

УДК/UDC 33:007, 519.86

Нейродинамические алгоритмы прогнозирования показателей финансовых рынков

Хмелев Александр Геннадиевич

доктор экономических наук, доцент, профессор кафедры экономической информатики

Белорусский государственный университет информатики и радиоэлектроники

г. Минск, Беларусь

e-mail: akhmelev@gmail.com

Хмелева Ангелина Владимировна

кандидат технических наук, доцент, доцент кафедры программного обеспечения информационных технологий

Белорусский государственный университет информатики и радиоэлектроники

г. Минск, Беларусь

E-mail: avkhmeleva@gmail.com

SPIN-код: 6715-1210

Потапов Владимир Дмитриевич

кандидат технических наук, доцент, доцент кафедры информационных радиотехнологий

Белорусский государственный университет информатики и радиоэлектроники

Г. Минск, Беларусь

E-mail: potapovvd@gmail.com

Аннотация

В данной работе предпринята попытка разработки формализованного метода построения нейросетевых моделей финансовых рынков, обладающего инвариантностью к структурным и параметрическим возмущениям с точностью до статистически значимого цикла переобучения нейросетевой модели по ранее накопленным данным о поведении исследуемого объекта.

Ключевые слова: финансы, прогнозирование, искусственные нейронные сети, математическая модель, генетический алгоритм, обучающая выборка.

Neurodynamic Algorithms for Forecasting Financial Markets Indicators

Khmelov Oleksandr

Doctor of Economics, Associate Professor, Professor of the Department of Economic Informatics

Belarusian State University of Informatics and Radioelectronics

Minsk, Belarus

E-mail: akhmelev@gmail.com

Khmelova Angelina

PhD of technical sciences, associate professor

Associate Professor of the Department of Information Technology Software

Belarusian State University of Informatics and Radioelectronics

Minsk, Belarus

E-mail: avkhmeleva@gmail.com

SPIN-код: 6715-1210

Potapov Vladimir

PhD of technical sciences, associate professor

Associate Professor of the Department of Information Radio Technologies

Belarusian State University of Informatics and Radioelectronics

Minsk, Belarus

E-mail: potapovvd@gmail.com

Abstract

In this paper, an attempt is made to develop a formalized method for constructing neural network models of financial markets that is invariant to structural and parametric disturbances up to a statistically significant cycle of retraining a neural network model based on previously accumulated data on the behavior of the object under study.

Key words: finance, forecasting, artificial neural networks, mathematical model, genetic algorithm, training sample.

В современных условиях в задачах управления и мониторинга финансовых рынков наблюдается повышенное внимание, как к автоматизации принятия управленческих решений, так и к информационным системам, обладающим расширенным инструментарием аналитического анализа. В конечном счете, именно функциональное наполнение такого инструментария во многом

определяет целесообразность и эффективность внедрения таких информационных систем. В то же время быстроменяющиеся условия финансовых рынков предполагают, как правило, анализ во временной области с нелинейными трендами и не всегда очевидной динамикой. Более того, практически всегда подобный анализ является многомерным, т.к. число исследуемых величин с каждым годом растет — в спектр наблюдаемых параметров входят не только прямые данные об опционах и фьючерсах, котировках акций и валют, но и другие показатели, например, данные о свопах, индикаторы, основанные на результатах технического и фундаментального анализов. Однако, существующие на рынке управляющие информационные системы не всегда имеют описанный инструментарий. Причиной подобного отставания является заметный разрыв между теоретическими исследованиями и прикладным уровнем в информационных системах обработки финансовой информации. В частности, многие предлагаемые методы построения гипотез динамических финансовых моделей формализованы недостаточно для прямого применения в компьютерной среде. Так, например, важными шагами в аналитических модулях информационных систем являются идентификация динамических финансовых моделей, причем, как правило, задача структурной и параметрической идентификации решается экспертным методом (с участием человека), что во многих случаях противоречит самой концепции использования компьютерной техники и существенно снижает скорость принятия решений. В этой связи дальнейшее

развитие теоретических основ в направлении формализации [1] идентификации динамических моделей финансовых рынков представляет значимый интерес, в силу потенциального сокращения обозначенного разрыва между теорией и практикой. Для этих задач создан и успешно эксплуатируется современный математический аппарат, основой которого являются искусственные нейронные сети и генетические алгоритмы

В настоящее время перспективные инновационные методы и технологии нейросетевого моделирования финансовых рынков можно разделить на несколько важных частей: предварительная обработка данных для обучения нейросетевых моделей; идентификация структуры и параметров частных динамических моделей для отдельных управляемых или наблюдаемых информационных каналов исследуемого рынка; генерация и обучение обобщающих нейронных сетей с применением генетических алгоритмов; анализ динамических характеристик во временной области.

