез RBF-NN:

$$g_i(z(t)) = P_i^{*T} h_i(z(t)) + \varepsilon_i(z(t)) \quad (3.19)$$

където $P_i^* \in \mathbb{R}^N$ е векторът на оптималните тегла на невронната мрежа, $h_i(z(t)) = [h_{i,1}(z(t)), h_{i,2}(z(t)), \dots, h_{i,N}(z(t))]^T$ е векторът с базовите функции, $\varepsilon_i(z(t))$ е грешката на идентификацията, за която $|\varepsilon_i| < \varepsilon_i^*, \varepsilon_i^* > 0$, и N е броят на невроните. Базовите функции обикновено се избират да бъдат Гаусови функции:

$$h_i(z(t)) = \exp(-\|z(t) - c_i\|^2 / b_i^2) \quad (3.20)$$

$$b_i \in \mathbb{R}^n, i = 1, 2, \dots, n$$

където $c_i = [c_{i,1}, c_{i,2}, \dots, c_{i,2n}]^T$ и b_i са центърът и широчината на i -тата Гаусова функция.

Чрез използването на невронна мрежа за апроксимиране на функцията $g_i(z(t))$ на наблюдателя, получаваме:

$$\hat{g}_i(z(t)) = \hat{P}_i^T h_i(z(t)) \quad (3.21)$$

където $\hat{P}_i \in \mathbb{R}^N$ е векторът на адаптивните тегла на невронната мрежа. Въвежда се следният вектор:

$$\tilde{P}_i = P_i^* - \hat{P}_i \quad (3.22)$$

и грешката от апроксимация, свързана с $\hat{g}_i(z(t))$ е:

$$\begin{aligned}\tilde{g}_i(z(t)) &= g_i(z(t)) - \hat{g}_i(z(t)) \\ &= P_i^{*T} h_i(z(t)) + \varepsilon_i(z(t)) - \hat{P}_i^T h_i(z(t)) \\ &= \tilde{P}_i^T h_i(z(t)) + \varepsilon_i(z(t))\end{aligned}\quad (3.23)$$

Синтезира се регулатор в режим на хлъзгане (SMC):

$$u_i = -\hat{g}_i(z(t)) - D_i - k_1 |e_i|^\mu \text{sign}(e_i) - k_2 s_i \quad (3.24)$$

където $k_1 > 0, k_2 > 0$.

Чрез заместване с (3.4) и (3.23) в (3.18) и имайки предвид, че $g_{s_i}(y(t)) - g_{m_i}(x(t)) = g_i(x(t), y(t))$ и $z(t) = [x^T(t), y^T(t)]^T$, функцията на производната на новата повърхнината на превключване, базирана на невронна мрежа е:

$$\begin{aligned}\dot{s}_i &= g_i(z(t)) + u_i + d_i(t) + k_1 |e_i|^\mu \text{sign}(e_i) \\ &= \tilde{g}_i(z(t)) - D_i + d_i(t) - k_2 s_i\end{aligned}\quad (3.25)$$

3.2.2. Анализ на устойчивостта

Теорема 3.1 Разглеждат се главната система (3.1) и подчинената система (3.2) и се приема, че Предположения 3.1 и 3.2 са изпълнени. Тогава, прилагането на закона на управление (3.24) с наблюдателя на смущението (3.9), при закона на адаптиране на параметрите на невронната мрежа:

$$\dot{\hat{P}}_i = \lambda s_i h_i(z(t)), \lambda > 0, \quad (3.26)$$

главната и подчинената системи са синхронизирани.


Предположенията 3.1 и 3.2, както и доказателството на теоремата са дадени в Глава 3 на дисертацията.

3.2.3. Симулационни резултати

Предложеният нов експоненциално смутен регулатор в режим на хлъзгане, базиран на невронни мрежи (NEPSM-NN), е приложен за синхронизиране на нелинейни хаотични главна и подчинена системи от трети ред. Главната система има следната динамика:

$$\begin{cases} \dot{x}_1 = 1 - x_2 x_3 \\ \dot{x}_2 = -a x_3 + b x_2 \\ \dot{x}_3 = x_1 x_2 \end{cases} \quad (3.31)$$

където $a=1, b=1$ са параметрите на системата, а началното състояние на системата е $x_1(0)=1, x_2(0)=-0.5, x_3(0)=1.5$. Фазовата диаграма на система (3.31) е дадена на Фигура 3.1.



Фигура 3.1. Фазова диаграма на система (3.31)

Динамиката на подчинената система е:

$$\begin{cases} \dot{y}_1 = 1 - y_2 y_3 + u_1 + d_1 \\ \dot{y}_2 = -c_1 y_3 + c_2 y_2 + u_2 + d_2 \\ \dot{y}_3 = y_1 y_2 + u_3 + d_3 \end{cases} \quad (3.32)$$


Функциите $g_i(x(t), y(t)) = g_{s_i}(y(t)) - g_{m_i}(x(t)), i = 1, 2, 3$ не са известни предварително, поради неопределеност за параметрите c_1, c_2 на подчинената система (3.32) и неизвестните смущения d_1, d_2, d_3 , които ѝ влияят. Както е отбелязано в Забележка 3.1, функциите $g_i(x(t), y(t)), i = 1, 2, 3$ са апроксимирани с невронни мрежи, използващи радиално-базови функции (RBF-NNs). При числената симулация началното състояние на подчинената система е $y_1(0) = -1, y_2(0) = 1.5, y_3(0) = 1$.

Главната и подчинената системи (3.31) - (3.32) са синхронизирани чрез прилагането на предложения NEPSM-NN регулатор (3.24) с параметри $k_1 = 10, k_2 = 10$ и $N = 7$ броя неврони в скрития слой на невронната мрежа, а $b_i = [-3, -2, -1, 0, 1, 2, 3]^T, c_i = 6$ са параметрите на Гаусовите функции (3.20). Стойността на параметъра k_2 е избрана съгласно Теорема 3.1, докато другите параметри са настроени чрез анализиране на поведението на затворената система. Действието на предложения регулатор е сравнено с това на пропорционално-интегрален (PI) регулатор:


$$\tilde{u}_i = -k_p e_i + k_i \int_0^t e_i(\tau) d\tau \quad (3.33)$$

с параметри $k_p = 16, k_i = 1$.


На Фигури 3.2 – 3.4 са показани траекториите на управляващите въздействия с предложения NEPSM-NN регулатор и с PI регулатора, когато смущение от вида $d_i = 0.5 \sin(t), i = 1, 2, 3$ въздейства на системата. На Фигури 3.5 – 3.7, съответните траектории на грешките от синхронизация са дадени.




Фигура 3.2 Управлящо въздействие u_1




Фигура 3.3 Управлящо въздействие u_2




Фигура 3.4 Управлящо въздействие u_3



Фигура 3.5 Грешка e_1 от синхронизация



Фигура 3.6 Грешка e_2 от синхронизация



Фигура 3.7 Грешка e_3 от синхронизация

Фигури 3.2 - 3.7 показват, че предложеният NEPSM-NN регулатор има много по-добро качество на управление в сравнение с PI регулатора, тъй като има силна способност за подтискане на смущенията и грешката от синхронизация бързо става равна на нула.

За да се представи подробно описанието на работата на двата регулатора при смущение $d_i = 0.5\sin(t), i = 1, 2, 3$ в системата, в Таблица 3.1 са дадени стойностите на основните показатели за качеството на управлението.

Както се вижда от Таблица 3.1, NEPSM-NN регулаторът има по-добро качество на управление, изразено чрез стойностите на времето на регулиране и интегрално-квадратичната грешка. И при двата регулатора отсъства пререгулиране.

Таблица 3.1 Сравнение на основните показатели за качеството на управление на новия експоненциално смутен регулатор в режим на хлъзгане, базиран на невронни мрежи (NEPSM-NN) и на PI регулатора

Регулатор	Грешка от синхронизация	Време на регулиране	Интегрално-квадратична грешка
NEPSM-NN	e_1	0.17 s	0.064
	e_2	0.26 s	0.065
	e_3	0.04 s	0.002
PI	e_1	0.32 s	0.147
	e_2	0.37 s	0.154
	e_3	0.38 s	0.039

3.3. Синхронизиране на системи от вида главна система-подчинена система чрез използване на нелинейно моделно предсказващо управление, базирано на дълбочинни невронни мрежи (NMPC-DNN)

3.3.1. Формулиране на задачата за синхронизиране на главната система и подчинената система като NMPC задача

