

ної модифікації **RSA**, у зашифрованому зображенні вдалось досягти повної зашумленості і уникнути областей однорідності (рис.5). При цьому виявити контури вихідного зображення стає практично неможливим. Це дало можливість нівелювати можливості використання традиційних засобів обробки зображень для несанкціонованого отримання інформації із зашифрованого зображення.

Описаний алгоритм може бути застосований для будь-яких зображень. В усіх випадках буде отримано результат повного зашумлення зображення.

1. *Компьютерные сети. 4-е изд. / Е. Тененбаум. – СПб.: Питер, 2006. – С. 832-852.*
2. Шнайдер Б *Прикладная криптография.*– М.: Издательство Триумф, 2003. – 816 с. 3. Гонсалес Р., Вудс Р. *Цифровая обработка изображений.*– М.: Техносфера, 2005. – 1072 с. 4. Рашкевич Ю.М., Пелешко Д.Д., Ковальчук А.М., Пелешко М.З. *Модифікація алгоритму RSA для деяких класів зображень // Технічні вісті. – 2008/1(27), 2(28). – С. 59 – 62.*

УДК 004.032.26:004.048

Р. Ткаченко, А. Дорошенко

Національний університет “Львівська політехніка”,
кафедра автоматизованих систем управління

НЕЙРОПОДІБНІ СТРУКТУРИ МАШИНИ ГЕОМЕТРИЧНИХ ПЕРЕТВОРЕНЬ У ЗАВДАННЯХ ІНТЕЛЕКТУАЛЬНОГО АНАЛІЗУ ДАНИХ

О Ткаченко Р., Дорошенко А., 2009

Показано особливості архітектури та застосування нейроподібних структур машини геометричних перетворень (МГП) до розв’язання задач передбачення в галузі інтелектуального аналізу даних (ІАД). Розроблений в статті метод передбачення на основі незалежного відтворення головних компонентів ілюструється прикладом.

The article describes the features of the architecture of neural networks and the approach to solving a problem of prediction for Data Mining tasks where data are high-dimensional. Essential principles of the methods of prediction on the base of neural networks base on geometrical transformation machine are proposed. This method of prediction is improved by independent reproduction of principal components.

Вступ

Розвиток технічних засобів та сучасних інформаційних технологій відбору призводить до накопичення величезних інформаційних масивів, які вимагають подальшого опрацювання та аналізу з метою ефективного використання даних в системах підтримки прийняття рішень. Велика розмірність завдань в галузі ІАД, істотні нелінійності та невизначеності різноманітної природи, виродженість задач, суперечливість, неповнота та неоднорідність даних передбачають в більшості випадків для отримання необхідних результатів застосування сучасних засобів штучного інтелекту, зокрема штучних нейронних мереж (ШНМ) та контролерів нечіткої логіки [1]. Існує також проблема інформаційного моделювання в ІАД, пов’язана з наявністю як глобальних залежностей між досліджуваними змінними, що діють однотипно в усій області визначення, так і локальних. Для моделювання і передбачення глобальних залежностей найчастіше застосовують багаточарові перцептрони, а для локальних – нейромережі радіальних базових функцій (РБФ) [2,7,8]. Отже, вказані вище нейромережні технології по суті виключають одна одну. Оскільки в багатьох реальних випадках структура даних є складнішою, відображає залежності обох типів, названий вище підхід

вибору альтернатив не можна назвати доцільним. Універсальними можливостями у цьому плані володіють структури МГП [3–6], чим пояснюється помітно вища точність розв'язку багатьох завдань з їх допомогою порівняно з традиційними нейромережними засобами.

Основи концепції МГП

Структури МГП скеровані на усунення або зменшення негативних властивостей існуючих засобів інформаційного моделювання – регресійних моделей, машин опорних векторів, штучних нейромереж, індуктивних моделей, контролерів нечіткої логіки, статистичних моделей.