Выделяют несколько подходов к вопросам параметрической и структурной идентификации. Параметрическая идентификация наиболее полно представлена такими технологиями как корреляционный и регрессионный анализ, факторный анализ, дисперсионный анализ, компонентный анализ, дискриминантный анализ, анализ временных рядов в частотной области. Также в последние годы можно отметить повышение интереса к так называемым «немодельным» технологиям генерации гипотез, а именно различным вариантам нейросетевого, сингулярного и

фрактального анализа. Что же касается структурной идентификации, то в последние годы часто используют экспертные методы, аппарат классификационных нейросетей, кластерный анализ, генетические алгоритмы, нечеткую логику. Серьезные достижения в данной предметной области являются надежным фундаментом для дальнейших исследований, однако среди всего спектра методов идентификации, как отмечалось, не всегда удается выбрать полностью формализованные и универсальные методы, лишь некоторые из перечисленных методов являются проработанными до состояния, позволяющего строить адекватные гипотезы моделей финансовых рынков полностью автоматически. В то же время в условиях трансформационной экономики наличие в аналитических отделах финансовых организаций автоматически наполняемой базы актуальных динамических моделей является серьезным конкурентным преимуществом. По этой причине развитие данного направления представляет, как теоретический, так и практический интерес.

В данной работе предпринята попытка разработки формализованного метода построения нейросетевых моделей финансовых рынков, обладающего инвариантностью к структурным и параметрическим возмущениям с точностью до статистически значимого цикла переобучения нейросетевой модели по ранее накопленным данным о поведении исследуемого объекта. В данной постановке задачи применение описываемого метода целесообразно при построении систем поддержки принятия решений (СППР), ядром

которых являются топологически и параметрически нестационарные нейросетевые модели финансового рынка как сложной экономической системы или их совокупность (для случая иерархического разделения экономической системы).

Финансовый рынок характеризуется высоким уровнем автоматизации сбора информации. В общем случае такой рынок можно представить как сложный объект, покомпонентные модели которого нестационарны и формируются на основе накопленных статистических данных. Пусть исследуемый объект является многомерной экономической динамической системой с входным тензором $X[n, k, z_x]$ и выходным тензором $Y[m, k, z_y]$, причем каждая строка описывает изменение входного состояния (одного из n в X) и выходного состояния (одного из m в Y) во времени с фиксированным шагом (длиной в k шагов). Ранг тензоров в общем случае равен 3. Соответственно, каждый столбец является мгновенным состоянием объекта в определенный момент времени в пространстве состояний, причем третья координата z_x, z_y используется когда состояние невозможно описать скалярно. Тензор X будем считать массивом управляющих и возмущающих воздействий. Тензор Y характеризует фактические выходные параметры финансового рынка. Пусть существует информационный канал (например, валютная котировка) как совокупность изменяющихся во времени одного входного и одного выходного параметров с размерностями z_x, z_y . Тогда для анализа динамических характеристик произвольного

информационного канала исследуемого объекта можно использовать по одной требуемой строке из входного и выходного тензора. Максимально возможное число информационных каналов такой системы может достигать $n \times k$, однако на практике это число всегда меньше в силу низкой или отсутствующей взаимной зависимости некоторых пар вход-выход.

Наличие статистически значимого объема данных во входном и выходном тензоре X и Y позволяет выполнить обучение искусственной нейронной сети (ИНС), моделирующей поведение исследуемого объекта, как совокупности информационных каналов. В зависимости от характера данных в информационных каналах возможны различные способы формирования обучающих выборок (множеств). На рис. 1 показаны различные способы формирования одиночного входного вектора для обучающего множества (выходной вектор выбирается по аналогичным принципам).