Първо, на базата на анализа в Секция 3.1 и с цел опростяване на записа, моделът (3.4) се представя:

$$\dot{e} = F(e(t)) + u(t) + d(t) \quad (3.34)$$

където $F(e(t)) = g_s(y(t)) - g_m(x(t))$, $d(t)$ е външно смущение, t е непрекъснатото време. Моделът (3.34) се дискретизира чрез използването на интервал на дискретизация $T_s = 0.01$ [s] и методът на Ойлер за интегриране напред:

$$e(k+1) = F_d(e(k)) + Bu(k) + d(k) \quad (3.35)$$

където $F_d(e(k)) = e(k) + T_s F(e(k))$, $B = \text{diag}\{T_s, T_s \dots T_s\}$, а k е дискретното време. Управляващото въздействие е ограничено да бъде в интервала:

$$-60 \leq u(k) \leq 60, \forall k \quad (3.36)$$

За системата (3.35), задачата на оптималното управление се състои в превеждане на текущата грешка $\tilde{e}$ до нулата при спазване на ограничението (3.36). В текущия момент k се решава следната задача на нелинейното моделно предсказващо управление (NMPC):

Задача P3.1:

$$V^*(\tilde{e}) = \min_U J(U, \tilde{e}) \quad (3.37)$$

при известно $e_{k|k} = \tilde{e}$ и:

$$e_{k+i+1|k} = F_d(e_{k+i|k}) + Bu_{k+i} + d_k, i = 0, 1, \dots, N_p - 1 \quad (3.38)$$

$$-60 \leq u_{k+i} \leq 60, i = 0, 1, \dots, N_p - 1 \quad (3.39)$$

Тук, последователността от стойности на управляващото въздействие в рамките на хоризонта на предсказване N_p е означена с $U = [u_k, u_{k+1}, \dots, u_{k+N_p-1}]$, а критерият за оптималност $J(U, \tilde{e})$ е:

$$J(U, \tilde{e}) = \sum_{i=0}^{N_p-1} [\|e_{k+i|k}\|_Q^2 + \|u_{k+i|k}\|_R^2] \quad (3.40)$$

Целта е да се минимизира критерият (3.40), което означава да се минимизира грешката от синхронизация при избягване на прекомерно големи стойности на управляващото въздействие. Предполага се, че тегловните матрици $Q \succ 0$ и $R \succ 0$ са симетрични. Означават се с $U^* = [u_k^*, u_{k+1}^*, \dots, u_{k+N_p-1}^*]$ оптималното решение на задачата P3.1. Тогава, в момента k управляващото въздействие, което се прилага на системата е $u(k) = u_k^*$.

3.3.2. Синтез на NMPC-DNN за синхронизиране на главната и подчинената системи

Динамиката на грешката от синхронизация се описва със следния нелинеен дискретен модел:

$$e(k+1) = h(e(k), u(k)) \quad (3.41)$$

където $e(k) \in \mathfrak{R}^{n_e}$ и $u(k) \in \mathfrak{R}^{n_u}$ са векторите на грешката и на управляващото въздействие, функционалното представяне на дълбочинната невронна мрежа на явния нелинеен моделно предсказващ регулатор (NMPC) е от вида $\mathcal{N} : \mathfrak{R}^{n_e} \rightarrow \mathfrak{R}^{n_u}$. Разглежда се следният модел на невронна мрежа:

$$\mathcal{N}(e; \theta, M, L) = \begin{cases} \delta_{L+1} \circ g_L \circ \delta_L \circ \dots \circ g_1 \circ \delta_1(e), & L \geq 2 \\ \delta_{L+1} \circ g_1 \circ \delta_1(e), & L = 1 \end{cases} \quad (3.42)$$

Композицията на двете функции q_l и g_l е представена като $g_l \circ q_l(\cdot) = g_l(q_l(\cdot))$, M е броят на невроните във всеки скрит слой (широчината на невронната мрежа (NN)), а L е броят на скритите слоеве (дълбочината на NN). Афинната функция q_l на l -тия скрит слой е:

$$\delta_l(\zeta_{l-1}) = W_l \zeta_{l-1} + b_l \quad (3.43)$$

където $\zeta_{l-1} \in \mathbb{R}^M$ означава изхода на $(l-1)$ -вия слой. Матрицата W_l и векторът b_l съдържат теглата и отместванията на l -тия слой. Нелинейната функция на активация g_l използва ректифициран линеен блок ReLU:

$$g_l(\delta_l) = \max(0, \delta_l) \quad (3.44)$$


Параметрите $\theta = \{\theta_1, \dots, \theta_{L+1}\}$ на невронната мрежа включват всички тегла W_l и отмествания $b_l, l=1, \dots, L+1$. Обучаващите данни се генерират чрез решаване на оптимизационната задача за N_s на брой начални грешки от синхронизация $\tilde{e}_i, i=1, 2, \dots, N_s$ и получаване на съответните оптимални управляващи въздействия $u^*(\tilde{e}_i), i=1, \dots, N_s$. Обучаването на невронната мрежа с определена архитектура се състои в определяне на оптималните параметри θ^* , които минимизират функцията на загубите:

$$\theta^* = \arg \min_{\theta} \frac{1}{N_s} \sum_{i=1}^{N_s} (u^*(\tilde{e}_i) - \mathcal{N}(\tilde{e}_i; \theta))^2 \quad (3.45)$$

Тук, $u^*(\tilde{e}_i)$ е оптималното управляващо въздействие, а $\mathcal{N}(\tilde{e}_i; \theta)$ е изходът, генериран от невронната мрежа. Законът за управление, реализиран от невронната мрежа е $u(e(k)) = \mathcal{N}(e(k); \theta^*)$. В NMPC задачата P3.1, $N_p = 15$, $Q = \text{diag}\{200, 200, 200\}$, $R = \text{diag}\{0.01, 0.01, 0.01\}$.

На базата на анализа по-горе, на Фигура 3.11 е дадена схемата на системата за управление чрез NMPC-DNN с цел синхронизиране на главната и подчинената системи.


Подходът NMPC-DNN е приложен за синхронизиране на нелинейните главна и подчинена системи. Използват се съответно главната система (3.31) и подчинената система (3.32). Моделът на грешката от синхронизация може да се получи чрез формулите (3.3) и (3.4). Освен това задачата на NMPC P3.1 се решава за началните състояния на модела на грешката с помощта на тулбокса CasADi. След това се получават оптималните стойности u_k^* на управляващите въздействия. По този начин се генерират наборите от данни за обучение и валидиране на невронната мрежа на регулатора.




Фигура 3.11 Структура на система за управление чрез NMPC-DNN за синхронизиране на главната и подчинената системи.

3.4. Симулационни резултати


Главната и подчинената системи (3.31) - (3.32) са синхронизирани чрез NMPC-DNN регулатора. Изследвана е грешката от синхронизация при въздействието на смущението $d_i = 0.5\sin(t), i = 1, 2, 3$. Съгласно началните състояния на главната и подчинената системи, дадени в Секция 3.2, началните стойности на грешките от синхронизация са известни, т.е. $e_1(0) = -2, e_2(0) = 2, e_3(0) = -0.5$. Структурата на дълбочинната невронна мрежа има $L = 4, M = 3$. Действието на NMPC-DNN регулатора е сравнено с това на новия експоненциално смутен регулатор в режим на хлъзгане, базиран на невронна мрежа (NEPSM-NN). NEPSM-NN регулаторът беше анализиран в Секция 3.2.



Фигура 3.12 Траектория на управляващото въздействие u_1




Фигура 3.13 Траектория на управляващото въздействие u_2




Фигура 3.14 Траектория на управляващото въздействие u_3


Фигури 3.12 - 3.14 показват траекториите на управляващите въздействия. На Фигури 3.15 - 3.17 са дадени съответните траектории на грешките от синхронизация с NMPC-DNN подхода и с NEPSM-NN подхода.



Фигура 3.15 Траектория на грешката e_1 от синхронизация



Фигура 3.16 Траектория на грешката e_2 от синхронизация



Фигура 3.17 Траектория на грешката e_3 от синхронизация

Фигури 3.12 - 3.17 показват, че NMPC-DNN регулаторът има по-добро действие от новия експоненциално смутен регулатор в режим на хлъзгане, базиран на невронна мрежа (NEPSM-NN). Освен това, ефективността на методите за управление чрез NMPC-DNN и чрез NEPSM-NN е сравнена въз основа на три ключови показателя за качество на управлението, както е показано в Таблица 3.2.

Таблица 3.2 Сравнение на основните показатели за качеството на управление на NMPC-DNN регулатора и на NEPSM-NN регулатора

Регулатор	Грешка от синхронизация	Време на регулиране	Интегрално-квадратична грешка
NMPC-DNN	e_1	0.04 s	0.047
	e_2	0.03 s	0.055
	e_3	0.04 s	0.002
NEPSM-NN	e_1	0.17 s	0.064
	e_2	0.26 s	0.065
	e_3	0.04 s	0.002

От гледна точка на качеството на управлението методът NMPC-DNN предлага по-добро качество с по-малко време на регулиране и по-малка интегрално-квадратична грешка при синхронизацията. За разлика от него, методът NEPSM-NN има значително по-голямо време на регулиране и по-голяма интегрално-квадратична грешка, което означава, че неговата точност на управление е по-ниска от тази на подхода NMPC-DNN. И двата метода не водят до пререгулиране.


