

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет
Кафедра

Комп'ютерної інженерії та управління
Комп'ютерних інтелектуальних технологій та систем

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти _____ другий (магістерський) _____

Робастна нейромережева ідентифікація
нелінійних об'єктів

(тема)

Виконав:

Студент II курсу, групи КІТМ-22-1

Деркач Є.О.

(прізвище, ініціали)

Спеціальність _____

123-Комп'ютерна інженерія

(код і повна назва спеціальності, напрям)

Тип програми освітньо-професійна

Освітня Програма Комп'ютерні

інтелектуальні технології

(повна назва освітньої програми)

Керівник проф. Безсонов О.О.

(посада, ініціали, прізвище)

Допускається до захисту

(підпис)

Зав. кафедри

(підпис)

О.Г. Руденко

2023 р.

Харківський національний університет радіоелектроніки

Факультет _____ комп'ютерної інженерії та управління _____
Кафедра _____ комп'ютерних інтелектуальних технологій та систем _____
Рівень вищої освіти _____ другий (магістерський) _____
Спеціальність _____ 123 Комп'ютерна інженерія _____
Тип програми _____ освітньо-професійна _____
Освітня програма _____ Комп'ютерні інтелектуальні технології _____

ЗАТВЕРДЖУЮ:

Зав. кафедри _____

(підпис)

« _____ » _____ 202_ р.

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

Студенту _____ Деркач Євгенію Олеговичу _____

1. Тема роботи (проекту) Робастна нейромережева ідентифікація нелінійних об'єктів

затверджена наказом університету від " _____ " _____ 202_ р. № _____

2. Термін подання студентом роботи до екзаменаційної комісії _____ 202_ р.

3. Вихідні дані до роботи (проекту) штучна нейронна мережа

4. Перелік питань, що потрібно опрацювати в роботі _____

Аналіз області дослідження

Методи ідентифікації нелінійних систем

Розгляд моделей для використання та аналізу

Моделювання та ідентифікація нелінійних об'єктів

Висновки

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (п.5 включається до завдання за рішенням кафедри) _____

Презентація - 9 слайдів

6. Консультанти розділів роботи (п.6 включається до завдання за наявності консультантів згідно до наказу, зазначеному у п.1)

Найменування розділу	Консультант посада, прізвище, ім'я, по батькові)	Позначка консультанта про виконання розділу	
		підпис	дата

1 КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Отримання завдання	5.11.2023	
2	Аналіз предметної області	6.11.2023-15.11.2023	
3	Аналіз джерел з проблемної галузі	15.11.2023-26.11.2023	
4	Проведення математичного аналізу	26.11.2023-13.12.2023	
5	Оформлення пояснювальної записки	13.12.2023-18.12.2023	
6	Оформлення графічного матеріалу	18.12.2023-19.12.2023	
7	Подання кваліфікаційної роботи на рецензування	19.12.2023-26.12.2023	

Дата видачі завдання 5 листопада 2023 р.

Студент _____
(підпис)

Керівник роботи _____
(підпис)

проф. каф КІТС О.О. Безсонов
(посада, ініціали, прізвище)

РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 64 с., 10 рис., 34 джерел.

ШТУЧНА НЕЙРОННА МЕРЕЖА, ІМІТАЦІЙНА ПАРАЛЕЛЬНА МОДЕЛІ, НЕЛІНІЙНИЙ ДИНАМІЧНИЙ ОБ'ЄКТ, ІДЕНТИФІКАЦІЯ, ANARX.

Було проаналізовано архітектуру мережі, яка може значно підвищити якість ідентифікації, що є важливим для проектування системи керування. Як інструменти апроксимації використовувалися різні структури штучних нейронних мереж для аналізу ідентифікації нелінійних об'єктів.

Поєднання традиційних алгоритмів управління з адаптацією та ідентифікацією стало можливим завдяки особливостям структур моделей на основі нейронної мережі. Крім того, було показано, що правильна архітектура мережі може значно вплинути на результати ідентифікації.

Нелінійні системи визначаються за структурою ANARX, а модель класу NN-ANARX представлена як альтернативний варіант для спрощення обчислень зворотного зв'язку. Ця структура запропонована та застосована для ідентифікації нелінійних систем МІМО.

Розроблено систему з використанням нейронної мережі за для моделювання нейромережевого керування електротяговим двигуном для обробки сигналу та виведення результатів.

ABSTRACT

Explanatory note for the qualification work: 64 pages, 10 figures, 34 sources.

ARTIFICIAL NEURAL NETWORK, IMITATION PARALLEL MODEL,
NONLINEAR DYNAMIC OBJECT, IDENTIFICATION, ANARX.

The architecture of a network that can significantly improve the quality of identification, crucial for control system design, has been studied. Various structures of artificial neural networks were employed as approximation tools for analyzing the identification of nonlinear systems.

The combination of traditional control algorithms with adaptation and identification became possible due to the characteristics of model structures based on neural networks.

Additionally, it was demonstrated that the correct network architecture can significantly impact identification outcomes. Nonlinear systems are characterized by the ANARX structure, and a model of the NN-ANARX class is presented as an alternative option to simplify the computations of feedback.

This structure has been proposed and applied for the identification of nonlinear MIMO systems.

A system has been developed using a neural network for modeling neural network control of an electric motor for signal processing and result output.

АНОТАЦІЯ

Деркач Є.О. Робастна нейромережева ідентифікація нелінійних об'єктів - Магістерська кваліфікаційна робота.

У магістерській кваліфікаційній роботі вирішено задачу побудови робастної нейромережевої ідентифікації нелінійних об'єктів.

Метою кваліфікаційної роботи є дослідження та ідентифікації нелінійних об'єктів на основі нейронних мереж для розробки і моделювання робастних нейромережевих систем керування.

У ході виконання кваліфікаційної роботи було розглянено питання ідентифікації на основі нейронних мереж нелінійними системами та використання різних моделей. Структури штучних нейронних мереж розглядаються як інструменти апроксимації для ідентифікації складних нелінійних систем і процесів.

У дослідженні показано, що правильна залежна від програми архітектура мережі може значно покращити якість ідентифікації, що має вирішальне значення для проектування системи керування..

Досліджено та порівняно дві моделі - Паралельну та Нелінійну авторегресійну модель з метою ідентифікації нелінійних динамічних об'єктів. Окрему увагу приділено використанню штучних нейронних мереж та багатошаровий перцептрон.

Крім того, специфічні структури моделі на основі нейронної мережі дозволяють комбінувати класичні алгоритми керування з ідентифікацією та адаптацією на основі нейронної мережі. Структура ANARX запропонована та застосована для ідентифікації нелінійних систем МІМО.

Розроблено систему з використанням нейронної мережі за для моделювання нейромережевого керування електротяговим двигуном. Обробка сигналу та виведення результатів в файл чи на екран у вигляді

графіка. Також передбачено можливість зупинити навчання, якщо обрані користувачем критерії досягають визначеного порогового значення.

Всі кроки і процеси виконуються відповідно до заданих користувачем параметрів, і результати представлені у формі графіків залежності вихідних сигналів моделі та об'єкта в часі.

ШТУЧНА НЕЙРОННА МЕРЕЖА, ІДЕНТИФІКАЦІЯ, МОДЕЛЬ,
АЛГОРИТМ, НЕЛІНІЙНИЙ ДИНАМІЧНИЙ ОБ'ЄКТ, ANARX.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ	
ВСТУП	12
1 АНАЛІЗ ОБЛАСТІ ДОСЛІДЖЕННЯ.....	14
1.1 Огляд предметної області.....	14
1.2 Актуальність та використання.....	15
2 ШТУЧНІ НЕЙРОННІ МЕРЕЖІ.....	17
2.1 Модель та структура нейронну.....	17
2.2 Алгоритми навчання.....	19
2.3 Зворотне поширення.....	22
2.4 Рекурентні нейронні мережі.....	24
2.5 Робастність в системах керування та ідентифікації.....	25
3 НЕЛІНІЙНІ ОБ'ЄКТИ ТА НЕЙРОМЕРЕЖЕВА ІДЕНТИФІКАЦІЯ... ..	28
3.1. Нейромережева ідентифікація.....	28
3.2. Нелінійні математичні моделі.....	29
4 МОДЕЛІ ТА МЕТОДИ ІДЕНТИФІКАЦІЇ НЕЛІНІЙНИХ СИСТЕМ... ..	34
4.1 Динамічні системи ідентифікації	34
4.2 Моделі нелінійних систем МІМО.....	37
4.3 Імітаційна модель.....	40
4.4 Паралельна модель та нелінійна авторегресійна модель.....	41
5 МОДЕЛЮВАННЯ ТА ІДЕНТИФІКАЦІЯ ДИНАМІЧНИХ ОБ'ЄКТІВ	43
5.1 Ідентифікація нелінійних динамічних об'єктів	43
5.2 Моделювання керування та функціоналу	46
5.3. Моделювання нейромережевого керування електротяговим двигуном	47
ВИСНОВКИ	54
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ	56

ДОДАТОК А Графічний матеріал кваліфікаційної роботи 60

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ,
СКОРОЧЕНЬ І ТЕРМІНІВ

NN — нейронна мережа

ANN — штучна нейронна мережа

RNN — Рекурентні нейронні мережі

VGG — Згорткова нейронна мережа

НДО — нелінійний динамічний об'єкт

SIMO — один вхід і кілька виходів

MISO — багато входів один вихід

NOE — нелінійна помилка виводу

NFIR — нелінійна кінцева імпульсна характеристика

NARX — нелінійна авторегресія з екзогенними входами

ANARX — адитивний нелінійний авторегресивний екзогенний

NARMAX — нелінійне авторегресивне ковзне середнє екзогенне

ВСТУП

На сьогоднішній день наука перебуває під враженням від досягнень, які нейромережеві технології принесли у різноманітних галузях. Ці відкриття виявили себе як ключові фактори у вирішенні завдань наукового характеру та виявили значний вплив у сферах техніки, бізнесу, фінансів, медичної діагностики та інших інтелектуальних галузях.