Способы формирования обучающих выборок для входной матрицы X

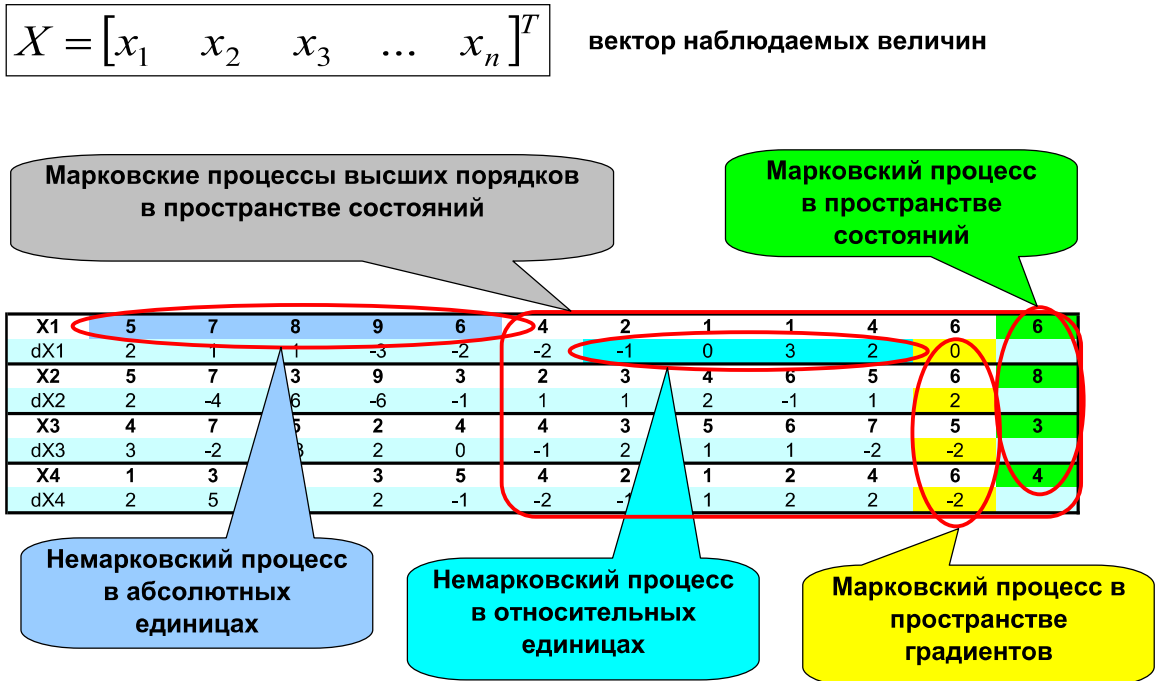


Рисунок 1

Выбор среза данных целесообразно выполнить после следующих видов предварительного экспертного анализа:

1. является ли исследуемый процесс марковским, т.е. в какой степени эволюция процесса после любого заданного значения временного параметра t независима от эволюции, предшествовавшей t , при условии, что значение процесса в этот момент фиксировано;
2. какие изменения объекта являются наиболее существенными для определения конечной цели моделирования, абсолютные или относительные;

3. относятся ли отдельные временные ряды к одному исследуемому (суб)объекту или к различным;
4. какова размерность предполагаемого пространства состояний исследуемого объекта.

Верный выбор среза данных является одним из наиболее значимых фактором построения адекватной нейросетевой модели, по этой причине игнорирование перечисленных видов анализа вполне способно привести к негативному результату при проверке полученных нейросетевых моделей на адекватность.

После выбора представления входных и выходных данных следует один из наиболее важных этапов подготовки обучающего множества – предобработка данных. В работе [3] отмечается, что игнорирование данного этапа в 80% случаев приводит к негативным результатам нейросетевого моделирования.

Наиболее важными методами предобработки являются:

- кодирование входов-выходов: ИНС могут работать только с числами, поэтому кодирование может быть, как количественным (для преобразования лингвистических значений в числовые в этом случае используют нечеткую логику), так и качественным (в таком случае каждой кодируемой лингвистической категории соответствует бинаризованный вход или выход сети);
- нормализация данных: результаты нейроанализа не должны зависеть от выбора единиц измерения, кроме того, диапазон возможных значений на входах и выходах

ИНС зависит от типов используемых нейронов, что делает этот шаг обязательным (в некоторых работах данный метод предобработки данных может быть также представлен в виде дополнительного слоя линейных нейронов с управляемым смещением их индуцированного локального поля на входе и/или выходе ИНС, что приводит к громоздким схемам получаемых ИНС, но не меняет математической сущности процесса нормализации);

