

Прогнозирование котировок на финансовых рынках с помощью искусственных нейронных сетей

Юрий САФРОНОВ



Аспирант кафедры денежного обращения, кредита и фондового рынка Белорусского государственного экономического университета

Ключевые слова:

котировка, финансовый рынок, прогнозирование, биржевая торговля, нелинейные динамические модели, нейронные сети.

Результативность применения традиционных методов прогнозирования финансовых активов (акций, облигаций, валют), которые свободно продаются и покупаются на биржах, можно назвать ограниченной. Ограниченность стандартных методов заключается в их зависимости от исходных условий и отсутствии гибкости. Задаваемые в моделях жесткие статистические предположения о свойствах финансовых временных рядов лимитируют возможности методов математической статистики, теории распознавания образов, теории случайных процессов и т. п. Традиционные статистические модели не способны учитывать то, что относительная значимость отдельных параметров финансовых временных рядов и определяющих их факторов в сегодняшней динамичной финансовой среде меняется со временем, зачастую очень резко и непредсказуемо. Кроме

того, традиционные подходы прогнозирования характеризуются ограниченной информативностью, они разработаны для отображения качественных факторов или закономерностей в количественных терминах.

В силу вышеупомянутых причин на смену традиционным методам прогнозирования финансовых временных рядов должны прийти новые, более эффективные подходы в условиях структурной нестабильности современной мировой экономики в целом и белорусской экономики в частности. В последнее время большое внимание стало уделяться исследованию и прогнозированию финансовых временных рядов с использованием теории динамических систем, или теории хаоса [1]. В современной науке это достаточно новая область, представляющая собой популярный и активно развивающийся раздел математических методов анализа [1].

Как правило, финансовые процессы, в том числе и показатели финансовых рынков, не могут быть достоверно оценены с помощью традиционных статистических моделей, так как такие модели являются нелинейными и им присуща либо хаотическая, либо квазипериодическая, либо смешанная (стохастика + хаос-динамика + детерминизм) природа [2, с. 399]. В такой ситуации адекватным инструментом для решения задач прогнозирования финансовых временных рядов могут стать нейронные сети, построенные на базе искусственного интеллекта. Программно-математической основой таких методов анализа временных рядов выступают самоорганизующиеся нейронные сети (НС) [3, с. 479].

На сегодняшний день методы искусственных сетей хоть и ограничено, но используются в области экономики и финансов и показали высокую эффективность [1]. Искусственные нейронные сети пришли в сферу финансов из нейрокомпьютинга – динамично развивающегося в последние годы раздела вычислительных технологий, исследования в данной области были протипулированы исследованиями мозга [4]. В нейронных сетях вычислительные операции выполняются раздельно большим количеством относительно простых процессорных элементов. Структура нейронной сети соответствует математической структуре вычислительной системы, где все операции производятся в отдельных узлах, а поток информации представляется направленными ребрами графа. Каждый узел сети (нейрон) представляет собой процессорный элемент, своеобразную нейроноподобную ячейку, образующую большую нейронную вычислительную сеть, комбинируясь с другими процессорными элементами. В природе аналогом узла нейронной сети (нейроном) является клетка головного мозга человека.

В целом искусственная нейронная сеть является адаптивной нелинейной динамической системой. С помощью равновесных состояний нейронной сети можно решать различные математические и вычислительные задачи. Различают два вида нейронных сетей [1]:

- сети, обучаемые с учителем;
- сети смешанного обучения.

Нейронные сети, обучаемые с учителем, являются средством для извлечения из области дан-

ных информации о связях между входами и выходами нейросети. Такие связи могут быть представлены в виде математических уравнений, которые затем можно применять для прогнозирования и последующего принятия управленческих решений. «Учителем» в таком варианте выступает набор параметров, который аналитик устанавливает на выходе сети. На входе нейронной сети применяется соответствующий выходу входной набор данных. Такая сеть учится строить взаимоотношения между начальными данными и результатами адаптивного итерационного процесса.