3.5. Изводи

В тази глава е предложен нов експоненциално смутен закон за управление в режим на хлъзгане заедно с наблюдател на смущенията, като е използвана невронна мрежа с радиални базисни функции (RBF-NN) с адаптивни тегла за описание на неопределеността в динамиката на главната и на подчинената системи. Доказано е, че новата схема за управление гарантира устойчивостта на нелинейната хаотична система от трети ред от вида главна система-подчинена система. Резултатите от симулациите показват, че предложената схема може ефективно да намали превключването на управляващото въздействие и има силна способност за подтискане на смущенията. Сравнението с ПИ-регулатор потвърждава превъзходството на предложения регулатор.

Същевременно, за постигане на синхронизация на главната система и подчинената система е използван друг интелигентен регулатор, който представлява явен нелинеен моделно предсказващ регулатор, базиран на дълбочинни невронни мрежи (NMPC-DNN). Невронната мрежа (DNN) на явния NMPC регулатор се обучава офлайн да апроксимира зависимостта на оптималното управляващо въздействие от текущото състояние на грешката от синхронизация. Методът NMPC-DNN е демонстриран за тримерни нелинейни главна и подчинена системи. Предимството на този подход е, че той значително намалява времето за изчисления и е подходящ за приложения в реално време. Освен това, ефективността на NMPC-DNN регулатора е сравнена с тази на новия експоненциално смутен регулатор в режим на хлъзгане, базиран на невронна мрежа, чрез използване на ключовите показатели за качеството на управлението.

4.1. Аналитичен модел на тръбен реактор

Тук се разглежда тръбен реактор, в който протича необратима химична реакция от първи порядък от вида $A \rightarrow B$. Реакцията е екзотермична, поради което охлаждащ агент (вода) с разход u и температура $\tilde{T}_c$ преминава в кожуха на реактора (Фигура 4.1). Предполага се, че тръбният реактор е от вида идеално изтласкване, т.е. той има цилиндрична форма, течността се смесва идеално в радиална посока, но няма никакво смесване в аксиална посока (по дължината на реактора).



Фигура 4.1 Тръбен реактор с кожух и с дължина L

Масовият и топлинен баланс на реактора в динамичен режим се изразяват чрез безразмерните концентрация $\tilde{c}$ и температура $\tilde{T}$ както следва:

$$\frac{\partial \tilde{c}}{\partial t} = -v \frac{\partial \tilde{c}}{\partial l} - k_0 e^{\frac{E}{\tilde{T}}} \tilde{c} \quad (4.1)$$

$$\frac{\partial \tilde{T}}{\partial t} = -v \frac{\partial \tilde{T}}{\partial l} + k_0 e^{\frac{E}{\tilde{T}}} \tilde{c} - \alpha u (\tilde{T} - \tilde{T}_c) \quad (4.2)$$

където t е непрекъснатото време, l е пространствената координата, а безразмерните величини са дефинирани като:

$$\tilde{c} = \frac{c}{c_f}, \tilde{T} = \frac{T}{Jc_f}, \tilde{T}_c = \frac{T_c}{Jc_f}, \tilde{T}_f = \frac{T_f}{Jc_f} \quad (4.3)$$

Тук, c и c_f са концентрациите в реактора и във входящия поток, T , T_c и T_f са температурите съответно в реактора, на охлаждащия агент и на входящия поток, J е топлината на химичната реакция. Скоростта на химичната реакция се определя от:

$$r = k_0 e^{\frac{E}{\tilde{T}}} \tilde{c} \quad (4.4)$$

където k_0 е предекспоненциалният множител, а E е енергията на активация на реакцията. В (4.1) - (4.2), v е линейната скорост на потока през реактора, а α е коефициентът на топлопредаване. Разходът u е управляващо въздействие и е ограничен да бъде в интервала:

$$0 \leq u \leq 600 \quad (4.9)$$

Моделът (4.1) - (4.3) на реактора с идеално изтласкване е адаптиран от модел на реактор с идеално смесване и непрекъснато действие. Стойностите на параметрите са: $c_f = 1$, $T_f = 300$, $v = 0.1$, $L = 0.6$, $E = 25.2$, $k_0 = 300$, $T_c = 290$, $\alpha = 1.95 \cdot 10^{-4}$, $J = 100$. Динамичният модел (4.1) - (4.2) е система от нелинейни частни диференциални уравнения от първи ред (PDEs), която може да бъде решена с помощта на числен метод. Тук за решаване на модела (4.1) - (4.2) е използван методът на линиите. Идеята е моделът да се дискретизира чрез апроксимиране на производните по пространствената координата чрез крайни разлики. По този начин, (4.1) - (4.2) се трансформира в съвкупност от свързани обикновени диференциални уравнения (ODEs), които могат да бъдат решени чрез прилагане на някой от методите за числено решаване на ODEs.

4.2. Синтез на моделно предсказващ регулатор на базата на аналитичния модел

4.2.1 Оптимизация на статичния режим на тръбния реактор

Тук е проектирана система за супервайзорно оптимално управление на тръбния реактор (Фигура 4.2). На горното ниво на системата се решава задачата за оптимизация на статичния режим, която има за цел да максимизира производителността на реактора. В резултат на това се определят оптималните профили на концентрацията и температурата в статичен режим по дължината на ректора. Те представляват зададените профили за моделно предсказващ регулатор на долното ниво. Задачата на моделно предсказващ регулатор (MPC) е да регулира по оптимален начин текущите профили на концентрацията и температурата до зададените такива.



Фигура 4.2 Супервайзорна система за управление

Масовият и топлинен баланс на реактора в статичен режим се описва чрез следните обикновени диференциални уравнения, където независима променлива е пространствената координата l :

$$\frac{d\tilde{c}}{dl} = -\frac{1}{v} k_0 e^{\frac{E}{\tilde{T}}} \tilde{c} \quad (4.6)$$

$$\frac{d\tilde{T}}{dl} = \frac{1}{v} k_0 e^{-\frac{E}{\tilde{T}}} \tilde{c} - \frac{1}{v} \alpha u (\tilde{T} - \tilde{T}_c) \quad (4.7)$$

На входа на реактора концентрацията и температурата са $\tilde{c}(0) = \tilde{c}_f = 1$, $\tilde{T}(0) = \tilde{T}_f = 3$. За дадената дължина на тръбния реактор максималната производителност се получава, когато количеството на продукта B в изходящия поток е максимално. Това се постига, когато концентрацията на реагента A в изходящия поток е минимална. Следователно, формулира се следната задача за оптимизация на статичния режим:

Задача P4.1:


$$\tilde{c}_L^* = \min_u \tilde{c}(L) \quad (4.8)$$

съгласно модела (4.6) - (4.7) с начално състояние $\tilde{c}(0) = \tilde{c}_f = 1$, $\tilde{T}(0) = \tilde{T}_f = 3$ и спазване на ограниченията:


$$0 \leq u \leq 600 \quad (4.9)$$

$$2.9 \leq \tilde{T}(l) \leq 3.4, l \in [0, L] \quad (4.10)$$

В резултат на решаването на задача P4.1 е определено, че оптималната стойност на разхода на охлаждащия агент е $u^* = 317.25$, минималната стойност на концентрацията на реагента на изход от реактора е $\tilde{c}_L^* = 0.49$, а оптималните статични профили на концентрацията и температурата са дадени на Фигури 4.3 и 4.4.



Фигура 4.3 Оптимален профил на концентрацията



Фигура 4.4 Оптимален профил на температурата

4.2.2. Синтез на моделно предсказващ регулатор

Разглежда се задачата за оптимално регулиране на тръбния реактор, където целта е профилите на концентрацията и температурата да се приведат към оптималните статични профили. Предполага се, че в текущия дискретен момент k са известни дискретните по пространствената координата профили на концентрацията и температурата $\bar{c} = [\bar{c}(1), \bar{c}(2), \dots, \bar{c}(N_l)]$, $\bar{T} = [\bar{T}(1), \bar{T}(2), \dots, \bar{T}(N_l)]$ (тук N_l е броят на точките при дискретизацията по

дължината на реактора). Тогава, в момента k регулиращото нелинейно моделно предсказващо управление (NMPC) решава оптимизационната задача:

Задача P4.2:

$$V^*(\bar{\mathbf{c}}, \bar{\mathbf{T}}) = \min_U J(U, \bar{\mathbf{c}}, \bar{\mathbf{T}}) \quad (4.11)$$

при известни $\tilde{c}_{k|k}(m) = \bar{c}(m)$, $\tilde{T}_{k|k}(m) = \bar{T}(m)$, $m = 1, 2, \dots, N_l$ и:

$$u_{k+i} \in \mathcal{U}, i = 0, 1, \dots, N-1 \quad (4.12)$$

$$\begin{cases} \tilde{c}_{k+i+1|k}(m) = f_1(\tilde{c}_{k+i|k}(m), \tilde{c}_{k+i|k}(m-1), \tilde{T}_{k+i|k}(m), \tilde{T}_{k+i|k}(m-1)) \\ \tilde{T}_{k+i+1|k}(m) = f_2(\tilde{c}_{k+i|k}(m), \tilde{c}_{k+i|k}(m-1), \tilde{T}_{k+i|k}(m), \tilde{T}_{k+i|k}(m-1), u_{k+i}) \\ i = 0, 1, \dots, N-1, m = 1, 2, \dots, N_l \end{cases} \quad (4.13)$$

