

ПРОГРАММНЫЙ КОМПЛЕКС ДЛЯ УПРАВЛЕНИЯ СТРУКТУРОЙ ИНВЕСТИЦИОННОГО ПОРТФЕЛЯ

А.Г. Исавнин,

доктор физико-математических наук, профессор кафедры математических методов в экономике Казанского федерального университета, филиал в г. Набережные Челны

Д.Р. Галиев,

ассистент кафедры математических методов в экономике Казанского федерального университета, филиал в г. Набережные Челны

Адрес: г. Набережные Челны, бульвар Строителей, д. 1 (5/10)

E-mail: isavnin@mail.ru, damir.galiev@mail.ru

В настоящей статье рассматривается разработанное программное обеспечение для управления структурой портфеля ценных бумаг. Описаны реализованные модели и алгоритмы, а также приведены результаты экспериментов на данных российского фондового рынка. Рассмотрены преимущества и недостатки, альтернативные методы измерения риска и доходности. Разработанное приложение позволяет подключаться к торгам посредством взаимодействия с популярными торговыми терминалами.

Ключевые слова: инвестиционный портфель, моделирование, генетические алгоритмы, нейронные сети.

1. Математические модели выбора оптимального инвестиционного портфеля

Формирование оптимального инвестиционного портфеля является весьма актуальной задачей, как для представителей бизнеса (институциональных инвесторов), так и для частных инвесторов. Применение количественных методов позволяет повысить качество

инвестиционного портфеля. В большинстве современных аналитических программ отсутствует возможность создавать продвинутые количественные модели выбора оптимального инвестиционного портфеля. В настоящей статье описывается разработанный нами программный комплекс для построения оптимальных инвестиционных портфелей с использованием нескольких оптимизационных моделей.

Рассмотрим некоторые математические модели выбора оптимального инвестиционного портфеля, представленные в программном обеспечении. Пусть $x=(x_1, x_2, \dots, x_n)$ – вектор, определяющий структуру инвестиционного портфеля, n – количество активов в портфеле. При этом

$$\sum_{i=1}^n x_i = 1.$$

Доходности активов являются случайными величинами и характеризуются вектором

$$\bar{R}=(R_1, R_2, \dots, R_n).$$

Очевидно, что доходность инвестиционного портфеля

$$R=\sum_{i=1}^n R_i x_i.$$

Основной идеей большинства моделей выбора оптимального инвестиционного портфеля является максимизация доходности при ограниченном риске или минимизация риска при ограниченной доходности. В качестве мер риска могут использоваться такие показатели как [1]:

1. Value-at-Risk (*VaR*)
2. Conditional Value-at-Risk (*CVaR*)
3. Mean Semi-Absolute Deviation (*MSAD*)
4. Нижние частные моменты (*LMP*) и, как частный случай, полудисперсия – нижний частный момент порядка 2
5. Просадка как мера риска (*CDaR*)

В одной из наших предыдущих работ были описаны результаты численных экспериментов на российском фондовом рынке с вышеперечисленными мерами риска [2]. Итак, рассмотрим следующие модели:

◆ 1. Классическая модель Г. Марковица.

$$\begin{aligned} \min_x \sum_{i=1}^n \sum_{j=1}^n x_i V_{ij} x_j, \\ \sum_{i=1}^n x_i MR_i = m_p, \\ \sum_{i=1}^n x_i = 1, \end{aligned} \quad (1)$$

где V_{ij} – матрица ковариаций доходностей, MR_i – средняя доходность актива i , m_p – заданная пользователем ожидаемая доходность. Целевая функция представляет собой среднее квадратическое отклонение (СКО) доходности портфеля. Минимизируя СКО, можно снизить и возможное отклонение доходности в положительную сторону, что является одним из недостатков данной модели.

◆ 2. Модель максимизации доходности при ограниченном Value-at-Risk (*VaR*).

$$\begin{aligned} \max_x \sum_{i=1}^n R_i x_i, \\ VaR_\alpha = -\mu_p - z_\alpha \sigma_p, \\ \sum_{i=1}^n x_i = 1, \\ l_i \leq x_i \leq u_i, \quad i = \overline{1, n}, \end{aligned} \quad (2)$$

где l_i и u_i отражают дополнительные ограничения на долю i -го актива в портфеле, VaR_α – заданный пользователем уровень Value-at-Risk. Значение VaR уровня $1 - \alpha$ (VaR_α) определяется как

$$P(R_p \leq -VaR_\alpha) = \alpha \quad (3)$$

Совершив ряд преобразований, получим:

$$\begin{aligned} P(R_p \leq -VaR_\alpha) = \alpha \Leftrightarrow P\left(\frac{R_p - \mu_p}{\sigma_p} \leq \frac{-VaR_\alpha - \mu_p}{\sigma_p}\right) = \alpha \Leftrightarrow \\ \frac{-VaR_\alpha - \mu_p}{\sigma_p} = z_\alpha \Leftrightarrow VaR_\alpha = -\mu_p - z_\alpha \sigma_p, \end{aligned} \quad (4)$$

где R_p – доходность портфеля, μ_p – средняя доходность портфеля, σ_p – риск портфеля (СКО), z_α – квантиль стандартного нормального распределения порядка α . При этом полагается, что доходность портфеля имеет распределение, близкое к нормальному. Так, VaR уровня 95% (т.е. при $\alpha = 0,05$) будет определяться как $VaR_{0,05} = -\mu_p + 1,6449 \sigma_p$.

◆ 3. Модель минимизации *MSAD* при ограниченной снизу доходности и наличии дополнительных ограничений на структуру портфеля.

$$\begin{aligned} \min_x M(|\min\{0, R - MR\}|), \\ \sum_{i=1}^n R_i x_i \geq R_0, \\ \sum_{i=1}^n x_i = 1, \\ l_i \leq x_i \leq u_i, \quad i = \overline{1, n}, \end{aligned} \quad (5)$$

где R_0 – константа, которая задается пользователем модели и означает нижний предельный уровень доходности портфеля; l_i и u_i отражают дополнительные ограничения на долю i -го актива в портфеле; M – знак математического ожидания. Целевая функция $M(|\min\{0, R - MR\}|)$ определяет среднее полуабсолютное отклонение доходности портфеля (Mean Semi-Absolute Deviation – *MSAD*).

