
НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ БИРЖЕВОЙ ДИНАМИКИ

Калайдин Евгений Николаевич,

доктор физико-математических наук, профессор кафедры теоретической экономики Кубанского государственного университета; kalaidin@econom.kubsu.ru

Дюдин Михаил Сергеевич,

аспирант кафедры теоретической экономики Кубанского государственного университета; diudin.m@yandex.ru

В статье рассматриваются прикладные аспекты нейросетевого моделирования зашумленной биржевой динамики.

Ключевые слова: биржевые цены, нелинейная динамика, случайный шум, нейронные сети.

В 90-х годах складывается новый подход к объяснению динамики фондовых рынков – гипотеза фрактального рынка (ФМН) [1, 2, 3, 4]. В противоположность гипотезе эффективного рынка (ЕМН), согласно которой ценовая динамика является случайной, ФМН предполагает, что рынки движутся по хаотическим нелинейным закономерностям, самоподобным в масштабе (фрактальными). При этом в динамике так же присутствует некоторая доля случайного шума (Яновский, Филатов, теория частично детерминированных временных рядов, [5, 6]). Нейросетевые модели позволяют моделировать и прогнозировать нелинейную хаотическую динамику. Представляет интерес вопрос, насколько сильно случайный шум способен помешать обучению нейронной сети и привести к отклонению прогноза от реальной динамики.

Теорема Такенса для нелинейных хаотических динамических систем доказывает, что по m ($m \geq 2d+1$, где d – размерность вложения) предыдущим значений временного ряда возможно реконструировать многомерное фазовое пространство системы. Так же теорема обосновывает существование функции F , которая однозначно определяет значение следующего элемента ряда по m предыдущим значениям.

$$x_{k+1} = F(x_k, x_{k-1}, \dots, x_{k-m+1}).$$

Таким образом, по m предыдущим значениям ряда теоретически возможно определить $(m+1)$ -е значения ряда. Эту функцию можно попытаться определить по имеющемуся временному ряду. Для этой задачи могут быть использованы нейронные сети, которые с математической точки зрения являются универсальными аппроксиматорами. Наличие нелинейных функций активации в составе нейронной сети позволяет моделировать сложную нелинейную динамику, если она является детерминированной.

Для задачи прогнозирования нелинейных временных рядов оптимальной является модель многослойного персептрона. Обычно нейронная сеть состоит из входного слоя, на который подается входящий сигнал, одного или нескольких скрытых слоев, через которые проходит входной сигнал, и одного выходного слоя. Обучение такой сети проводится при помощи алгоритма обратного распространения ошибки, который основывается на правиле коррекции ошибок. Фактически, оно является обобщением минимизации среднеквадратичной ошибки. Алгоритм обратного распространения ошибки был разработан в 1986 году [7, 8]. Алгоритм обратного распространения ошибки, применяемый в данной работе, подробно изложен в [9]. В кратком изложении, настройка синаптических весов происходит по обучающей выборке. Ошибка вычисляется как разность между выходным и целевым вектором, в зависимости от полученной ошибки корректируются веса нейронов по правилу обратного распространения ошибки.

Для исследования возможности прогнозирования финансовых временных рядов написана программа. Используется нейронная сеть типа «многослойный персептрон», обучение нейронной сети обучается алгоритмом обратного распространения ошибки. Вычислительная часть алгоритма написана на Visual Fortran для ускорения работы алгоритма, параметры нейросети задаются в визуальной оболочке, написанной на Visual Basic. Для Visual Fortran существуют библиотеки для работы с нейронными сетями, но для программы используется самостоятельно написанный алгоритм, для того чтобы иметь возможность настраивать его в соответствии с особенностями проводимых вычислений. Возможно выбирать участки временного ряда для обучения и для тестирования, производить прогнозирование, менять параметры нейросети, такие как функции активации (логистическая, гиперболический тангенс, линейная), количество нейронов в слоях, скорость обучения, коэффициенты функции активации. Нейросеть состоит из 1-го входного, 1-го скрытого и одного выходного слоя. По умолчанию используется логистическая функция активации на скрытом слое и линейная на остальных.

