

ПРОГНОЗИРОВАНИЕ ФИНАНСОВЫХ РЫНКОВ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННЫХ НЕЙРОСЕТЕЙ

А.А. Кокишарова

Д.Б. Шумкова

*Пермский национальный исследовательский
политехнический университет, г.Пермь*

Исследование посвящено проблеме построения прогнозов, используемых на рынке Forex. Предложена методика, позволяющая повысить точность прогнозирования валютных курсов, оперативность вычислений которой пригодна для использования на торговых терминалах. Теоретическими посылами для построения предлагаемых моделей являются исследования McCulloch, Pitts, Saidane, Ghiassi. Во вводной части приведены основные понятия теории нейронных сетей, многоуровневых перцептронов и динамических искусственных нейронных сетей DAN2. Построенные модели протестированы на динамике курса GBPUSD за 2012 г.

С развитием информационных и компьютерных технологий широким слоям населения нашей страны стали доступны западные финансовые рынки, и прежде всего FOREX. Между тем, большинство сделок, заключаемых на финансовых рынках, являются спекулятивными, т.е. заключаемыми исключительно с целью получения прибыли от разницы курсов продажи и покупки. Таким образом, для выбора наиболее прибыльных стратегий на рынке FOREX следует учитывать прогнозируемое движение цены. Иными словами, наша успешность на рынке зависит от точности решения задачи прогнозирования движения курсов.

Математически задачу прогнозирования значения котировки в наперед заданный момент времени можем свести к задаче поиска аппроксимирующей функциональной зависимости, т.е. для временного ряда $Z(t)$ с известными значениями в моменты времени t_1, t_2, \dots, T задачу прогнозирования сводим к задаче поиска зависимости вида

$$Z_t = F(Z_{t-1}, Z_{t-2}, \dots) + \varepsilon_t,$$

где ε_t – ошибка аппроксимации, заданная из практических соображений. Возможность построения такой зависимости обусловлена одним из положений теории хаоса, согласно которому временные ряды валютных пар только выглядят случайно, на самом же деле они полны скрытых закономерностей. Таким образом, поскольку колебания валютных курсов представимы сложной функциональной зависимостью, то для прогнозирования нелинейных связей целесообразно использовать инструменты нейросетевого анализа.

Центральным понятием в теории нейронных сетей является формальный нейрон, его модель предложена основоположниками теории W.McCulloch & W.Pitts в 1943г.

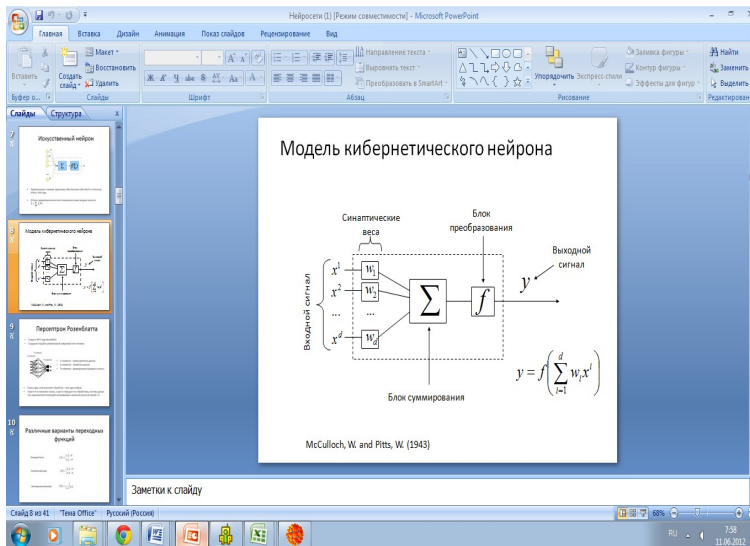


Рис. 1. Базовая модель формального нейрона

Чаще всего в качестве функции на блоке преобразования используют сигмоидные функции:

$$f(x) = \frac{1}{1 + e^{-ax}}$$

Помимо формальных нейронов, используемых для построения нейросетей в формате многоуровневых перцептронов, необходимо рассмотреть концепцию динамических нейросетей DAN2, предложенную в 2005 г. Ghiassi & Saidane.