Описание используемого алгоритма

Алгоритм функционирования нейронной сети, обучаемой без учителя, базируется на соревновательном обучении. Такой алгоритм предполагает соревнование входного набора данных на наилучшее соответствие заданным критериям. После того как будет определено значение наилучшего набора данных, структура сети будет подвержена коррекции. Нейронные сети, обучаемые без учителя, относятся к адаптивным нейронным сетям (далее – АНС). Адаптивные нейронные сети – численный, а не символьный метод обработки данных. Особенностями этих сетей является то, что в такой модели можно проводить расчеты с высокой степенью параллельности, благодаря интегрированным механизмам для разделения вычислительной задачи на отдельные субъединицы. АНС обладают свойством обнаруживать во входных наборах данных такие структуры и закономерности, которые не были выявлены ранее. Данное свойство дает возможность сети обобщать большие объемы многомерных данных, выявлять и наглядно демонстрировать содержащиеся в них структуры, а также обнаруживать взаимосвязи в этих наборах данных. Такие наборы данных как раз и присущи финансовым временным рядам и финансово-экономическим показателям предприятий.

Нейронные сети представляют собой мощный инструмент прогнозирования нелинейных динамических рядов. Основываясь на

генетических алгоритмах, они способны эволюционировать естественным путем, с помощью таких алгоритмов можно выявить правила и стратегии, способные решать множественные цели. Для оптимизации такой системы можно ввести одно или большее количество ограничений. Это позволяет осуществлять так называемое направленное прогнозирование, именно поэтому нейронные сети представляют собой перспективный инструмент для изучения и анализа динамики нелинейных процессов, которые характеризуются потоками входных данных.

На сегодняшний день разработано большое количество нейросистем, которые применяются в различных научных областях: прогнозировании финансовых временных рядов, показателей финансовой деятельности предприятия, управлении, диагностике в технике и медицине, распознавании образов и т. п. Для обучения сети используются различные алгоритмы обучения и их модификации [4].

Стоит также отметить, что использование нейронных сетей для прогнозирования динамических временных рядов зачастую является недостаточно гибким. Так, в процессе самообучения нейронной сети нет возможности добавления новых нейронов. Использование АНС осложняется тем, что размерность плоскости выходных параметров задается до начала обучения. Для увеличения достоверности прогноза в таких случаях метод АНС целесообразно дополнить генетическими алгоритмами [4].

Идея прогнозирования с использованием инструментов генетических алгоритмов впервые предложена еще в 70-е гг. XX века. К идее применения генетических алгоритмов вернулись в конце 80-х гг. в связи с тем, что необходимо было применить такие алгоритмы для обучения нейронных сетей. Сейчас генетические алгоритмы широко используются для вычисления банковских прогнозов [4]. Генетические алгоритмы незаменимы в случаях, когда привычное решение определенной задачи зависит от интуиции или опыта, а не строится на математическом ее описании. Механизмы

генетической эволюции разрабатываются по аналогии с мозгом человека и реализуют некоторые отдельные его особенности, появившиеся в результате эволюции, поэтому их использование для обучения нейронных сетей вполне уместно и логично.

На сегодняшний день существует большое количество разнообразных нейросетевых структур, которые отличаются друг от друга числом и расположением нейронов и их синоптических связей [1]. Самая известная нейронная структура – многослойный персептрон. Многослойный персептрон (MLP) является полносвязной моделью без обратных связей [1]. Число слоев и нейронов в персептроне зависит от конкретной задачи и вычислительных характеристик ЭВМ. Для вычисления количества весовых коэффициентов (синоптических связей) в многослойном персептроне используют формулу (1) [1]:

$$I_w = \sum_{i=1}^{N_L-1} \hat{N}_i \hat{N}_{i+1}, \quad (1)$$

где N_L – количество слоев в искусственной нейронной сети;

\hat{N}_i – количество нейронов на i -ом слое.

На рисунке 1 представлен персептрон, у которого присутствует один скрытый слой с 7 нейронами, входной слой с 3 нейронами, а выходной слой содержит 1 нейрон. Количество весовых коэффициентов равно 28.