където $U = [u_k, u_{k+1}, \dots, u_{k+N-1}]$, а критерият за оптималност е:

$$\begin{aligned} J(U, \bar{\mathbf{c}}, \bar{\mathbf{T}}) = & \sum_{i=0}^{N-1} \sum_{m=1}^{N_l} \{q_1[\tilde{c}_{k+i+1|k}(m) - \tilde{c}^*(m)]^2 + \\ & q_2[\tilde{T}_{k+i+1|k}(m) - \tilde{T}^*(m)]^2\} + r(u_{k+i} - u^*)^2 \end{aligned} \quad (4.14)$$

Системата от уравнения (4.13) е предсказващият модел, получен при пространствено-времевата дискретизация на непрекъснатия динамичен модел (4.1) - (4.2) чрез прилагане на метода на линиите и използване на метода на Ойлер за числено интегриране на получените свързани обикновени диференциални уравнения (ODEs). Така m е дискретната пространствена координата, $\tilde{c}_{k+i+1|k}(m)$, $\tilde{T}_{k+i+1|k}(m)$ са предсказаните стойности на концентрацията и температурата в бъдещия момент $(k+i+1)$ при пространствена координата m . В (4.12), $\mathcal{U} = \{u \in \mathbb{R} \mid 0 \leq u \leq 600\}$ е допустимата област от стойности на управляващото въздействие. В (4.14), N е краен хоризонт, $q_1, q_2, r > 0$ са тегловни коефициенти, а $\tilde{c}^*(m)$, $\tilde{T}^*(m)$, $m = 1, 2, \dots, N_l$ са оптималните статични профили на концентрацията и температурата, определени чрез решаване на задача P4.1.

Оптимизационната задача P4.2 може да бъде формулирана по компактен начин както следва:

Задача P4.3:

$$V^*(\bar{\mathbf{c}}, \bar{\mathbf{T}}) = \min_U J(U, \bar{\mathbf{c}}, \bar{\mathbf{T}}) \text{ при спазване на } G(U, \bar{\mathbf{c}}, \bar{\mathbf{T}}) \leq 0 \quad (4.15)$$

Вектор-функцията G в (4.15) включва функциите на неравенствените и равенствените ограничения (4.12) - (4.13). Задача P4.3 е задача на мултипараметричното нелинейно програмиране (mp-NLP), тъй като тя е нелинейна оптимизационна задача (NLP) по U и е параметризирана по вектора $[\bar{\mathbf{c}}, \bar{\mathbf{T}}]$. Означаваме оптималното решение на тази задача с $U^* = [u_k^*, u_{k+1}^*, \dots, u_{k+N-1}^*]$, а управляващото въздействие се определя съгласно стратегията на преместващия се хоризонт, т.е. $u(k) = u_k^*$.

Алгоритъмът за моделно предсказващо управление на тръбния реактор, базиран на онлайн оптимизация, се описва както следва.

Алгоритъм 1:

Нека измерените профили на концентрацията и температурата в текущия дискретен момент k да са $\bar{c} = [\bar{c}(1), \dots, \bar{c}(N_l)]$ и $\bar{T} = [\bar{T}(1), \dots, \bar{T}(N_l)]$.


1. Оптимизационната задача P4.2 се решава за начално състояние $\bar{c}$, $\bar{T}$ и се изчислява оптималната поредица $U^* = [u_k^*, u_{k+1}^*, \dots, u_{k+N-1}^*]$ от стойности на управляващото въздействие.
2. Управляващото въздействие, приложено на тръбния реактор в момента k е $u(k) = u_k^*$.
3. $k := k + 1$ и се преминава към стъпка 1.

4.2.3. Симулационни експерименти


Моделно предсказващият регулатор за тръбния реактор има хоризонт на предсказване $N = 10$ и тегловни коефициенти $q_1 = q_2 = 6$, $r = 1 \cdot 10^{-7}$ в критерия за оптималност (4.14). Интервалът на дискретизация е 0.1 [s] и променливите за оптимизация в задача P4.2 са 10 (стойностите на разхода на охлаждащия агент в рамките на хоризонта). Действието на предсказващия регулатор е изследвано на базата на пространствено-времевия динамичен модел на тръбния реактор. Разгледани са следните сценарии.

4.2.3.1 Пълно съответствие между модела и обекта и отсъствие на смущения

Траекторията на управляващото въздействие, генерирана с Алгоритъм 1 е показана на Фигура 4.5, а съответните пространствено-времеви траектории на концентрацията и температурата са дадени на Фигура 4.6.




Фигура 4.5 Траектория на управляващото въздействие



Фигура 4.6 Пространствено-времеви траектории на концентрацията (вляво) и температурата (вдясно)

На Фигура 4.5 може да се забележи, че траекторията на оптималното управляващо въздействие има начален период, в който на реактора не се прилага никакво охлаждане ($u = 0$), който е последван от период с максимален разход на охлаждащия агент ($u = 600$), и накрая приема установената стойност. Това може да бъде интерпретирано по следния начин. Отсъствието на охлаждане в началото осигурява голяма скорост на реакцията (виж уравнение (4.4)) и следователно бързо трансформиране на реагента в продукт. Но тъй като реакцията е екзотермична, ще има много бързо увеличение на температурата и тогава периодът с максимално охлаждане бързо ще приведе температурата до оптималната зададена стойност.

На Фигура 4.7 са дадени времевите траектории на изходната концентрация и изходната температура. От друга страна, преходните процеси, изобразени на Фигура 4.7 показват, че динамиката на изходните концентрация и температура съответстват на система с времезакъснение.




Фигура 4.7 Времева траектория на изходната концентрация (вляво) и изходната температура (вдясно)


4.2.3.2 Неопределеност за коефициента на топлопредаване

Предполага се, че съществува неопределеност за стойността на коефициента на топлопредаване α . Така, моделно предсказващият регулатор (МРС) е синтезиран на базата на дискретизация на модела (4.1) – (4.2) за $\alpha = 1.95 \cdot 10^{-4}$, но всъщност тръбният реактор има $\alpha = 1.5 \cdot 10^{-4}$. Действието на регулатора в затворен контур с тръбния реактор (дискретизираният вариант на модела (4.1) –

(4.2) с $\alpha = 1.5 \cdot 10^{-4}$) е изследвано и траекторията на управляващото въздействие е показана на Фигура 4.8. Получените статични профили на концентрацията и температурата по дължината на реактора са дадени на Фигура 4.9, където може да се забележи, че те се различават незначително от зададените профили. От Фигура 4.8 може да се види, че траекторията на оптималното управление изглежда подобно на тази, получена при пълно съответствие между модела и обекта (Фигура 4.5), но сега периодът с максимален разход на охлаждащия агент е по-дълъг. Това може да бъде обяснено с по-малката стойност на коефициента на топлопредаване α , респективно с по-малката интензивност на охлаждане на реактора, което е компенсирано с по-дълъг период на максимално охлаждане. От Фигура 4.9 може да се забележи, че съществува пренебрежима разлика между крайните профили на концентрацията и температурата по дължината на реактора и зададените профили.




Фигура 4.8 Траектория на управляващото въздействие



Фигура 4.9 Профили в установен режим на концентрацията (вляво) и температурата (вдясно)


Времевите траектории на изходната концентрация и изходната температура са дадени на Фигура 4.10.




Фигура 4.10 Времева траектория на изходната концентрация (вляво) и изходната температура (вдясно)

4.2.3.3 Наличие на постоянно случайно смущение на температурата на охлаждащия агент



Сега се предполага, че има постоянно случайно смущение на температурата на охлаждащия агент, както е показано на Фигура 4.11. Траекторията на управляващото въздействие, генерирана от моделно предсказващия регулатор (реализиран чрез Алгоритъм 1), е показана на Фигура 4.12, а получените профили в статичен режим са дадени на Фигура 4.13. Може да се види, че получените статични профили на практика съвпадат със зададените.



Фигура 4.11 Случайно смущение на температурата на охлаждащия агент




Фигура 4.12 Траектория на управляващото въздействие



Фигура 4.13 Профили в установен режим на концентрацията (вляво) и температурата (вдясно)

Времевите траектории на изходната концентрация и изходната температура са дадени на Фигура 4.14.



Фигура 4.14 Времева траектория на изходната концентрация (вляво) и изходната температура (вдясно)

От Фигура 4.14 може да се забележи, че въпреки наличието на постоянно случайно смущение, изходната концентрация и изходната температура плавно доближават зададените стойности.