У науці нейромережі використовуються для моделювання складних систем, розгадування важливих наукових загадок та аналізу величезних обсягів даних, що виходять за межі здатностей традиційних методів. У технічних застосуваннях, вони використовуються для розв'язання складних інженерних завдань, оптимізації виробництва та розробки нових технологій.

В галузі бізнесу нейромережі революціонізують процеси прийняття рішень, прогнозування ринкових тенденцій та вдосконалення стратегій маркетингу. У фінансовому секторі вони використовуються для прогнозування ризиків, аналізу портфелів та оптимізації інвестицій.

В області медичної діагностики нейромережі роблять величезний внесок у точність виявлення захворювань, автоматизацію аналізу зображень та розробку персоналізованих підходів до лікування.

Ці інтелектуальні технології також знайшли широке застосування в інших сферах, де вони забезпечують автоматизацію завдань, оптимізацію ефективності та сприяють створенню нових можливостей у величезному спектрі дисциплін. Нейромережеві технології не лише досягли значних

успіхів, але й продовжують відкривати нові перспективи для трансформації різних галузей знань.

Виникнення Штучних Нейромереж (ANN) пов'язане з розумінням того, що робота живого мозку відрізняється від роботи комп'ютера. Людський мозок представляє собою вкрай складну, нелінійну та паралельну інформаційно-керуючу систему, здатну до мислення, накопичення та відновлення інформації, а також розв'язання проблем. Його структура базується на нервових клітинах або нейронах, що виконують функції обробки сигналів та обмінюються інформацією через дендрити.

Розвиток технічних систем, що ґрунтуються на взаємозв'язку вузлів та представляють математичні моделі біологічних нейронів, коли Мак-Калох і Піттс вперше висунули математичну модель нейронів. Ця модель, відома як штучний нейрон, застосовується у більшості додатків, базуючись на штучних нейронних мережах, і є ключовим елементом систем, що досліджуються у цій кваліфікаційній роботі.

Першим симулятором штучної нейронної мережі можна вважати навчальну машину, створену Едмондсом і Мінським, відому як SNARC. Ця навчальна нейронна мережа була заснована на ідеях Хебба, які математично моделюють синаптичні передачі в мозку. Однак справжній початок нейронних мереж і навчання на їхній основі належить винаходу Розенблатта - першої простої нейроноподібної мережі навчання, відомої як персептрон. Сучасний багатошаровий персептрон залишається найпопулярнішою та найпоширенішою структурою нейронних мереж сьогодні, завдяки своїм відмінним та перевіреним можливостям апроксимації.

Ця робота спрямована на узагальнення досвіду досліджень і основних результатів у сфері ідентифікації систем на основі моделей нейронних мереж.

Особлива увага приділяється ідентифікації нелінійних систем за допомогою моделей, зокрема структури ANARX.

Робота також зосереджена на вивченні ідентифікації ANARX-моделей для нелінійних систем, враховуючи їхні переваги перед класичними моделями NARX. ANARX є підкласом NARX з відокремленими екземплярами часу, що забезпечує лінеаризованість за допомогою динамічного вихідного зворотного зв'язку та репрезентативність в просторі станів.

У роботі також висвітлено здатність нейронних мереж моделювати складну поведінку нелінійних систем та відтворювати будь-яку їхню структуру. Штучна нейронна мережа розглядається як інструмент ідентифікації нелінійних систем для управління на основі моделі. Результати дослідження вказують на те, що штучні нейронні мережі можуть ефективно апроксимувати та ідентифікувати складні системи, що робить їх потужним інструментом для проектування систем керування.

1 АНАЛІЗ ОБЛАСТІ ДОСЛІДЖЕННЯ

1.1 Огляд предметної області

Нейронні мережі, відомі як штучні нейронні мережі (ANN) є частиною машинного навчання та лежать в основі алгоритмів глибокого навчання. Ці мережі імітують людський мозок, моделюючи взаємодію біологічних нейронів.

Нейронні мережі, або штучні нейронні мережі (ANN) являють собою важливий компонент машинного навчання та глибокого навчання, які наслідують взаємодію біологічних нейронів у людському мозку. Ці складні структури використовують шари вузлів, включаючи вхідний, прихований і вихідний, де кожен нейрон з'єднаний із іншим, має вагу та поріг. Важливо зазначити, що нейронні мережі виявляють високу ефективність в інформатиці та обробці природної мови.

Для моделювання тягового пристрою з використанням нейронної мережі, кількість вхідних нейронів повинна відповідати загальній кількості входів у моделюванні. Проте, практично важко досягти цього, і можна скористатися значно меншою кількістю вхідних нейронів, враховуючи ваги, що представляють значення входів і виходів з попередніх кроків часу. Це дозволяє ігнорувати тривалі сигнали, які майже не впливають на поточний вихід.

Ідентифікація за допомогою нейронної мережі програмно реалізовується шляхом створення об'єкта нейронної мережі з унікальним вихідним нейроном, визначеною кількістю прихованих шарів, кількістю нейронів у кожному

прихованому шарі та функціями активації вихідних і прихованих нейронів, які встановлюються користувачем. Кількість вхідних нейронів визначається на основі файлу даних та кількості вхідних і вихідних затримок сигналу.

Нейромережевий підхід до моделювання використання цієї технології в різних областях, включаючи автоматизовані системи та промислові застосування. Як у тягового пристрою.

Штучні нейронні мережі мають шари вузлів, включаючи вхідний, прихований і вихідний. Кожен штучний нейрон з'єднаний з іншим та має вагу та поріг. Якщо вихід вузла перевищує поріг, він активується та передає дані на наступний рівень.

Нейронні мережі використовуються для навчання та поліпшення своєї точності за допомогою навчальних даних. Вони ефективні в інформатиці, обробці даних.

Переваги використання нейромережі включають ігнорування сторонньої інформації: Нейромережі здатні ігнорувати зайву інформацію. Нейромережі можуть самостійно адаптуватися до нових умов та змінюваних вхідних даних, що робить їх гнучкими та придатними для різноманітних завдань без необхідності повторного програмування.

Стійкість до втрат елементів: Мережі залишаються працездатними при втраті окремих елементів. Висока швидкість роботи: Завдяки тисячам мікропроцесорів, що взаємодіють, завдання вирішуються швидше.

Однак не можна повністю покладатися на нейромережі. Їх слід використовувати як доповнення до інших методів через ймовірність

недостовірних результатів. Кожен нейрон діє незалежно, і немає гарантії абсолютної правдивості результатів.

1.2 Актуальність та використання

За використанням штучних нейронних мереж стоїть великий потенціал у тих галузях, де традиційні методи обчислень непридатні або виявляються неефективними для відтворення реальних фізичних процесів. Суттєвий ріст актуальності нейронних мереж відзначається, коли порушується завдання з поганою формалізацією.

Основні напрямки використання включають автоматизацію класифікації, прогнозування, розпізнавання та процесу прийняття рішень, а також управління інформацією та апроксимацію залежностей. В галузі телекомунікацій, нейронні мережі успішно використовуються для оптимізації мереж зв'язку та ефективного управління маршрутизацією трафіку.

У сфері управління цінами та виробництвом, де велика втрата від неоптимального планування виробництва, нейромережі доводяться ефективними у виборі оптимальних стратегій для максимізації обсягу продажів чи прибутку. В маркетинговому аналізі, коли традиційні методи прогнозування можуть бути непереконливими, використання прогнозуючих нейромереж дозволяє виявити складні залежності та оптимізувати стратегії реклами, а також визначати перспективні сегменти споживачів.

2 ШТУЧНІ НЕЙРОННІ МЕРЕЖІ

2.1 Модель нейронну та структура

Працездатні мережі з багатьма шарами були винайдені Івахненком та Лапою визначили метод групового урахування аргументів. Після досліджень Мінського та Пейперта, які виявили дві ключові проблеми нейронних мереж, а саме нездатність обробки схем виключного або базовими перцептронами та нестача обчислювальної потужності комп'ютерів для ефективної роботи з великими нейронними мережами, дослідження у цій галузі сповільнилося до моменту, коли комп'ютери досягли великої обчислювальної потужності.

Штучні нейронні мережі (ANN) представляють собою обчислювальні системи, інспіровані біологічними нейронними мережами мозку тварин. Вони навчаються розв'язувати задачі, поліпшуючи свою продуктивність, аналізуючи приклади без спеціального програмування для конкретної задачі, наприклад, розпізнавання зображень.

Нейрон входу служить інтерфейсом входу для всієї мережі, а нейрон виходу - інтерфейсом виходу. З'єднання передають вихід одного нейрона до входу іншого, визначаючи взаємозв'язок попередника та наступника. Функція поширення обчислює вхід до нейрону з виходів його попередників, використовуючи ваги та часову залежність.

Правило навчання - це алгоритм, що змінює параметри мережі, забезпечуючи вихід, придатний для заданого входу. Моделі ANN можуть розглядатися як математичні моделі, які визначають функцію або розподіл.