Проверим возможность моделирования нелинейной динамики нейронной сети на модельных данных. Система Лоренца – одна из наиболее сложных модельных хаотических динамических систем (число переменных – 3, фрактальная размерность – 2,08, шаг временного ряда – 0,05 секунды). Обучение проводится на первых 200 элементах ряда. Число элементов, подающихся в нейронную сеть – 7 ($m \geq 2d+1$, $d=2,08$). Число нейронов на входном слое – 7, на скрытом – 10, на выходном – 1. Скорость обучения – 0,01, коэффициент логистической функции активации – 0,005. Прогнозирование проводится на интервале от 193-го до 500-го элемента. Хороший результат получен после 500-800 обучений сети. Несмотря на относительно высокую ошибку, аттрактор системы Лоренца реконструирован достаточно точно. На рис. 1 справа – ряд, спрогнозированный на 300 элементов вперед по 7-ми элемента с 193-го до 200-го, слева – действительные значения ряда. Первые 30 элементов прогноз совпадает с

действительными значениями ряда, затем динамика нейро-сетевой модели и ряда Лоренца расходятся, хотя их динамика относительно близка до 150-го – 180-го элемента. Прогнозированием на 10000 элементов вперед получен временной ряд. Корреляционная размерность полученного ряда составила 2,01, размерность вложения – 3. Фазовый портрет аналогичен фазовому портрету ряда Лоренца, за исключением редких отклонений траектории (как, например, на 25-28 элементах на правом графике на рис. 1).




Рис. 1. Нейросетевая модель ряда Лоренца (справа) и исходный ряд Лоренца, по которому проводилось обучение

Таким образом, возможно точное прогнозирование нелинейной хаотической динамики на достаточно длинный горизонт прогноза.

В биржевой динамике присутствует некоторая доля случайного шума, зависящая от конкретной ценной бумаги и частоты данных. Яновский, Филатов в [5, 6] предложили теорию частично детерминированных временных рядов, предложен метод оценки случайной компоненты по наклону графика корреляционной размерности. В [10] предложен метод оценки случайной компоненты во временном ряде по началу линейного участка на графике корреляционного интеграла.

Проводятся вычисления с рядом Лоренца с добавленным динамическим шумом, равномерно распределенным на интервале $[-1;1]$. Обучение и тестирование нейросети проводится с теми же параметрами, что и выше. Результат представлен на рис. 2. Прогнозирование достоверно (с небольшой погрешностью) на глубину 15 элементов. Смоделировать систему Лоренца и воссоздать аттрактор с соответствующими фрактальными свойствами не удалось. При этом добавленный динамический шум составляет достаточно небольшую долю относительно размера ряда.




Рис. 2. Нейросетевая модель ряда Лоренца, (справа) обученная по зашумленным данным (слева)

Прогнозирование модельных рядов с еще большей долей добавленного динамического шума дало еще худшие результаты, успешное прогнозирование на несколько элементов вперед зависит от наличия случайных воздействий на прогнозируемом участке ряда. Если случайных воздействий на прогнозируемом участке нет или они невелики, возможно прогнозирование на небольшое количество шагов.

Проведены вычислительные эксперименты с реальными экономическими данными. Ряды высокочастотных доходностей не поддаются моделированию из-за высокой доли шума. В части случаев удалось достаточно точно прогнозировать динамику на 1-3 шагов вперед.




Рис. 3. Динамический шум в нелинейной динамике

Таким образом, можно выделить две причины, по которым точное моделирование реальной экономической динамики на длинный временной интервал при помощи нейросетей невозможно. Это невозможность предсказания на большую глубину прогноза, так как имеют место случайные воздействия на ряд, которые в любой момент могут изменить траекторию системы, и сложность моделирования динамической системы обучением по зашумленным данным.

