

УДК 004.942

DOI: 10.32626/2308-5916.2024-25.129-139

О. О. Фомін, д-р. техн. наук, професор,

В. О. Сперанський, канд. техн. наук,

А. А. Орлов, аспірант,

О. В. Татарин, аспірант,

В. О. Канєвський, аспірант

Національний університет «Одеська політехніка», м. Одеса

МЕТОД ОПОРНИХ МОДЕЛЕЙ СИНТЕЗУ ІНТЕЛЕКТУАЛЬНИХ СИСТЕМ ІДЕНТИФІКАЦІЇ НЕЛІНІЙНИХ ДИНАМІЧНИХ ОБ'ЄКТІВ

Робота присвячена вирішенню протиріччя між точністю моделювання нелінійної динаміки і швидкістю побудови моделей в умовах обмежених обчислювальних ресурсів. Метою роботи є скорочення часу побудови моделей нелінійних динамічних об'єктів із безперервними характеристиками у вигляді нейронних мереж при забезпеченні заданої точності моделювання. Ця мета досягається шляхом розробки нового метода синтезу інтелектуальних систем на основі суперпозиції переднавчених (опорних) моделей у вигляді нейронних мереж, що відбивають базові властивості об'єкта. Наукова новизна роботи полягає у розробці методу ідентифікації нелінійних динамічних об'єктів у вигляді нейронних мереж з часовими затримками на основі набору попередньо навчених нейромережевих моделей, що відбивають базові властивості предметної області. На відміну від традиційного підходу до попереднього навчання, розроблений метод дозволяє будувати моделі меншої складності та з меншим часом навчання при забезпеченні необхідної точності. Для визначення початкових параметрів моделі запропоновано вирази на основі суперпозиції опорних моделей у вигляді нейронних мереж. Практична користь роботи полягає в розробці алгоритму методу опорних моделей для навчання нейронних мереж із часовими затримками, що дозволяє суттєво скоротити час навчання нейронних мереж без втрати точності моделі. Цінність проведеного дослідження полягає у визначенні області ефективного використання запропонованого методу, а саме в наявності достатнього об'єму якісних даних для побудови опорних моделей. Недостатня кількість даних або низька якість даних може суттєво знизити точність опорних моделей і як наслідок, суттєво знизити час навчання цільової моделі.

Ключові слова: *нелінійна динаміка, ідентифікація, нейронні мережі з часовими затримками, попереднє навчання.*

1. Вступ. Сучасний етап розвитку моделювання, що переважно ґрунтується на використанні інтелектуальних технологій, відзначається низкою вимог з боку практики як до високої точності моделей, так і до швидкості їх побудови [1].

Досягнення високої точності моделювання сьогодні здійснюється за рахунок застосування методів машинного навчання, зокрема, нейронних мереж (НМ) [2]. Цей апарат добре впорається з побудовою моделей об'єктів з високим ступенем внутрішньої складності та взаємодії, передусім, багатовимірних нелінійних динамічних об'єктів [2]. Проте використання таких методів часто пов'язане з високою обчислювальною складністю, що призводить до значних витрат часу на побудову моделей [2, 3].

Проблема підвищення швидкості моделювання залишається однією з найактуальніших, особливо в галузях, пов'язаних із персоналізацією моделей, де рішення мають адаптуватися до змін у поведінці користувача та навколишнього середовища (наприклад, у задачах автентифікації, біомедичних додатках, людино-машинних системах), під час функціонування в режимі реального часу [4, 5].

Тому, незважаючи на успіхи машинного навчання, цей напрямок потребує нових підходів і методів, що уможливають значне скорочення часу на створення та навчання моделей при збереженні високої точності моделювання.