Фраза "модель ANN " визначає клас таких функцій, які можуть бути змінені параметрами, вагами з'єднань та архітектурними особливостями.

З математичної точки зору, функцію нейромережі можна представити як композицію функцій залежності між змінними. Це може бути виглядно представлено мережевою структурою, де стрілки відображають залежності між функціями. Існують два способи інтерпретації цієї структури: функційний та ймовірнісний, які можуть існувати паралельно для даної архітектури.




Рисунок 2.1 — Модель штучного нейронну

Базуючись на з'єднаних вузлах, які називаються штучними нейронами, подібно біологічним нейронам. Вони взаємодіють між собою, оброблюючи сигнали, що передаються від одного до іншого. Ваги на з'єднаннях між нейронами адаптуються під час навчання, регулюючи силу сигналу. Штучні нейрони можуть мати пороги, які активуються тільки при перетині сумарного

сигналу з порогом. Зазвичай вони організовані в шари, кожен з яких може виконувати різні перетворення вхідних сигналів.

З рисунка видно, що штучний нейрон складається з двох основних частин. Перша частина - це зважена сума вхідних даних, а друга частина - нелінійний елемент, відомий як функція активації. Вибір конкретної функції активації, такої як $\phi(\cdot)$, сильно залежить від застосування, стратегії навчання та алгоритму.

Розглянемо математичне визначення штучного нейрона з n входами, як це представлено на рисунку. Такий нейрон можна описати рівнянням, де X - вектор вхідних даних, а W - вектор синаптичних ваг.

Лінійний нейрон без функції активації, представлений рівнянням. Ще один параметр θ , називаний зміщенням або порогом, може додатково вводитися в деяких реалізаціях, але це додатковий параметр, який потрібно налаштовувати під час навчання. Серед найпоширеніших функцій активації є сигмоїдальні функції, такі як логістична та гіперболічний тангенс. Ці функції відрізняються гладкістю та диференційованістю.

Важливою властивістю цих функцій є їх легка обчислюваність та диференційованість, що важливо для програм управління. Ці функції використовуються для моделювання штучних нейронів в нейромережевих системах.

Порівняно з більш складними мережами мозку людини, штучні нейромережі значно менше. Найбільші з них в системах управління мають лише кілька сотень нейронів. Мережі організовані в послідовність шарів, де кожен нейрон з одного шару з'єднаний з кожним нейроном наступного шару.

2.2 Алгоритми навчання

Штучні нейронні мережі можна визначити як системи обробки даних, що складаються з великої кількості простих, взаємопов'язаних елементів обробки (нейронів). Ці елементи зазвичай організовані в шари.

Штучні нейронні мережі взаємодіють як велика мережа вузлів, що нагадує структуру біологічних нейронних мереж. Математична модель нейронних мереж була розроблена в 1943 році Ворреном Маккалохом і Волтером Піттсом, визначивши порогову логіку. Це дало початок досліджень нейронних мереж, які поділилися на два підходи: вивчення біологічних процесів у мозку та застосування нейронних мереж до штучного інтелекту.

Функція витрат грає ключову роль у навчанні, оскільки вона вимірює відстань між певним розв'язком та оптимальним вирішенням задачі.

Алгоритми навчання вибирають розв'язки, спробуючи знайти функцію з найменшими можливими витратами.

В випадках, коли розв'язок залежить від даних, витрати обов'язково виражаються як функція від спостережень, щоб модель мала зв'язок із вхідними даними. Зазвичай ці витрати оцінюють як статистику, що може бути апроксимована.

У нейромережевих методах інтерактивного навчання, де витрати зменшуються з кожним побаченим зразком, є корисним. Навіть якщо можливо визначити функцію витрат, часто використовують конкретні витрати, орієнтовані на бажані властивості або впливаючі з формулювання задачі. Функція витрат завжди тісно пов'язана із характером задачі. Існує три основні парадигми навчання, спрямовані на різні типи навчальних задач: кероване

навчання, спонтанне навчання та навчання з підкріпленням. Кожна з них визначає підхід до тренування моделі.

Кероване навчання використовує набір прикладів у вигляді пар (x, y) і спрямоване на пошук функції в дозволеному класі функцій, яка відповідає цим прикладам. Зазвичай використовується функція витрат, така як середньоквадратична похибка, для зведення до мінімуму різниці між виходом мережі та цільовим значенням. Спонтанне навчання включає дані x та функцію витрат, і його метою є зведення цієї витрати до мінімуму. Форма функції витрат залежить від конкретної задачі та апріорних припущень про модель.

Навчання з підкріпленням відрізняється тим, що дані x породжуються взаємодією агента з середовищем. Метою є визначення стратегії вибору дій, яка мінімізує довготривалі витрати. Використовуються методи марковських процесів вирішення та стратегій, що приводять до мінімуму витрати.

У великій мірі нейронні мережі використовуються в усіх трьох парадигмах, особливо в навчанні з підкріпленням. Вони допомагають зм'якшувати втрати точності навіть при невеликій щільності ґратки дискретизації для чисельного наближення розв'язків задач керування. Загалом, кожне навчання визначає підхід до вирішення конкретних класів задач, таких як розпізнавання образів, кластерування чи управління.

Нейрони вихідного шару можуть ефективно апроксимувати безперервно диференційовані динамічні функції, при умові, що кількість нейронів у повторюваному шарі перевищує порядок ідентифікованої мережі.

Апроксимація функції за допомогою нейронної мережі (статичної або динамічної) включає коригування параметрів, таких як синаптичні ваги і зміщення, через процес, відомий як мережеве навчання. Існують

контрольовані і неконтрольовані алгоритми навчання. У контрольованому навчанні використовується набір еталонних карт для навчання мережі, що визначається як "вчитель". В цьому випадку обговорюється лише контрольований підхід, оскільки він більше зацікавлений у задачах моделювання та контролю.

Ранні ідеї щодо навчання в нейронних мережах включають працю Хебба , але справжній початок значущого мережевого навчання пов'язують із роботою Розенблата у 1962 році. Кероване навчання, що розглядається тут, потребує "вчителя" або іншого джерела інформації, яке вказує мережі правильні відповіді на кожен стимул.

Навчання у нейронних мережах є процесом адаптації ваг зв'язків для отримання бажаного вихідного вектора у відповідь на стимул вхідного буфера. Цей процес ґрунтується на вхідно-вихідних даних, представлених у вигляді $ZN = \{[u(t), y(t)], t = 1, \dots, N\}$, де N - розмір навчальної множини.

2.3 Зворотне поширення

Ключовим активатором відновлення зацікавленості нейронними мережами та навчанням був алгоритм зворотного поширення Вербоса , який ефективно розв'язував проблему виключного «або», і загалом прискорив навчання багат шарових мереж. Зворотне поширення розповсюджувало член похибки шарами в зворотному напрямку, змінюючи ваги в кожному вузлі.

Метод опорних векторів та інші простіші методи, наприклад, лінійні класифікатори, поступово витіснили нейронні мережі в популярності в області машинного навчання. Успішне розв'язання попередніх викликів у тренуванні

глибоких нейронних мереж стало можливим завдяки методам, таким як спонтанне попереднє тренування та зростанню обчислювальної потужності за допомогою графічних процесорів та розподілених обчислень.

Розгортання нейронних мереж на велику шкалу, зокрема в задачах розпізнавання зображень та відео, визначається терміном "глибинне навчання", хоча це поняття не є абсолютним синонімом для глибоких нейронних мереж.

Максимізаційне агрегування, вирішило проблеми інваріантності та терпимості до деформацій у розпізнаванні тривимірних об'єктів. Однак проблема зникання градієнту впливає на багат шарові мережі прямого поширення та рекурентні нейронні мережі.

Щоб подолати ці труднощі, Шмідгубер вибрав підхід з використанням багат шарової ієрархії мереж, що попередньо тренується шар за шаром через спонтанне навчання, а потім тонко налаштовується зворотнім поширенням. Дослідження глибинного навчання зосереджувалося на різних методах, таких як навчання високорівневих представлень та використання мереж із зв'язаними шарами.

Глибокі нейронні мережі досягли успіху в різних міжнародних змаганнях з розпізнавання образів та машинного навчання, вигравши вісім конкурсів. При цьому важливим стало поєднання глибокого навчання зі згортковими та максимізаційними шарами, як із наступними пов'язаними шарами для класифікації.

Нейронні архітектури, такі як неокогнітрон та "стандартна архітектура бачення", вдосконалені Хінтоном, виграла змагання в розробці програм для пошуку нових ліків. Важливим кроком було поєднання глибокого навчання з конволюційними та максимізаційними. Ці підходи, керовані глибоким навчанням, стали ефективними в порівнянні з людською продуктивністю в

певних задачах. Штучні нейронні мережі вдало розв'язали проблеми інваріантності та класифікації об'єктів у великих сценах.

Мережі прямого поширення, як вже зазначалося, відзначаються тим, що їх граф є спрямованим ациклічним графом, тоді як мережі з циклами отримали назву рекурентними. Заслужуючи особливого інтересу, нейронні мережі спрямовані на можливість навчання. Навчання включає в себе використання набору спостережень для знаходження функції, яка оптимальним чином вирішує конкретну задачу. Задачею навчання є визначення функції витрат, яка визначає, наскільки далеко розв'язок знаходиться від оптимального в розумінні математичної оптимізації.

