

и монотонно убывающей или седлообразной напорной характеристике насоса демпфирующего контура.

ЛИТЕРАТУРА

1. Поликовский В. И. Исследование работы насосов и воздушных машин на режимах пониженных подач / В. И. Поликовский, А. А. Левин // Теплоэнергетика. — 1966. — № 3. — С. 49—53.
2. Пилипенко В. В. Кавитационные автоколебания и динамика гидросистем / Пилипенко В. В., Задонцев В. А., Натанзон М. С. — М. : Машиностроение, 1977. — 352 с.
3. Пилипенко В. В. Кавитационные автоколебания / Пилипенко В. В. — К. : Наукова думка, 1989. — 313 с.
4. Натанзон М. С. Экспериментальное исследование кавитационных колебаний шнеко-центробежного насоса / М. С. Натанзон, П. И. Бальцев и др. // Изв. АН СССР. Энергетика и транспорт. — 1973. — № 3. — С. 151—157.
5. Гоцуленко В. Н. Экспериментальное исследование автоколебаний в системе, включающей лопастной насос с монотонно убывающей напорной характеристикой / В. Н. Гоцуленко, Н. Н. Гоцуленко // Энергомашиностроение. — 1978. — №5. — С. 44—45.
6. Гоцуленко В. В. К проблеме неустойчивости лопастных насосов при малых величинах кавитационного запаса / В. В. Гоцуленко, В. Н. Гоцуленко // Наукові праці ДонНТУ. — 2002. — Вип. 51. — С.64—68.
7. Гоцуленко В. В. Вибрационное горение и термоакустические автоколебания / Гоцуленко В. В. — LAMBERT Academic Publishing, 2012. — 152 с.
8. Казакевич В. В. Автоколебания (помпаж) в компрессорах / Казакевич В. В. — М. : Машиностроение, 1974. — 264 с.
9. Холл Дж. Современные численные методы решения обыкновенных дифференциальных уравнений / Дж. Холл, Дж. Уатт. — М. : Мир, 1979. — 312 с.
10. Гоцуленко В. В. Демпфирование автоколебаний вибрационного горения проточными динамическими демпферами / В. В. Гоцуленко, В. Н. Гоцуленко // Авиационно-космическая техника и технология. — 2011. — № 3(80). — С. 53—57.

пост.18.03.13

Про доцільність використання нейромережових методів детерміністичного прогнозування в галузі аналізу валютних котирувань на ринку Forex

О. П. ЛУЦЕНКО, О. Г. БАЙБУЗ

Дніпропетровський національний університет ім. О. Гончара

Проведено аналіз ефективності нейромережового детерміністичного прогнозування котирувань на ринку валют Forex. Описані недоліки нейромережових методів прогнозування стосовно даної предметної галузі.

Проведен анализ эффективности нейросетевого детерминистического прогнозирования котировок на рынке валют Forex. Описаны недостатки нейросетевых методов прогнозирования в применении к данной предметной области.

The effectiveness of the deterministic neural prediction on the currency market Forex has been analyzed. Disadvantages of neural network forecasting methods as applied to Forex are described.

В Україні торгівля на спекулятивному ринку фінансів і цінних паперів набула величезної популярності за останні роки. Це пов'язане передусім зі зростом можливостей обробки і розповсюдження фінансової інформації, завдяки якому фінансова торгівля стала більш досяжною для фізичних і юридичних осіб. Число учасників ринку невідомо продовжує зростати, в чому немаловажну роль грають його висока ліквідність і помірні вимоги до стартового капіталу.

В умовах зростання об'ємів операцій, що здійснюються на спекулятивному фінансовому ринку, збільшення кількості гравців на ньому і скорочення часу розповсюдження інформації та здійснення угод, надзвичайно зросла зацікавленість в автоматизованих технологіях технічного аналізу стану ринку.

Збільшення кількості учасників ринку обумовило появу конкуренції між ними. Намагаючись отримати більший прибуток, ринкові гравці проявляють великий інтерес до нових перспективних підходів технічного аналізу. Існуючі індикаторно-осциляторні методи перестають задовольняти їхні вимоги, і новітні підходи до аналізу даних стрімко набирають популярність. Серед таких технологій, в тому числі, нейромережіві.