4.3. NARX модел на динамиката на реактора, базиран на Гаусови процеси

4.3.1. Моделиране на динамични системи с Гаусови процеси

Предполагайки съществуването на зависимост от вида $y = f(z) + \xi$ (ξ е случаен шум) между входния вектор $z \in \mathbb{R}^D$ и изходната величина $y \in \mathbb{R}$, разполагаме с M -на брой стойности $y(1), y(2), \dots, y(M) \sim \mathcal{N}(0, \Sigma)$ на y , където $\Sigma_{pq} = \text{Cov}(y(p), y(q)) = C(z(p), z(q))$ е ковариацията между изходните точки $y(p)$ и $y(q)$ съответстващи на входните точки $z(p)$ и $z(q)$. По такъв начин, математическото очакване $\mu(z)$ (обикновено се приема, че е равно на нула) и функцията на ковариациите $C(z(p), z(q))$ напълно определят Гаусовият процес. Една възможна функция на ковариациите е изометричната рационално-квадратична функция:

$$C(z(p), z(q) | \theta) = \sigma_f^2 \left(1 + \frac{[z(p) - z(q)]^T [z(p) - z(q)]}{2a\sigma_l^2} \right)^{-a} \quad (4.16)$$

където σ_l е характерната скала на дължината, σ_f е стандартното отклонение на сигнала и a е положителен хипер-параметър. За дадена задача, хипер-параметрите θ на функцията на ковариациите се идентифицират чрез използване на наличните данни.

Разглеждаме съвкупност от M на брой D -мерни входни вектори $\mathbf{Z} = [z(1), z(2), \dots, z(M)]^T$ и вектор с изходни данни $\mathbf{Y} = [y(1), y(2), \dots, y(M)]^T$. На базата на данните $(\mathbf{Z}, \mathbf{Y})$, при даден нов входен вектор z^* , бихме искали да оценим разпределението на вероятностите на съответния изход y^* . За разлика от другите видове модели, тук няма определяне на параметрите на модела в рамките на фиксирана структура на модела. С този вид модел, по-голямата част от усилието се състои в *настройване* на хипер-параметрите на функцията на ковариациите. Определя се матрица на ковариациите $\mathbf{K}$ с размерност $M \times M$ на

базата на обучаващата съвкупност $\mathbf{Z}$. Както беше споменато, целта е да се оцени разпределението на вероятностите на съответния изход y^* при подаване на нов входен вектор z^* . За нов тестов входен вектор z^* , постериорното апостериорното разпределение на съответния изход е $y^* | z^*, (\mathbf{Z}, Y)$ и е Гаусово с математическо очакване и дисперсия:

$$\begin{aligned} E\{y^*\} &= \mu(z^*) = c(z^*)^T \mathbf{K}^{-1} Y \\ \text{var}\{y^*\} &= \sigma^2(z^*) = c_0(z^*) - c(z^*)^T \mathbf{K}^{-1} c(z^*) + v_0 \end{aligned} \quad (4.17)$$

където $c(z^*) = [C(z(1), z^*), \dots, C(z(M), z^*)]^T$ е векторът на ковариациите между тестовия входен вектор и обучаващите вектори, $c_0(z^*) = C(z^*, z^*)$ и е ковариацията между между тестовия входен вектор и самия него.

Гаусовите процеси (GP) могат да моделират статични нелинейни зависимости и следователно могат да се използват за моделиране на динамични системи, ако миналите входни и изходни сигнали се използват като регресори. В тези случаи, се разглежда нелинеен авторегресионен модел с външно въздействие (NARX), където текущият предсказан изход зависи предходно оценените изходи and предишните входове:

$$\begin{aligned} z(k) &= [\hat{y}(k-1), \dots, \hat{y}(k-m), u(k-1), \dots, u(k-m)]^T \\ \hat{y}(k) &= \tilde{f}(z(k)) + \eta(k) \end{aligned} \quad (4.18)$$

където k е последователният номер на данните, m е дадено закъснение, а $\eta(t)$ е грешката от предсказване.

4.3.2. Динамично моделиране на тръбния реактор чрез използване на Гаусови процеси

Аналитичният модел, описан в Секция 4.1, е използван за генериране на данни за динамичното функциониране на тръбния реактор. При изменение на управляващото въздействие u (разхода на охлаждащ агент), частните диференциални уравнения (4.1) - (4.2) са решени и са получени данните за концентрацията на реагента и за температурата на изход от реактора (т.е. за $l = L$). В практиката такива данни се получават чрез провеждането на експерименти. Тъй като динамиката на реактора е чувствителна към промените на параметрите на входящия поток, моделът (4.1) - (4.2) е решен за различни стойности на температурата $\tilde{T}_f$ на този поток (трябва да се отбележи, че поради това, че реагентът е един, неговата концентрация във входящия поток е винаги $c_f = 1$). Нека $\mathcal{T}_f$ да е следната съвкупност от десет стойности на $\tilde{T}_f$:

$$\mathcal{T}_f = \{\tilde{T}_{f,i} = 2.9 + 0.067i, i = 1, 2, \dots, 10\} \quad (4.19)$$

На базата на наличните данни са идентифицирани десет съвкупности от NARX модели, описващи динамиката на концентрацията $\tilde{c}_L$ и на температурата $\tilde{T}_L$ на изхода от реактора, които съответстват на стойностите $\tilde{T}_{f,i} \in \mathcal{T}_f$ на температурата на входящия поток:

$$\tilde{c}_L(k) = f_i(\tilde{T}_L(k-1), \dots, \tilde{T}_L(k-n_T), u(k-1), \dots, u(k-n_u) | \theta_{f_i}) \quad (4.20)$$


$$\begin{aligned}\tilde{T}_L(k) &= g_i(\tilde{c}_L(k-1), \dots, \tilde{c}_L(k-m_c), \tilde{T}_L(k-1), \dots, \tilde{T}_L(k-m_T), \\ &\quad u(k-1), \dots, u(k-m_u) | \theta_{g_i}) \\ i &= 1, 2, \dots, 10\end{aligned}\quad (4.21)$$

Тук, θ_{f_i} и θ_{g_i} са хипер-параметрите на i -тите модели (4.20) - (4.21), а закъсненията в тези модели са:


$$n_T = 6, n_u = 4, m_c = 9, m_T = 13, m_u = 9 \quad (4.22)$$

Съвкупността от модели (4.20) - (4.21) представлява сурогатен модел на динамиката на реактора. Такава мрежа от независими модели е по-проста за проектиране, обучение и интерпретиране в сравнение с един единствен сложен модел, който да включва влиянието на $\tilde{T}_f$ върху динамиката на реактора.

Генератор на случайни числа формира тестов сигнал на управляващото въздействие с нормално разпределение и скорост на изменение, която е различна от тази на сигнала, използван при идентификацията на моделите. Отговорите на GP моделите на концентрацията и на температурата, получени за $\tilde{T}_f = 3$ и за $\tilde{T}_f = 3.3$ са показани на Фигура 4.15 и Фигура 4.16, съответно.



Фигура 4.15 Отговор на GP моделите за $\tilde{T}_f = 3$



Фигура 4.16 Отговор на GP моделите за $\tilde{T}_f = 3.3$

4.4. Адаптивно оптимално управление на тръбния реактор на базата на GP моделите

4.4.1. Синтез на адаптивен моделно предсказващ регулатор (MPC)

Чрез дефиниране на векторите от регресори:

$$z_{\tilde{c}}(k) = [\tilde{T}_L(k), \tilde{T}_L(k-1), \dots, \tilde{T}_L(k-n_T+1), \\ u(k-1), \dots, u(k-n_u+1)] \quad (4.23)$$

$$z_{\tilde{T}}(k) = [\tilde{c}_L(k), \tilde{c}_L(k-1), \dots, \tilde{c}_L(k-m_c+1), \\ \tilde{T}_L(k), \tilde{T}_L(k-1), \dots, \tilde{T}_L(k-m_T+1), \\ u(k-1), \dots, u(k-m_u+1)] \quad (4.24)$$

получаваме от моделите (4.20) - (4.21) следната съвкупност от компактни предсказващи модели за изходните концентрация и температура:

$$\tilde{c}_L(k+1) = f_i(z_{\tilde{c}}(k), u(k) | \theta_{f_i}) \quad (4.25)$$

$$\tilde{T}_L(k+1) = g_i(z_{\tilde{T}}(k), u(k) | \theta_{g_i}) \quad (4.26)$$

$$i = 1, 2, \dots, 10$$

Разглеждаме задачата за оптимално регулиране на тръбния реактор, където целта е изходните концентрация и температура да бъдат преведени на оптималните зададени стойности $\tilde{c}_{L,sp}$ и $\tilde{T}_{L,sp}$, които неявно зависят от температурата $\tilde{T}_f$ на входящия поток:

$$\tilde{c}_{L,sp} = h_1(\tilde{T}_f), \tilde{T}_{L,sp} = h_2(\tilde{T}_f) \quad (4.27)$$

За $\tilde{T}_{f,i} \in \mathcal{T}_f$, оптималните зададени стойности $\tilde{c}_{L,sp,i}$, $\tilde{T}_{L,sp,i}$ се определят чрез решаване на задачата за оптимизация на статичния режим:

Задача P4.4:

$$\tilde{c}_{L,sp,i} = \min_u \tilde{c}_{L,steady,i}(u) \quad (4.28)$$

при отчитане на статичния модел:

$$\tilde{c}_{L,steady,i}(u) = \lim_{k \rightarrow \infty} \tilde{c}_L(k+1) = \lim_{k \rightarrow \infty} f_i(z_{\tilde{c}}(k), u | \theta_{f_i}) \quad (4.29)$$

$$\tilde{T}_{L,steady,i}(u) = \lim_{k \rightarrow \infty} \tilde{T}_L(k+1) = \lim_{k \rightarrow \infty} g_i(z_{\tilde{T}}(k), u | \theta_{g_i}) \quad (4.30)$$

за дадени начални вектори с регресори $z_{\tilde{c}}(0)$, $z_{\tilde{T}}(0)$ и спазване на ограничението:

$$0 \leq u \leq 600 \quad (4.31)$$

Означаваме оптималното решение на задачата P4.4 с $u_{steady,i}$, а съответните оптимални зададени стойности на изходните концентрация и температура са:

$$\tilde{c}_{L,sp,i} = \tilde{c}_{L,steady,i}(u_{steady,i}) \quad (4.32)$$

$$\tilde{T}_{L,sp,i} = \tilde{T}_{L,steady,i}(u_{steady,i}) \quad (4.33)$$

В текущия момент k , означаваме с $\tilde{c}_L(k)$ и $\tilde{T}_L(k)$ измерените изходни концентрация и температура на реактора и с $\tilde{T}_f(k)$ измерената температура на входящия поток. Също така, нека i^* да е индексът на стойността $\tilde{T}_{f,i} \in \mathcal{T}_f$ м която е най-близка до $\tilde{T}_f(k)$, т.е.:

$$\tilde{T}_{f,i}^* = \arg \min_{\tilde{T}_{f,i} \in \mathcal{Z}_f} |\tilde{T}_{f,i} - \tilde{T}_f(k)| \quad (4.34)$$

Тогава, съответните оптимални зададени стойности се означават с $\tilde{c}_{L,sp,i}^*$, $\tilde{T}_{L,sp,i}^*$, а установената стойност на управляващото въздействие с $u_{\text{steady},i}^*$. Предполага се, че в текущия момент k векторите на регресорите $z_{\tilde{c}}(k) = z_{\tilde{c},k|k}$ и $z_{\tilde{T}}(k) = z_{\tilde{T},k|k}$ са известни и стойностите на управляващото въздействие $u(k+j) = u_{k+j}$, $j = 0, 1, \dots, N-1$ са дадени (тук N е хоризонтът на предсказване). Тогава, моделът (4.25)-(4.26) може да се използва, за да се получат предсказаните стойности на изходната концентрация $\tilde{c}_{L,k+j+1|k}$ и изходната температура $\tilde{T}_{L,k+j+1|k}$, $j = 0, 1, \dots, N-1$ чрез итеративни предсказания с една стъпка напред, където на всяка стъпка предсказаната стойност на изходната величина се подава обратно към векторите на регресорите:

$$\tilde{c}_{L,k+j+1|k} = f_{i^*}^*(z_{\tilde{c},k+j|k}, u_{k+j} | \theta_{f_i^*}) \quad (4.35)$$

$$\tilde{T}_{L,k+j+1|k} = g_{i^*}^*(z_{\tilde{T},k+j|k}, u_{k+j} | \theta_{g_i^*}) \quad (4.36)$$

За да се избегне възможна статична грешка на нелинейния моделно предсказващ регулатор (NMPC) поради неточност на предсказването с NARX моделите, две допълнителни изходни променливи (означени с $e_{\tilde{c}}$ и $e_{\tilde{T}}$) се предсказват, които представляват интегралните грешки на регулиране на изходните концентрация и температура:

$$e_{\tilde{c},k+j+1|k} = e_{\tilde{c},k+j|k} + (\tilde{c}_{L,k+j|k} - \tilde{c}_{L,sp,i}^*) \quad (4.37)$$

$$e_{\tilde{T},k+j+1|k} = e_{\tilde{T},k+j|k} + (\tilde{T}_{L,k+j|k} - \tilde{T}_{L,sp,i}^*) \quad (4.38)$$

Началните стойности на тези грешки се задават равни на нула, т.е. $e_{\tilde{c}}(0) = 0$, $e_{\tilde{T}}(0) = 0$. Означаваме с $n_{\max}$ максималното закъснение измежду закъсненията в (4.22). Тогава, за текущите вектори на регресорите $z_{\tilde{c}}(k)$ и $z_{\tilde{T}}(k)$ (където $k \geq n_{\max}$) и текущите стойности на интегралните грешки, означени с $e_{\tilde{c}}(k)$ и $e_{\tilde{T}}(k)$, регулиращото NMPC решава оптимизационната задача:

Задача P4.5:

$$V^*(z_{\tilde{c}}(k), z_{\tilde{T}}(k)) = \min_U J(U, z_{\tilde{c}}(k), z_{\tilde{T}}(k)) \quad (4.39)$$

при известни $z_{\tilde{c},k|k} = z_{\tilde{c}}(k)$, $z_{\tilde{T},k|k} = z_{\tilde{T}}(k)$, $e_{\tilde{c},k|k} = e_{\tilde{c}}(k)$, $e_{\tilde{T},k|k} = e_{\tilde{T}}(k)$ и:

$$u_{\min} \leq u_{k+j} \leq u_{\max}, \quad j = 0, 1, \dots, N-1 \quad (4.40)$$

$$\tilde{c}_{L,k+j+1|k} = f_{i^*}^*(z_{\tilde{c},k+j|k}, u_{k+j} | \theta_{f_i^*}), \quad j = 0, 1, \dots, N-1 \quad (4.41)$$

$$\tilde{T}_{L,k+j+1|k} = g_{i^*}^*(z_{\tilde{T},k+j|k}, u_{k+j} | \theta_{g_i^*}), \quad j = 0, 1, \dots, N-1 \quad (4.42)$$

$$e_{\tilde{c},k+j+1|k} = e_{\tilde{c},k+j|k} + (\tilde{c}_{L,k+j|k} - \tilde{c}_{L,sp,i}^*), \quad j = 0, 1, \dots, N-1 \quad (4.43)$$

$$e_{\tilde{T},k+j+1|k} = e_{\tilde{T},k+j|k} + (\tilde{T}_{L,k+j|k} - \tilde{T}_{L,sp,i}^*), \quad j = 0, 1, \dots, N-1 \quad (4.44)$$

$$z_{\tilde{c},k+j|k} = [\tilde{T}_{L,k+j|k}, \tilde{T}_{L,k+j-1|k}, \dots, \tilde{T}_{L,k+j-n_T+1|k}, u_{k+j-1}, \dots, u_{k+j-n_u+1}] \quad (4.45)$$

$$z_{\tilde{T},k+j|k} = [\tilde{c}_{L,k+j|k}, \tilde{c}_{L,k+j-1|k}, \dots, \tilde{c}_{L,k+j-m_c+1|k}, \tilde{T}_{L,k+j|k}, \tilde{T}_{L,k+j-1|k}, \dots, \tilde{T}_{L,k+j-m_T+1|k}, u_{k+j-1}, \dots, u_{k+j-m_u+1}] \quad (4.46)$$

където $U = [u_k, u_{k+1}, \dots, u_{k+N-1}]$, а критерият за оптималност е:

$$J(U, z_{\tilde{c}}(k), z_{\tilde{T}}(k)) = \sum_{k=0}^{N-1} J_S(\tilde{c}_{L,k+j|k}, \tilde{T}_{L,k+j|k}, e_{\tilde{c},k+j|k}, e_{\tilde{T},k+j|k}, u_{k+j}) + J_T(\tilde{c}_{L,k+N|k}, \tilde{T}_{L,k+N|k}, e_{\tilde{c},k+N|k}, e_{\tilde{T},k+N|k}) \quad (4.47)$$


Тук, N е краен хоризонт, J_S е етапният критерий, дефиниран както следва:

$$J_S(\tilde{c}_{L,k+j|k}, \tilde{T}_{L,k+j|k}, e_{\tilde{c},k+j|k}, e_{\tilde{T},k+j|k}, u_{k+j}) = q_1(\tilde{c}_{L,k+j|k} - \tilde{c}_{L,sp,i^*})^2 + q_2(\tilde{T}_{L,k+j|k} - \tilde{T}_{L,sp,i^*})^2 + q_3 e_{\tilde{c},k+j|k}^2 + q_4 e_{\tilde{T},k+j|k}^2 + q_5(u_{k+j} - u_{steady,i^*})^2 \quad (4.48)$$

а J_T е терминалният критерий:

$$J_T(\tilde{c}_{L,k+N|k}, \tilde{T}_{L,k+N|k}, e_{\tilde{c},k+N|k}, e_{\tilde{T},k+N|k}) = p_1(\tilde{c}_{L,k+N|k} - \tilde{c}_{L,sp,i^*})^2 + p_2(\tilde{T}_{L,k+N|k} - \tilde{T}_{L,sp,i^*})^2 + p_3 e_{\tilde{c},k+N|k}^2 + p_4 e_{\tilde{T},k+N|k}^2 \quad (4.49)$$

В (4.48), (4.49), $q_i > 0, i = 1, \dots, 5$ и $p_i > 0, i = 1, \dots, 4$ са тегловни коефициенти. Означаваме оптималното решение на задачата P4.5 с $U^* = [u_k^*, u_{k+1}^*, \dots, u_{k+N-1}^*]$, а управляващото въздействие се избира съгласно стратегията на преместващия се хоризонт $u(k) = u_k^*$. Схемата на системата за адаптивно оптимално управление на тръбния реактор е показана на Фигура 4.17.