- модификация плотности обучающих данных во времени: обычно состояние объекта в текущее или последнее время важнее более давних данных, поэтому в динамических процессах часто имеет смысл уплотнение исторических данных ближе к моменту перехода ИНС в экстраполирующий режим (или режим прогнозирования);
- предобработка данных: удаление регулярностей — излишне частых повторений из данных облегчает ИНС выявление нетривиальных закономерностей, впрочем, данная мера может быть, как предварительной, так и применяемой непосредственно при обучении — т.н. пропуск обратного хода при малых значениях ошибки;
- восстановление пропущенных значений: для решения этой задачи обычно используются классические методы интерполяции и регрессии.

Однако, для получения качественной нейросетевой модели финансового рынка этих мер может оказаться недостаточно. Шумовые компоненты данных и их влияние на качество моделирования особенно сильно заметны на нейросетевых моделях. Сама ИНС является гиперповерхностью, сложность и размерность которой растет с увеличением числа нейронов и, соответственно, (в гораздо большей степени) числа межнейронных связей. При этом наличие шума в обучающей выборке часто приводит к быстроосцилирующей гиперповерхности ИНС, что чревато как банальным переобучением, так и существенным снижением быстродействия градиентных методов обучения ИНС. По этой причине важным фактором является минимизация шума. Для этого предлагается использовать два подхода: анализ временных рядов и моделирование динамических характеристик отдельных информационных каналов.

Существует несколько методов анализа временных рядов: регрессионные, ARIMA-модели, методы, основанные на сингулярном разложении (SSA), вейвлет-разложение, разложение в ряды Фурье и др. Достоинством метода SSA является отсутствие требования априорного знания модели ряда, но при этом сравнение этого метода с «модельными» методами показывает хорошие результаты на таких объектах как финансовый рынок. В качестве примера можно отметить, что так же как волны Эллиота могут быть представлены как частный случай разложения в ряд Фурье, само разложение Фурье является частным случаем SSA, что косвенно указывает на

универсальность предлагаемого подхода. К преимуществам метода можно в первую очередь отнести возможность работы с модулированными гармониками, что выгодно отличает его от методов, использующих анализ Фурье. Кроме того, SSA не является «черным ящиком», в ходе работы можно проводить детальный покомпонентный анализ, что выгодно отличает SSA от вейвлет-анализа.

В основе метода SSA лежит следующий алгоритм. Задавшись числом $L < N/2$ (длина скользящего окна), значениями исходного ряда $F_N = \{f_0, f_1, \dots, f_{N-1}\}$ последовательно заполняют строки матрицы \mathbf{M} . При этом первая строка содержит первые L элементов ряда, вторая – со второго элемента по $L+1$ и так далее, пока ряд не исчерпается. Далее находятся собственные числа $\lambda_1, \lambda_2, \dots, \lambda_L$ (в порядке убывания) и соответствующие собственные векторы $\mathbf{U}_1, \mathbf{U}_2, \dots, \mathbf{U}_L$ матрицы $\mathbf{S} = \mathbf{M} \cdot \mathbf{M}^T$. Сингулярное разложение матрицы \mathbf{M} может быть записано, как:

$$\mathbf{M} = \mathbf{M}_1 + \mathbf{M}_2 + \dots + \mathbf{M}_d \quad (1)$$

где элементарные матрицы \mathbf{M}_i вычисляются по формулам

$$\mathbf{M}_i = \sqrt{\lambda_i} \mathbf{U}_i \cdot \mathbf{V}_i^T, \text{ причем } \mathbf{V}_i = \mathbf{X}^T \cdot \mathbf{U}_i / \sqrt{\lambda_i}, \quad d = \max\{i, \lambda_i > 0\}.$$

Применив к элементарным матрицам \mathbf{M}_i процедуру диагонального усреднения,

получают временные ряды $F^i_N = \{f_0^i, f_1^i, \dots, f_{N-1}^i\}$, представляющие

собой компоненты исходного ряда F_N , такие, что

$$F_N = F_N^1 + F_N^2 + \dots + F_N^d.$$

После группировки компонент по абсолютной величине собственных чисел, характеру и амплитуде осцилляций на временной оси, а также с учетом степени вклада каждой в общую сумму получают окончательное разбиение ряда на полезный сигнал \tilde{F}_N и шум $\tilde{\tilde{F}}_N$:

$$F_N = \tilde{F}_N + \tilde{\tilde{F}}_N \quad (2)$$

где $\tilde{F}_N = \tilde{F}_N^1 + \tilde{F}_N^2 + \dots + \tilde{F}_N^m$ представляется в виде суммы тренда, тренд-циклических, циклических, экспоненциальных и экспоненциально-модулированных компонент.