Базові властивості МГП : єдина методологічна основа побудови архітектур МГП для різних завдань та предметних областей застосування; швидке неітеративне навчання за наперед задану кількість кроків обчислень, що відкриває можливість розв'язування завдань великих розмірностей, повна повторюваність результатів навчання; можливість отримання задовільних розв'язків для тренувальних вибірок зменшеного об'єму; можливість розв'язування задач в автоматичному режимі; розширення кібернетичного принципу “чорної скриньки” на користь “сірої скриньки”, оскільки МГП володіють додатковими можливостями аналізу внутрішньої структури даних; висока точність та покращені генералізуючі властивості; ефективне розв'язання завдань обчислювальної математики, зокрема систем алгебраїчних рівнянь; прості варіанти опрацювання завдань нечіткої логіки; можливість доповнення навчання моделей МГП оптимізаційними процедурами адаптації до додаткових критеріїв навчання; виділення та аналіз всіх наявних незалежних трендів для часових послідовностей; візуалізація розв'язків задач з врахуванням гомеоморфізму перетворень.

Аналогії зі штучними нейромережами

Особливістю МГП є однотипність алгоритмів навчання та функціонування [3–6]. Топологія алгоритму навчання МГП представляється в виді деякого графу, вершини якого відповідають основним операціям алгоритму – скалярному добутку вектора входних сигналів на вектор вагових коефіцієнтів та нелінійному перетворенню від скалярного добутку.

Отже, вершини графу можна розглядати як відповідники нейронних елементів прихованого шару штучної нейромережі, а моделі МГП описуються структурами нейроподібного типу. Подібне трактування є продуктивним як при налагодженні моделей МГП, так і при побудові архітектур відповідних комплексів на основі МГП для розв'язання багатьох задач, зокрема, прогнозування часових послідовностей, виділення головних компонент, ущільнення даних і т.п. з використанням нейромережних підходів до реалізації [3,6].

Одночасно зауважимо принципову відмінність МГП від нейромережних засобів – якщо в штучних нейромережах навчання здійснюється (як правило, ітеративно) з метою встановлення параметрів для обраної заздалегідь структури, то в МГП структура моделі формується за результатами навчання відповідно до заданих його характеристик. Тобто в нейромережному тлумаченні МГП являють собою лише графи відповідних алгоритмів, які, однак, містять внутрішній просторовий і часовий паралелізм і можуть бути реалізовані також апаратно. Тобто, концепція МГП забезпечує реалізацію принципів функціонального моделювання, а не структурного, оскільки структура моделі МГП визначається структурою табличних даних.

Постановка задачі передбачення

Опишемо послідовність кроків розробленого методу для обраного модельного прикладу передбачення шуканих відгуків (витрат електричної енергії в електричній мережі) на підставі незалежних відомих входів (11 відомих сигналів стану електричної мережі, отриманих на підставі даних телеметрії). Тренувальна вибірка складається з 365 векторів, що містять відповідно 11 входів та 1 вихід. Отже, дані для навчання мережі МГП збиралися протягом календарного року. Передбачення в режимі тестування виконувалися для 214 днів наступного року. Пропонована задача не є унікальною щодо свого розв'язку, отже, описані нижче процедури методу можуть без змін переноситися на інші задачі передбачення.

Основи методу передбачення шляхом незалежного виділення головних компонентів

1. Виділення головних компонентів даних тренувальної вибірки за допомогою автоасоціативної мережі МГП

Автоасоціативною мережею вважатимемо одну з двох можливих конфігурацій мереж МГП. Проаналізуємо особливості застосування різних варіантів нейроподібних структур МГП для виділення головних компонентів. Для цього обираємо нейроподібні структури, зображені на рис.1 (а, б), де

x_1, x_2, \dots, x_{11} – компоненти вхідних векторів,

$ГК_1, ГК_2, \dots, ГК_{12}$ – головні компоненти, отримані на основі вхідних даних,

y – значення функції відгуку,

$\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_{11}$ – передбачені значення входів,

\tilde{y} – передбачене значення функції відгуку.