2. Огляд літератури. Останніми роками проблема підвищення швидкості навчання НМ набула широкого поширення серед дослідників [4, 5]. Одним із поширених підходів до розв'язання цієї задачі є оптимізація архітектури НМ, яка містить у собі скорочення кількості параметрів моделей без істотної втрати їхньої продуктивності [6]. Другим актуальним напрямом підвищення швидкості навчання НМ є використання алгоритмів прискореного навчання, таких як стохастичний градієнтний спуск з моментумом та адаптивні методи оптимізації [2, 5]. Ще одним напрямом прискорення процесу навчання НМ є перенесення навчання [7]. Основна перевага цього методу полягає в можливості використання моделей, попередньо навчених на наборі даних з однієї предметної області, для розв'язання цільових задач з іншої предметної області.

Окремим випадком перенесення навчання можна вважати попереднє навчання, за якого модель спочатку навчають на великому наборі даних загального характеру, а потім донавчають на більш специфічних даних цільового завдання [8]. Цей підхід дає змогу значно поліпшити якість моделей у випадках, коли обсяг специфічних даних обмежений, а також підвищити стійкість моделі до перенавчання. Попередньо навчені моделі зазвичай швидше сходяться і потребують менше ресурсів для донавчання на цільовому наборі даних [8].

Проте, попереднє навчання має свої недоліки [7, 8]. Зокрема, якщо дані для попереднього навчання і цільове завдання істотно різняться, це може призвести до неправильної ініціалізації цільової моделі та зниження її точності. Крім того, попереднє навчання може вимагати значних обчислювальних ресурсів на початковому етапі навчання на великому наборі даних загального характеру, що обмежує його застосування в умовах лімітованих ресурсів.

Проте, технології передавання навчання та попереднього навчання НМ стали невід'ємною частиною багатьох досліджень і розробок у сфері штучного інтелекту. Вони довели свою ефективність у задачах опрацювання природної мови (мережа опрацювання природної мови BERT, мережа генерації тексту GPT), побудові систем комп'ютерного зору (попередньо навчені згорткові мережі DenseNet, VGG), біомедичних дослідженнях та у людино-машинних інтерфейсах [4]. Таке поширення підходу до побудови моделей стало можливим завдяки його практичним перевагам: значному зниженню витрат на навчання моделей і підвищенню їхньої ефективності у реальних додатках, де важлива не тільки точність, а й швидкість роботи. Крім того, попередньо навчені моделі можуть бути легко адаптовані до нових завдань, що робить їх незамінними інструментами в умовах динамічно мінливих вимог і завдань.

Цей напрям виглядає перспективним і в задачах ідентифікації нелінійних динамічних об'єктів. Водночас, спостерігається нестача робіт у сфері попереднього навчання НМ, що моделюють нелінійні динамічні властивості об'єктів із безперервними характеристиками.

3. Постановка проблеми. Нехай S – предметна область, що містить задачі загального характеру та для якої є розмічений набір даних D_S достатнього розміру N_S . Нехай T_k – специфічна задача з множини цільових задач \mathbf{T} , визначених в предметній області S ($k = 1, \dots, p$, p – розмір множини задач \mathbf{T}), для якої є розмічений набір даних D_{T_k} обмеженого розміру N_{T_k} .

Задача попереднього навчання полягає у визначенні таких параметрів θ_S загальної моделі $f_{\theta_S}(D_S)$, при використанні яких в якості початкових значень $\theta_{T_k0} = \theta_S$ в задачах донавчання кожної з p цільових моделей $f_{\theta_{T_k}}(\theta_S, D_{T_k})$ досягається заданий рівень точності (допустимої помилки E_{θ_T}) за мінімальний в середньому проміжок часу:

$$\begin{cases} \theta_S = \arg \min_{\theta} t_{\theta_T}(f_{\theta_{T_k}}(\theta, \mathbf{x}_j^{T_k})) \\ L_T(f_{\theta_{T_k}}(\theta_S, \mathbf{x}_j^{T_k}), y_j^{T_k}) < E_{\theta_T} \end{cases}, \quad (1)$$

де t_{θ_T} – середня тривалість донавчання серед p цільових моделей $f_{\theta_{T_k}}(\theta_S, D_{T_k})$; в якості величини t_{θ_T} може використовуватися середня

кількість епох навчання моделі; L_T – функція втрат, прийнята для множини цільових моделей $f_{\theta_{Tk}}(\theta_S, D_{Tk})$. В якості функції втрат L_T зазвичай використовується середньоквадратична помилка (*mse*) [9].