Основную проблему при обучении составляет наличие шума в целевой выборке. Наличие динамического (не наблюдаемого) шума во входных данных не представляет проблемы, более того его удаление нежелательно, так как он является частью динамики системы (рис. 3). Таким образом, теоретически динамический шум не должен служить препятствием для реконструкции аттрактора динамической системы. Эволюция системы после случайного отклонения так же содержит информацию о закономерности, по которой движется система. Основным препятствием являются случайные отклонения в целевой выборке при обучении нейронной сети (x_1 , x_2 на рис. 3). Сами по себе случайные отклонения в отличие от динамического шума успешно сглаживаются скользящими средними (простое усреднение не подходит, так как меняется частота данных).

Для снижения влияния случайного шума на обучение предлагается вычисления с использованием в качестве целевой выборки сглаженных методом скользящего среднего данных, при этом входные данные не должны сглаживаться. Модифицируем алгоритм скользящего среднего так, чтобы не изменять длину сглаживаемого ряда (интервалы длиной $m/2$ в начале и в конце ряда заполняются несглаженными данными). Таким образом, исходный, не сглаженный ряд подается на вход нейронной

сети, в качестве целевых данных подается ряд, сглаженный так, чтобы максимально снизить долю случайного шума, минимизировав потери детерминированной динамики (скользящее среднее применяется несколько раз, пока уменьшается корреляционная мера шума [10] и не слишком снижается корреляционная размерность).

Для проверки метода проведем эксперименты с модельными данными. В ряд Лоренца с вероятностью 10% добавляется равномерно распределенный на диапазоне $[-2;2]$ аддитивный случайный шум. Обучение обычным методом не дает удовлетворительных результатов. Обучение с использованием модифицированного алгоритма (целевая выборка сглажена скользящим средним по 5 элементам) дало результат, указанный на рис. 4. По зашумленной обучающей выборке, указанной на рисунке, обучена нейросеть, которая реконструирует аттрактор системы Лоренца.




Рис. 4. Нейросетевая модель ряда Лоренца (справа) обученная по зашумленному ряду Лоренца (слева)

Фазовый портрет нейросетевой модели сохраняет основные особенности системы Лоренца (расположение фокусов, направление траекторий, расположение в пространстве). Нейросетевая модель имеет больше сходства с системой Лоренца, чем зашумленный ряд Лоренца, по которому проводилось обучение.

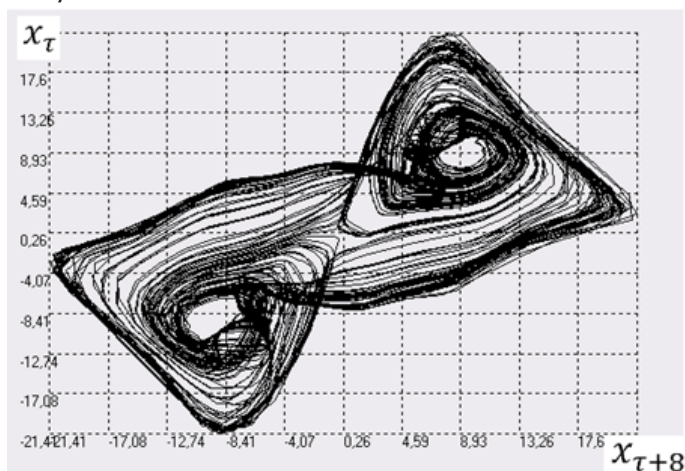


Рис. 5. Фазовый портрет нейросетевой модели обученной по зашумленному ряду Лоренца в 2-х мерном пространстве

Корреляционная размерность смоделированного нейросетью аттрактора

составляет 1,97, размерность вложения – 3.

Аналогичные вычисления с более зашумленными рядами также показали лучшие результаты, чем стандартный алгоритм.

Таким образом, данный алгоритм позволяет моделировать динамику нелинейной хаотической системы даже при достаточно высоком уровне шума. При высокой доле случайного шума нейросетевая модель обладает лишь общими чертами моделируемой системы.