Моделювання та Алгоритми Навчання. В контрольованого та неконтрольованого навчання, основною метою є мінімізація функції вартості $F(\Theta, ZN)$, де Θ - вектор параметрів мережі (синаптичні ваги та, можливо, деякі зміщення). Середньоквадратична помилка часто використовується як критерій мінімізації:

$$F(\Theta, ZN) = N \sum_t [y(t) - \hat{y}(t)]^2 \quad (2.1)$$

де $F(\Theta, ZN)$ є вихідним значенням, яке мережа (оцінений вихід) має наблизити до $y(t)$, яке виступає в якості еталону або "вчителя". Метою навчання є здійснення процедур, під час яких значення $F(\Theta, ZN)$ прямують до нуля:

$$F(\Theta, ZN) \rightarrow 0 \quad (2.2)$$

Зворотне Поширення Помилки Градієнтного Спуску

Алгоритм зворотнього поширення помилки градієнтного спуску (BP) є методом першого порядку, де градієнт визначається як:

$$G(\Theta) = \partial_{\Theta} \partial F(\Theta, ZN) \quad (2.3)$$

де $G(\Theta)$ - градієнт, після застосування алгоритму BP, вектор параметрів мережі оновлюється за правилом.

$$\Theta(k + 1) = \Theta(k) - \lambda(k) \cdot G(\Theta) \quad (2.4)$$

де $\lambda(k)$ - адаптивний коефіцієнт, також відомий як швидкість навчання.

Кожна ітерація цього навчального алгоритму також називається епохою навчання.

2.4 Рекурентні нейронні мережі

Рекурентні нейронні мережі відрізняються тим, що вони включають внутрішні зворотні зв'язки від виходів нейронів до входів того ж шару, що і попередній. Зазвичай ці мережі не потребують додаткових зовнішніх

зворотних зв'язків для моделювання динамічних процесів, і кількість мережевих входів відповідає кількості входів процесу.

Прикладом рекурентних мереж є мережа Елмана, яка має внутрішні зворотні зв'язки від виходу першого рівня до входу того самого рівня. Це періодичне з'єднання дозволяє мережам Елмана ефективно виявляти та генерувати змінювані у часі шаблони.

Мережа Елмана може бути описана як двошарова мережа із зворотнім зв'язком. У такій мережі рекурентний (повторюваний) шар містить один прихований шар. Функція мережі з одним входом і одним виходом представлена рівнянням , яке вказує на динамічні властивості мережі. Рекурентна мережа Елмана здатна зберігати вихідні значення прихованого шару в пам'яті на один такт і впливати на вихід мережі та вектор стану наступного кроку часу.




Рисунок 2.2 – Рекурентна мережа Елмана

Параметри мережі Елмана включають матриці синаптичних ваг між різними шарами, вектори зміщень та функції активації нейронів. Мережа здатна апроксимувати будь-які безперервно диференційовані динамічні функції. Теорема, стверджує, що мережа Елмана із сигмоїдними функціями рекурентного шару та лінійними нейронами вихідного шару може ефективно апроксимувати динамічні системи.

2.5 Робастність в системах керування та ідентифікації

Робастність системи вказує на її здатність забезпечувати стабільність та високу продуктивність при змінних умовах експлуатації, випадкових впливах та похибках в моделі.

Системи керування робастні, коли вони можуть ефективно функціонувати навіть у випадку змін параметрів системи, втрати точності моделі або появи внутрішніх та зовнішніх пертурбацій. Протистояння завадам вказує на здатність системи компенсувати негативний вплив внутрішніх або зовнішніх завад на її вихід. Системи зі зворотнім зв'язком: Багато систем керування використовують зворотний зв'язок для виявлення та компенсації завад. Завдяки цьому, система може динамічно реагувати на зміни та втручання, що забезпечує високу якість керування та стійкість. Системи адаптивного керування можуть автоматично змінювати свій внутрішній стан або параметри для адаптації до змін у середовищі або динаміці системи. Техніки ідентифікації моделей дозволяють системі самостійно визначати свої параметри або модель для коректного функціонування навіть при невідомих чи змінюючихся умовах.

Використання фільтрів та алгоритмів компенсації дозволяє зменшити чи вилучити вплив шумів та помилок, що може бути важливим у вимірювальних системах.

Забезпечення робастності та протистояння завадам є важливими завданнями в проектуванні та управлінні системами, особливо в умовах змінних чи невизначених умов експлуатації.

Система регулювання температури в приміщенні використовує датчики для вимірювання поточної температури. Зворотній зв'язок отримує інформацію про відхилення фактичної температури від заданої. Контролер вирішує, чи потрібно включати опалення або кондиціонер для підтримки бажаної температури. Система зі зворотнім зв'язком забезпечує постійне коригування роботи обладнання, щоб утримувати температуру на заданому рівні, навіть при змінних умовах навколишнього середовища.

Сучасні літаки використовують автопілот для автоматичного управління курсом, висотою та іншими параметрами польоту. Автопілот отримує інформацію з різних датчиків та систем, а зворотній зв'язок використовується для корекції шляху літака в реальному часі. Завдяки зворотньому зв'язку автопілот може автоматично адаптуватись.

Протистояння завадам у контексті нейромереж та ідентифікації об'єктів означає здатність системи ефективно компенсувати негативний вплив вхідних аномалій або змін у середовищі на точність ідентифікації.

Нейромережі зі здатністю протистояти завадам можуть адаптуватися до змін в реальному часі, враховуючи змінюючіся умови навколишнього середовища та непередбачені фактори.

Ідентифікація об'єктів: В контексті нейромереж і ідентифікації об'єктів, це включає в себе здатність системи розпізнавати та класифікувати об'єкти на основі вхідних даних.

Робастність в Ідентифікації Об'єктів: Робастність ідентифікації об'єктів вимагає, щоб система нейромережі залишалася точною та надійною навіть у випадку обмеженої чи неповної інформації про об'єкти, а також у випадку змін в їх зовнішніх параметрах.

Розширення мережі додатковими шарами або нейронами може підвищити робастність та ефективність ідентифікації шляхом вивчення більш складних залежностей.

Використання адаптивних алгоритмів навчання, які дозволяють нейромережі адаптуватися до нових умов та швидко виявляти зміни в об'єктах.

Використання механізмів зворотного зв'язку для постійного коригування параметрів нейромережі, щоб підтримувати точність ідентифікації в реальному часі.

Забезпечення робастності та протистояння завадам у нейромережах стає важливим завданням для ефективною ідентифікації об'єктів у різних умовах та середовищах.

3 НЕЛІНІЙНІ ОБ'ЄКТИ ТА НЕЙРОМЕРЕЖЕВА ІДЕНТИФІКАЦІЯ

3.1 Нейромережева ідентифікація

Управління реальними об'єктами вимагає високоякісних математичних моделей, що повно відображають їх властивості та дозволяють зручно реалізувати алгоритми керування. Однак у багатьох випадках відсутність повної інформації вимагає використання адаптивного підходу, що дозволяє використовувати спрощені лінійні моделі.

Спроби обмежитися лінійними моделями часто не дозволяють отримати потрібний результат управління, особливо при наявності нелінійних залежностей та неконтрольованих факторів. Ефективнішим виходом є поєднання адаптивного підходу з методами теорії штучних нейронних мереж (ANN).

Більшість реальних систем мають нелінійні залежності та складну динаміку, що робить традиційні стратегії управління обмеженими. Широке застосування отримують нейромережі, які виявляються адаптивними, стійкими, та нелійними.

Альтернатива традиційним методам – нейромережевий підхід. Використання повністю визначених ANN для генерації сигналів управління дозволяє подолати труднощі при роботі з нелійними об'єктами та об'єктами невідомої структури.

Основні переваги включають адаптивність, можливість навчання, та високу швидкодію, роблячи їх вигідними для управління складними нелійними об'єктами в реальному часі.

Задача ідентифікації нелінійних об'єктів має багато підходів та методів на сучасному етапі. Зросли вимоги до точності характеристик алгоритмів ідентифікації, що призводить до модифікації класичних підходів та використання універсальних пошукових методів.

Серед таких методів варто відзначити генетичні алгоритми багатопараметричного пошуку, що адекватно описують значення параметрів системи, і різні методи самоорганізації та нейронні мережі. Важливим аспектом є модифікація класичного методу Вольтерра з метою підвищення точності та зменшення обмежень застосування.

3.2 Нелінійні математичні моделі

При проектуванні систем керування для різних динамічних об'єктів потрібна нелінійна математична модель. Такі моделі використовуються для прогнозування стану об'єкта та параметрів середовища. Деякі методи ідентифікації нелінійних систем, що застосовуються на практиці, включають алгоритм ідентифікації на основі розкладання функціоналів Вінера.

Проблемою використання цього методу є необхідність подавати ідеальний білий шум на вхід досліджуваної системи, що на практиці є важкоздійсненним. Для нелінійних систем важко визначити оптимальний частотний діапазон тестуючого сигналу, який гарантує білий шум.

Генетичні алгоритми, які використовують популяцію оцінок потенційних рішень, мають обмеження щодо масштабування, особливо при великих областях пошуку рішень. Нейронні мережі, хоча дозволяють побудову моделей з високою точністю, вимагають тривалого часу навчання.

У роботі з нелінійними системами важливо враховувати альтернативні пошукові алгоритми, такі як алгоритм диференційованого підходу для вибору оптимального частотного діапазону тестуючого сигналу. Однак такі підходи можуть бути складні у реалізації на динамічних об'єктах.