Метою роботи є скорочення часу побудови моделей нелінійних динамічних об'єктів із безперервними характеристиками при забезпеченні заданої точності моделювання шляхом розробки нового метода синтезу інтелектуальних систем на основі суперпозиції переднавчених (опорних) моделей у вигляді нейронних мереж, що відбивають базові властивості об'єкта.

4. Викладення основного матеріалу.

4.1. Метод опорних моделей синтезу НМ.

Для розв'язання проблеми надмірної складності та підвищення ефективності навчання цільових моделей в роботі використовується набір опорних датасетів D_{Sv} ($v = 1, \dots, g$, g – кількість базових характеристик предметної області). Кожен з них описує окрему базову властивість досліджуваної області. На базі цих датасетів будуються опорні попередньо навчені моделі $f_{\theta_{Sv}}(D_{Sv})$ з параметрами θ_{Sv} . Шляхом комбінування та адаптації відповідних опорних моделей будується груба модель $f_{\theta_S}(D_S)$, якій притаманний певний набір характеристик (нелінійних і динамічних) об'єкта дослідження. Цільова моделі $f_{\theta_{Tk}}(\theta_{Sv}, D_{Tk})$ об'єктів з певними характеристиками будується шляхом донавчання грубої моделі на датасеті D_{Tk} .

Даний підхід дозволяє зберігати переваги попереднього навчання, так як опорні моделі, отримані одноразово, можуть багатократно використовуватися для різних предметних областей та цільових задач, значно скорочуючи загальний час та ресурси на навчання моделей без збору додаткових даних.

У роботі запропоновано метод синтезу моделей нелінійних динамічних об'єктів, заснований на використанні набору опорних попередньо навчених НМ, що відображають базові властивості предметної області. Алгоритм запропонованого методу полягає у виконанні наступних етапів.

Крок 1. Вибір базових властивостей предметної області та формування набору датасетів D_{Sv} , що відображають обрані властивості.

Крок 2. Визначення структури θ_{Sv} опорних моделей $f_{\theta_{Sv}}(D_{Sv})$ у вигляді НМ, що відповідають встановленим базовим властивостям предметної області та попереднє навчання опорних моделей на сформованих датасетах D_{Sv} .

Крок 3. Визначення властивостей цільової задачі з множини базових властивостей предметної області та побудова грубої моделі $f_{\theta_S}(D_S)$ на основі суперпозиції відповідних опорних моделей, отриманих на *Кроці 2*.

Крок 4. Навчання точної нейромережевої моделі $f_{\theta_{Tk}}(\theta_{Sv}, D_{Tk})$ на базі грубої моделі $f_{\theta_S}(D_S)$, отриманої на *Кроці 3*.

Крок 5. Визначення показників точності та часу навчання $t_{\theta T}$ моделі. При незадовільних показниках якості цільової моделі здійснюється перехід на *Крок 2* для корегування структури θ_{sv} опорних моделей $f_{\theta_{sv}}(D_{sv})$, та, за необхідності, на *Крок 1* для корегування набору базових властивостей предметної області та набору датасетів D_{sv} , що відображають обрані властивості.

4.2. Вибір базових властивостей предметної області для формування набору датасетів.

Під базовими властивостями предметної області в роботі розуміються характеристики об'єктів, що відображають суттєві аспекти їх поведінки в різних умовах. Ці властивості можуть включати фізичні, технічні, соціальні або інші параметри, які є важливими для розв'язання задачі, поставленої перед моделлю.

Процедура вибору базових властивостей предметної області та формування набору датасетів D_{sv} , що відображають обрані властивості, полягає у наступному.