На следующем этапе проводится сравнительный анализ выделенных компонент с другими факторами и индикаторами с целью выявления скрытых ранее (до разложения) закономерностей, что является основным функциональным наполнением SSA. С одной стороны, сохранение возможности в SSA интерактивно производить непосредственный поиск гармонических и квазипериодических компонент, фильтрацию или сглаживание ряда, выбирая соответствующие значимые компоненты, делает SSA серьезным инструментом. Но в то же время представляет особый интерес автоматизация именно этого процесса. Проблемы применения метода SSA в классическом виде таковы:

- не решена задача выбора основных управляющих параметров, отвечающих за размерность выборки, полученной из одномерного временного ряда;
- анализ промежуточных результатов, интерпретация и отбор главных компонент осуществляются как правило интерактивно;
- метод не является абсолютно жестким и допускает модификации, причем выбор оптимальной для конкретной задачи неочевиден.

Отличительной особенностью предложенного SSA является возможность автоматического определения значимых компонент разложения. Предлагается выбирать обычно эмпирически подбираемые параметры глубины погружения во временной ряд, величину окна, размерность набора значимых компонент, модификацию SSA и т. д. с помощью классического генетического алгоритма ГА [2] с кроссинговером и дискретной мутацией. Адекватность модели в этом случае легко контролировать, используя хорошо известный в теории искусственных нейронных сетей метод разделения ряда на обучающее, тестовое и экзаменационное множества. Тестовое множество в этом случае используется для вычисления фитнес-функции конкретной реализации-особи SSA в ходе ГА, а экзаменационное множество – для окончательной проверки полученной динамической модели временного ряда на адекватность после остановки ГА. В обоих случаях вычислению подвергается величина интегрального

квадратичного отклонения: $J = \sum_{t=n}^m (P_t - T_t)^2$ или $J = \sum_{t=n}^m (P_t - E_t)^2$

тестового T_t или экзаменационного E_t фрагмента от прогноза P_t на это же время $[n, m]$ полученного из обучающего множества. Направление ГА классическое $J \rightarrow \min$.

Дополнительными косвенными факторами адекватности полученной модели могут быть исследование полученной модели на стационарность, вычисление показателя Херста и другие классические методы.

В силу генетической природы предложенного способа применения SSA емкость вычислений становится весьма значительной, но эта задача решена применением технологии платных «облачных» или же локальных пиринговых вычислений, когда используется вычислительная мощность незадействованных на 100% в момент эксперимента процессоров (компьютеров), каждый из которых тестирует особь SSA в текущей популяции ГА. Для применимости пиринговых вычислений достаточно наличия компьютерной сети. На рис. 2 показаны результаты разложения SSA в модуле для проведения такого анализа.

Фильтрация временного ряда на основе метода SSA.