◆ 4. Модель максимизации асимметрии доходности при ограниченной снизу доходности и наличии дополнительных ограничений на структуру портфеля.

$$\begin{aligned} & \max_x \frac{M[(R-MR)^3]}{\sigma_R^3}, \\ & \sum_{i=1}^n R_i x_i \geq R_0, \\ & \sum_{i=1}^n x_i = 1, \\ & l_i \leq x_i \leq u_i, \quad i = \overline{1, n}, \end{aligned} \quad (6)$$

где R_0 – константа, задается пользователем модели и означает нижний предельный уровень доходности портфеля; l_i и u_i отражают дополнительные ограничения в портфеле на актив i ; σ_R – СКО доходности портфеля. Целевая функция

$$\frac{M[(R-MR)^3]}{\sigma_R^3}$$

определяет коэффициент асимметрии доходности портфеля, который обладает определенным экономическим смыслом. Если коэффициент асимметрии имеет положительное значение, то высокие значения доходности являются более вероятными (рис. 1а) и наоборот (рис. 1б). Следовательно, чем выше значение положительного коэффициента асимметрии, тем лучше сформированный портфель.

◆ 5. Модель максимизации эксцесса доходности при ограниченной снизу доходности и наличии дополнительных ограничений на структуру портфеля.

$$\begin{aligned} & \max_x \left(\frac{M[(R-MR)^4]}{\sigma_R^4} - 3 \right), \\ & \sum_{i=1}^n R_i x_i \geq R_0, \\ & \sum_{i=1}^n x_i = 1, \\ & l_i \leq x_i \leq u_i, \quad i = \overline{1, n}, \end{aligned} \quad (7)$$

где R_0 – константа, которая задается пользователем модели и означает нижний предельный уровень доходности портфеля; l_i и u_i отражают дополнительные ограничения в портфеле на актив i ; M – математическое ожидание; σ_R – СКО доходности портфеля. Целевая функция

$$\gamma = \left(\frac{M[(R-MR)^4]}{\sigma_R^4} - 3 \right)$$

определяет коэффициент эксцесса доходности портфеля. Эксцесс характеризует меру остроты пика распределения доходности портфеля. Острый




Рис. 1. Гистограммы доходности с разными коэффициентами асимметрии: (а) положительная асимметрия; (б) асимметрия отрицательна

пик $\gamma > 0$ говорит о преимущественном стремлении доходности к своему среднему значению (рис. 2а), что, как правило, говорит о меньшем значении волатильности портфеля σ_R , а, следовательно, о меньшем риске. Гладкий пик $\gamma < 0$ свидетельствует о тяжелых хвостах распределения и, следовательно, о повышенных рисках (рис. 2б).




Рис. 2. Гистограммы доходности с разными коэффициентами эксцесса: (а) положительный коэффициент эксцесса; (б) отрицательный коэффициент эксцесса

В моделях (2-5) используется классический показатель эффективности – средняя доходность и прогнозы по нейросетевым и эконометрическим моделям.

Для решения оптимизационных задач применен метод генетических алгоритмов [3]. Генетические алгоритмы (ГА) относятся к классу эволюционных алгоритмов. В теории генетических алгоритмов принято использовать биологические термины. Например, хромосома – конкретное решение, представ-

ленное в виде битовой строки. Индивид, родитель, потомок являются хромосомами. Набор хромосом образует популяцию. Общий порядок работы генетического алгоритма выглядит следующим образом:

1. Инициализация популяции решения случайным образом.
2. Выбор части популяции (родителей) для порождения потомков. Процедура выполняется с помощью оператора селекции.
3. Применение оператора скрещивания.
4. Мутация новых решений (потомков).
5. Формирование новой популяции путем выбора лучших решений из множества родителей и потомков.
6. Повторение шагов 2-5 до тех пор, пока не будет выполнен критерий останова.

На первом шаге инициализации определяются значения параметров генетического алгоритма: длина хромосомы, размер популяции и вероятность мутации. Для осуществления процедуры селекции можно использовать метод турнирной селекции [4]. Сначала пользователь определяет, так называемый, размер турнирной группы N_i и количество групп (обычно создают 5-6 групп). Далее случайным образом в каждую группу из популяции индивидов выбираются N_i индивидов. Из выбранных индивидов в каждой группе отбирается индивид с лучшим значением функции приспособления (например, максимальная доходность или минимальный риск). В качестве функции приспособления (фитнесс-функции) используется целевая функция оптимизационной задачи. Для учета ограничений можно применять метод штрафных функций. После чего лучшие индивиды от каждой группы подвергаются скрещиванию.

Для скрещивания индивидов используют следующий подход [5]. С помощью оператора селекции отбирают 2 индивида. Одноточечное скрещивание

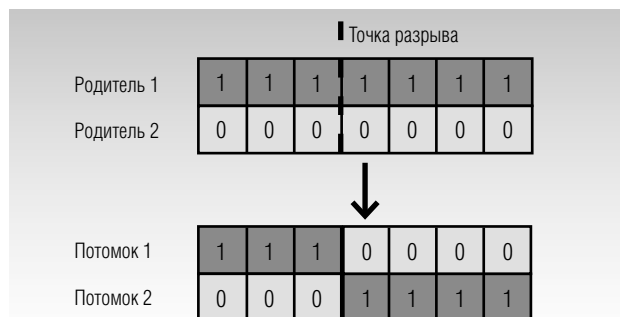


Рис. 3. Пример точечного скрещивания




Рис. 4. Пример мутации

позволяет получить два новых индивида. Точка скрещивания выбирается случайно. Пример показан на рис. 3. Мутация осуществляется следующим образом: с выбранной вероятностью P , каждый бит индивида, полученного после процедуры скрещивания, изменяется на противоположный. Пример представлен на рис. 4.

Новая популяция формируется путем сортировки. То есть формируется промежуточная популяция путем объединения родителей и потомков. N лучших, с точки зрения функции приспособления, индивидов перейдут в новое поколение. Здесь N – размер популяции. Алгоритм останавливают после того, как будет выполнено заданное количество итераций. Обычно принято проводить $N_1 \times N_2$ итераций, где N_1 – максимальное число популяций, N_2 – размер популяций, изначально задаваемые пользователями.