Тим не менш, публікації щодо аналізу ефективності нейронних мереж у застосуванні до предметної області фінансових ринків практично відсутні і обмежуються маркетинговими заявами.

У зв'язку з цим було розглянуте питання ефективності прогнозування курсів валют з застосуванням класичного підходу нейромережового

прогнозування, який полягає у використанні нейронних мереж як інструменту рішення задач регресії.

Штучні нейронні мережі являють собою систему з'єднаних і взаємодіючих між собою простих процесорів (штучних нейронів). Кожен процесор подібної мережі має справу тільки з сигналами, які він періодично отримує, і сигналами, які він періодично посилає іншим процесорам. Вхід для кожного нейрона визначається за допомогою адитивної функції з ваговим коефіцієнтом і з аргументами – входами. Вихід розраховується за допомогою нелінійних функцій, які вибираються за певними правилами. На виході робиться порівняння вхідних векторних значень з реальним результатом, коректуються вагові коефіцієнти адитивних функцій. Така організація розрахунків робить можливою інтерполяцію даних нелінійними функціями майже довільної складності, в залежності від кількості нейронів у шарах мережі та активаційних функцій цих нейронів.

Серед способів використання нейронних мереж можна виділити наступні:

1) Технології розпізнавання образів. Даний підхід заснований на виділенні певних паттернів на графіках котирувань і навчанні нейронної мережі розпізнаванню цих паттернів. Серед паттернів можуть бути як фігури технічного аналізу (голова-плечі, прапор, тощо), так і інші, що виділяються самою нейронною мережею. Даний підхід використовується в декількох програмних пакетах (BioComp Patterns, частково Wave59). Підхід має значний недолік – аналіз ринку, заснований на виділенні фігур технічного аналізу, є суб'єктивним, і не існує єдиного способу виділення таких фігур. Локальні паттерни, що виділяються самою нейронною мережею, також є неоднозначними.

2) Нейромережеві технології побудови нових індикаторів на основі існуючих. Такий підхід використовується, наприклад, у Neuroshell Trader. Кожному індикатору присвоюється ваговий коефіцієнт, що підбирається на основі співставлення результатів роботи індикаторів на певній виборці даних. Даний підхід є порівняно новим і розвивається. На даному етапі його недолік полягає у тому, що кожний індикатор має різну перевагу у різних ситуаціях. Усереднену значимість індикатору на певній виборці не завжди коректно екстраполювати на інші виборки, як відбувається при використанні даного підходу. Крім того, даний підхід дозволяє лише дещо зменшити один з недоліків стандартних індикаторів, мінімізуючи кількість помилкових сигналів, але не здатний подолати інші недоліки, наприклад затримку сигналів індикаторів у часі.

3) Класичний підхід, який полягає у використанні нейронних мереж як інструменту рішення задач регресії. Здатність нейронних мереж до виявлення нелінійних залежностей між величинами дозволяє ефективно використовувати їх в деяких випадках, коли потрібно отримати прогнозне значення функції з її значень в минулому. На такому підході зупинимося докладно з ціллю проаналізувати можливості його застосування до предметної області фінансового ринку Forex.

Дані, що обробляються. При проведенні дослідження використовувалися історичні дані про ціни відкриття, закриття, мінімум і максимум цін валютних

пар, зібрані forexite.com на одногодинних проміжках у період з 2002 по кінець 2012 року. За необхідності, дані на кратних проміжках часу (в даному випадку з шагом у одну добу) обчислювалися на основі годинних даних.

Перед поданням на вхід нейронної мережі дані нормувалися таким чином, щоб потрапляти у проміжок $[-1;1]$:

$$x_i^n = \frac{2(x_i - x_{\min})}{x_{\max} - x_{\min}} - 1,$$

де x_i - вихідне значення ціни з ряду-вибірки,

x_i^n - нормалізоване значення,

x_{\min} - мінімальне значення з вибірки,

x_{\max} - максимальне значення з вибірки.

Для навчання мережі використовувався змішаний підхід: до моменту, коли значення помилки прогнозування не досягало відносно стабільного значення, навчання проводилося методом зворотного розповсюдження помилки. При сповільненні зменшення помилки проводилося до 5 ітерацій методом імітації віджигу з ціллю вийти з можливого локального екстремуму.