Узагальнюючи, важливо розглядати інноваційні методи ідентифікації для нелінійних систем, забезпечуючи високу точність та ефективність в різних умовах застосування.

У сфері розв'язання задачі ідентифікації нелінійних об'єктів існує ряд різноманітних підходів і методів. В сучасному контексті вимоги до точності алгоритмів ідентифікації значно зросли, що призвело до модифікації традиційних підходів. Ця модифікація спрямована на поліпшення точності та зменшення обмежень застосування класичних методів, а також на використання універсальних пошукових методів, таких як генетичні алгоритми, нейронні мережі та методи самоорганізації.

Одним з популярних методів ідентифікації є алгоритм, заснований на розкладанні функціоналів Вінера. Однак для використання цього методу необхідно подавати ідеальний білий шум на вхід досліджуваної системи, що може бути складно в реалізації. Для нелінійних систем вибір оптимального частотного діапазону тестуючого сигналу стає проблемою, оскільки характеристика лінійних систем тут не є інформативною.

У сучасних дослідницьких роботах велика увага приділяється пошуковим алгоритмам, зокрема генетичним алгоритмам, які оптимізують параметри системи, але мають обмежену масштабованість при складних задачах. Нейронні мережі, хоча точні, але вимагають тривалого часу для навчання.

Сучасні тенденції включають в себе використання алгоритмів самоорганізації, які реалізують механізми спрямованого самовідбору. Однак

обмеженість цих підходів полягає в тому, що для кожного застосування обирається топологія, алгоритми та коефіцієнти, що можуть бути непридатними для інших задач.

Аналізуючи різноманітні підходи, слід відзначити, що фільтр Вольтерра, зокрема другого порядку, виглядає привабливим для ідентифікації нелінійних систем. Однак використання його в практиці зустрічає значні труднощі через складність реалізації. Оптимізація цього підходу може зробити його більш доступним і ефективним для вирішення складних завдань ідентифікації.

4 МОДЕЛІ ТА МЕТОДИ ІДЕНТИФІКАЦІЇ НЕЛІНІЙНИХ СИСТЕМ

4.1 Динамічні системи ідентифікації

Наведені різноманітні методи ідентифікації нелінійних систем, які використовують параметризовану модель. Оновлення параметрів здійснюється з метою мінімізації ідентифікаційної помилки виходу. Широкий спектр нелінійних динамічних систем з входом і виходом може бути охарактеризований моделями, такими як:

$$Y_m(k) = f_m(\phi(k), \theta), \text{ де } y_m(k) \quad (4.1)$$

Де, результат моделі, $\phi(k)$ - вектор регресії, а θ - вектор параметрів. Залежно від вибору регресорів у $\phi(k)$ виходять різноманітні моделі.

Модель NFIR - нелінійна кінцева імпульсна характеристика:

$$\phi(k) = (u(k-1), u(k-2), \dots, u(k-n_u)) \quad (4.2)$$

де n_u - максимальна затримка вхідних даних.

Модель NARX - нелінійна авторегресія з екзогенними входами:

$$\phi(k) = (u(k-1), u(k-2), \dots, u(k-n_u), y(k-1), y(k-2), \dots, y(k-n_y)) \quad (4.3)$$

де n_y - максимальна затримка виходу.

Модель NARMAX нелінійне авторегресивне ковзне середнє з екзогенними входами, де $\phi(k)$ враховує вхідні та вихідні дані, а також помилки передбачення.

Модель NOE - нелінійна помилка виводу:

$$\phi(k) = (u(k-1), u(k-2), \dots, u(k-n_u), y_m(k-1), y_m(k-2), \dots, y_m(k-n_y)) \quad (4.4)$$

де $\phi(k)$ враховує вхідні та вихідні дані.

NBJ Nonlinear Box-Jenkins модель, яка використовує всі чотири типи регресорів.

Важливими представленнями нелінійних систем є NARX і NOE. Блок-схема моделі DRN, що відповідає моделі NOE, показана на рисунку 1.




Рисунок 4.1 - Блок-схема моделі нейронної мережі

У прикладі DRN вихід мережі виступає як зворотній зв'язок з входом. Вихід мережі функціонує не лише як вагові коефіцієнти, зміщення і вхідні дані мережі, але також як виходи мережі з попередніх моментів часу. Для адаптації ваг використовується алгоритм динамічного зворотного поширення та упередження. Вихід мережі:

$$y_m(k) = \sum_{i=1}^n \omega_i v_i + b \quad (4.5)$$

Де:

$Y_m(k)$ - вихід для моменту часу k ,

ω_i - ваговий коефіцієнт для входу v_i ,

b - зміщення,

$\sum_{i=1}^n$ - сумування за всіма n входами.

Мережа DRN складається з нелінійного прихованого шару та лінійного вихідного рівня. Вхідні дані $u(k-1), u(k-2), \dots, u(k-n_u)$ множаться на ваги ω_{uij} . Виходи $y_m(k-1), y_m(k-2), \dots, y_m(k-n_y)$ множаться на ваги $\omega_{\gamma ij}$ і сумуються в кожному прихованому вузлі. Після цього активується сумарний сигнал за допомогою нелінійної функції. Функцією активації прихованих нейронів є гіперболічна дотична сигмоїда.

$$v_i = (e^{n^i} - e^{-n^i}) / (e^{n^i} + e^{-n^i}) \quad (4.6)$$

$$n_i = \sum(u(k-j)\omega_{uij}) + \sum(y_m(k-j)\omega_{\gamma ij}) + b_i \quad (4.7)$$

де n_i активація нейрону з індексом i b_i цу відсув (зсув, bias) для нейрону з індексом i .

Ця помилка використовується для коригування ваг та зсувів у мережі з метою мінімізації функціоналу.

З використанням градієнта можна визначити правила оновлення ваг та зсувів:

$$\omega_{uij}(k + 1) = \omega_{uij}(k) - \eta * \partial\varepsilon / \partial\omega_{uij} \quad (4.8)$$

$$\omega_{\gamma ij}(k + 1) = \omega_{\gamma ij}(k) - \eta * \partial\varepsilon / \partial\omega_{\gamma ij}$$

$$b_i(k + 1) = b_i(k) - \eta * \partial\varepsilon / \partial b_i$$

де $\omega_{uij}(k)$ - попереднє значення ваги між входом та нейроном перед оновленням.

Зазначені терміни повинні бути розповсюджені в часі, враховуючи їхні непрямі ефекти.

$$b(k + 1) = b(k) - \eta * \partial\varepsilon / \partial b \quad (4.9)$$

$$\partial\varepsilon / \partial\omega_{uij} = \partial\varepsilon / \partial y_m * \partial y_m / \partial\omega_{uij};$$

$$\partial\varepsilon / \partial\omega_{\gamma ij} = \partial\varepsilon / \partial y_m * \partial y_m / \partial\omega_{\gamma ij};$$

$$\partial\varepsilon / \partial b_i = \partial\varepsilon / \partial y_m * \partial y_m / \partial b_i;$$

$$\partial\varepsilon / \partial b = \partial\varepsilon / \partial y_m * \partial y_m / \partial b;$$

де ω_{uij} - градієнт по вазі (вага вхідного сигналу для нейрона i в момент j).

Отже, оновлення ваг та зсувів здійснюється з використанням градієнтного спуску з метою навчання нейронної мережі адаптуватися до нелінійної динаміки системи та забезпечити більш точну ідентифікацію.

4.2 Моделі нелінійних систем MIMO

Дуже зручним інструментом для ідентифікації систем Multiply Input – Multiply Output (MIMO) є штучні нейронні мережі. У цьому розділі обговорюються обидві моделі нелінійних систем MIMO, засновані на нейронних мережах NARX і ANARX.

Відомо, що широкий клас нелінійних систем MIMO може бути представлений нелінійною дискретною моделлю в описі введення-виведення, як модель NARX. Це може бути як послідовно-паралельна модель, так і модель із кроком вперед. Модель MIMO NARX визначається як:

$$Y(t) = f(Y(t-1), \dots, Y(t-n_y), U(t-1), \dots, U(t-n_u)) \quad 4.10$$

де $U(t)=[u_1(t), \dots, u_r(t)]$ — вектор системних входів, $Y(t)=[y_1(t), \dots, y_m(t)]$ — вектор вихідних даних системи, r — кількість входів, m - кількість виходів, n_u і n_y — порядок введення та виведення, а f — нелінійна функція з n_u+n_y аргументами.

Для отримання моделі можна використовувати двошаровий перцептрон, який апроксимує нелінійну функцію. Моделі, засновані на цій структурі, називаються моделями NARX на основі нейронних мереж, або моделями NN-NARX.

Модель MIMO NARX, яка отримана шляхом навчання двошарового перцептронну, має параметри у вигляді двох матриць синаптичних ваг вхідна матриця кількість нейронів у прихованому шарі, і вихідна матриця.




Рисунок 4.2 – Модель MIMO NARX на основі нейронної мережі

Коли мережа навчена, значення вектору виведення $Y(t)$ можна розрахувати за допомогою рівняння:

$$Y(t) = C \cdot f(W \cdot [Y(t-1), \dots, Y(t-n_y), U(t-1), \dots, U(t-n_u)]^T) \quad 4.11$$

Проте, кількість параметрів для розрахунку під час навчання може стати обмежувачим фактором, особливо при збільшенні кількості виходів або входів та порядку моделі. У таких випадках навчальні алгоритми можуть сходитися повільно або навіть не збігатися. Експерименти показують, що в деяких

випадках навчальні алгоритми можуть не сходитися через велику кількість регульованих параметрів (синаптичних ваг). Наприклад, при використанні двошарового персептрону для моделювання системи МІМО третього порядку з 2 входами і 2 виходами, потрібно розрахувати 126 синаптичних ваг, що може бути часово витратно. Для подолання цих обмежень була запропонована модель МІМО NN-ANARX.