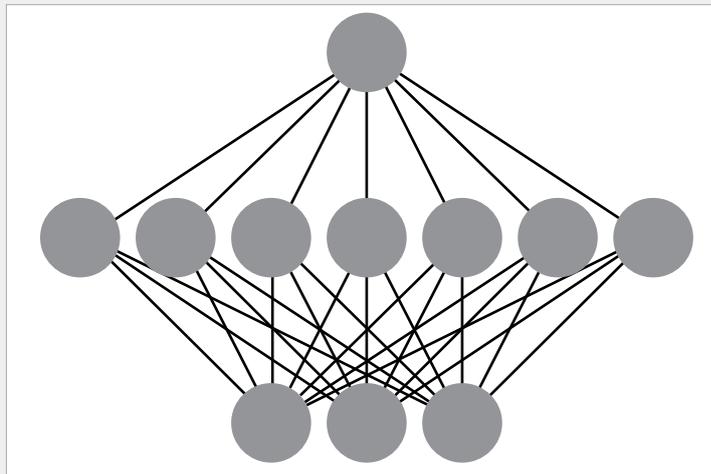
На сегодняшний день есть множество методов подбора весовых коэффициентов. В данной статье используется один из градиентных методов QuickProp, разработанный Фальманом [5]. Характерной особенностью градиентных алгоритмов является необходимость вычисления градиента по весовым коэффициентам

$$\nabla \varepsilon = \left(\frac{\partial \varepsilon(w)}{\partial w_0}, \frac{\partial \varepsilon(w)}{\partial w_1}, \dots, \frac{\partial \varepsilon(w)}{\partial w_{M-1}} \right),$$

а также изменение значений весовых коэффициентов w в противоположном направлении [6]. В случае использования алгоритма QuickProp, изменение i -ого весового коэффициента на I -ой итерации считается согласно правилу (2):

$$\Delta w_i^{(I)} = -s \times (\nabla \varepsilon^{(I-1)} + c_w \times w_i^{(I-1)}) + q_i^{(I)} \times \Delta w_i^{(I-1)}, \quad (2)$$

Многослойный персептрон, содержащий входной, выходной и скрытый слои



Примечание. Собственная разработка автора.

Рисунок 1

прогноз динамики валютной пары EUR/USD. Источником данных послужили котировки валютной пары EUR/USD (отношение евро к доллару) за май 2016 г. Значения котировок фиксировались каждую минуту. Для построения прогноза временного ряда используется структура, изображенная на рисунке 2. Анализируемая искусственная нейронная сеть имеет 12 входных нейронов, 25 скрытых и 1 выходной. Для формирования обучающей выборки используется коэффициент разряжения 15. Так как число строк обучающей выборки должно существенно превосходить число весовых коэффициентов, в данном временном ряду берем 500 обучающих примеров. Полученная обучающая выборка (5) образует недельный период и выглядит следующим образом:

где c_w – коэффициент минимизации значений весовых коэффициентов;

$q_i^{(l)}$ – коэффициент фактора момента.

Характерной особенностью данного метода является наличие двух слагаемых – минимизатора значений весовых коэффициентов ($s \times c_w \times w_i^{(l-1)}$) и фактора момента ($q_i^{(l)} \times \Delta w_i^{(l-1)}$). Как правило, коэффициенту минимизации c_w соответствует значение 10^{-4} . Данный коэффициент используется для ослабления весовых связей (вплоть до полного разрыва), в то же время фактор момента нужен для адаптации алгоритма к полученным результатам обучения. Надо отметить, что коэффициент q_i уникален для каждого весового коэффициента, а его расчет проводится в 2 этапа. На первом этапе определяется величина (3):

$$\hat{q}_i = \frac{\nabla \varepsilon^{(l-1)}}{\nabla \varepsilon_i^{(l-2)} - \nabla \varepsilon_i^{(l-1)}}, \quad (3)$$

а на втором этапе коэффициент момента принимает минимальное значение из q_i и \hat{q}_{max} . Так, автором алгоритма значение q_{max} предложено 1,75 [6].

Необходимо отметить, что также возможно использование модифицированной формы алгоритма (4), суть которой заключается в уменьшении числа управляющих параметров без потери эффективности [7].

$$\Delta w_i^{(l)} = \begin{cases} q_i^{(l)} \times \Delta w_i^{(l-1)}, & \Delta w_i^{(l-1)} \neq 0 \\ s \times \nabla \varepsilon_i^{(l-1)}, & \Delta w_i^{(l-1)} = 0 \end{cases} \cdot (4)$$

Из формулы (4) видно, что если значение вектора градиента $\nabla \varepsilon_i^{(l-1)}$ равно нулю, на следующей итерации значение соответствующего ему весового коэффициента вычисляется классическим градиентным методом [6].