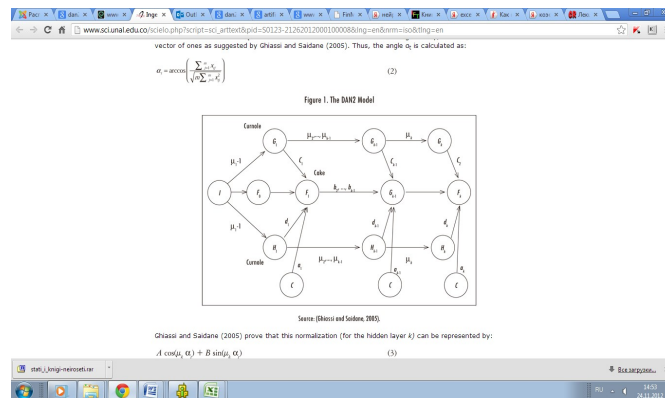


Рис.2. Модель DAN2

Здесь на узлах типа F линейно накапливается знание о системе, узлы G и H вносят в модель нелинейность, коэффициенты на линейных узлах несут смысл синаптических весов наравне с коэффициентами \$\mu\$, используемыми в нелинейных преобразованиях.

Построим модель прогнозирования максимального и минимального уровня цен. Базой для формирования обучающего и тестового множества послужит дневная динамика колебаний курсов GBPUSD за 01.06.2010 – 01.11.2012. Для увеличения точности прогноза к данным базы применяем преобразование приращением, иными словами, задачу прогнозирования значения котировки сводим к задаче прогнозирования изменения значения.

$$\Delta \text{Highi} = \text{Highi} - \text{Highi} - 1$$

$$\Delta Low_i = Low_i - Low_{i-1}$$

$$\Delta Close_i = Close_i - Close_{i-1}$$

Для получения более адекватной модели к получившемуся ряду применяем преобразование, переводящее искомое множество в интервал активационных функций нейронов, а также приближающее искомое множество к обладающему наибольшей энтропией равномерному распределению.

$$S\Delta High_i = 11 + e^{-1,5 * 100 * \Delta High_i - 0,5}$$

$$S\Delta Low_i = 11 + e^{-1,5 * 100 * \Delta Low_i - 0,5}$$

$$S\Delta Close_i = 11 + e^{-1,5 * 100 * \Delta Close_i - 0,5}$$

Тогда распределение значений на первом входном нейроне проиллюстрировано на полигоне (рис.3), при этом число интервалов найдено по формуле Стерджесса.

Рис. 3. Полигон частот

По результатам спектрального анализа, проведенного в пакете Statistica, был найден основной значимый период, который оказался равным трем дням. Тогда согласно исследованию М.А. Моцакова число нейронов входного слоя $N = k * P$, где P – основной значимый период. Таким образом, выдвигаем гипотезы:

$$N_{High} = S\Delta High_i + 1 = F(S\Delta High_{i-2}, S\Delta Low_{i-2}, S\Delta Close_{i-2}, S\Delta High_{i-1}, S\Delta Low_{i-1}, S\Delta Close_{i-1}, S\Delta High_{i-1},$$

$$S\Delta Low_i, S\Delta Close_i)$$

$$N_{Low} = S\Delta Low_i + 1 = G(S\Delta High_{i-2}, S\Delta Low_{i-2}, S\Delta Close_{i-2}, S\Delta High_{i-1}, S\Delta Low_{i-1}, S\Delta Close_{i-1}, S\Delta High_{i-1},$$

$$S\Delta Low_i, S\Delta Close_i)$$

Для проверки гипотез строим две нейросети – NeuroHigh и NeuroLow. Обучаем методом обратного распространения ошибки, взяв в качестве начального вектора результат функционирования генетического алгоритма. Обученная на данных 1.06.2010 – 1.09.2012 нейросеть тестировалась на данных 2.09 – 1.11.2012.