1. Визначення кола завдань, які вирішуються в предметній області, аналіз властивостей предметної області, які є істотними для об'єктів предметної області, суттєво впливають на результати моделювання та мають бути відображені при формуванні датасету D_S .
2. Визначення типів сигналів (наприклад, періодичні, випадкові, імпульсні), які найкращим чином відображають властивості досліджуваних об'єктів.
3. Формування датасету D_S на основі переліку базових властивостей предметної області встановлених в пункті 1 та сформованого в пункті 2 набору вхідних сигналів та реакцій об'єкта.
4. Сегментація датасету D_S на окремі датасети D_{sv} ($v = 1, \dots, g$) відповідно до визначеного переліку базових властивостей предметної області.

4.3. Визначення структури опорних моделей та їх попереднє навчання.

Як зазначалося раніше, опорні моделі для ідентифікації нелінійних динамічних об'єктів будуються у вигляді НМ. В роботі використовується НМ з часовими затримками (TDNN) [10]. Завдяки своїй простоті та універсальності TDNN набули найбільшого поширення в задачах моделювання нелінійних динамічних об'єктів. На практиці найчастіше використовується структура TDNN, що складається з трьох шарів: вхідного, прихованого та вихідного [10]. Розмір шарів в цій структурі TDNN визначається наступним чином:

- вхідний шар складається з M нейронів та відповідає за пам'ять (динамічні характеристики) моделі;
- прихований шар складається з K нейронів та відповідає за нелінійні характеристики моделі;

- вихідний шар містить кількість нейронів Y , яка дорівнює кількості виходів моделі.

Для визначення структури опорних моделей, що являють собою тришарові TDNN достатньо знайти кількість нейронів M у вхідному та K у прихованому шарах.

4.4. Побудова грубої моделі на основі композиції відповідних опорних моделей.

Після завершення процесу попереднього навчання множини опорних моделей на їх основі будується груба модель $f_{\theta_S}(D_S)$. Ця модель складається з набору опорних переднавчених моделей $f_{\theta_{S_v}}(D_{S_v})$, що відповідають наявним базовим характеристикам об'єкта ($v = 1, 2, \dots, b$, де b – кількість базових характеристик об'єкта, $b \leq p$).

За умови побудови грубої моделі $f_{\theta_S}(D_S)$, а в подальшому, й точної моделі $f_{\theta_{TK}}(\theta_S, D_{TK})$, у вигляді НМ з тією ж структурою (розмірністю вектору параметрів θ_S), що мають опорні моделі $f_{\theta_{S_v}}(D_{S_v})$, визначення грубої моделі зводиться до обчислення середнього арифметичного відповідних компонентів векторів параметрів опорних моделей θ_{S_v} :

$$\theta_S^i = \frac{1}{b} \sum_{v=1}^b \theta_{S_v}^i, \quad (2)$$

де i – індекс відповідних елементів векторів параметрів грубої θ_S та опорних θ_{S_v} моделей.

Таким чином, ще однією перевагою формування грубої моделі за методом опорних моделей є відсутність процедури навчання, що значно пришвидшує процес побудови грубої моделі.

4.5. Навчання точної моделі на базі грубої.

Після побудови грубої моделі $f_{\theta_S}(D_S)$ здійснюється навчання точної нейромережевої моделі. Для точної моделі обирається така ж структура як для грубої моделі. В якості початкового вектору параметрів точної моделі θ_{TK} приймається вектор θ_S , отриманий за виразом (2). Далі точна модель у вигляді НМ навчається методом зворотнього розповсюдження помилки з оновленням параметрів мережі методом Левенберга-Марквардта для забезпечення високої точності моделювання і швидкої збіжності процесу навчання. Процес навчання продовжується до тих пір, поки функція втрат не досягне мінімуму або не буде виконано умову зупинки (наприклад, досягнення заданої точності або максимального числа епох).

Цей підхід дозволяє зберігати знання, отримані на загальному наборі даних D_S і ефективно адаптувати модель $f_{\theta_{TK}}(\theta_S, D_{TK})$ до цільової задачі.

Апробація розробленого методу синтезу інтелектуальних систем ідентифікації нелінійних динамічних об'єктів на основі опорних мо-

делей проводиться на задачі моделювання тестового об'єкта з безпервними характеристиками.