Фигура 4.17 системата за адаптивно оптимално управление, базирана на мулти-модели и моделно предсказващо управление (MPC)


Това е система за супервайзорно управление, където оптималните зададени стойности $\tilde{c}_{L,sp,i}^*$, $\tilde{T}_{L,sp,i}^*$ и съответните установени стойности $u_{steady,i}^*$ се изчисляват предварително чрез решаване на задачата P4.4 и се записват в табличния автомат. Този автомат съдържа също мулти-моделите (4.25) - (4.26). Схемата включва блок за идентификация на стойността $\tilde{T}_{f,i} \in \mathcal{T}_f$, която е най-близка до текущата измерена стойност $\tilde{T}_f$ на температурата на входящия поток.

4.4.2. Симулационни резултати


Адаптивният моделно предсказващ регулатор (MPC), базиран на GP мулти-модели на тръбния реактор има хоризонт на предсказване $N = 20$ и тегловни коефициенти $q_1 = q_2 = 300$, $q_3 = q_4 = 0.2$, $q_5 = 1 \cdot 10^{-6}$, $p_i = q_i$, $i = 1, \dots, 4$ в критериите (4.48), (4.49). Интервалът на дискретизация е 0.1 [s] и променливите за оптимизация в задачата P4.5 са 20 (стойностите на разхода на охлаждащ агент в рамките на хоризонта). Изследвано е действието на MPC регулатора в затворен контур с аналитичния модел (4.1) - (4.4) на тръбния реактор. Разгледан е следният сценарий. В дискретния момент 70, температурата на входящия поток променя своята стойност от $\tilde{T}_f = 3$ на $\tilde{T}_f = 3.1$. Траекторията на управляващото въздействие, генерирана с адаптивния моделно предсказващ регулатор, е показана на Фигура 4.18, а съответните пространствено-времеви траектории на концентрацията и температурата са дадени на Фигури 4.19 и 4.20.



Фигура 4.18 Траектория на управляващото въздействие




Фигура 4.19 Пространствено-времева траектория на концентрацията




Фигура 4.20 Пространствено-времева траектория на температурата

На Фигури 4.21-4.22, времевите траектории на изходната концентрация и изходната температура са дадени. От Фигури 4.21-4.22 се вижда, че динамиката на изходните концентрация и температура съответстват на система с

времезакъснение. Също така, цялата траектория включва два преходни процеса: първият процес (по-изразен) се дължи на факта, че началните стойности на изходните концентрация и температура са далеч от зададените стойности, съответстващи на $\tilde{T}_f = 3$, а вторият процес е свързан с промяната на температурата на входящия поток на новата стойност $\tilde{T}_f = 3.1$.



Фигура 4.21 Времева траектория на изходната концентрация



Фигура 4.22 Времева траектория на изходната температура

4.5. Изводи

Разработена е система за супервайзорно управление, която извършва статична и динамична оптимизация на тръбен реактор въз основа на неговия пространствено-времеви аналитичен модел. На горното ниво на системата се решава задачата за оптимизация на статичния режим, която има за цел да максимизира производителността на реактора. На долното ниво се използва моделно предсказващ регулатор (MPC) за постигане на оптимално управление в затворен контур при наличие на ограничения. Изследвана е работата на предсказващия регулатор при наличие на неопределеност относно коефициента на топлопредаване и смущения в температурата на охлаждащия агент. Резултатите показват, че оптималната система за управление поддържа профилите на концентрацията и температурата на зададените такива, въпреки параметричната неопределеност и наличието на смущения.

Освен това е направено ново изследване на моделирането и адаптивното оптимално управление на тръбен реактор чрез използване на Гаусови процеси (GP). Подходът за моделиране с Гаусови процеси е приложен за получаване на съвкупност от NARX модели на изходната концентрация и изходната температура на реактора за няколко стойности на температурата на входящия поток. След това идентифицираните модели се използват за синтез на адаптивен моделно предсказващ регулатор за постигане на оптимално функциониране на реактора въпреки промените в температурата на входящия поток. Адаптивната система е реализирана като табличен автомат, който съхранява предварително изчислените оптимални зададени стойности на концентрацията и температурата за различни стойности на температурата на входящия поток. След това оптималното регулиране на изходните променливи до тези зададени стойности се постига от моделно предсказващия регулатор. Симулационните експерименти показват, че адаптивният MPC регулатор довежда изходните концентрация и температура на реактора до новите оптимални зададени стойности, когато температурата на входящия поток се промени.

ИЗВОДИ

От резултатите, получени в дисертацията, могат да се направят следните изводи:

Конвенционалните методи за управление са подходящи за решаване на сравнително прости задачи за управление, като например тези, свързани с линейните стационарни динамични системи. Въпреки това, задачите на управлението често включват системи със съществено нелинейна динамика, хаотични системи, неопределени системи или системи с разпределени параметри. С конвенционалните методи за управление е трудно да се решат тези практически задачи и да се постигне необходимата точност на управление. Интелигентните системи за управление се характеризират с функции като обучение, моделиране, оптимизиране, адаптиране. Това им позволява да компенсират недостатъците, характерни за конвенционалните методи.

Невронният модел на Хиндмарш-Роуз (HR) има множество динамични поведения, като състояние на покой, периодично състояние, периодичен взрив и хаотична динамика при промяна на външния входен поток, и е силно чувствителен към началните условия. Системите от вида главна система-подчинена система се използват широко в различни области, като например безопасна комуникация, откриване на неизправности и др. Синхронното им състояние е широко разпространено нелинейно явление в промишлеността. Химическите реактори са основните технологични единици в химикотехнологичните процеси. Типичен пример за това са непрекъснатите неизотермични реактори с идеално изтласкване. Такива реактори са изключително сложни, тъй като представляват нелинейни системи с разпределени параметри, чиято динамика се описва с частни диференциални уравнения, произтичащи от материалните и енергийните баланси в пространството и времето. Ето защо ефективното управление на тези три класа специфични нелинейни системи е задача от изключителна важност.

За HR невронния модел е синтезиран явен нелинеен моделно предсказващ регулатор, базиран на дълбочинни невронни мрежи (NMPC-DNN). Основната мотивация за явния NMPC подход е всички изчисления, свързани с нелинейната оптимизация, да се извършат офлайн. DNN на явния предсказващ регулатор се обучава да апроксимира зависимостта на оптималното управляващо въздействие от текущото състояние на HR невронния модел. Нелинейната функция на активация представлява ректифициран линеен блок. Дадени са симулационни резултати за работата на NMPC регулатора, базиран на дълбочинни невронни мрежи. Явният NMPC-DNN е сравнен с NMPC регулатор, базиран на онлайн оптимизация. Предимствата на NMPC-DNN са намалената изчислителна сложност в онлайн режим и простата софтуерна реализация. Освен това е направено сравнение на качеството на управлението на NMPC-DNN и на регулатор в режим на хлъзгане (SMC). Резултатите показват, че NMPC-DNN регулаторът има по-добро качество на управление с по-малки времена на регулиране и по-малки интегрално-квадратични грешки, което го прави идеален за приложения, изискващи бързо и точно управление. За разлика от него, методът SMC води до по-големи времена на регулиране, но няма никакво пререгулиране. Като цяло подходът NMPC-DNN предлага по-добро качество на управление за HR невронния модел.

Предложен е нов експоненциално смутен невронен регулатор в режим на хлъзгане (NEPSM-NN) и е използвана невронна мрежа с радиални базисни функции с адаптивни тегла за описание на неопределеността в динамиката на хаотичната система от вида главна система-подчинена система. Синтезиран е експоненциален наблюдател на смущенията, който компенсира смущенията и намалява усилването на превключването при управлението в режим на хлъзгане. Анализирана е устойчивостта на динамиката на грешката от синхронизация за нелинейни хаотични системи от трети ред от вида главна система-подчинена система с помощта на функцията на Ляпунов. Симулацията показва, че предложеният NEPSM-NN регулатор има по-добро действие в сравнение с PI регулатора, тъй като има силна способност за подтискане на смущенията и грешката от синхронизация бързо става равна на нула. Освен това е дадено сравнението на действието на предложения NEPSM-NN регулатор и на PI регулатора с помощта на основните показатели за качеството на управление. Резултатите показват, че методът за управление NEPSM-NN е по-добър по отношение на времето на регулиране и интегрално-квадратичната грешка.