Функціонування такої нейроподібної структури описується співвідношенням

$$y = \sum_{i=1}^n ГК_i \cdot w_i,$$

де w_1, w_2, \dots, w_{12} – вагові коефіцієнти.




Рис.1. Нейроподібні структури МГП

Аналіз експериментів показав, що видобування головних компонентів доцільніше виконувати за допомогою варіанта (а) структури, яка краще задовольняє вимоги точності, хоча і поступається варіанту (б) в плані швидкості функціонування. Виявлено також, що остання, дванадцята головна компонента має значно вищу похибку відтворення, ніж попередні одинадцять. Геометричне обґрунтування останнього результату є таким. Перші одинадцять головних компонент представляють геометричні виміри гіпертіла, які відповідають поняттям довжини і ширини тривимірного тіла. Остання – головна компонента – відповідає виміру „товщина тіла”.

Цю гіпотезу покладено в основу пропонованого методу передбачення, за яким виконується розділення задачі передбачення на дві окремі підзадачі. Здійснюється також незалежне передбачення суми перших одинадцяти головних компонент нейроподібною структурою з глобальними властивостями відтворення та дванадцятій ГК, що вносить найбільшу похибку в прогнозування – мережею РБФ, з вираженими локальними властивостями.

Проілюструємо наведене вище даними експериментів, що виконувалися засобами програмної мережі func.net.express, версія 1.4. Вікно інтерфейсу програми подано на рис. 2.

1. Для навчання нейроподібної структури МГП (рис.3) використовуємо тренувальну вибірку з 365 елементів – векторів.

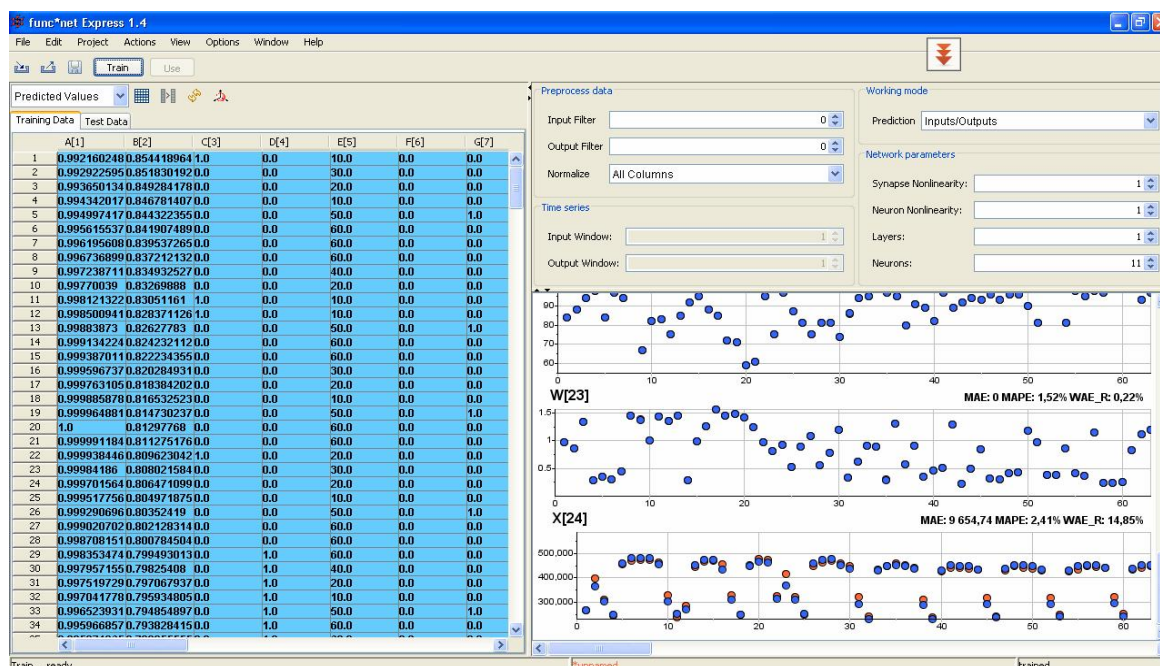


Рис. 2. Навчання розробленої нейроподібної структури за допомогою програмного продукту func*net

Отримуємо передбачені значення виходів \tilde{y} , які враховують вплив лише 11 головних компонент. Формуємо нову навчальну вибірку із входами x_1, x_2, \dots, x_{11} та значенням функції відгуку \tilde{y} .