5. Постановка експерименту. Дослідження точності метода опорних моделей проводиться на прикладі тестового об'єкта. Імітаційна модель тестового об'єкта у вигляді послідовності нелінійної ланки з насиченням та динамічної ланки першого порядку наведена на рис. 1. Перехідні характеристики об'єкта, що демонструють його нелінійні та динамічні характеристики наведено на рис. 2.




Рис. 1. Імітаційна модель тестового об'єкта




Рис. 2. Перехідні характеристики тестового об'єкта

В якості типових властивостей предметної області для формування опису тестового об'єкта обрано нелінійну характеристику у вигляді насичення та динамічну ланку першого порядку.

Для тестового об'єкта сформовано розміщений набір даних $D_S = \{(\mathbf{x}_i^S, y_i^S)\}$ на основі сигналів $x(t)$ на вході об'єкта та відгуків $y(t)$ на його виході. В якості вхідних сигналів використовуються імпульсні $x(t) = a\delta(t)$, ступінчасті $x(t) = a\Theta(t)$, лінійні $x(t) = at$ і гармонічні $x(t) = a \sin(t)$ сигнали різної амплітуди $a \in (0, 1]$.

На базі датасету D_S сформовано два опорних датасету:

- вхідні ступінчасті сигнали $x(t) = a\Theta(t)$ та відгуки $y(t)$ об'єкту з нелінійністю у вигляді насичення $D_{T1} = \{(\mathbf{x}_j^{T1}, y_j^{T1})\}$,
- вхідні ступінчасті сигнали $x(t) = a\Theta(t)$ та відгуки $y(t)$ об'єкту у вигляді динамічної ланки першого порядку $D_{T2} = \{(\mathbf{x}_j^{T2}, y_j^{T2})\}$.

Експеримент полягає у дослідженні швидкості навчання точної моделі тестового об'єкта, збудованої різними методами:

- навчання на основі попередньо навченої моделі на загальному датасеті D_S ;
- навчання на основі окремих опорних моделей попередньо навчених на датасетах D_{T1} та D_{T2} ;
- навчання методом опорних моделей.

Для визначення структури грубої моделі $f_{\theta_S}(D_S)$, що являє собою тришарову TDNN за результатами додаткових досліджень прийнято кількість нейронів $M = 30$ в вхідному та $K = 30$ в прихованому шарах. Модель навчається методом зворотнього розповсюдження помилки з оновленням параметрів мережі методом Левенберга-Марквардта. Попереднє навчання обмежується 50 епохами для запобігання перенавчання і збереження здатності до адаптації. На рис. 3 наведено залежності функцій втрат mse від кількості епох навчання.




Рис. 3. Залежності функцій втрат mse під час навчання грубої моделі від кількості епох навчання

Структура точної моделі $f_{\theta_T}(\theta_S, D_T)$ на основі переднавченої грубої моделі $f_{\theta_S}(D_S)$, моделей $f_{\theta_{Tk}}(D_{Tk})$ на основі окремих опорних моделей датасетів D_{T1} та D_{T2} і моделі $f_{\theta_T}(D_T)$ на основі суперпозиції опорних моделей обирається ідентичною грубій моделі $f_{\theta_S}(D_S)$ у вигляді тришарової TDNN. НМ навчається методом зворотнього розповсюдження помилки з оновленням параметрів мережі методом Левенберга-Марквардта. Навчання точної моделі здійснюється протягом 50 епох. На рис. 4 наведено залежності функцій втрат mse від кількості епох навчання для точних моделей на основі грубої моделі, на основі окремих опорних моделей $f_{\theta_{T1}}(D_{T1})$ та $f_{\theta_{T2}}(D_{T2})$, на основі суперпозиції опорних моделей.