2. Использование прогнозов доходностей активов при моделировании

В разработанном нами программном обеспечении были использованы два типа моделей прогнозирования временных рядов: модель авторегрессии-скользящего среднего (*autoregressive moving-average model, ARMA*) и нейросетевая модель прогнозирования временного ряда. Прогнозы доходности по этим моделям могут быть учтены при формировании оптимального инвестиционного портфеля. Рассмотрим их основную суть. Моделью *ARMA* (p, q), где p и q целые числа, задающие порядок модели, называется следующий процесс генерации временного ряда y_t :

$$y_t = c + \sum_{i=1}^p \alpha_i y_{t-i} + \varepsilon_t - \sum_{j=1}^q \beta_j \varepsilon_{t-j}, \quad (8)$$

где c – константа, $\{\varepsilon_t\}$ – белый шум, т.е. последовательность независимых и одинаково распределённых случайных величин с нулевым средним, а α_i и β_j – действительные числа (авторегрессионные коэффициенты и коэффициенты скользящего среднего, соответственно) [6]. Для идентификации модели (нахождения значений p и q) анализируются автокорреляционная и частная автокорреляцион-

ная функции. Для оценки параметров модели α_i, β_j и c можно применить алгоритм Бокса-Дженкинса [7] или метод максимального правдоподобия [8]. В нашем приложении реализован последний метод.

Нейронные сети являются мощным эвристическим инструментом для решения широкого класса задач. В нашем программном комплексе алгоритм нейронных сетей применен для прогнозирования временного ряда. Математическая модель нейрона выглядит следующим образом (рис. 5). Эта модель была предложена Макколлом и Питтсом [9] еще в 1943 г.

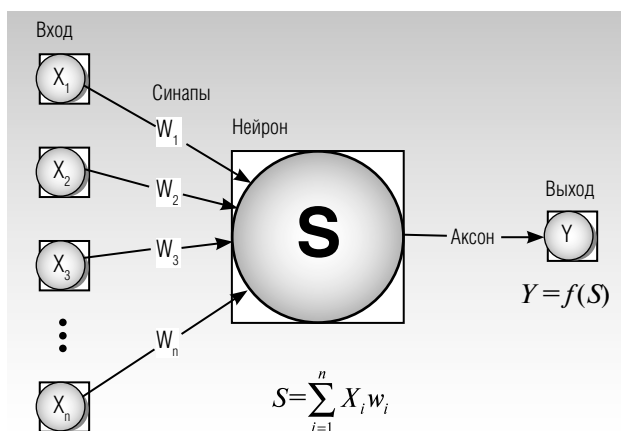


Рис. 5. Математическая модель нейрона

Сигналы X_1, X_2, \dots, X_n , поступаая на синапсы, преобразуются линейным образом

$$S = \sum_{i=1}^n X_i w_i,$$

где w_i – веса соответствующих синапсов, n – размерность пространства входных сигналов. Далее в действие вступает нелинейная функция активации $Y = f(S)$. В нашем случае, в качестве функции активации была выбрана сигмоидная функция:

$$f(S) = \frac{1}{1 + e^{(-bS)}}. \quad (9)$$

Для обучения нейронной сети был использован алгоритм обратного распространения ошибки – это итеративный градиентный алгоритм обучения, который используется с целью минимизации среднеквадратичного отклонения текущего выхода и желаемого выхода многослойных нейронных сетей [10].

Архитектура двухслойной сети для прогнозирования временного ряда представлена на рис. 6. У рассматриваемой сети n входов и один выход. Несмотря на свою простоту, подобная архитектура широко используется для решения прикладных задач [11]. Каждый i -й нейрон первого слоя ($i=1, m$) имеет n входов с весами $w_{1i}, w_{2i}, \dots, w_{ni}$. Заметим, что сумма весов не обязательно равна единице. После получения входных сигналов, нейрон суммирует их с соответствующими весами, затем применяет к этой сумме функцию активации и пересылает результат на вход нейрона второго (выходного) слоя. В свою очередь, нейрон выходного слоя суммирует полученные от второго слоя сигналы с некоторыми весами v_j , после чего результат вновь проходит через функцию активации.

Алгоритм обратного распространения ошибки можно описать следующим образом.

1. На этапе инициализации весам сети присваиваются начальные значения – некоторые малые случайные числа.
2. Выбирается очередная обучающая пара $(X; Y)$ из обучающего множества; вектор X подается на вход сети. Значения входа X формируются методом «скользящего окна». К примеру, для временного ряда X_t обучающая пара с размером окна, равным 3, может выглядеть следующим образом: $(X_{t-1}, X_{t-2},$

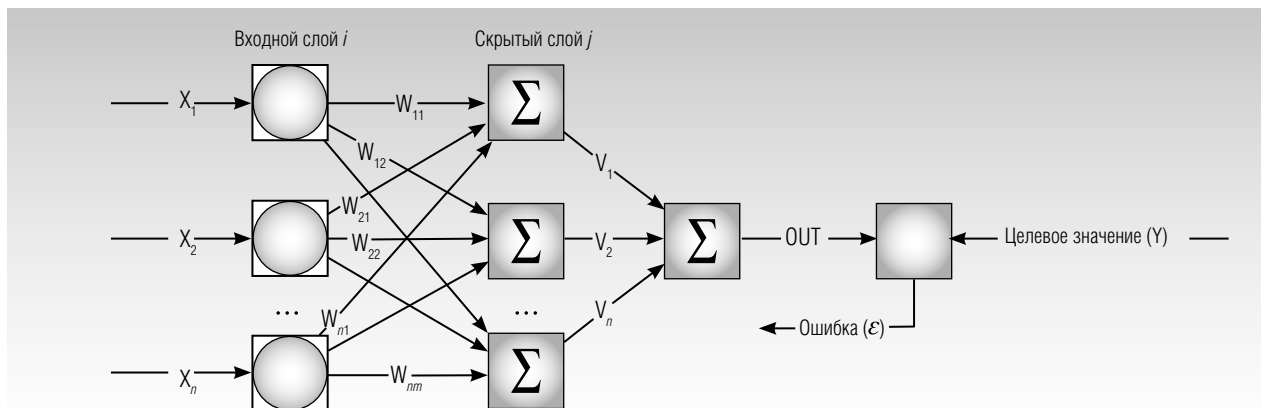


Рис. 6. Двухслойная нейронная сеть

X_{t-3} ; X_t). Здесь в качестве целевого значения (Y) выступает реальное значение котировки (X_t) в момент t , а в качестве входа (X) «предыстория» в виде вектора ($X_{t-1}, X_{t-2}, X_{t-3}$).