У алгоритмі зворотного поширення помилки відбувається поширення помилки від виходів нейронної мережі до входів, тобто в напрямку, зворотному поширенню сигналів у звичайному режимі роботи. Цільовою функцією мінімізації помилки нейронної мережі є величина середньоквадратичної помилки:

$$RMSE = \frac{1}{n} \sum \sqrt{(x_i - x_{\text{розр } i})^2}$$

де $x_{\text{розр } i}$ - реальний стан i -го вихідного нейрону при поданні на його вхід певного образу;

x_i - бажаний стан вихідного нейрону (експериментальне значення функції).

Сумування проводиться по всім вихідним нейронам. Мінімізація відбувається методом градієнтного спуску, тобто ваги нейронів змінюються наступним чином:

$$\Delta w_{ij} = -\eta \frac{\partial RMSE}{\partial w_{ij}}$$

де η - величина, що контролює швидкість навчання.

Алгоритм зворотного розповсюдження помилки не потребує великої кількості обчислень і характеризується досить швидкою зходимістю. В той же час, ймовірність знаходження ним локального мінімуму замість глобального є меншою, ніж така ймовірність при використанні алгоритму прямого розповсюдження. Для гарантованого виключення заходу в локальні мінімуми разом з даним алгоритмом був застосований ще один алгоритм навчання – алгоритм імітації віджигу.

Алгоритм імітації віджигу є в даний час одним з найпопулярніших алгоритмів для вирішення задач оптимізації. Перш за все, він використовується для розміщення мікросхем на друкованих платах, але використовується для навчання нейронних мереж порівняно малої розмірності – з числом синаптичних ваг і зміщень порядку декількох сотень [1].

Алгоритм імітації віджигу заснований на моделюванні фізичного процесу, який відбувається при кристалізації речовини з рідкого стану в твердий.

Передбачається, що процес протікає за спаданою температурою, а атоми вже вишикувалися в кристалічну решітку, однак переходи атомів з однієї комірки в іншу ще можливі. Імовірність цих переходів залежить від температури: чим нижче температура, тим нижче вірогідність. Стійка кристалічна структура речовини відповідає мінімальному значенню енергії.

При рішенні задачі аналогом решітки є сукупність ваг w_{ij} . Параметром, який мінімізується (еквівалентом енергії), є величина помилки. На кожній ітерації рішення величини змінюються у напрямі градієнту, що вказує в бік зменшення помилки, на величину, значення якої тим більше, чим більший параметр «температура». З кожною ітерацією «температура» поступово зменшується, приводячи до зменшення кроків і поступового наближення до оптимального значення помилки.

На роботу даного алгоритму не впливають локальні мінімуми, але його недоліком є мала швидкість роботи. З цієї причини він застосовувався не частіше, ніж 5 ітерацій імітації віджигу на 100 ітерацій навчання.

При рішенні задачі розглядалося три конфігурації нейронної мережі, що відрізнялися набором вхідних даних.

Конфігурація 1. Для прогнозування використовувалися тільки величини приросту котирувань за кожний період часу. По навчальній вибірці заданої глибини нейронна мережа повинна була встановити залежність між даними ряду шляхом інтерполяції і екстраполювати її на наступні часові періоди. Вихідною величиною є значення приросту ціни в наступний період часу.


Експериментальним шляхом встановлювалися наступні параметри: глибина передісторії (період основи прогнозу), величина навчальної вибірки, кількість шарів нейронної мережі, кількість нейронів у кожному з них. Критерієм вибору кращої конфігурації слугувало значення середньоквадратичної помилки прогнозування і візуальна розбіжність прогнозних і реальних значень на графіку.