Рис. 3. Архітектура нейроподібної структури МГП

Створюємо нейроподібну структуру МГП, зображену на рис.4. Для цього використовуємо програмні нейроподібні мережі Equo, версія 1.6.



Рис. 4. Структурна схема нейроподібної МГП, яка відтворює 11 головних компонент

Для навчання та тестування використовувалися нейроподібні варіанти МГП з різними функціями активації: лінійний поліном, лінійний поліном Паде, степеневий поліном тощо.

На рис.5. наведено результати навчання нейроподібної структури МГП із використанням 11 головних компонент та типом формули – лінійний поліном.

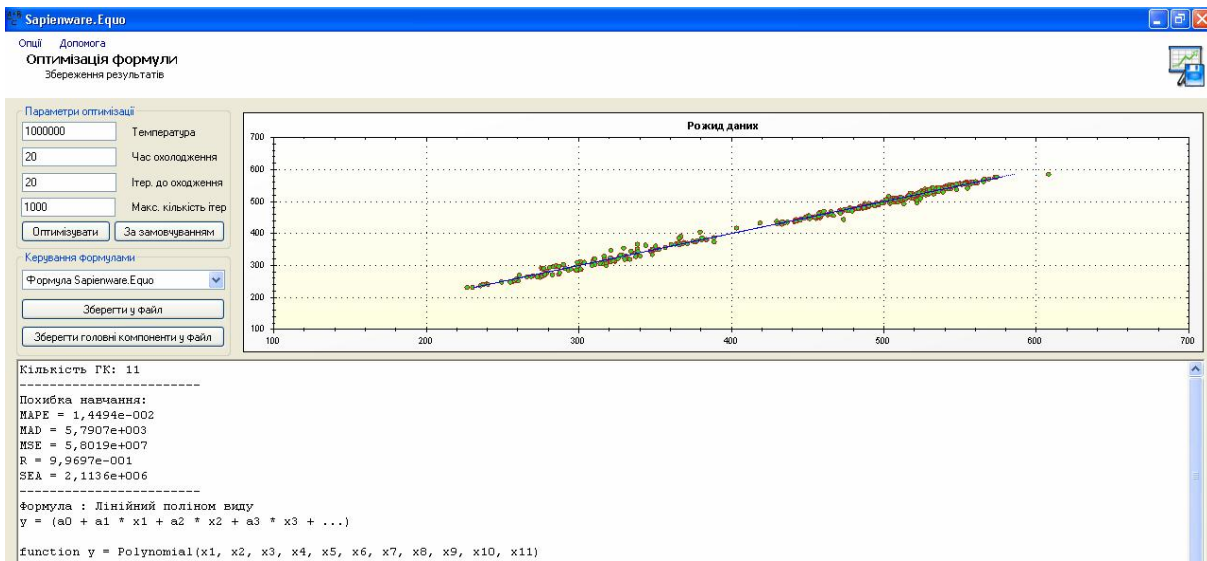


Рис. 5. Навчання розробленої нейроподібної структури за допомогою програмного продукту Sapientware.Equo




Рис.6. Оптимізація навченої нейроподібної структури за допомогою методу імітації відпалу металу програмного продукту Sapientware.Equo

Точність навчання покращувалася також шляхом застосування додаткової процедури методом імітації відпалу металу (рис.6).

Результати прогнозування для кожного з цих типів нейроподібних структур наведено в табл.1, де

MAPE (middle absolute percent error) – середня абсолютна похибка у відсотках,

RMSE – (root mean square error) – середньоквадратична похибка.

