

НЕЙРОЕВОЛЮЦІЙНИЙ ПІДХІД ДО ПРОГНОЗУВАННЯ НЕСТАЦІОНАРНИХ ПОСЛІДОВНОСТЕЙ

Труднощі прогнозування нестационарних часових рядів обумовлені необхідністю змінення або корегування структури математичної моделі об'єкта прогнозування, що використовується, і переналаштунку всіх її параметрів. У зв'язку з цим виникає потреба в розробці нових методів і алгоритмів, які роблять можливим отримання адекватних прогнозів. Середі таких методів одним з найбільш перспективних є нейромережеві, що можуть служити основою створення інтелектуальних інформаційних систем прогнозування часових рядів, що потребують при своєму функціонуванні мінімальної участі людини.

Експериментально встановлено, що нейромережеві моделі забезпечують більшу точність при виявленні нелінійних залежностей порівняно з регресійними моделями. Деякі штучні нейронні мережі (ШНМ) є універсальними апроксиматорами, які дозволяють встановити з заданою точністю будь-яку складну неперервну нелінійну функцію, що і обумовлює їх ефективність в задачах прогнозування. Найбільш поширення при рішенні цих задач отримали такі статичні ШНМ, як багатошаровий персептрон і один з його варіантів - ШНМ з елементами затримки сигналу та радіально-базисні мережі [1].

Використання ШНМ потребує рішення задач структурної та параметричної оптимізації, які відповідають вибору оптимальної топології мережі та її навчанню (налаштуванню параметрів). Якщо задача визначення структури є дискретною оптимізаційною (комбінаторною), то пошук оптимальних параметрів здійснюється в неперервному просторі за допомогою класичних методів оптимізації. Традиційні методи визначення структури мережі полягають або в послідовному її ускладненні шляхом введення нових нейронів і нових зв'язків між ними, або в послідовному її спрощенні, починаючи з деякої досить складної топології. Найбільш відомим методом вибору топології мережі з одночасним визначенням ваг є каскадна кореляція, що використовує навчання з учителем, був запропонований С.Фалманом [2]. Основний недолік даного методу - складність розпаралелювання обчислень внаслідок наявності зв'язків між прихованими вузлами, усувається шляхом різних модифікацій даного методу (використання спрощеної каскадної кореляції, випадкового вибору шару тощо). Для навчання (налаштування параметрів) мереж використовують, як правило, методи, які потребують обчислення градієнта функціонала, що використовується: алгоритм зворотнього поширення похибки (ОР), алгоритм Гауса-Ньютона, Левенберга-Марквардта тощо, які мають цілий ряд суттєвих недоліків (рішення залежить від форми функції, що мінімізується, рішення застрягають в локальних екстремумах, а при наявності декількох екстремумів не забезпечують знаходження глобального, їх використання потребує, щоб функціонал був диференційовним тощо).

Спроби усунути недоліки традиційних методів синтезу та функціонування ШНМ привели до появи нового класу мереж - еволюціонуючих ШНМ (ЕШНМ), в яких як додаток до традиційного навчання використовується інша фундаментальна форма адаптації - еволюція, що реалізується шляхом застосування еволюційних обчислень [3]. Еволюційний підхід використовує в якості основних структурні елементи обчислювальних моделей механізмів природної еволюції, на відміну від навчання, що базується на конективістському підході до моделювання діяльності мозку за допомогою ШНМ. Якщо еволюція - досить повільний процес, який визначає закони зміни виду, то навчання є процесом більш швидким, який покращує адаптацію особини до умов, що змінюються, шляхом зміни її характеристик. Використання в ЕШНМ цих двох форм адаптації - еволюції та навчання, що дозволяє

змінювати структуру мережі, її параметри і алгоритми навчання без зовнішнього втручання, робить ці мережі найбільш пристосованими для роботи в нестаціонарних умовах і наявності невизначеності відносно властивостей існуючого об'єкта, що досліджується, та умов його функціонування. Основною перевагою використання еволюційних алгоритмів (ЕА) в якості алгоритмів навчання є те, що багато параметрів ШНМ можуть бути закодовані в геномі і визначатися паралельно. Більш того, на відміну від значної кількості алгоритмів оптимізації, які використовуються для потакового рішення задачі, ЕА оперують з множиною рішень - популяцією, що дозволяє досягти глобального екстремума. При цьому інформація про кожну особину популяції кодується в хромосомі (генотипі), а отримання рішення (фенотипу) здійснюється після еволюції (відбору, схрещування, мутації) шляхом декодування. Серед ЕА, які є стохастичними і включають еволюційне програмування, еволюційні стратегії, генетичні алгоритми, генетичне програмування, зокрема, програмування з експресією генів, одним з найбільш поширених є генетичні алгоритми (ГА), які абстрагують фундаментальні процеси дарвінівської еволюції: природного відбору і генетичних змін внаслідок рекомбінації і мутації.

Особливостями коеволюційних систем є те, що, по-перше, популяції можуть мати різний розмір; по-друге, еволюція в різних популяціях може йти на основі різних алгоритмів; в-третьє, альтернативні рішення з різних популяцій можуть бути використані для рішення задач, які відрізняються фізичною розмірністю. Взаємодія між різними популяціями може приводити до двох основних форм коеволюційних систем: - системи, в яких реалізується кооперативна поведінка; - системи, в яких реалізується конкурентна.

В роботі проведено дослідження різних структур ЕШНМ при вирішенні задачі прогнозування. Це пов'язано з тим, що структури, що виникають в кооперативних системах, можуть суттєво відрізнятися від тих, які розвиваються в конкурентних системах.

Слід зазначити, що в даних системах найбільш ефективним виявилось використання гібридного навчання, яке поєднує традиційні та еволюційні алгоритми.

Результати моделювання підтверджують ефективність використання коеволюційних нейронних мереж в задачах прогнозування, що дозволяє, по-перше, вирішувати більш складні задачі, по-друге, отримувати та використовувати більш прості структури ШНМ за рахунок зменшення кількості нейронів. Розвиток даного підходу потребує подальших досліджень.

Список використаних джерел

1. Хайкин С. Нейронные сети: полный курс. – М.: Вильямс, 2006.
2. Fahlman S., Lebiere C. The cascade-correlation learning architecture // Advances in Neural Information Processing Systems 2, D. S. Touretzky (ed.). – Los Altos CA: Morgan-Kaufmann, 1990. – Pp. 524-532.
3. Yao X. Evolving Artificial Neural Networks // Proc. of the IEEE. – 1999. – V.87. - №9. – Pp. 1423-1447.
4. Руденко О.Г., Бессонов А.А. Многокритериальная оптимизация эволюционирующих сетей прямого распространения // Проблемы управления и информатики. – 2014. – № 6. – С.29-41.1

Науковий керівник: Руденко О.Г., д.т.н., професор, професор кафедри ЕОМ ХНУРЕ