Иллюстративный пример работы алгоритма

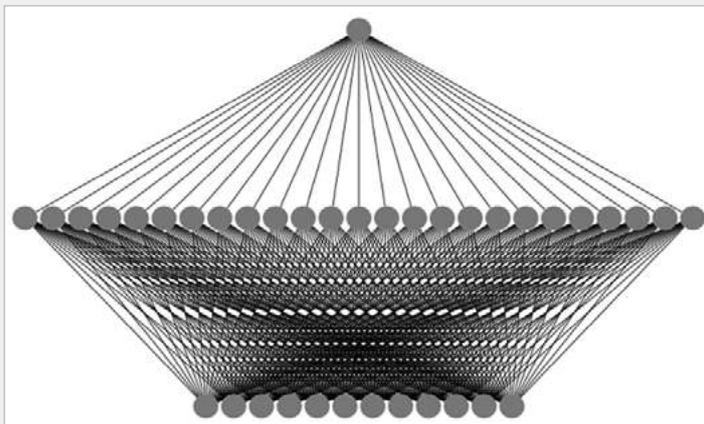
Для наглядной демонстрации работы алгоритма автором сделан

$$X = \begin{bmatrix} x(t_{7340}) & x(t_{7355}) & \dots & x(t_{7485}) \\ x(t_{7325}) & x(t_{7340}) & \dots & x(t_{7460}) \\ \vdots & \vdots & \ddots & \vdots \\ x(t_{15}) & x(t_{30}) & \dots & x(t_{180}) \\ x(t_0) & x(t_{15}) & \dots & x(t_{165}) \end{bmatrix}$$

$$D = \begin{bmatrix} x(t_{7500}) \\ x(t_{7485}) \\ \vdots \\ x(t_{195}) \\ x(t_{180}) \end{bmatrix} \cdot (5)$$

В используемом многослойном персептроне активационные

Структура многослойного персептрона, который используется для прогнозирования динамики валютной пары EUR/USD



Примечание. Собственная разработка автора.

Рисунок 2

функции представлены в следующем виде функции

$y = \frac{1}{1 + e^{0.5x}}$, выходные значения которой расположены в диапазоне (0;1). Таким образом обучающая выборка была пронормирована в этом же диапазоне [8, с. 100].

На рисунке 3 представлены два временных ряда котировок валютной пары EUR/USD: спрогнозированный и фактический. Вычислив по формуле (6) значение ошибок, получим: для ИНД значение ошибки составляет 13%, для традиционных ARIMA-моделей – 17%.

$$\varepsilon = \sum_{i=0}^{N-1} \left(\frac{|y_i - d_i|}{|d_i|} \right), \quad (6)$$

где y_i – спрогнозированные значения;

d_i – реальные значения.

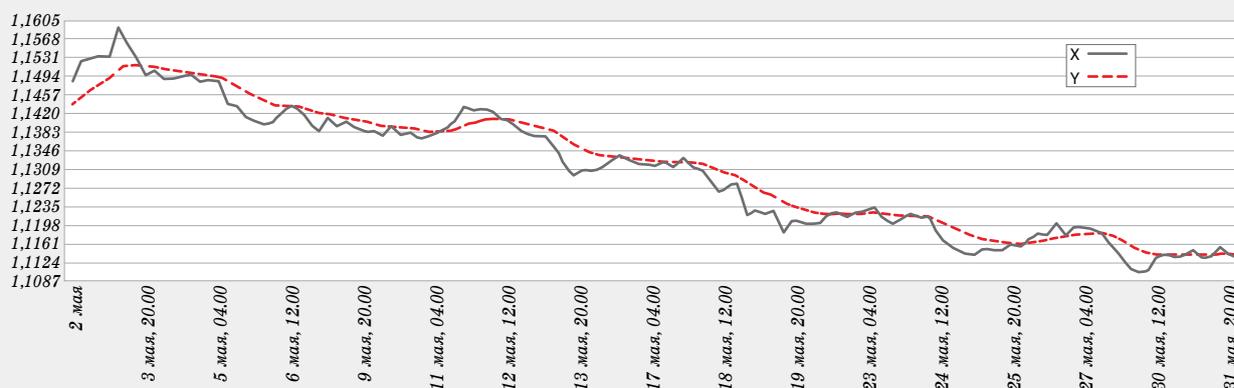
В качестве дополнительного примера была спрогнозирована динамика цен на золото в долларах США (XAU/USD) в мае 2016 г. Результаты прогноза представлены на рисунке 4.