Таблиця 1

Тренування				Тестування			
Тип похибки	Тип формули			Тип похибки	Тип формули		
	Лінійний поліном	Лінійний поліном Паде	Степеневий поліном		Лінійний поліном	Лінійний поліном Паде	Степеневий поліном
MAPE	3,8 %	3,3 %	2,7%	MAPE	4,28 %	3,87 %	3,5%
RMSE	5,3%	4,9%	3,8%	RMSE	6,4 %	5,34%	5,05%

3. Обчислюємо значення $R = y - \tilde{y}$ для тренувальної та тестової вибірок, формуємо нову навчальну вибірку із входами x_1, x_2, \dots, x_{11} та значенням цільової функції R . Створюємо нейроподібну структуру на основі МГП, архітектуру якої зображено на рис. 4.



Рис. 7. Структурна схема нейроподібної структури на основі МГП, яка відтворює дванадцять незалежну головну компоненту

Остаточно спрогнозоване вихідне значення обчислюємо за формулою

$$y^* = \tilde{y} + \tilde{R}.$$

Точність прогнозування вихідного значення наведено в табл. 2.

Таблиця 2

Тренування				Тестування			
Тип похибки	Тип формули			Тип похибки	Тип формули		
	Лінійний поліном + RBF	Лінійний поліном Паде + RBF	Степеневий поліном + RBF		Лінійний поліном + RBF	Лінійний поліном Паде + RBF	Степеневий поліном + RBF
MAPE	0,45 %	0,31 %	0,27 %	MAPE	3,1 %	2,8 %	2,6 %
RMSE	3 %	2,6 %	2,34 %	RMSE	4,07 %	3,77 %	3,56 %

Висновки

Застосування нейроподібних структур МГП забезпечує надійний і швидкий розв'язок задач передбачення і класифікації для систем ІАД, зокрема в умовах невизначеностей, пропусків в даних, виродженості даних.

Метод передбачення з незалежним виділенням головних компонентів інформаційної моделі, можливий лише за умов застосування нейромереж МГП, забезпечує як високу точність навчання, так і можливість генералізації за рахунок поєднання переваг локального і глобального методів передбачення.

1. Васильев В.И., Коноваленко В.В., Горелов Ю.И. Имитационное управление неопределенными объектами. – К.: “Наукова думка”, 1989. – 216с. 2. Дорошенко А.В. Нейромережний розв'язок задач класифікації в умовах неповноти інформаційного базису // Моделювання та керування станом еколого-економічних систем регіону: Зб.наук.пр.–К., 2006. – Вип.3. – С. 115–122. 3. Ткаченко Р.О. Модель нейронних мереж // Вісник Держ. ун-ту “Львівська політехніка”: Комп'ютерна інженерія та інформаційні технології. – 1998. – № 349. – С.83–86. 4. Ткаченко Р.О. Нейронні мережі з нелінійними синаптичними зв'язками // Вісник Держ. ун-ту “Львівська політехніка”: Комп'ютерні системи проектування. Теорія і практика. – 1999. – № 373. – С.20–22. 5. Ткаченко Р.О., Ткаченко П.Р. Багатошаровий перцептрон з неітеративним навчанням // Збірник матеріалів міжнародної наукової конференції “Інтелектуальні системи прийняття рішень та прикладні аспекти інформаційних технологій” (ISDMIT' 2005). – Т.5. – С.69–73. 6. Tkachenko R., Tkachenko P., Tkachenko O., Schmitz J. Geometrical Data Modelling // Збірник матеріалів міжнародної наукової конференції “Інтелектуальні системи прийняття рішень та прикладні аспекти інформаційних технологій” (ISDMIT' 2006). –Т.2. – С.279–283. 7. Хайкин С. Нейронные сети: полный курс: Пер с англ. – М.: “Вильямс”, 2006. – 1104 с. 8. Осовский С. Нейронные сети для обработки информации / Пер. с польск. И.Д. Рудинского. – М.: Финансы и статистика, 2004. – 344 с.