Същевременно за постигане на синхронизация на главната система и подчинената система е използван друг интелигентен регулатор, който представлява явен нелинеен моделно предсказващ регулатор (NMPC), базиран на дълбочинни невронни мрежи (DNN). DNN на явния NMPC регулатор е обучена офлайн да апроксимира зависимостта на оптималното управляващо въздействие от текущата грешка от синхронизация. Методът NMPC-DNN е демонстриран върху нелинейни системи от вида главна система-подчинена система. Предимството на този подход е, че той значително намалява изчислителното време и е по-подходящ за приложения в реално време. Действието на NMPC-DNN регулатора е сравнено с това на новия експоненциално смутен невронен регулатор в режим на хлъзгане чрез използване на ключови показатели за качеството на управление.

Синтезирана е супервайзорна система за оптимално управление на тръбен реактор. На горното ниво на системата се решава задачата за оптимизация на статичния режим, която има за цел да максимизира производителността на реактора. На долното ниво се използва моделно предсказващ регулатор (MPC) за постигане на оптимално управление в затворен контур при наличие на ограничения. Изследвана е работата на предсказващия регулатор при наличие на неопределеност относно коефициента на топлопредаване и смущения в температурата на охлаждащия агент. Резултатите показват, че оптималната система за управление поддържа профилите на концентрацията и температурата на зададените такива, въпреки параметричната неопределеност и наличието на смущения.

Освен това е направено ново изследване на моделирането и адаптивното оптимално управление на тръбен реактор чрез използване на Гаусови процеси (GPs). Благодарение на това, че GPs могат да моделират статични нелинейности, те могат да се използват за моделиране и на динамични системи, ако миналите стойности на входните и изходни сигнали се използват като регресори. Подходът за моделиране с Гаусови процеси е приложен за получаване на съвкупност от нелинейни авторегресионни модели с външен вход (NARX модели) на изходната концентрация и изходната температура на реактора за няколко стойности на температурата на входящия поток. След това идентифицираните модели се използват за синтез на адаптивен моделно

предсказващ регулатор за постигане на оптимално функциониране на реактора въпреки промените в температурата на входящия поток. Оптималните зададени стойности се изчисляват предварително за различни стойности на температурата на входящия поток чрез решаване на оптимизационна задача и се съхраняват в табличен автомат. Изследвано е действието на MPC регулатора в затворен контур с аналитичния модел на тръбния реактор. Резултатите показват, че адаптивният MPC регулатор довежда изходните концентрация и температура на реактора до новите оптимални зададени стойности, когато температурата на входящия поток се промени.

ПРИНОСИ НА ДИСЕРТАЦИОННИЯ ТРУД

В тази дисертация са разработени методи за интелигентно управление, базирано на модели, за няколко вида сложни нелинейни системи, като невронния модел на Хиндмарш-Роуз, хаотичните системи от вида главна система-подчинена система и тръбните химически реактори. Основните приноси на дисертацията са обобщени, както следва:

- 1.** Синтезиран е явен нелинеен моделно предсказващ (NMPC) регулатор, базиран на дълбочинни невронни мрежи (DNN), за оптимално управление на невронния модел на Хиндмарш-Роуз. Невронната мрежа (DNN) на регулатора се обучава офлайн, като се използват траекториите на оптималното управление, генерирани за редица начални състояния на HR невронния модел. Симулационните експерименти показват, че NMPC-DNN има висока точност на апроксимация на оптималното управление. Предимствата на NMPC-DNN в сравнение с NMPC, базиран на онлайн оптимизация, са намалената изчислителна сложност в реално време и простата софтуерна реализация. Също така за невронния HR модел е проектиран регулатор в режим на хлъзгане и неговото действие е сравнено с това на NMPC-DNN регулатора. Резултатите показват, че NMPC-DNN регулаторът има по-добро качество на управление
- 2.** Предложен е нов експоненциално смутен закон на управление в режим на хлъзгане за синхронизиране на системи от вида главна система-подчинена система, като е синтезиран наблюдател на смущенията и са използвани невронни мрежи с радиални базисни функции (RBF-NN) с адаптивни тегла за описание на неопределеността в динамиката на системите. Доказано е, че новата схема за управление гарантира устойчивостта на нелинейна хаотична система от трети ред от вида главна система-подчинена система. Резултатите от симулацията показват, че предложената схема може ефективно да намали превключването на управляващото въздействие и има силна способност за подтискане на смущенията. Сравнението с пропорционално-интегрален (PI) регулатор потвърждава превъзходството на предложения интелигентен регулатор в режим на хлъзгане.
- 3.** Разработена е супервайзорна система за статична и динамична оптимизация на тръбен реактор въз основа на неговия пространствено-времеви аналитичен модел. Оптимизацията на статичния режим на реактора има за цел да се максимизира концентрацията на продукта на изхода от реактора при зададени концентрация на реагента и температура на входа. Оптималното управление в затворен контур при наличие на ограничения се постига чрез решаване на задачата за статична оптимизация и чрез използване на MPC регулатор. Изследвано е действието на предсказващия контролер при наличие на

параметрична неопределеност в модела и при наличие на смущения в температурата на охлаждащия агент. Резултатите показват, че оптималната система за управление гарантира стабилизиране на изходните променливи без статична грешка въпреки неопределеността в модела и води до високо качество на преходните процеси при наличие на смущения.

4. Разработен е нов подход за моделиране и адаптивно оптимално управление на тръбни реактори, основан на Гаусови процеси (GPs). Подходът за моделиране чрез GPs е приложен за получаване на съвкупност от нелинейни авторегресионни модели с външен вход (NARX модели) на изходната концентрация и изходната температура на реактора за няколко стойности на температурата на входящия поток. Идентифицираните модели след това се използват за синтез на адаптивен моделно предсказващ регулатор за постигане на оптимално функциониране на реактора въпреки промените в температурата на входящия поток. Адаптивната система е реализирана като табличен автомат, който съхранява предварително изчислените оптимални зададени стойности на концентрацията и температурата за различни стойности на температурата на входящия поток. След това оптималното регулиране на изходните променливи до тези зададени стойности се постига чрез моделно предсказващо управление (MPC). Симулационните експерименти показват, че адаптивният MPC регулатор довежда изходните концентрация и температура на реактора към новите оптимални зададени стойности при промяна на температурата на входящия поток.

АПРОБАЦИЯ НА РЕЗУЛТАТИТЕ

Резултатите, описани в дисертацията са представени и дискутирани на следните конференции:

Представяне на международни конференции:

1. IEEE International Conference on Automatics and Informatics (ICAI 2023), Varna, Bulgaria, 5-7 October, 2023
2. Jubilee International Conference “70 years UCTM”, Sofia, 22-23 May, 2023
3. 12th IEEE International Conference on Intelligent Systems (IS’24), Varna, Bulgaria, 29-31 August, 2024
4. 19th International Conference on Artificial Intelligence: Methodology, Systems, and Applications (AIMSA 2024), Varna, Bulgaria, 18-20 September, 2024

Представяне на конференция на ХТМУ:

1. XX Научна постерна сесия, ХТМУ-София, 23 юни, 2023

Някои от получените резултати са използвани в следните проекти:

1. Договор на ХТМУ No. 12277/2023 “Подходи за интелигентно моделно предсказващо управление на сложни динамични системи”
2. Договор на ХТМУ No. 239-10/2024 “Приложение на методите на машинното обучение за оптималното управление на нелинейни системи с неопределености”

СПИСЪК НА ПУБЛИКАЦИИТЕ ПО ДИСЕРТАЦИЯТА

A1. Xie, J., Grancharova, A., Fan, L., Synchronization of chaotic systems using novel sliding mode neural network controller. Proceedings of IEEE International Conference Automatics and Informatics (ICAI 2023), Varna, Bulgaria, 5-7 October, 2023, pp. 301-305, DOI: 10.1109/ICAI58806.2023.10339087 (Scopus).

A2. Grancharova, A., Xie, J., Kocijan, J., Steady state optimization and model predictive control of a tubular reactor. Proceedings of IEEE International Conference Automatics and Informatics (ICAI 2023), Varna, Bulgaria, 5-7 October, 2023, pp. 246-251, DOI: 10.1109/ICAI58806.2023.10339034 (Scopus).

A3. Xie, J., Grancharova, A., Nonlinear model predictive control based on deep learning for Hindmarsh–Rose neuron model. Proceedings of 12th IEEE International Conference on Intelligent Systems (IS'24), Varna, Bulgaria, 29-31 August, 2024, DOI: 10.1109/IS61756.2024.10705274 (Scopus).

A4. Grancharova, A., Xie, J., Kocijan, J., A novel study on modelling and adaptive optimal control of a tubular reactor based on Gaussian processes. In: Petia Koprinkova-Hristova, Nikola Kasabov (eds.), Artificial Intelligence: Methodology, Systems, and Applications (19th International Conference AIMSA, Varna, Bulgaria, 18-20 September, 2024), Lecture Notes in Artificial Intelligence, Springer Nature Switzerland AG, vol. 15462, pp. 155-167, DOI: 10.1007/978-3-031-81542-3_13 (Scopus).