Таким образом, на основании вышеприведенного анализа можно сказать, что искусственные нейронные сети представляют собой хороший инструмент для прогнозирования финансовых временных рядов. В ряде случаев прогнозы, полученные с помощью ИНС, более точны, чем прогнозы, полученные с помощью традиционных моделей прогнозирования.

Хотелось бы отметить, что за последние несколько десятилетий в прогнозировании нелинейных динамических систем, к которым относятся котировки на финансовых рынках, был сделан серьез-

ный рывок. Опыт математического моделирования нелинейных динамических процессов показал, что использовавшиеся ранее линейные математические модели уступают современным нелинейным моделям в точности и достоверности полученных прогнозов. Классических математических моделей, базирующихся на линейной парадигме, недостаточно для построения экономического прогноза, учитывающего несколько факторов влияния. В связи с этим возникла необходимость разработки новых методов анализа динамических временных рядов, к которым относятся биржевые котировки, основанные на нелинейных свойствах исследуемых объектов, хаотичности их поведения, чувствительности к большому количеству различных параметров. Преимущество исполь-

Фактические (x) и спрогнозированные (y) значения котировок валютной пары EUR/USD со 2 по 31 мая 2016 г.



Примечание. Собственная разработка автора.

Рисунок 3

Фактические (x) и спрогнозированные (y) значения котировок золота в долларах США (XAU/USD) со 2 по 31 мая 2016 г.



Примечание. Собственная разработка автора.

Рисунок 4

зования нелинейной концепции в прогнозировании современных экономических и финансовых временных рядов заключается в том, что с ее помощью можно адекватно отразить специфические характеристики иерархично-

сти, большой неопределенности и высокой динамики котировок. В связи с переходом к прогнозированию временных рядов методами нелинейной динамики появилась необходимость разработки нового инструментария математического

моделирования. Таким инструментарием стали методы нейронных сетей.

* * *

Материал поступил 15.03.2016.

Источники:

1. Бэстенс, Д.Э. *Нейронные сети и финансовые рынки: принятие решений в торговых операциях* / Д.Э. Бэстенс, В.М. Ван Ден Берг, Д. Вуд. – Москва: ТВП, 1997. – 236 с.
2. Сергеева, Л.Н. *Клеточные сети с опосредованным взаимодействием в микроэкономическом моделировании* / Л.Н. Сергеева // *Искусственный интеллект*. – 1999. – № 2 (специальный выпуск). – С. 398–406.
3. Billings, S.A. *Dual – orthogonal radial function networks for nonlinear time series prediction* / S.A. Billings, X. Hong // *Neural Networks*. – 1998. – № 11. – P. 479–493.
4. *Адаптивные нейронные сети [Электронный ресурс]* / *Справочник по нейросетям*. – Режим доступа: http://www.neuroshell.forekc.ru/ans/index_7.htm. – Дата доступа: 22.02.2016.
5. Fahlman, S.E. *An empirical study of learning speed in back-propagation networks* / S.E. Fahlman // *Technical report*. – Carnegie-Mellon University. – 1988. – 21 p.
6. Крючин, О.В. *Параллельные градиентные алгоритмы подбора весовых коэффициентов [Электронный ресурс]* / О.В. Крючин, Е.В. Вязова // *Научная электронная библиотека «Киберленка»*. – Режим доступа: <http://cyberleninka.ru/article/n/parallelnye-gradientnye-algoritmy-podbora-vesovyh-koeffitsientov>. – Дата доступа: 22.02.2016.
7. Veith, A.C. *A modified quickprop algorithm* / A.C. Veith, G.A. Holmes // *Neural Computation*. – 1991. – Vol. 3. – P. 310–311.
8. Козадаев, А.С. *Предварительная оценка качества обучающей выборки для искусственных нейронных сетей в задачах прогнозирования временных рядов* / А.С. Козадаев // *Вестн. Тамб. ун-та. Сер. Естеств. и техн. науки*. – 2008. – Т. 13, вып. 1. – С. 99–100.