3. Вычисляется выход сети.
4. Вычисляется разность между требуемым (целевым, Y) и реальным (вычисленным) выходом сети.
5. Веса сети корректируются так, чтобы минимизировать ошибку.
6. Шаги со 2-го по 5-й повторяются для каждой пары обучающего множества до тех пор, пока ошибка на всем множестве не достигнет приемлемой величины или не будет произведено допустимое число итераций.

Главной проблемой большинства моделей прогнозирования временных рядов является подбор горизонта обучения. Нейронные сети могут подгоняться под обучающую выборку и вне пределов этой выборки часто обладают не очень качественными предикативными свойствами. Рассмотренные и реализованные в программе модели прогнозирования временных рядов не являются исчерпывающими и лучшими в своем роде. Нашей основной целью является показать, как наличие более-менее качественных оценок будущих доходностей может повлиять на результат и качество инвестиционного портфеля.

3. Описание разработанного программного комплекса

Приложение разрабатывалось в среде Microsoft Visual Studio 2010 (Express edition) на языке C# 4.0. Продукт требует установленной среды Microsoft .Net 4, которая, в случае отсутствия, загружается автоматически с узла Microsoft во время установки. Приложение тестировалось и корректно работало на ОС Windows XP, Vista, Seven. Структура программы представлена на схеме.

Ядро системы состоит из модуля общих вычислений, модуля генетических алгоритмов оптимизации и модуля прогноза временных рядов. Информация об активах хранится в базе данных. Пользовательский интерфейс позволяет работать с данными, отображать графики и указывать настройки алгоритмов. Возможность подключения к реальным торгам осуществлена благодаря использованию свободно распространяемой библиотеки Stock# [12]. В разработанном приложении реализовано подключение к торгам посредством биржевого торгового терминала Quik [13]. Однако библиотека Stock# позволяет с малейшими изменениями в коде связать разрабатываемое приложение с другими торговыми терминалами: SmartCOM, Alfa-Direct, PlazaII и др. [14]. Механизм взаимодействия приложения с Quik представлен на рис. 8. Dynamic

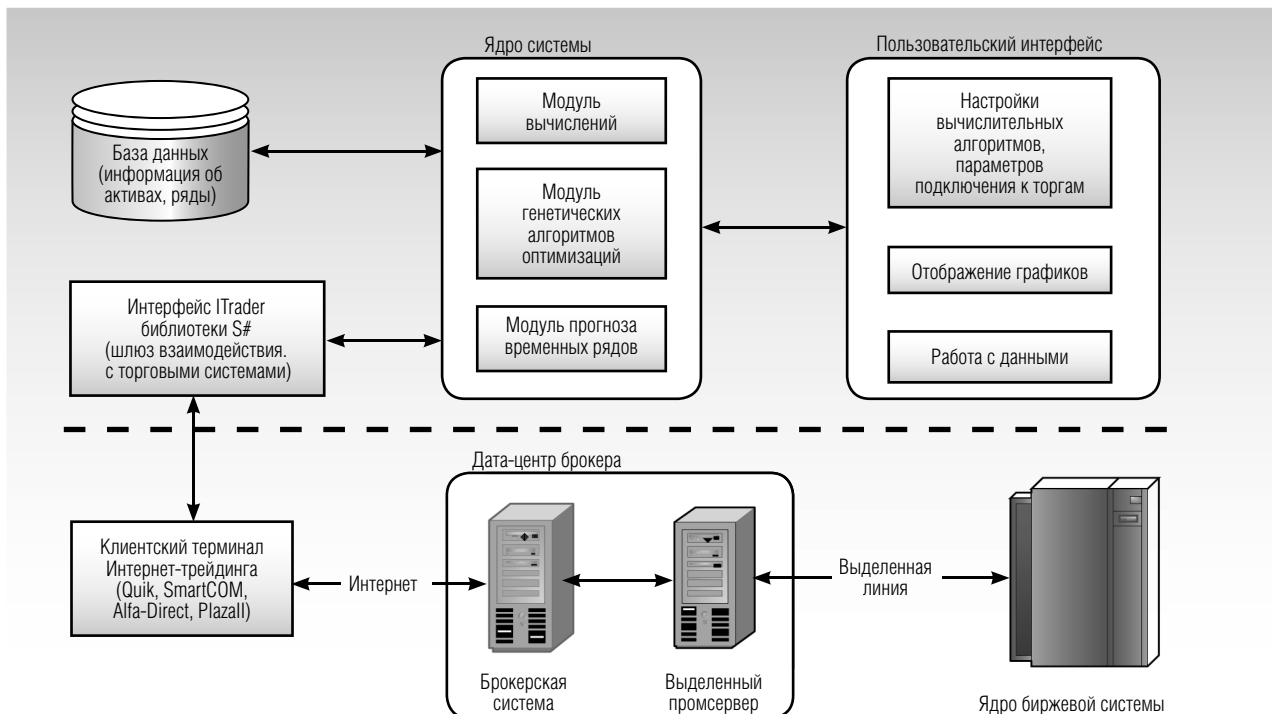


Рис. 7. Схема структуры программы




Рис. 8. Механизм взаимодействия Quik и приложения

Data Exchange (DDE) – это технология быстрой передачи данных, которую поддерживает Quik.

Рассмотрим процесс работы с программой. Главное окно предоставлено на рис. 9. Пользователю выводится список активов, из которых будет составлен инвестиционный портфель. Панель инструмента состоит из трех блоков. Первый блок отвечает за стандартные действия с файлами: создание нового файла, открытие, сохранение. Второй блок отвечает

за управление списком активов: добавление, редактирование и удаление. В третьем блоке находятся средства редактирования настроек, средства расчета структуры портфеля по определенным моделям и средство вывода результатов вычислений.