4.5 Моделі ANARX МІМО

Модель ANARX відноситься до підкласу моделей NARX і має особливість у відокремленні всіх екземплярів часу. Для систем МІМО модель ANARX можна визначити як:

$$Y(t) = \sum_{i=1}^n f_i (Y(t - i), U(t - i)), \quad (4.12)$$

де n - порядок моделі, а $f_1(\cdot), \dots, f_n(\cdot)$ — нелінійні функції.

Модель ANARX на основі нейронних мереж для систем МІМО визначається як:

$$Y(t) = \sum_{i=1}^n C_i f_i (W_i \cdot [Y(t - i), U(t - i)]^T) \quad (4.13)$$

де $f_1(\cdot), \dots, f_n(\cdot), \dots, f_n(\cdot)$, W_1, \dots, W_n , C_1, \dots, C_n — нелінійні функції активації та матриці синаптичних ваг підшарів мережі. [4]




Рисунок 4.3 – Структура Архітектура нейронної мережі, яка відображає модель ANARX.

Переваги використання ANARX для систем MIMO. Зокрема, у випадку MIMO NN-ANARX з 9 нейронами у прихованому шарі для системи третього порядку (з 2 входами і 2 виходами), потрібно розрахувати лише 54 синаптичні ваги, що у 2 рази менше. Експерименти підтверджують, що обмеження в структурі мережі не впливають на якість ідентифікації. Навіть більше, це поліпшує ефективність, оскільки кількість параметрів стає меншою, сприяючи швидкості навчання та розширенню вибору алгоритмів.

Для покращення точності моделі при ідентифікації складних багатовимірних процесів, можна використовувати набір одноканальних моделей MISO або декілька MIMO систем, де виходи поділяються між окремими моделями.

4.3 Імітаційна модель

Розглянуто задачу побудови моделі реального часу для нелінійного динамічного об'єкта, параметри якого в загальному випадку можна розглядати як змінні в часі. Для контролю необхідно створити адекватну модель цього об'єкта, а критерієм якості ідентифікації є середні втрати. Алгоритм ідентифікації змінює параметри моделі на основі спостережень вхідних та вихідних даних об'єкта, допомагаючи досягти мінімальних середніх втрат.

Для вивчення цієї задачі доступним стає імітаційний метод аналізу. Імітаційна модель відтворює поведінку системи в часі, зберігає внутрішній зв'язок між елементами системи та відображає залежність виходів системи від входів.

Імітаційний експеримент включає в себе налаштування параметрів чи управління моделі, знаходження траєкторії, що відповідає заданим умовам, та оцінку показників ефективності. Цей підхід дозволяє отримати уявлення про можливості досліджуваного об'єкта та обрати найбільш відповідний контроль.

Ідентифікація моделі, процес визначення зовнішніх параметрів, є важливою частиною моделювання. Ідентифікація пов'язана із встановленням адекватності моделі до реальних процесів. Процес імітаційного моделювання включає складання моделі, розробку процедур розрахунку параметрів та перевірку її функціонування.

Практичне застосування імітаційної моделі полягає у спостереженні результатів розрахунків для різних значень параметрів досліджуваного процесу, що дозволяє зробити висновки щодо поведінки системи.

4.4. Паралельна модель та нелінійна авторегресійна модель

Нелінійну авторегресійну модель із зовнішнім входом, часто використовувану для опису електричних машин у системах керування, можна представити у вигляді:

$$u(k), \dots, u(k - q), y(k - 1), \dots, y(k - p) \quad (4.15)$$

- де $f(\cdot)$ - задана функція, $u(k)$ - вхід, $y(k)$ - вихід.

Паралельна модель:

$$Y_m(k) = f(u(k), \dots, u(k - q), y_m(k - 1), \dots, y_m(k - p)) \quad (4.16)$$

де y_m у часі k залежить від ряду вхідних сигналів u та попередніх значень вихідного сигналу.

Серійно-паралельна модель :

$$Y_m(k) = f(u(k), \dots, u(k - q), y_m(k - 1), \dots, y_m(k - p), y_0(k), \dots, y_0(k - p)) \quad (4.17)$$

Тут $y_m(k)$ - це вихід моделі, $u(k)$ - вхідні сигнали, а $y_0(k)$ - вихідні сигнали моделі на кроці k .

Під час ідентифікації нелінійних об'єктів, модель можна використовувати двома способами визначають вивід моделі та об'єкта на кроці

к. Модель, представлена, називається паралельною, а модель, представлена - послідовно-паралельною. Паралельну модель можна використовувати, якщо вихідні сигнали об'єкта недоступні, але налаштування її є складнішим порівняно з послідовно-паралельною моделлю. Проте, якщо деякі вихідні сигнали об'єкта доступні, їх можна використовувати для налаштування паралельної моделі.

Алгоритм ідентифікації визначається функцією втрат і структурою спеціальної моделі. Під час ідентифікації параметрів, змінюючи їх на основі спостережень за входом та виходом об'єкта та конфігурованої моделі, алгоритм пристосовує їх так, щоб середні втрати досягали мінімуму із зростанням кількості спостережень. Ці умови відповідають процесу ідентифікації при нормальній експлуатації об'єкта.

5 МОДЕЛЮВАННЯ ТА ІДЕНТИФІКАЦІЯ ДИНАМІЧНИХ ОБ'ЄКТІВ

5.1 Ідентифікація нелінійних динамічних об'єктів

Ідентифікація динамічних об'єктів зазвичай включає визначення їх структури та параметрів за спостережуваними даними - вхідними та вихідними значеннями. Спеціальна модель використовується для проведення ідентифікації, і її конфігурація визначається сімейством функцій $f(c, u)$, де вектор c є параметрами моделі. Схема ідентифікації та весь контур слідження виходу об'єкта за моделлю представлена на рисунку 6.

Проведення ідентифікації: В кожен момент часу $k = 1, 2, \dots$ зовнішній вплив $u(k)$ подається на входи об'єкта та конфігуровану модель. Об'єкт також піддається впливу випадкових невидимих перешкод $\xi(k)$. Вихідний сигнал об'єкта $y_0(k)$ залежить від зовнішнього впливу та втручання. Вихідний сигнал регульованої моделі $y_m(k)$ залежить від вектора настроюваних параметрів c , який перераховується за допомогою алгоритму ідентифікації.

Розрахунок невідповідності: Різниця між вихідними значеннями об'єкта та настроюваної моделі формує невідповідність: $\varepsilon(k) = y_0(k) - y_m(k)$, яка подається на вхід перетворювача функції, зображеного на рисунку 1.

Оцінка якості ідентифікації: Оцінка власної моделі об'єкта, яка визначає якість ідентифікації, виконується через критерій якості $J(c)$, де c - вектор регульованих параметрів моделі. Критерій $J(c)$ представляє середню втрату і визначається як $J(c) = M[F, \varepsilon(k)]$, де $F, \varepsilon(k)$ - функція втрат.

Підвищення якості ідентифікації досягається вибором відповідної структури моделі та зміною її параметрів. Цю зміну здійснює алгоритм ідентифікації.

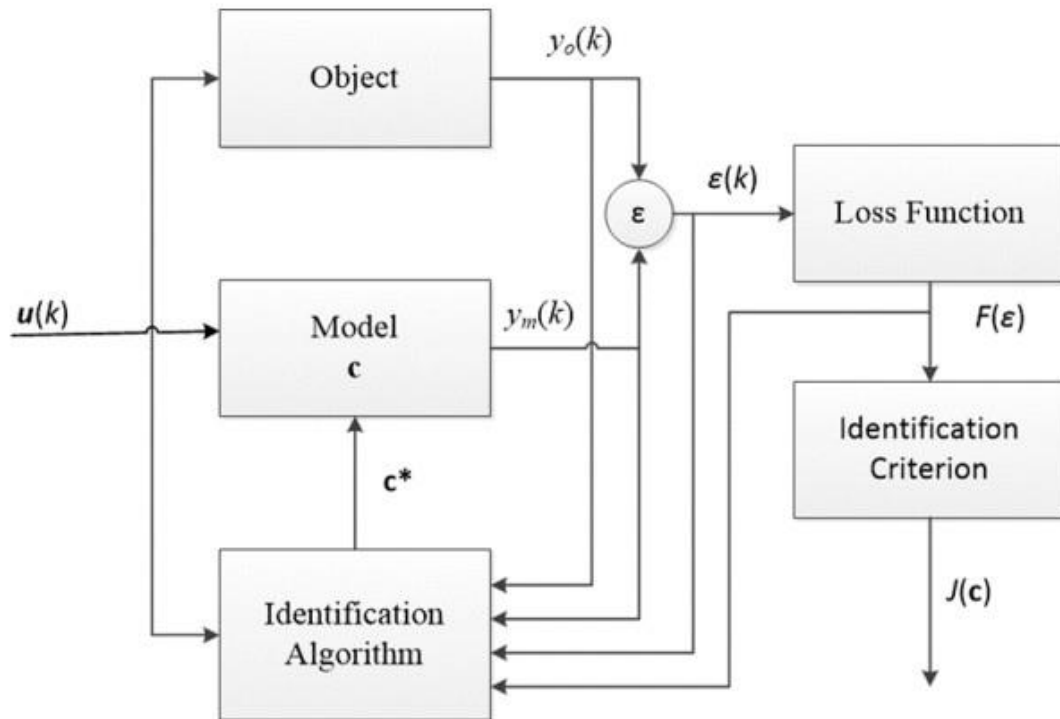


Рисунок 5.1 Схема ідентифікації

Під час проектування системи керування, вибір $J(c)$ має здійснюватися з урахуванням особливостей об'єкта керування та базуватися на результаті експериментального моделювання. Формулювання усіх нелінійних динамічних моделей входу/виводу можливе у такій формі: $y_0(k) = f\varphi(k)$ - , де вектор регресії $\varphi(k)$ може включати попередні та, можливо, поточні входи процесу, попередній процес або вихід моделі, і попередні помилки прогнозування.