Рассмотрим почасовую динамику курса евро/доллар. Исследуется доходности с периодом 20. Ряд масштабирован умножением на 200. Ряд сглаживается простым скользящим средним 10 раз по 2 элемента. На рис. 6 слева представлена обучающая выборка из 500 элементов, справа нейросетевая модель ряда из 500 элементов. В смоделированном ряде отсутствует случайный шум, поэтому его динамика выглядит менее хаотической, чем у исходного ряда. Корреляционная размерность исходного ряда – 2,3, корреляционная размерность ряда, смоделированного нейронной сетью – 2,16 при меньшем линейном участке.




Рис. 6. Нейросетевая модель динамики курса евро/доллар (справа) обученная по данным на графике слева

Далее на рис. 7 представлены графики спрогнозированного значения ряда на 100 элементов вперед (слева) и реальные значения ряда (справа). На рис. 7 слева пунктиром показываются результаты прогнозирования на 1 шаг вперед. Правильно прогнозируются значения ряда на 4 элемента вперед. При прогнозировании на 1 элемент вперед первые 70 элементов ошибка не превышает величину случайного шума в ряде на большей части интервала либо превышает незначительно на остальной части, (корреляционная мера шума [10] – 3,22, больше чем 31% элементов ряда) далее ошибка увеличивается.




Рис. 7. Прогноз полученный при помощи нейростевой модели (справа) и реальная динамика ха этот период (слева). Пунктиром на левом графике показано прогнозирование на 1 шаг

Таким образом, проведенные вычисления показывают, что алгоритм обучения нейронной сети, при котором в качестве целевых данных подаются данные со сглаженным случайным шумом, стабильно дает лучшие результаты, чем стандартный алгоритм как в случае модельных, так и в случае реальных временных рядов. Помимо практической значимости, этот факт доказывает, что основным препятствием при нейросетевом моделировании реальной нелинейной динамики является случайный шум. Главную роль в процессе обучения рассмотренным алгоритмом играет сглаживание данных для снижения доли случайного шума. Можно предположить, что дальнейшее совершенствование нейросетевого моделирования экономической динамики состоит в усовершенствовании методов сглаживания случайного шума.

В статье рассмотрено нейросетевое моделирование частично детерминированных нелинейных временных рядов, предложен модифицированный алгоритм обучения нейронной сети, которая дает лучшие результаты, чем стандартный результат. Выявлены причины, по которым достоверное прогнозирование на большой горизонт невозможно. Случайный шум приводит к отклонению ценовой динамики, что делает невозможным её точное прогнозирование на долгий срок. Случайный шум в финансовых временных рядах является динамическим, и его невозможно оценить статистическими характеристиками. При таком подходе основным критерием, по которому следует выбирать рыночный инструмент и срок инвестиций, является доля случайной компоненты в ценовой динамике. При значительной доле случайной компоненты использование любых математических методов не может дать достоверных результатов.

Аналогичные вычисления, показавшие те же результаты, проводились с другими рыночными инструментами. На основе проведенных вычислений можно выделить следующие особенности нейросетевого моделирования нелинейной динамики:

1. Для моделирования нелинейной динамики не требуется большого количества нейронов на скрытом и входном слоях. Нейросети с большим количеством нейронов на скрытом слое (30-50) аппроксимируют любую (в том числе и случайную) динамику с высокой точностью ($E_{av} < 10^{-3}$), но обычно не способны прогнозировать её даже на 1 шаг. В тех случаях, когда удавалось достаточно точно моделировать нелинейную динамику (как в случае незашумленных модельных данных, так и в случае зашумленных модельных и реальных данных), число нейронов на входном слое составляло 7-12, на скрытом – 10-20.

2. Не требуется очень низкой ошибки обучения, так как можно переобучить сеть по данной выборке. При прогнозировании реальной динамики случайные отклонения значительно превышают возможную ошибку обучения.