При добавлении и редактировании активов отображается окно примерно одинаковой структуры (рис. 10). Пользователь вручную вводит название и тикер актива, а также временной ряд цен, который также можно вставить из буфера обмена. После чего рассчитывается временной ряд доходности, базовая статистика доходности актива, а также отображаются график цен и гистограмма распределения доходности. В меню редактирования можно осуществлять прогноз временного ряда по нейросетевой и ARMA моделям. Предусмотрена возможность ручного ввода стороннего прогноза (прогноза, полученного из других источников) по средством отдельного окна.

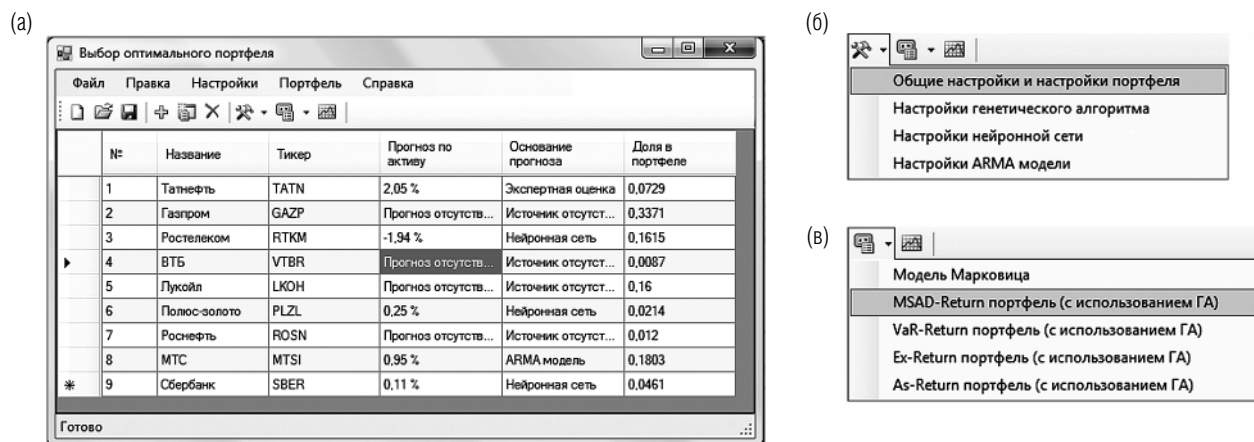


Рис. 9. Главное окно программы; (а) – главное окно; (б) – настройка программы; (в) – выбор модели