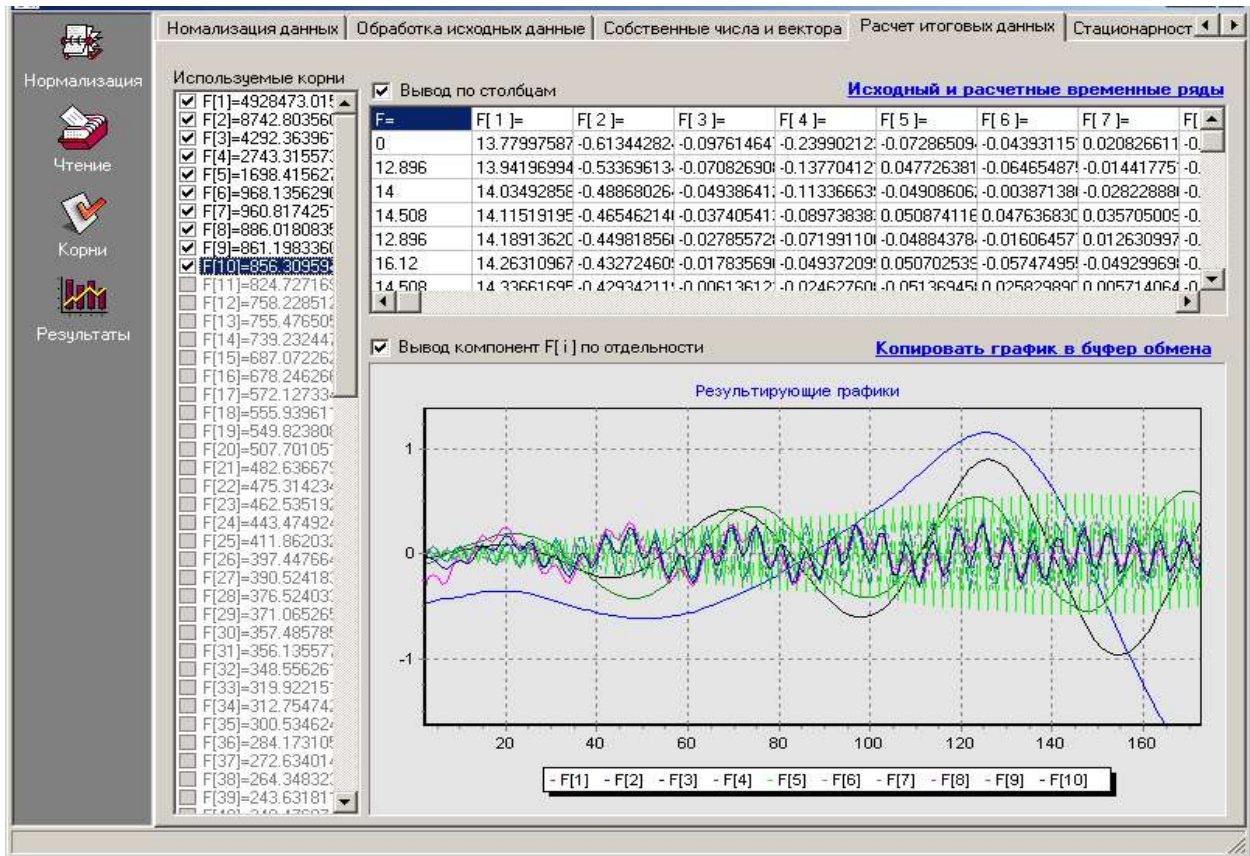


Рисунок 2

Важным моментом для применимости рассмотренного метода является эквидистантность анализируемого ряда на временной оси. В случае отсутствия таковой требуется первичная предварительная интерполяция или аппроксимация ряда, которая обязательно должна быть низкоосцилирующей.

Эмпирически установлено, что допустимы лишь самые низкие порядки интерполирующего полинома: от линейной до сплайн-интерполяции. Аппроксимация же в данной конкретной задаче неприменима в силу потерь за счет упрощения модели. Применение аппроксимации усиливает соотношение сигнал/шум в компонентах ряда, но при этом страдает точность.

В целом по результатам рассмотренных исследований можно привести ряд выводов. Во-первых, применение эволюционных алгоритмов обучения ИНС является весьма перспективным инновационным направлением именно в области финансовых рынков, т.к. с одной стороны снижает требования к уровню квалификации в области нейросетевого моделирования для конечного пользователя, с другой стороны позволяет оперативно перестраивать модельную базу финансовой организации. Во-вторых, спектр возможных вариаций эволюционной адаптации топологии ИНС в настоящее время разработан лишь для узкого класса сетей прямого распространения, в этой области предстоит еще много новых исследований. В-третьих, косвенные методы кодирования вполне могут конкурировать в плане производительности как с классическими методами прямого кодирования, так и с их более современными модификациями.

Список литературы

1. David E. Moriarty, Risto Mikkulainen. Efficient reinforcement learning through symbiotic evolution. *Machine Learning* 44(1-3): 11-32, Department of Computer Sciences, The University of Texas at Austin. Austin, TX 78712, 1996.
2. Gomez, F., and Mikkulainen, R. (2001). Learning robust nonlinear control with neuroevolution. Technical Report AI01-292, Department of Computer Sciences, The University of Texas at Austin.
3. Саймон Хайкин Нейронные сети: полный курс = *Neural Networks: A Comprehensive Foundation*. — 2-е изд. — М.: «Вильямс», 2006. — С. 1104. — ISBN 0-13-273350-1