3. Наилучшие результаты дает моделирование рядов доходностей с периодом большим 5 для данных частотой менее часа и большим 10 для бо-

лее высокочастотных данных.

4. Прогнозирование дальше, чем на 1 шаг вперед зависит от случайных отклонений, которые будут иметь место в прогнозируемой динамике. Ошибка прогноза может быть больше чем диапазон значений случайного шума (так как случайное воздействие может отклонить траекторию системы). Данное ограничение относится к любым математическим методам и моделям, аппроксимирующих ценовую динамику фондовых рынков.

В целом, нейросетевое прогнозирование с применением предложенного в данной статье метода обучения нейронной сети может дать приемлемые результаты на коротком горизонте прогноза при выборе рыночного инструмента и срока инвестиций с минимальным уровнем случайного шума в динамике и при эффективной обработке данных.

Список источников

1. Mandelbrot, B.B. Fractals and Scaling in Finance [текст] / B.B. Mandelbrot. – New York: Springer New York, 1997.

2. Mandelbrot, B.B. Statistical methodology for non-periodic cycles: from the covariance to R/S analysis [текст] / B.B. Mandelbrot // Annals of Economic and Social Measurement 1. – 1972. – P. 259 – 290.

3. Peters, E.E. Chaos and order in the capital markets [текст] / E.E. Peters. – New York: Wiley New York, 1991.

4. Peters, E.E. Fractal Market Analysis. Applying Chaos Theory to Investment & Economics [текст] / E.E. Peters. – J. Wiley & Sons, New York, 1994.

5. Яновский, Л.П. Оценка степени детерминированности временных рядов валют и курсов акций на российском финансовом рынке [текст] / Л.П. Яновский, Д.А. Филатов // Экономическое прогнозирование: модели и методы 2004 г. Материалы Всероссийской научно-практической конференции. 18-19 марта 2004 г. 2 часть. Под редакцией В.В. Давниса. – Воронеж: ВГУ, 2004. – С. 228 – 232.

6. Яновский, Л.П. О соотношении случайного и детерминированного хаоса на российском валютном рынке [текст] / Л.П. Яновский, Д.А. Филатов // Актуальные проблемы планирования и прогнозирования. (Посвящается 100-летию со дня рождения Н.А. Вознесенского). Ч.3: Методы математического и компьютерного планирования и прогнозирования в экономике. Материалы международной научно-методической конференции. 10-13 декабря 2003 г. – Орел: ОГУ, 2004. – С. 132 – 137.

7. Rumelhart, O.E. Learning representations of backpropagation errors [текст] / O.E. Rumelhart, G.E. Hinton, R.J. Williams. – London, 1986. – Vol. 323. – P. 533 – 536.

8. Rumelhart, O.E. Parallel Distributed Processing: Explorations in the Microstructure of Cognition [текст] / O.E. Rumelhart, J.L. McClelland. – Cambridge, MA: MIT Press, 1986. – vol. 1.

9. Хайкин, С. Нейронные сети: полный курс: Пер. с англ. 2-е изд [текст] /

С. Хайкин. – М.: Издательский дом "Вильяме", 2006. – 1104 с.

10. Дюдин, М.С. Определение доли шума в хаотических временных рядах. Влияние шума на корреляционный интеграл [текст] / М.С. Дюдин, Е.Н. Калайдин // Актуальные проблемы экономики, социологии и права в современных условиях: сб. научн. тр. – Пятигорск, 2010. – С. 149 – 153.

NEURAL NETWORK MODELING OF EXCHANGE DYNAMICS

Kalaidin Eugeny Nikolayevich,

Dr. Sc. of Physics and Mathematics, Professor of the Chair of Theoretical Economics of Kuban State University; kalaidin@econom.kubsu.ru

Dyudin Mikhail Sergeyeovich,

Post-graduate student of the Chair of Theoretical Economics of Kuban State University; diudin.m @ yandex.ru

The article deals with applied aspects of neural network modeling of universe exchange dynamics.

Keywords: stock prices, nonlinear dynamics, random noise, neural networks.