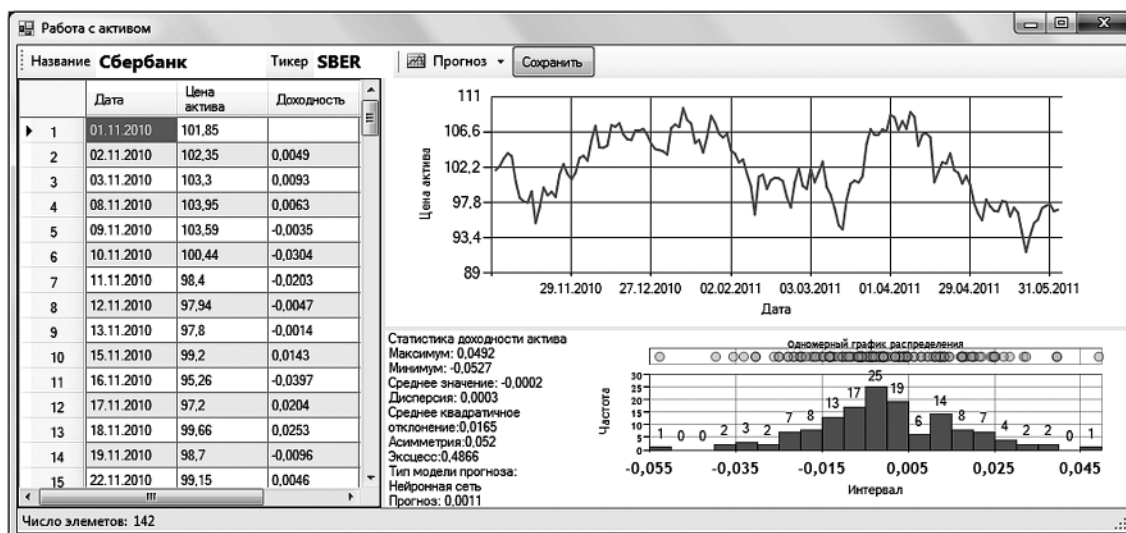


Рис. 10. Меню редактирования актива

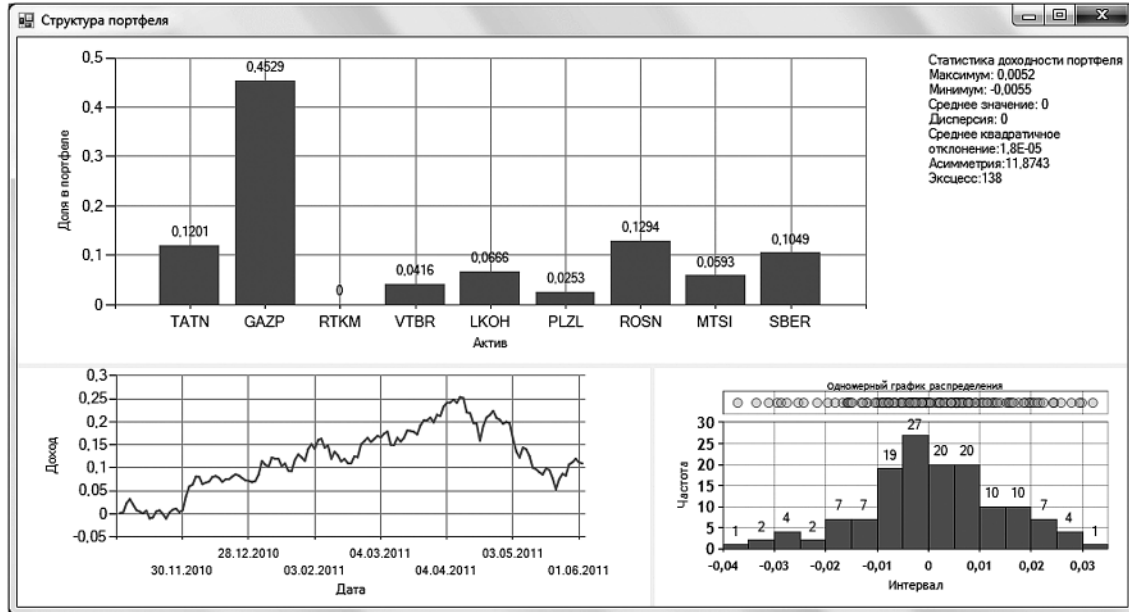


Рис. 11. Отображение результатов оптимизации

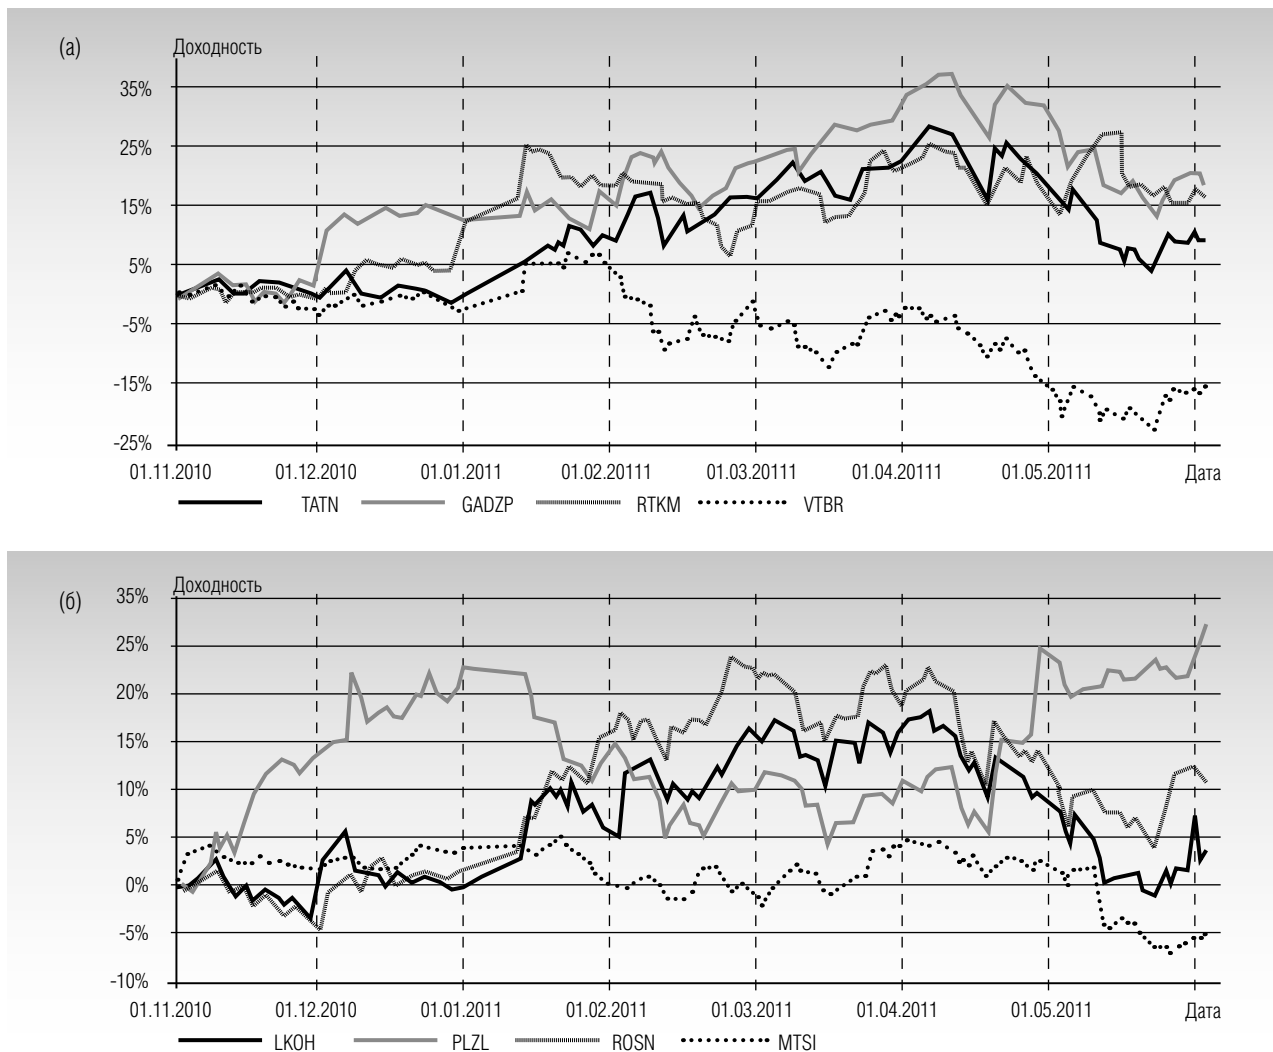


Рис. 12. Кривые доходностей активов

Результаты оптимизации структуры портфеля выносятся в отдельном окне (рис. 11). В верхней части окна отображена гистограмма структуры портфеля и базовая статистика исторической доходности портфеля. В левом нижнем углу отображается кривая доходности портфеля при вычисленной структуре. В правом нижнем углу выводится гистограмма распределения исторической доходности портфеля.

Структуру портфеля и информацию об активах можно экспортировать в Microsoft Excel.

4. Эксперименты на данных российского фондового рынка

Эксперименты проводились на данных российского фондового рынка – объединенной биржи ММВБ-РТС. Активы, с которыми проводились эксперименты: обыкновенные акции ОАО «Татнефть» (TATN), ОАО «Газпром» (GAZP), ОАО «Ростелеком» (RTKM), ОАО «ВТБ» (VTB), ОАО «Лукойл» (LKOH), ОАО «Полюс-Золото» (PLZL), ОАО «Роснефть» (ROSN), ОАО «МТС» (MTSI), ОАО «Сбербанк» (SBER). Временной период проведения экспериментов: 01.11.2010 – 01.06.2011. Кривые доходностей активов на рассматриваемом промежутке представлены на рис. 12 (а) и (б).