Для проверки адекватности модели вычислялись показатели ошибок (ошибки вычислены для значений сигмоидов):

$$MSE = \frac{1}{n} \sum_{i=1}^n (S\Delta High_i - S(\Delta High_i))^2 = 0,03938$$

$$NMSE = \frac{MSE_{\max} S\Delta High_i - \min S(\Delta High_i)}{MSE} = 0,6836$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |S\Delta High_i - S(\Delta High_i)| = 0,166$$

$$\min MAE = \min_{i=1}^n |S\Delta High_i - S(\Delta High_i)| = 0,0022$$

$$\max MAE = \max_{i=1}^n |S\Delta High_i - S(\Delta High_i)| = 0,4375$$

График соответствия прогнозных значений фактическим для сети NeuroHigh представлен на рис.4. Для сети NeuroLow графическое соответствие аналогично по виду, значения ошибок имеют тот же порядок.

Рис.4. Соответствие прогнозных и фактических значений

Таким образом, использование многоуровневого персептрона дает информацию о движении цены, но не дает однозначной информации о численных значениях, характеризующих это движение.

Построим аналогичную модель с применением технологии DAN2. Обучающие и тестовые множества построены по тому же принципу, что и для построения предыдущей модели. Поскольку алгоритмы DAN2 не реализованы ни в одном нейропакете, то для построения модели написана программа на C#. На узлах текущего накопленного знания вычисляются коэффициенты многофакторной регрессии, нелинейность в модель вносится преобразованиями синуса и косинуса, элемент случайности внесен использованием случайного вектора для вычисления угла. В целом использование модели с применением DAN2 позволило увеличить точность прогноза. Соответствие реальных данных прогнозным (на тестовом множестве) приведено на рис.5.

Рис.5. Соответствие реальных данных прогнозным (DAN2)

Оперативность обработки массивов большой размерности с применением технологии DAN2, высокое качество построенных прогнозов делает возможным использование построенной модели в торговом зале для выбора потенциально прибыльных стратегий.

Таким образом, в ходе исследования построены две модели, потенциально пригодные для использования на торговых терминалах в качестве пользовательских индикаторов поведения пары. Однако модель, построенная на принципах персептрона, будет иметь смысл индикатора направления движения курсов валют, модель же, созданная на основе концепций Ghiassi & Saidane, может служить однозначным индикатором, позволяющим судить о значении цены обмена в прогнозируемом периоде.

На основании анализа результатов расчетов можем сделать выводы о состоятельности нейросетей в задачах построения аппроксимации сложных функциональных зависимостей, нейросетевая нелинейная система может быть обучена выполнению анализа валютных курсов, решение задач с применением нейросетей целесообразно в условиях неопределенности алгоритма решения задачи, т.к. этот алгоритм формируется в процессе обучения нейросети. В тех случаях, когда статическая система сети неспособна дать

четкого представления о поведении курсов, использование DAN2 дает дополнительные возможности для повышения точности прогнозов.

Список литературы

1. Бокс Дж., Дженкинс Г.М.. Анализ временных рядов, прогноз и управление. М.: Мир, 1974. С.407.
2. Ежов А., Шумский С.. Нейрокомпьютинг и его применения в экономике и бизнесе. М., 1998. С.222.
3. Jang, Jyh-Shing Roger. Neuro-fuzzy and soft computing. A computational Approach to Learning and Machine Intelligence. Prentice-Hall, Inc., P.614.
4. Guresen, E. and Kayakutlu, G., in EFIP International Federation for Information Processing, Volume 228; Intelligent Information Processing IV; Zhongshi, E. Mercier-Laurent, D. Leake; (Boston: Springer), pp 129-137
5. Juan David Velásquez-Henao, Carlos Jaime Franco-Cardona, Yris Olaya-Morales. A Review of DAN2 (Dynamic Architecture for Artificial Neural Networks) Model in Time Series Forecasting. Ing. Univ. vol.10 no.1 suppl.1 Bogota Jan./June 2012
6. М.А. Моцаков. О проблеме прогноза временных рядов при помощи искусственных нейронных сетей. Ученые записки РГГМУ, №07, 2012. С. 53 – 64
7. J.P. Marney, Heather Tarbert, Jos Koetsier, Marco Guidi. The application of the self-organizing map, the k-means algorithm and the multi-layer perceptron to the detection of technical trading pattern. Applied Financial Economics ISSN 0960-3107 print/ ISSN 1466-4305 online. 2008, Taylor&Francis. P.1009 - 1019