

ПРОГНОЗИРОВАНИЕ ВАЛЮТНОГО КУРСА EUR/USD С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

© 2012 А. В. Абрамов

*аспирант каф. программного обеспечения
и администрирования информационных систем
e-mail: Abramov.saracin@yandex.ru*

Курский государственный университет

Валютный рынок FOREX сегодня является сферой интересов не только крупных компаний, но и многочисленных трейдеров, основная цель деятельности которых – получить прибыль. Основопологающим фактором успеха в этом деле является предсказание будущих котировок. В статье рассматривается нейросетевая модель прогнозирования валютного курса EUR/USD, приводится описание комбинированного алгоритма обучения.

Ключевые слова: валютный курс, прогнозирование, нейронные сети, алгоритм имитации отжига.

В последнее время тема «игры» на международном рынке FOREX стала весьма популярной в обществе. В сети Интернет сегодня можно найти множество предложений от брокерских компаний, которые предоставляют клиенту возможность стать участником рынка и получать прибыль от сделок. Без соответствующих инструментов и методов прогнозирования будущих значений валютного курса шансы на успех в данном виде деятельности весьма малы. Ранее было показано, что использование нейронных сетей в подобных задачах обладает рядом неоспоримых достоинств [Абрамов 2011].

Предлагаемая методика прогнозирования состоит из четырех основных этапов:

- предварительный анализ финансового ряда;
- построение нейросетевой модели;
- обучение нейронной сети по комбинированному алгоритму;
- прогнозирование с помощью обученной нейронной сети.

В качестве прогнозируемого временного ряда в рамках данной статьи выбран финансовый ряд котировок валютного курса EUR/USD, содержащий ежедневные цены закрытия [Архив котировок 2012]. Известно, что в качестве входных и выходных параметров нейронной сети не следует выбирать сами значения котировок $C(t)$. Действительно значимыми для прогнозирования являются их изменения. В силу того, что эти изменения в большинстве случаев «гораздо меньше по амплитуде, чем сами котировки, между последовательными значениями курсов имеется большая корреляция – наиболее вероятное значение курса в следующий момент равно его предыдущему значению» [Ежов 1998: 153].

Наличие таких статистических взаимосвязей в обучающем наборе данных приводит к низкому качеству обучения сети. Для устранения подобного рода корреляций при подготовке входных данных логично выполнить над значениями котировок некоторые преобразования, например вычислить изменения котировок

$$\Delta C = C(t) - C(t - 1) \quad (1)$$

или логарифм относительного приращения

$$C_{lg} = \lg\left(\frac{C(t)}{C(t-1)}\right). \quad (2)$$

Рассмотрим график курса EUR/USD с 03.01.2000 по 14.05.2012 (рис. 1) [Архив котировок 2012]. Очевидно, значения котировок ограничены снизу значением 0.8, а сверху 1.6. Вычтя из каждого значения 0.7, мы получим числовой ряд, все значения которого одного порядка и лежат в диапазоне (0;1). Данная историческая особенность котировок EUR/USD позволяет не применять к исходному ряду преобразования (1) или (2), а воспользоваться более простой формулой для получения входных данных нейронной сети:

$$x_i = C_i - 0.7, \quad (3)$$

где x_i – входное значение, C_i – исходное значение котировки.



Рис. 1. График валютного курса EUR/USD

Известно, что Европейский центральный банк (ЕЦБ) имеет большое количество финансовых рычагов и оказывает наиболее существенное влияние на курс валюты Еврозоны. Наиболее важным финансовым инструментом ЕЦБ является процентная ставка, при помощи которой регулируются инфляционное давление и темпы экономического роста. Для улучшения качества прогноза данные процентной ставки ЕЦБ добавлены в обучающее множество наряду с котировками EUR/USD.