Модель об'єкта керування, представлена штучною нейронною мережею, може бути реалізована за допомогою багат шарового перцептрону.

У цій архітектурі кожен нейрон прихованого шару використовує сигмовидну активаційну функцію, а нейрон вихідного рівня має лінійну функцію активації, що дозволяє апроксимувати будь-яку безперервну функцію.




Рисунок 5.2 - Функціональна схема вихідної системи для нелінійного об'єкта із входними та вихідними затримками в нейронній мережі.

Такий багатошаровий перцептрон може бути використаний як модель для управління будь-яким об'єктом, функція якого є безперервною. Під час налаштування цієї моделі застосовується навчання з учителем, де входні мережеві сигнали і сигнал об'єкта збігаються, а очікувані виходи мережі співпадають з вихідним сигналом об'єкта.

У завданні ідентифікації об'єкта керування встановлюється певний критерій ідентифікації, який має бути досягнутий при конфігурації моделі. На сьогоднішній день відсутні теоретично обґрунтовані методи розрахунку розміру навчальної вибірки. Для пакетного навчання може бути вибраний занадто великий розмір вибірки, але це може призвести до великого часу навчання, що важливо для ідентифікації, оскільки модель часто використовується для керування негайно після налаштування. Тому в ідентифікаційних завданнях бажано використовувати послідовне навчання, використовуючи рекурсивні нейронні мережі.

Нейронна мережа з затримками вхідного та вихідного сигналів є окремим випадком нелінійної авторегресійної моделі з зовнішніми входами. На рисунку 5.2 представлені сигнали об'єкта, необхідні для навчання та функціонування використовуваної нейронної мережі як послідовно-паралельної моделі.

5.2 Моделювання керування та функціоналу

Більшість сучасних поїздів і транспортних засобів місцевого транспорту використовують електротягові двигуни транспортний засіб показано у вигляді блок-схеми на рисунку 8.

Підсилювач потужності є нелінійним і може бути наближено представлений як експоненціальна функція.

Із нормальною робочою точкою, $v_1 = 1,5V$, v_1 вхід і v_2 вихідна напруга підсилювача потужності. Ця система раніше досліджувалася, але розглядалася випадок безперервного часу та була побудована лінійна модель.

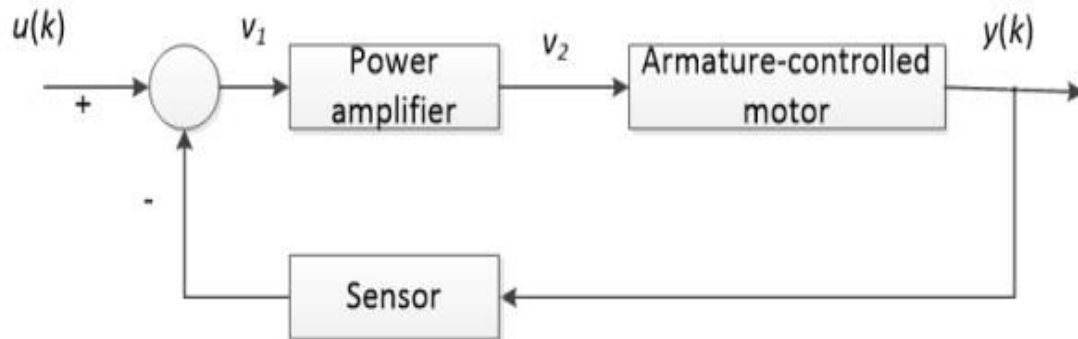


Рисунок 5.3 - Схема пристрою електротяги: $x(k)$ - задана швидкість, $y(k)$ – швидкість автомобіля.

5.3 Моделювання нейромережевого керування електротяговим двигуном

Для моделювання тягового пристрою за допомогою нейронної мережі, відповідно до останнього виразу, кількість вхідних нейронів цієї мережі повинна дорівнювати загальній кількості входів у моделюванні. На практиці це є майже неможливим. Однак можна обійтися значно меншою кількістю вхідних нейронів, враховуючи знаменник дробу під знаком суми, який представляє ваги, з якими значення входів і виходів беруться на попередніх кроках часу. Таким чином, можна ігнорувати тривалі сигнали, оскільки вони майже не впливають на поточний вихід.

Ідентифікація за допомогою нейронної мережі програмно реалізовується наступним чином:

1. Дані завантажуються з файлу даних.

2. Створено об'єкт нейронної мережі з унікальним вихідним нейроном, визначеною кількістю прихованих шарів, кількістю нейронів у кожному прихованому шарі та функціями активації вихідних і прихованих нейронів, які встановлюються користувачем. Кількість вхідних нейронів визначається на основі файлу даних та кількості вхідних і вихідних затримок сигналу.

3. Створено об'єкт, методи якого реалізують алгоритм зворотного поширення помилки. Швидкість навчання встановлюється користувачем.

4. Починається тренування, що передбачає цикл. Кожна ітерація змінює вміст пам'яті - масиву вхідних векторів та масив вихідних сигналів об'єкта, які визначають глибину пам'яті. Нейронна мережа навчається на всьому тренуванні пар, яке повторюється стільки разів, скільки вказано користувачем у параметрі "Кількість тренувальних циклів". Кожна ітерація також отримує відповідь нейронної мережі на вхідний вектор, який записується в окремий масив.

5. Якщо користувач не визначив критерії ідентифікації, то крок 4 виконується для всіх вхідних сигналів з файлу. Це також справедливо, якщо користувач вибрав певні критерії ідентифікації, але не встановив порогове значення, щоб вимкнути ідентифікацію. У іншому випадку, якщо хоча б один із вибраних критеріїв ідентифікації приймає значення, менше встановленого користувачем, навчання припиниться, і продовжиться лише обробка сигналу.

6. Результати виводяться у файл або на екран у вигляді графіка, на вибір користувача. Багатошаровий перцептрон із єдиною затримкою виходу та 20 нейронами прихованого шару із функцією логістичної активації використовувався для моделювання електродвигуна, а тренування проводилось із швидкістю 0,05 та глибиною пам'яті 10.

і 200 тренувальних циклів. Вхідні дані були випадковими і розподілені на інтервалі $[0,5; 0,5]$.

Сучасну точність побудови моделі можна оцінити за таким показником.

$$D(k) = \frac{1}{k} \sum_{j=1}^k (y_0 - y_m)^2 \quad 5.1$$

Де $D(k)$: Середньоквадратична помилка на момент часу k ,

y_0 - реальне значення, яке ми хочемо передбачити,

y_m - предбачене значення моделі чи системи,

k – кількість часових кроків.




Рисунок 5.4 - Виходи: y_0 об'єкт (червоний) і модель y_m (синій).
Горизонтальна вісь показує час.

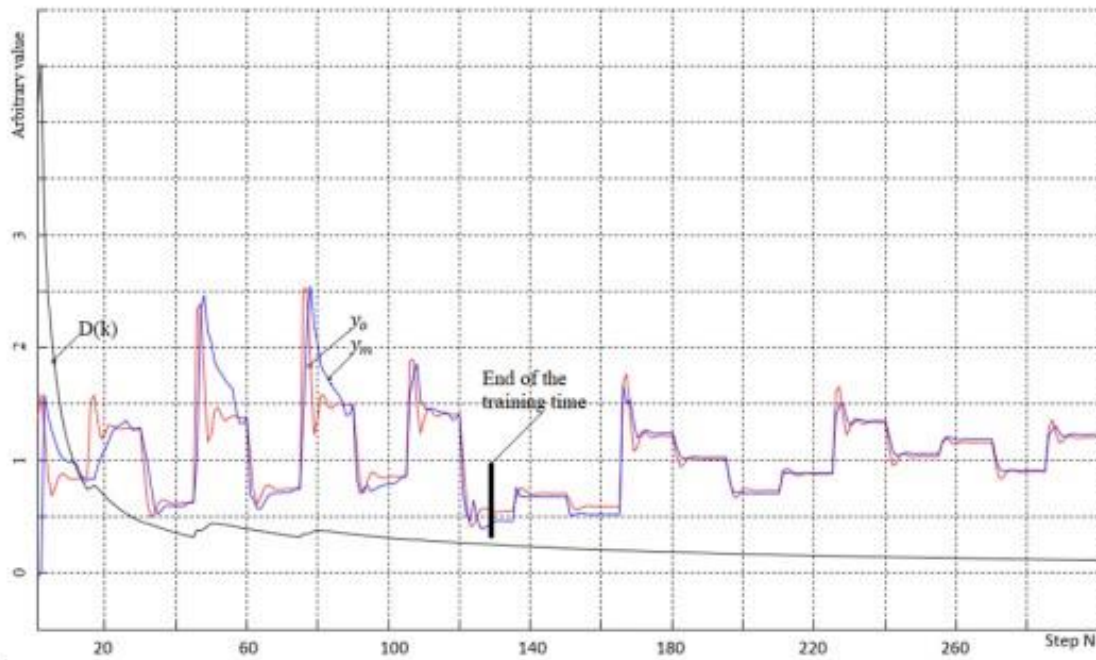


Рисунок 5.5 - Виходи: y_0 об'єкт (червоний) і модель y_m (синій). Показник $D(k)$ зменшується експоненціально. Горизонтальна вісь показує час.