При проведении экспериментов с реальными активами необходима была историческая информация о доходности активов. На каждом этапе (всего 14 этапов) рассматриваемого промежутка нейронная сеть и ARMA предварительно обучались на основе информации о доходности активов за предыдущие 3 месяца. Прогнозы моделей использовались в течение 2-х недель, после чего происходило их переобучение.

Как уже отмечалась, для оценки доходности кроме исторической средней использовались прогнозы на основе нейросетевой и ARMA моделей. Результаты прогнозирования с использованием модели ARMA представлены в табл. 1. Результаты для нейронной сети приведены в табл. 2. Информация в таблицах представлена по данным вне обучающей выборки. Здесь MSE (Mean Squared Error) - средне-квадратическая ошибка:

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2, \quad (10)$$

где e_t – разность фактического и реального значения для момента t , n – объемы выборки. Как видно из результатов, практически для всех активов нейронные сети демонстрируют более предпочтительные результаты по сравнению с ARMA моделью.

Таблица 1.

Результаты обучения ARMA моделей

Актив	Макс. ошибка, (%)	Мин. ошибка, (%)	Средняя ошибка, (%)	MSE
TATN	20.02	2.10	13.93	6.85e-2
GAZP	17.01	1.84	14.70	9.91e-2
RTKM	16.71	3.44	15.22	1.14e-2
VTBR	19.62	2.09	14.70	5.75e-2
LKOH	21.70	3.66	13.34	8.51e-2
ROSN	18.64	2.44	17.23	2.74e-2
MTSI	19.50	1.37	15.44	5.81e-2

Таблица 2.

Результаты обучения нейросетевых моделей

Актив	Макс. ошибка, (%)	Мин. ошибка, (%)	Средняя ошибка, (%)	MSE
TATN	18.33	0.71	11.97	5.76e-2
GAZP	18.38	0.95	8.98	8.71e-2
RTKM	14.97	0.45	10.10	1.64e-2
VTBR	17.35	1.46	14.77	4.63e-2
LKOH	16.05	1.04	15.39	7.15e-2
ROSN	18.32	0.69	12.53	1.93e-2
MTSI	12.89	2.35	12.06	4.34e-2

Для оценки соотношения риска и доходности портфелей использовался коэффициент Шарпа [15]. Этот показатель по-другому называют коэффициент «доходность-разброс» (reward-to-variability ratio):

$$RVAR = \frac{r_p - r_f}{\sigma_p}, \quad (11)$$

где r_p – средняя доходность портфеля за рассматриваемый промежуток времени, r_f – среднее значение безрисковой ставки, σ_p – стандартное отклонение доходности портфеля (общий риск). В качестве безрисковой ставки использовалась доходность государственных облигаций. Мы также приводим статистику максимальной просадки доходности портфеля. Этот показатель в последнее время становится все более популярным. В табл. 3 приведена статистика портфелей. Здесь характеристики портфеля в рамках модели Марковица рассчитывались только для случая с использованием средней исторической доходности (для сравнения методов оценки риска).

Что касается близости ожидаемых характеристик портфелей (риска и доходности) и реальных значений, то здесь результат напрямую зависит от использованной модели прогнозирования временных рядов доходностей. Особенно это существенно для доходности портфеля. Ожидаемые значения коэффициентов асимметрии и эксцесса отличались несильно от ожидаемых значений (максимальное отличие – 20,33%, минимальное – 2,87%, среднее

– 15,82%). В то же время значения мер риска VaR и MSAD отличались сильнее (максимальное отличие – 35,03%, минимальное – 3,11%, среднее – 21,23%).

Таблица 3.

Статистика портфелей

Модель	Доходность на рассматриваемом периоде, (%)	Максимальная просадка, (%)	Коэффициент Шарпа
1. Использование средней доходности			
1. Модель Марковица	7,8	5,10	1,25
2. VaR-Доходность	10,1	3,52	1,27
3. MSAD-Доходность	11,8	3,61	1,31
4. Асимметрия-Доходность	12,3	4,61	1,29
5. Экссцесс-Доходность	12,1	4,94	1,28
2. Использование прогноза доходности по модели ARMA			
1. VaR-Доходность	11,5	3,44	1,36
2. MSAD-Доходность	12,8	3,51	1,40
3. Асимметрия-Доходность	13,3	4,41	1,41
4. Экссцесс-Доходность	12,9	4,81	1,45
3. Использование прогноза доходности по нейросетевой модели			
1. VaR-Доходность	13,4	3,45	1,39
2. MSAD-Доходность	13,2	3,49	1,42
3. Асимметрия-Доходность	13,43	4,45	1,41
4. Экссцесс-Доходность	13,5	4,78	1,43

Динамика доходности некоторых портфелей представлена на рис. 13 (а, б). В скобках указаны модели, которые были использованы для прогнозирования доходности.

По результатам можно сделать основной вывод, что использование прогнозов доходностей, особенно на основе нейронных сетей, позволяет повысить качество инвестиционных портфелей. Модели, в которых были использованы прогнозы доходностей активов, в большинстве случаев, обладают лучшим соотношением риска и доходности, по-сравнению с моделями, где в качестве доходности была использована историческая средняя доходность. Результативность напрямую зависит от качества выбранной модели прогнозирования. Что касается мер риска, то практически сохранились результаты, которые были ранее полученные в [2]. То есть мы ещё раз можем наблюдать, что портфели, оптимизированные по VaR и асимметрии, обладают лучшим соотношением риска и доходности. Также можно отметить тот факт, что модели «экссцесс-доходность» продемонстрировали довольно приемлемые результаты.