Для решения задачи прогнозирования временного ряда z_k , где $k = 0, 1, \dots$, могут использоваться нелинейные модели вида $\bar{z}_{k+1} = F(z_k, \dots, z_{k-n+1})$, где $F(z_k, \dots, z_{k-n+1})$ – некоторая нелинейная функция; \bar{z}_{k+1} – прогнозируемое значение ряда; z_k, \dots, z_{k-n+1} – наблюдаемые значения (предыстория ряда); n – порядок модели.

Возможность использования нейронных сетей в прогнозировании временных рядов основывается на теореме об универсальной аппроксимации, которая утверждает, что многослойного персептрона с одним скрытым слоем достаточно для построения равномерной аппроксимации с точностью ε для любого обучающего множества, представленного набором входов (x_1, x_2, \dots, x_n) и желаемых откликов $f(x_1, x_2, \dots, x_n)$. Однако из теоремы не следует, что один скрытый слой является оптимальным с точки

зрения времени обучения, простоты реализации, а также качества обобщения [Хайкин 2006].

Для прогнозирования финансового ряда в рамках данной статьи использована полносвязная нейронная сеть, в которой каждый нейрон предшествующего слоя имеет связи со всеми нейронами последующего слоя. Пусть на нейрон j поступает поток сигналов от нейронов, расположенных в предыдущем слое, тогда индуцированное локальное поле $(s_j)^{(n)}$, полученное на входе функции активации, связанной с данным нейроном, вычисляется по формуле

$$(s_j)^{(n)} = \sum_{i=0}^m (w_{ji})^{(n)} (y_i)^{(n)}, \quad (4)$$

где m – общее число входов нейрона j , $(w_{ji})^{(n)}$ – синаптический вес, связывающий выход нейрона i со входом нейрона j на итерации n , $(y_i)^{(n)}$ – значение, генерируемое на выходе нейрона i на итерации n . Функциональный сигнал $(y_j)^{(n)}$ на выходе нейрона j на итерации n равен:

$$(y_j)^{(n)} = \varphi_j((s_j)^{(n)}), \quad (5)$$

где φ_j – функция активации j -го нейрона. Функция активации – непрерывно дифференцируемая нелинейная функция. В качестве функции активации выбрана функция гиперболического тангенса:

$$\varphi_j(s) = \frac{e^{2s} - 1}{e^{2s} + 1}, \quad (6)$$

где s – индуцированное локальное поле. Используемая в данной работе сеть содержит 10 входных нейронов, 20 нейронов в скрытом слое и один выходной нейрон. На первые пять нейронов входного слоя подаются цены закрытия EUR/USD в хронологическом порядке, а на оставшиеся нейроны подаются значения процентной ставки ЕЦБ соответственно датам котировок.

Для обучения нейронной сети используется комбинация алгоритма обратного распространения ошибки и метода Simulated Annealing (имитация отжига, модельная закалка, далее – SA-алгоритм). Данный метод впервые был разработан Скоттом Киркпатриком в середине 70-х и предназначался для оптимизации проектирования интегральных схем [Heaton 2008]. Идея алгоритма была позаимствована из процесса отжига в металлургии, использующегося для повышения однородности и прочности металла. Данный процесс заключается в нагревании металла до определенной температуры и последующего медленного охлаждения, приводящего к повторной кристаллизации вещества. При высоких температурах атомы обладают высокими уровнями энергии и степенями свободы, что увеличивает их способность к реструктуризации. Последующее медленное охлаждение создает возможность для формирования более прочной и стабильной кристаллической решётки.

В соответствии с физическим процессом SA-алгоритм пытается заменить текущее решение задачи случайным решением с вероятностью, зависящей от разности значений целевой функции начального и нового решения и параметра, условно называемого температурой.

Допускается, что система может перейти в состояние с меньшим значением целевой функции из состояния с большим значением с вероятностью тем большей, чем

больше температура, которая медленно понижается на каждом шаге оптимизации. По завершению процесса система «застывает» в состоянии с минимальной температурой. На рисунке 2 представлена схема SA-алгоритма в общем случае.