ВИСНОВКИ

У даній кваліфікаційній роботі вивчались проблеми ідентифікації нелінійних систем за допомогою штучних нейронних мереж з різною структурою та можливості застосування цих моделей для розробки алгоритмів управління.

Особливо важливою є робастність систем керування в умовах змінюючихся параметрів системи та невизначеності в моделі. Техніки ідентифікації моделей, використовані в даній роботі, дозволяють системі визначати свої параметри або модель для коректного функціонування, навіть за наявності невідомих чи змінюючихся умов. Це сприяє підтримці високої ефективності та стабільності системи в умовах невизначеності та змін.

Розглядалась можливість моделювання об'єкта цифровою рекурентною мережею при проектуванні моделі нейронної мережі. Розглядалась можливість розробки контролера для керування та ідентифікації нелінійного об'єкта і його особливості.

Проблема полягає в тому, як визначити оптимальну архітектуру мережі. Визначення значень n_u і n_y - це відкрите питання. Великі часові затримки призводять до кращого прогнозування NN. Однак великі n_u і n_y також призводять до великої кількості параметрів (ваги та зміщення), які необхідно адаптувати.

Результати моделювання, показують, що прогнозні контролери можуть бути успішними застосовується для керування нелінійним об'єктом. Оптимальними значеннями керуючих сигналів. Задана похибка відстеження траєкторії мала. Запропонована структура може бути застосована при контролі лінійних об'єктів, які є моделюється нейронною мережею. Рекурентні мережі

є більш потужними, ніж рекурентні мережі мають важливе застосування в програмах керування та обробки сигналів.

Результати моделювання на прикладах, відібраних з літератури, дають хороші результати, що надихає наш майбутній план впровадження системи контролю в реальному часі.

Структура нейронної мережі була обрана з урахуванням конкретних вимог алгоритму управління чи структурних особливостей системи. Використання штучної нейронної мережі, що складається з простих вузлів, пов'язаних між собою відповідно до потреб, є ефективним інструментом для отримання моделі заздалегідь визначеної структури.

Застосування відповідної структури нейронної мережі, що відображає моделі, виявилось ефективним для керування системами зі статичною нелінійністю приводу.

Крім того, досліджено та порівняно методи управління, системи ідентифікації нелінійних об'єктів на основі прогностичного керування, отримані результати та їх застосування.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. D. Cleveland, How Do We Know How the Brain Works, Rosen Publishing Group, 2005.
2. J. L. Shearer, B. T. Kulakovski, J. F. Gardner, Dynamic Modeling and Control of Engineering Systems, Prentice Hall, Upper Saddle River, New Jersey, 1997.
3. H. K. Khalil, Nonlinear Systems, Macmillan Publishing Company, New York, 1992.
4. H. Nijmeier, A. J. van der Schaft, Nonlinear Dynamical Control Systems, Springer-Verlag, New-York, 1990.
5. H. J. Marquez, Nonlinear Control Systems, John Wiley & Sons, New Jersey, 2003.
6. R. Iserman, Digital Control Systems, Springer-Verlag Berlin, Heidelberg, 1981.
7. Ü. Kotta, F. Chowdhury, and S. Nömm, "On realizability of neural networks-based input-output models in the classical state space form," Automatica, 2006, vol. 42, no. 7, pp. 1211-1216.
8. Ü. Kotta and N. Sadegh, "Two approaches for state space realization of NARMA models: bridging the gap," Mathematical and Computer Modelling of Dynamical Systems, vol. 8, no. 1, pp. 21-32, 2002.
9. [F. N. Chowdhury, Ü. Kotta and S. Nömm, "On realizability of neural networks-based input-output models," Proc. of the 3rd Int. Conf. on Differential Equations and Applications vol 6., pp. 47-51, 2000.
10. C.-H. Lu, C.-C. Tsai, Generalized predictive control using recurrent fuzzy neural networks for industrial processes, Journal of Process Control, 2007.

11. K. Laabidi, F. Bouani, M. Ksouri, Multi-criteria optimization in nonlinear predictive control, *Mathematics and Computers in Simulation*, 363-374, 2008.
12. M. Hagan, O.D. Jesus, R. Schultz, Training Recurrent Networks for Filtering and Control, Chapter 11 of *Recurrent Neural Networks: Design and Applications*, L.R. Medsker and L.C. Jain, Eds., CRC Press, 325-354, 1999.
13. R.K. Al Seyab, Y. Cao, Nonlinear system identification for predictive control using continuous time recurrent neural networks and automatic differentiation, *Journal of Process Control*, 18(6):568-581, 2008.
14. Y-Z. Lu, *Industrial intelligent control. Fundamentals and applications*. Chicher: Wiley, 1996.
- 15 T. Hrycey, *Neurocontrol. Towards an Industrial Control Methodology*, John Wiley & Sons, Inc., Toronto, 1997.
16. P. M. Mills, A. Z. Zomaya and M. O. Tade, *Neuro-Adaptive Process Control*, John Wiley & Sons, Inc., England, 1996.
17. L. H. Tsoukalas and R. E. Uhrig, *Fuzzy and neural approaches in engineering*. Wiley-Interscience, New York, 1996.
18. D. E. Rumelhart and J. L. McClelland, *Parallel Distributed Processing*, vol. 1 Foundation, MIT Press, Cambridge, 1988.
19. D. Marquardt, "An algorithm for least-squares estimation of nonlinear parameters," *SIAM J. Appl. Math.*, 1963, Vol. 11, pp. 431–441.
20. A. Toledo, M. Pinzolas, J. J. Ibarrola and G. Lera, "Improvement of the neighborhood based Levenberg-Marquardt algorithm by local adaptation of the learning coefficient," *Neural Networks, IEEE Transactions on*, Vol. 16, Issue 4, July 2005, pp. 988-992.
21. M. T. Hagan and M. B. Menhaj, "Training feedforward networks with the Marquardt algorithm," *Neural Networks, IEEE Transactions on*, Vol. 5, Issue 6, November 1994, pp. 989-993.

22. Declercq and R. De Keyser, "Comparative study of neural predictors in model-based predictive control" Proc. of The International Workshop on Neural Networks for Identification, Control, Robotics, and Signal/Image Processing, Venice, Italy, 21-23 Aug. 1996, pp..

24. E. Petlenkov and E. Rüstern, "Linear Dynamic Systems with Static Actuator Nonlinearities Identification for Control," Proceedings of the ICGST Automatic Control and System Engineering Conference: ACSE05, December 19-21, 2005, Cairo, Egypt, pp. 41-46.

25. E. Petlenkov, „NN-ANARX Structure Based Dynamic Output Feedback Linearization for Control of Nonlinear MIMO Systems,“ In Proc. Of The 15th Mediterranean Conference on Control and Automation, MED'07, Athena, Greece, June 2007, pp. 1-6.

26. E. Petlenkov, and J. Belikov, "NN-ANARX Structure for Dynamic Output Feedback Linearization of Nonlinear SISO and MIMO Systems: Neural Networks Based Approach," In Proc. Of the 26th Chinese Control Conference, Zhangjiajie, China, July 2007, vol. 4, pp. 138-145.

27. H. Demuth, M. Beale, Neural network toolbox: for use with MATLAB, The MathWork, Inc., 1998.

28. S. Chen, S. Billings, and P. Grant, "Non-linear system identification using neural networks," International Journal on Control, 1990, vol. 51, no. 6, pp. 1191–1214.

29. K. Narendra, and K. Parthasarathy, "Identification and control of dynamical systems using neural networks," IEEE Transactions on Neural Networks, March 1990, vol. 1, pp. 4–27.

30. K. Narendra, and S. Mukhopadhyay, "Adaptive Control Using Neural Networks and Approximate Models," IEEE Transactions on Neural Networks, vol. 8, no. 3, pp. 475-485, 1997.

31. H. T. Siegelmann, B. G. Horne and C. L. Giles, "Computational Capabilities of Recurrent NARX Neural Networks," IEEE Transactions on Systems, Man, and Cybernetics – Part B: Cybernetics, vol. 27, no. 2, April 1997, pp. 208-215.

32. S. Billings, "Identification of Nonlinear Systems - A survey," Proceedings of IEE, Part D, 1980, pp. 127-272.

33. G. A. Pajunen, "Application of a Model Reference Adaptive Technique to the Identification and Control of Wiener Type Nonlinear Processes," Thesis for the degree of Doctor of Technology, Helsinki University of Technology, Espo, Finland, 1984.

34. B.-J. Yang, A. J. Calise, and N. Hovakimyan, "Augmenting adaptive output feedback control of uncertain nonlinear systems with actuator nonlinearities," Proceedings of the 2004 American Control Conference, Boston, Massachusetts, Vol. 5, June 30 - July 2, 2004, pp. 4675-4680