В даній постановці задачі найкращий результат був досягнений при основі прогнозу 20 періодів (20 вхідних нейронів) при використанні нейронної мережі з двома прихованими шарами – 60 і 40 нейронів відповідно (в 3 і 2 рази більше за кількість у вхідному шарі). Зі збільшенням основи прогнозу відбувалася втрата точності як інтерполяції, так і екстраполяції внаслідок нестачі вхідних даних на навчальній вибірці, збільшення неоднозначності вхідних даних (значення цін на надто старих часових періодах мало впливають на прогноз, але збільшують кількість вхідних нейронів, збільшуючи складність інтерполяції). При збільшенні кількості нейронів і додавання ще одного прихованого шару якість навчання нейронної мережі відчутно падала, до повної втрати здатності до навчання. Оптимальна величина навчальної вибірки знаходиться в межах 200-300 днів. При меншій величині помилка прогнозування збільшується через перенавчання (при гарній якості інтерполяції, отримані закономірності не екстраполюються за межі навчальної вибірки), в той час як при подальшому збільшенні навчальної вибірки непринятною стає точність інтерполяції (занадто збільшується неоднозначність вхідної вибірки).


Слід відмітити, що навіть при кращій

конфігурації з протестованих якостей екстраполяції знайдених закономірностей не може вважатися задовільною для практичного використання, так як середньоквадратична помилка на невідомих даних сягає 0,7-0,8 при вхідних даних, нормалізованих на проміжку від -1 до 1, проти помилки в межах 0,05 на знайомій вибірці.

Результати роботи мережі наведені на *рис. 1*. Вертикальною лінією позначена межа між даними, що були в навчальній вибірці, і даними, що не були відомі нейронній мережі.



а



б

Рис. 1. Результати роботи нейронної мережі: а – один прихований шар, б – два прихованих шари.

Конфігурація 2. Разом з вихідними даними на вхід нейронної мережі подавався додатковий вектор параметрів: приріст середніх значень за короткий і довгий період часу (приріст ковзних середніх кривих), а також приріст індексу відносної сили (RSI). Як і в попередньому випадку, вихідним параметром є значення приросту ціни.

В даному випадку істотно збільшується кількість вхідних нейронів (так, для основи прогнозу у 20 періодів вхідних нейронів буде 80). Використання кількох прихованих шарів нейронів з кількістю нейронів більше, ніж у вхідному шарі призводить до настільки повільного темпу зменшення помилки при навчанні, що стає можливим говорити про повну нездатність нейронної мережі до навчання. В цьому випадку прийнятної якості інтерполяції (середньоквадратична помилка в межах 0,05-0,1 на знайомій вибірці) вдалося досягти лише при використанні одного прихованого шару. При кількості прихованих нейронів, рівній кількості нейронів у вхідному шарі, були отримані наступні результати:

- При значеннях середньоквадратичної помилки 0,07-0,08 на навчальній вибірці, на незнайомих даних помилка становить 0,5-0,6. Це менше, ніж у попередньому випадку, при меншій кількості прихованих нейронів, однак, як і в попередньому

випадку, така якість екстраполяції малоприйнятна для практичного використання.

- На відміну від попереднього випадку, в даному випадку нейронна мережа показала чутливість до наявності великих значень в навчальній вибірці, які впливають на результат нормалізації даних. При запусках навченої нейронної мережі відрізках навчальної вибірки, але з вилученими великими значеннями (в результаті змінюються абсолютні значення даних у нормалізованій вибірці, при збереженні співвідношення між ними), якість інтерполяції знайомих даних падала (рис. 2). Така особливість, що не була властива нейронній мережі у випадку 1, звужує можливість практичного використання розглянутого підходу.

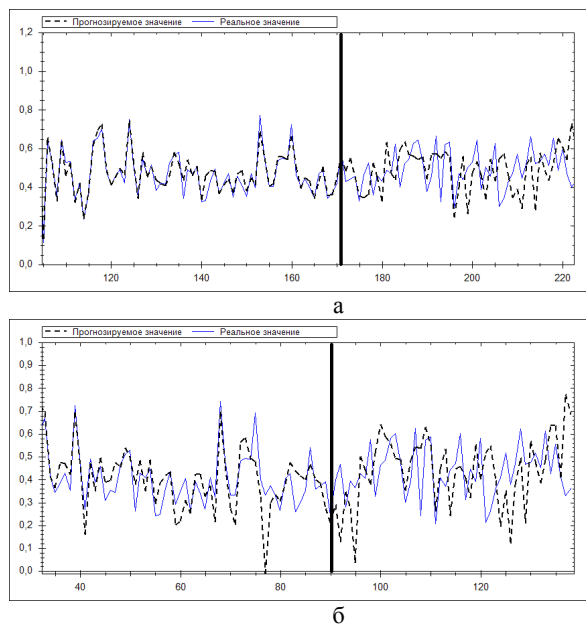


Рис. 2. Залежність результатів роботи мережі від екстремальних значень ряду: а – екстремуми навчальної і тестової вибірок приблизно рівні, б – екстремуми відрізняються.