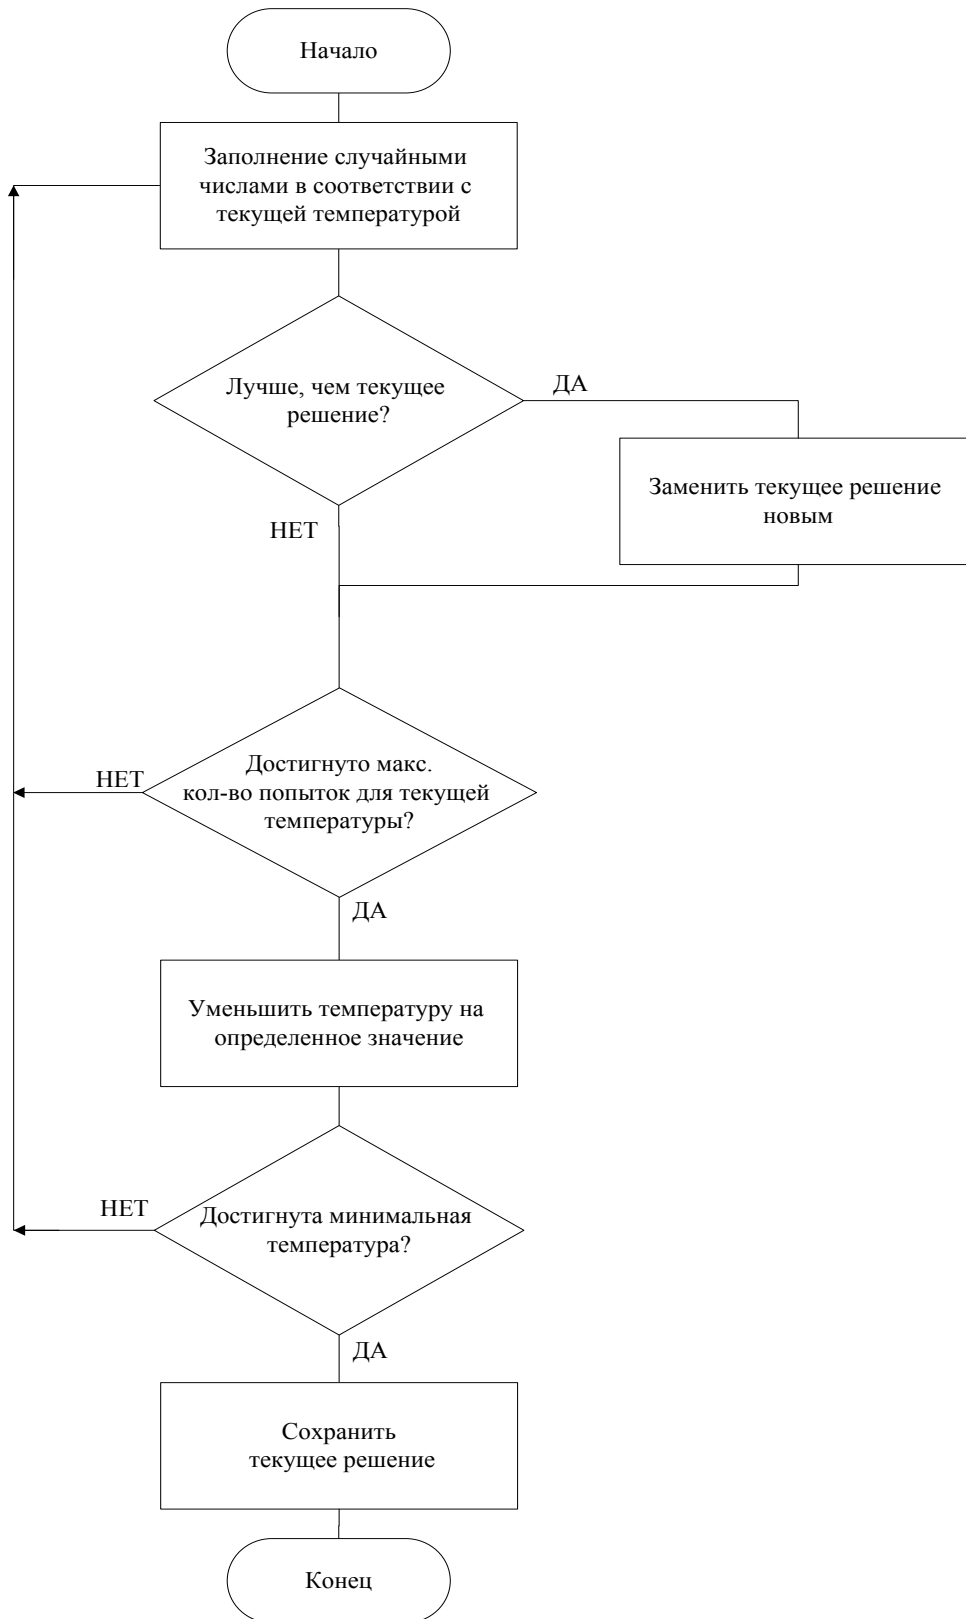


Рис. 2. Блок-схема SA-алгоритма

В реализации SA-алгоритма, предназначенной для обучения нейронных сетей, под решением понимается набор весовых коэффициентов нейронов, а в качестве целевой функции выступает функция ошибки сети [Heaton 2008]. Шаг изменения температуры вычисляется по формуле

$$s = e^{\frac{\ln(\frac{b}{e})}{c-1}}, \quad (7)$$

где b – начальная температура, e – конечная температура, c – количество циклов. В рамках данного эксперимента выбраны следующие параметры: $b=10$; $e=2$; $c=100$.

Идея комбинирования алгоритмов заключается в следующем: обучение начинается с помощью алгоритма обратного распространения ошибки, как только ошибка перестает уменьшаться в течение определенного количества итераций, происходит переключение на SA-алгоритм, который пытается решить проблему локального минимума, затем процесс снова возвращается к алгоритму обратного распространения ошибки. Обучение заканчивается после достижения целевого значения ошибки сети.

Для обучения сети были выбраны цены закрытия пары EUR/USD с 19.03.2008 по 01.05.2012 [Архив котировок 2012] и соответствующие им процентные ставки ЕЦБ [Ставка ЕЦБ 2012]. Эксперимент проводился с помощью программы, разработанной на языке С#, в которой для ускорения работы предусмотрен запуск процессов обучения и прогнозирования в отдельных потоках. В результате нескольких попыток удалось обучить нейронную сеть с ошибкой 3,5%. Процесс тренировки прошел за 3488 итераций. График зависимости величины ошибки от номера шага обучения приведен на рисунке 3.