5. Заключение

Разработанное программное обеспечение позволяет решать задачу выбора оптимального инвестиционного портфеля с использованием современных специализированных моделей выбора оптимального инвестиционного портфеля. В приложение встроено модуль по прогнозу доходности рассматриваемых активов на основании ARMA- и нейросетевых моделей. Также есть возможность учитывать прогнозы экспертов и сторонних моделей. Комплекс обладает возможностью подключения к биржевым торгам, благодаря использованию библиотеки Stock#. Программа обладает достаточной гибкостью: можно реализовывать новые модели выбора портфеля, до-

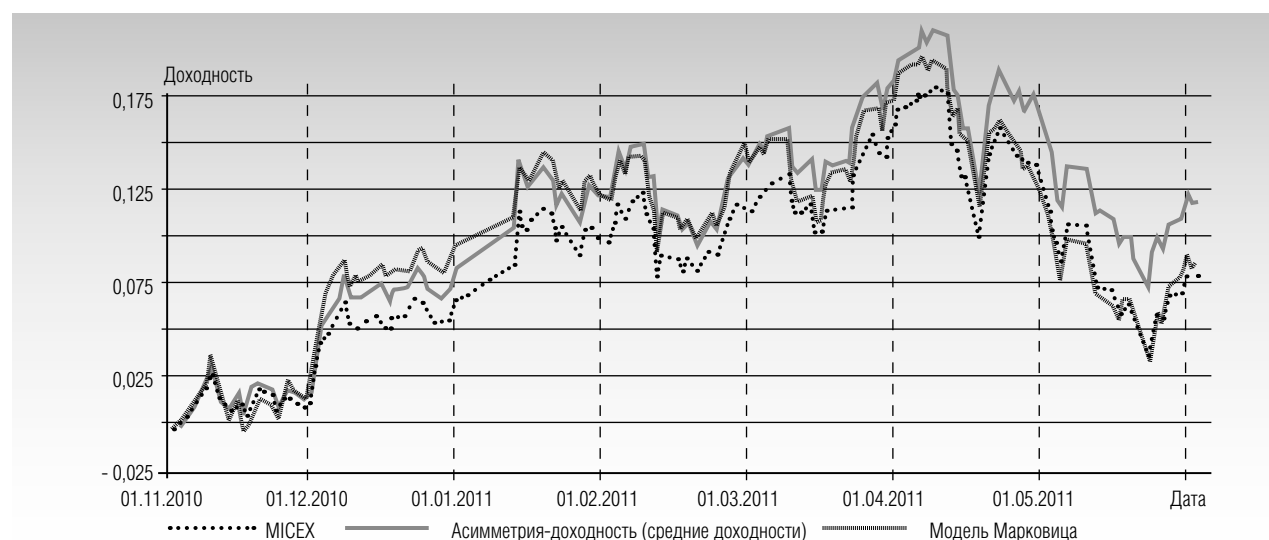


Рис. 13 а. Динамика доходности некоторых портфелей




Рис. 13 б. Динамика доходности некоторых портфелей

бавить модели прогнозирования временных рядов, улучшить взаимодействие программы с биржевыми терминалами. Результаты экспериментов на российском фондовом рынке позволяют говорить о возможности использования разработанного приложения на практике. Результаты моделей в большой степени зависят от качества введенных экспертных оценок или методов прогноза временных рядов. Экспери-

менты с данными российского фондового рынка с использованием разработанного приложения позволили убедиться в приемлемости некоторых моделей и их преимуществе перед стандартными подходами. Модели, в которых рассчитываются показатели на основе исторических данных, являются адекватными в течение относительно короткого срока и только в рамках сложившейся рыночной ситуации. ■

Литература

1. Lohre H., Neumann T., Winterfeldt T. Portfolio construction with Asymmetric Risk Measures. — Frankfurt am Main: Union Investment, 2007.
2. Исавнин А.Г., Галиев Д.Р. Модели портфельного инвестирования с применением асимметричных мер риска и генетических алгоритмов // Финансовая аналитика. — 2011. — №48. — С. 32–38.
3. Курейчик В.В., Голодков Л.А., Курейчик В.Н. Генетические алгоритмы. — М.: Физматлит, 2010.
4. Еремеев А.В. Генетические алгоритмы и оптимизация. — Омск: Институт математики им. С.Л. Соболева, 2010. — URL: <http://iitam.omsk.net.ru/~eremeev/PAPERS.SK/Method.pdf> (дата обращения 17.03.2012)
5. Эволюционные методы моделирования и оптимизации сложных систем / Е.С.Семенкин, М.Н.Жукова, В.Г.Жуков, И.А.Панфилов, В.В.Тынченко. — Красноярск, 2007. — URL: http://library.krasu.ru/ft/ft_umkd/22/u_lectures.pdf (дата обращения 17.03.12)
6. Дуброва Т.А. Статистические методы прогнозирования в экономике. — М.: Московский международный институт эконометрики, информатики, финансов и права, 2003.
7. Бокс Д., Дженкинс Г. Анализ временных рядов. Прогноз и управление. Вып. 2. — М.: Мир, 1974.
8. Эконометрия / В.И.Суслов, Н.М.Ибрагимов, Л.П.Талышева, А.А.Цыплаков. — Новосибирск : Изд. Новосибирского государственного университета, 2005.
9. Хайкин С. Нейронные сети: полный курс. 2-е издание.: Пер. с англ. — М.: Изд. дом «Вильямс», 2006.
10. Каллан Р. Основные концепции нейронных сетей.: Пер. с англ. — М.: Изд. дом «Вильямс», 2001.
11. Каширина И.Л. Нейросетевые технологии: учебно-методическое пособие для вузов. — Воронеж : Изд. Воронежского государственного университета, 2008.
12. Официальный сайт библиотеки Stock#. URL: <http://stocksharp.com/> (дата обращения: 17.03.2012)
13. Официальный сайт системы Quik. URL: <http://quik.ru/about/> (дата обращения: 17.03.2012)
14. Справочная система библиотеки Stock#. URL: <http://stocksharp.com/doc/html/87d2cacd-5492-4bca-9140-7d7c3f5218d7.htm> (дата обращения: 17.03.2012)
15. Le Sourd V. Performance Measurement for Traditional Investment // EDHEC, 2007. URL: http://www.edhec-risk.com/performance_and_style_analysis/perf_measurement (дата обращения: 17.03.2012)