Конфігурація 3. В третьому випадку часовий ряд валютних котирувань розглядається не як множина окремих точок, а як сукупність стаціонарних відрізків, на які він розбивається точками розладнань.

Знаходження точок розладнань ряду дозволяє розділити ряд на ділянки з подібними статистичними властивостями, що відповідає одній з основних парадигм технічного аналізу – розподілу часового ряду на відрізки з постійною тенденцією [2].

Оскільки в даному випадку використовуються інтервали часу змінної довжини, необхідно оцінювати не тільки приріст ціни на інтервалі, а і довжину самого інтервалу.

Нехай після розбиття маємо n відрізків стаціонарності. Кожен з відрізків характеризується вектором параметрів v , що включає його тривалість у часі (довжину по осі x), різницю між цінами на початку і у кінці відрізка (різницю по осі y), а також допоміжні величини, що характеризують дані в середині проміжку: математичне очікування, дисперсію, фрактальний показник, тощо. На основі цих даних на певній кількості

d попередніх інтервалів необхідно визначити характеристики наступного відрізка стаціонарності: як мінімум – тривалість у часі та різницю цін (рис. 3).

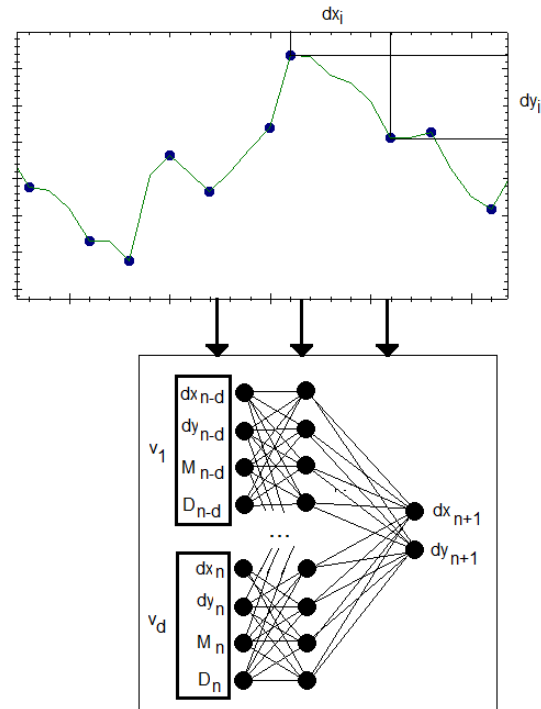


Рис. 3. Розбиття ряду на відрізки стаціонарності за допомогою алгоритму пошуку розладнань.

На жаль, в даному випадку нейронні мережі показують низьку точність. Навіть при прийнятній точності інтерполяції, отримані залежності практично не екстраполюються на незнайомі вибірки. Негативний результат може бути пояснений наступними причинами:

- 1) На відміну від випадків 1 і 2, в даному випадку часовий ряд цін є неевклідидастним, що значно ускладнює його прогнозування.
- 2) Довжина часових інтервалів є слабо корельованою величиною.

В даному випадку середньоквадратична помилка прогнозу на незнайомих вибірках при різних комбінаціях вхідних даних, активаційних функцій нейронів і кількості прихованих нейронів становить 0,9-1,0 і майже не відрізняється від результату, отриманого за допомогою не навченої мережі. Використання інформації про статистичні властивості даних всередині інтервалів в різних комбінаціях (середнє значення, мінімум, максимум, фрактальний показник, тощо) не впливає на якість прогнозу.

Отримані результати вказують на недостатність ефективності нейронних мереж як інструменту прогнозування стану фінансового ринку FOREX, що пов'язане з:

- 1) високою динамікою даного виду ринку;
- 2) недостатньою тривалістю закономірностей, що діють на ринку, що ускладнює виявлення цих закономірностей, так і їхню екстраполяцію на наступні часові відрізки, а також унеможлиблює використання великих навчальних вибірок даних;