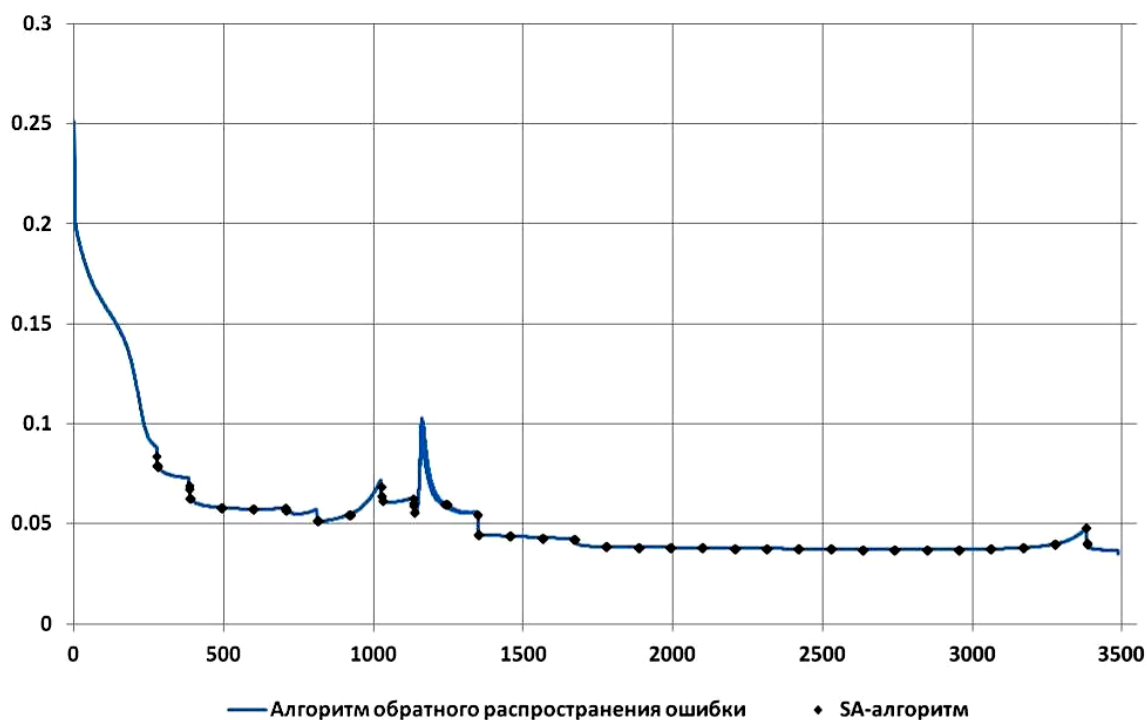


Рис. 3. Зависимость ошибки от номера итерации

Точками отмечены места переключения алгоритма обратного распространения ошибки на SA-алгоритм. Как видно из графика, комбинация указанных методов в данном случае оправдала себя и обеспечила сходимость процесса тренировки нейронной сети.

В качестве проверочного множества нейронной сети были выбраны цены закрытия EUR/USD с 02.05.2012 по 10.05.2012 [Архив котировок 2012]. Результат прогнозирования цен указанного периода с помощью обученной нейронной сети приведен на рисунке 4. Среднеквадратичная ошибка прогноза составила 7,3%. В трех случаях из шести нейронная сеть верно предсказала направление движения дневной цены, а также правильно предсказала нисходящий недельный тренд.




Рис. 4. Прогноз нейронной сети

В целом точность прогноза в данном эксперименте недостаточно высока для принятия серьезных решений в реальной торговле, однако полученный результат может быть улучшен за счет более глубокого анализа исходного финансового временного ряда и тщательной подготовки входных данных, использования так называемых «комитетов» сетей и более содержательных экономических индикаторов. Применение нейронных сетей в задачах прогнозирования имеет большой потенциал, который ещё только предстоит раскрыть.

Библиографический список

Абрамов А. В. Перспектива применения нейронных сетей для прогнозирования валютного рынка FOREX // Применение инновационных технологий в научных исследованиях: сб. науч. ст. по материалам Междунар. науч.-практ. конф. / редкол.: А. В. Филонович (отв. ред.) [и др.]. Курск: Юго-Зап. гос. ун-т, 2011. С. 194.

Архив котировок [Сайт]. URL: http://www.fibo.ru/trader/download_quotes.html (дата обращения 20.05.2012).

Ежов А. А., Шумский С. А. Нейрокомпьютинг и его применения в экономике и бизнесе. М.: МИФИ, 1998. 224 с.

Ставка ЕЦБ [Сайт]. URL: <http://quote.rbc.ru/macro/indicator/22/169.shtml> (дата обращения 20.05.2012).

Хайкин С. Нейронные сети: полный курс, 2-е изд.: пер. с англ. М.:Издательский дом «Вильямс», 2006. 1104 с.

Heaton J. Introduction to Neural Networks for C#, 2 Ed., 1st printing, Heaton Research, Inc, 2008. 428 p.