З експерименту видно перевагу використання попередньо навчених опорних НМ під час ідентифікації нелінійних динамічних

об'єктів, а саме, істотне скорочення часу навчання TDNN моделі (в 4.6 рази) у порівнянні з традиційним підходом побудови точної моделі на основі переднавченої грубої моделі при порівнянній точності обох моделей. Використання окремих опорних моделей в якості грубих моделей також спроможне забезпечити скорочення часу навчання точної моделі (в 1.8 рази).

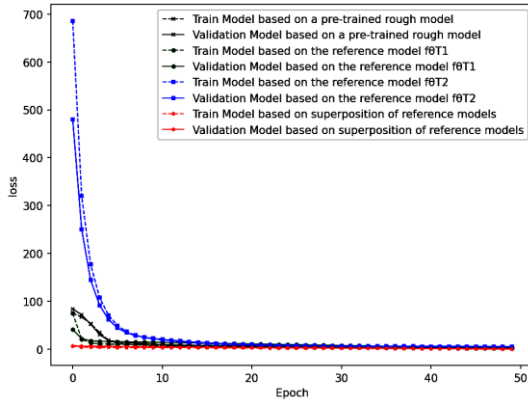


Рис. 4. Залежності функцій втрат mse від часу навчання точних моделей на основі грубої моделі, на основі окремих опорних моделей, на основі суперпозиції опорних моделей від кількості епох навчання

6. Висновки. В роботі успішно вирішено задачу скорочення часу побудови моделей нелінійних динамічних об'єктів із безперервними характеристиками при забезпеченні заданої точності моделювання. Для вирішення протиріччя між точністю моделювання нелінійної динаміки і швидкістю побудови моделі розроблено новий метод синтезу інтелектуальних систем на основі суперпозиції опорних моделей у вигляді НМ, що відбивають базові властивості об'єкта.

Ефективність розробленого методу ідентифікації нелінійних динамічних об'єктів доведено при вирішенні задачі ідентифікації тестового нелінійного динамічного об'єкта. Експеримент демонструє скорочення часу побудови точної TDNN моделі з використанням опорних моделей в 4.6 рази у порівнянні з повною процедурою навчання при порівнянній точності обох моделей.

Перевагами запропонованого підходу є здатність швидко адаптуватися до мінливих умов експлуатації, висока швидкість побудови точної моделі при забезпеченні заданої точності моделювання. Крім того, розроблений метод дозволяє поліпшити ефективність навчання моделі за нестачі розмічених даних для цільової задачі.

Недоліками запропонованого підходу, успадкованими від методів на основі попереднього навчання, є залежність результатів моделювання від кількості та якості даних датасету.

Практичними обмеженнями застосування запропонованого підходу є апріорна потреба у опорних моделях, збудованих на достатньому об'ємі якісних даних. Недостатня кількість даних або низька якість даних може суттєво знизити точність опорних моделей і як наслідок, суттєво знизити час навчання точної моделі.

Таким чином, виокремлено область ефективного застосування запропонованого методу: нестача розмічених даних цільової задачі при наявності загального датасету достатнього розміру; відсутність суттєвих розбіжностей між характеристиками загального та цільового датасету.

Список використаних джерел:

1. Chisty N. M. A., Adusumalli H. P. Applications of artificial intelligence in quality assurance and assurance of productivity. *ABC Journal of Advanced Research*. 2022. Vol. 11 (1). P. 23-32. DOI: 10.18034/abcjar.v11i1.625.
2. Sen J. Machine learning – algorithms, models and applications. *IntechOpen*. London: United Kingdom. 2021. DOI: 10.5772/intechopen.94615.
3. Kutyniok G. The mathematics of artificial intelligence. *Proc. Int. Cong. Math*. 2022. Vol. 7. P. 5118-5139. DOI: 10.4171/ICM2022/141.
4. Kariri E., Louati H., Louati A., Masmoudi F. Exploring the Advancements and Future Research Directions of Artificial Neural Networks: A Text Mining Approach. *Appl. Sci*. 2023. Vol. 13. P. 3186. DOI: 10.3390/app13053186.
5. Islam M., Chen G., Jin S. An Overview of Neural Network. *American Journal of Neural Networks and Applications*. 2019. Vol 5 (1). P. 7-11. DOI: 10.11648/j.ajna.20190501.12.
6. Elsken T., Metzen J. H., Hutter, F. Neural architecture search: A survey. *Journal of Machine Learning Research*. Springer. Cham. 2019. Vol 20. DOI: 10.1007/978-3-030-05318-5.
7. Hosna A., Merry E., Gyalmo J. et al. Transfer learning: a friendly introduction. *J Big Data*. 2022. Vol. 9 (1). P. 102. DOI: 10.1186/s40537-022-00652-w.
8. Fomin O. O., Orlov A. A. Modeling nonlinear dynamic objects using pre-trained time delay neural networks. *Applied Aspects of Information Technology*. 2024. Vol. 7 (1). P. 24-33. DOI: 10.15276/aait.07.2024.2.
9. Tian J. Quality-evaluation models and measurements. *IEEE Software*. May-June 2004. Vol 21 (3). P. 84-91. DOI: 10.1109/MS.2004.1293078.
10. Fomin O. et al. Interpretation of dynamic models based on neural networks in the form of integral-power series. *Smart Technologies in Urban Engineering. Lecture Notes in Networks and Systems*. Springer. Cham. 2022. Vol. 536. P. 258-265. DOI: 10.1007/978-3-031-20141-7-24.

METHOD OF REFERENCE MODELS FOR SYNTHESIS OF INTELLIGENT SYSTEMS FOR IDENTIFICATION OF NONLINEAR DYNAMIC OBJECTS

The paper is devoted to resolving the contradiction between the accuracy of modeling nonlinear dynamics and the speed of model construction under conditions of limited computing resources. The aim of the work is to reduce the time for building models of nonlinear dynamic objects with continuous characteristics in the form of neural networks while ensuring a given modeling accu-

racy. This goal is achieved by developing a new method for synthesizing intelligent systems based on the superposition of pre-trained (support) models in the form of neural networks that reflect the basic properties of the object. The scientific novelty of the work lies in the development of a method for identifying nonlinear dynamic objects in the form of neural networks with time delays based on a set of pre-trained neural network models that reflect the basic properties of the subject area. In contrast to the traditional approach to pre-training, the developed method allows building models of lower complexity and with shorter training time while ensuring the required accuracy. To determine the initial parameters of the model, expressions based on the superposition of reference models in the form of neural networks are proposed. The practical utility of the work lies in the development of an algorithm for the method of reference models for training neural networks with time delays, which can significantly reduce the training time of neural networks without losing model accuracy.

Key words: *nonlinear dynamics, identification, time-delay neural networks, pre-training.*

Отримано: 01.09.2024

УДК 519.71

DOI: 10.32626/2308-5916.2024-25.139-145

В. С. Щирба, канд. фіз.-мат. наук

Кам'янець-Подільський національний університет
імені Івана Огієнко, м. Кам'янець-Подільський

ФОРМУВАННЯ ТРАЄКТОРІЇ КЕРОВАНИХ ЛІТАЛЬНИХ АПАРАТІВ

На даний час відзначається підвищений інтерес до створення систем управління польотом безпілотної літального апарата, яка б з врахуванням реальних умов забезпечувала б його траєкторію і цим самим визначала б ефективність застосування літального апарата. Навігація літального апарату, зокрема балістичних крилатих ракет, потребує формування високоточного управління для досягнення як кінцевих результатів, так і локальних оптимізаційних задач на кожному з етапів польоту: старті, виході на задані траєкторії, маневруванні тощо.

Розробка допустимого управління та його оптимізація комп'ютерно-математичними методами моделювання і оптимізації є трудомістким процесом і вимагає значних витрат різних видів ресурсів. Елементом ефективності такого математичного апарату для гарантування та підвищення надійності і результативності в досягненні поставленої цілі постає швидкодія в розрахунках що, в свою чергу, потребує забезпечення спрощення математичної моделі шляхом одержання функціональних залежностей для обчислення траєкторії польоту уникаючи складних математичних розрахунків.