

# Разработка анимата для скальпинга

Мартынович В.В.<sup>2</sup>, Витяев Е.Е.<sup>1,2</sup>

<sup>1</sup>Институт математики им. Соболева, г. Новосибирск

<sup>2</sup>Новосибирский Государственный Университет

evgenii.vityaev@math.nsc.ru, vilco@ya.ru

**Аннотация.** *Объектом исследования является высокочастотная торговля на фондовом рынке (скальпинг). Целью исследования была поставлена разработка модели указанных объектов и конструирование анимата действующего в среде «биржа» на основе имитаций действий компетентного лица (эксперта). В данной работе мы фактически предлагаем механический способ решения задачи черного ящика посредством техники семантического вероятностного вывода. Законченный план действий наряду с разработанным программным комплексом служит полным решением поставленной задачи. В качестве подтверждения эффективности работы метода поставлен эксперимент, ясно дающий понять, что достаточно логичная и прозрачная конструкция обеспечивает замечательные результаты в смысле предложенной само собой разумеющейся полезности. К сожалению, теоретический анализ ожидаемой эффективности на данный момент не представляется возможным, ввиду принципиальной неформализуемости многих компонентов исследуемой системы, и заслуживает отдельной исследовательской работы.*

**Ключевые слова:** анимат, обучение, имитация, черный ящик, биржа, скальпинг, принцип MEU, вероятностная закономерность, DISCOVERY, предсказание, прогноз

## 1 Введение

Ситуация, с которой начинается приведенное здесь описание, весьма типична. Для начала рассмотрим некоторый объект  $O$ , находящийся в сфере внимания субъекта  $S$ . Субъект  $S$  не понимает принципа действия  $O$ , но видит некоторый желаемый с его точки зрения результат.

Предлагаемая задача широко известна в мире как задача о «черном ящике». Решающий такую задачу имеет возможность воздействовать на изучаемое нечто всеми допускаемыми этим нечто образами, а также наблюдать за полученным от него ответом. Иными словами, экспериментатору доступен некоторый набор действий с подопытным черным ящиком, подаваемый на его вход, и данные на выходе. Проблема экспериментатора в том, что он не имеет доступа к внутренности и механизму работы черного ящика, что существенно снижает его шансы на проникновение в функциональную суть изучаемого.

Более широкая постановка может включать в себя понятие обучения. Действительно, что значит «понять как работает черный ящик  $O$ »? Понять механизм – значит научиться мысленно воспроизводить ход работы  $O$ . Только тогда мы можем ясно представить себе происходящее внутри функционально важных элементов изучаемого объекта. В свою очередь, это и обозначает, что мы должны научиться действовать (хотя бы мысленно, хотя это состояние перевести в физически осуществленное представляется тривиальной задачей) ровно так, как это делает черный ящик. Задача изучения работы объекта  $O$  равносильна задаче обучения субъекта  $S$  в смысле выполнения функций возложенных на  $O$  его же методами.

Научив субъект  $S$  действовать в соответствии с рассматриваемым механизмом, мы получаем возможность имитировать действие  $O$  средствами  $S$ . Сказанное в данном контексте обозначает тесную (если вообще отличимую) связь обучения с имитацией. Если читателю угодно, можно закрепить сие, как «обучение посредством имитации» или же «имитация базирующаяся на обучении».

## 2 Фондовый рынок и роботы

В качестве области деятельности для наглядной реализации излагаемого принципа «расшифровки» черного ящика мы выбрали финансы. Причина проста и кроется в очевидном критерии оценки качества результата.

Суть игры на фондовом рынке сводится к извлечению денежной прибыли из ценовых флуктуаций в рамках торговых инструментов (например, акций). Каждый из участников процесса оказывает на флуктуации некоторое влияние посредством выставления заявок, отражающих стремление игрока к покупке или продаже определенного количества ценных бумаг по указанной цене. При соответствии интересов владельцев двух разнонаправленных заявок, они сводятся в сделку (рис. 2.1). Каждая такая сделка называется тиком, а последовательность цен в тиках формирует кривую цены (и другие вспомогательные графические представления).



Рис. 2.1. Образование сделки (тика данных)



Рис. 2.2. Тиковые данные

Предположим теперь, что у нас есть некоторый эксперт (далее обозначаемый Э), эффективно решающий задачу получения прибыли путем игры на описанном фондовом рынке. Рассматривая действия Э как некий эталон, образец для подражания, мы попытаемся вскрыть черный ящик и воссоздать логику действий эксперта путем имитационного обучения. Таким образом, будет построен робот, самостоятельно играющий на фондовом рынке.

Следует также отметить именно в скаперовский режим будущего робота: субъект производит операции по выставлению-снятию заявок очень часто, в пределах нескольких секунд, пытаясь, таким образом, уловить хотя бы малейшее движение рынка.

Подход, предлагаемый в данной работе, заключается в использовании машинного обучения. За основу мы берем идеи, известные в области искусственного интеллекта как направление «Адаптивное поведение», занимающееся разработкой обучающихся аниматов. В рамках этого направления разработана модель «адаптивной системы управления» [2] моделирующая Теорию Функциональных систем работы мозга.

### 3 Постановка задачи

С чисто человеческой точки зрения задачу можно сформулировать весьма просто: разработать систему, которая за заданный промежуток времени приносила бы стабильный доход при фиксированном стартовом капитале. Для более точной формулировки нам понадобятся несколько классических понятий из области искусственного интеллекта.

Во-первых – количественное выражение понятия «выгодно», которое сгодились бы для описания «хороших», желаемых для анимата состояний внешней среды. Такое выражение дается введением **функции полезности**. В нашем случае в качестве такой полезности напрашивается выигрыш анимата (выраженный, например, в рублях или в условных ценовых пунктах). Во-вторых, требуется определить, как робот будет планировать свои действия. В этом нам помогут следующее замечание из [1]. **Принцип MEU** (Maximum Expected Utility) говорит, что рациональный агент должен выбирать действие, максимизирующее ожидаемую полезность.

Техники, предложенные в том же труде [1], имеют порядок  $O(n^3)$ , где  $n$  – число состояний внешней среды. Для оценки можно взять группы из 15 тиков, колебание каждого из которых принимает одно из 5 значений ( $0, \pm 10, \pm 20$ ), что уже дает  $5^{15}$  возможных исходов. Эти соображения показывают вычислительную несостоятельность указанных алгоритмов.

Другим методом решения рассматриваемой задачи могут служить байесовские сети принятия решений. Один характерный недостаток, на который сразу же можно указать – необходимость наличия априорных знаний об изучаемом объекте. Мы обязаны иметь некоторые сведения о связях (такие как условные вероятности и признак наличия связи) между различными узлами в сети. Последнее зачастую приводит к нагромождению инструментов технического анализа и мало отличается от существующих индикаторных систем.

Заметим теперь, что в качестве действий, фигурирующих в принципе MEU и входящих в описание стратегий в нашем случае, для анимата нужно рассмотреть совершаемые им торговые сделки; обозначим их как  $e_0, \dots, e_{\tau-1}$ . Если  $R$  – выбранная функция полезности (например, средняя прибыль за  $\tau$  указанных сделок), описанное выше требование можно переписать так:

$$\forall \varepsilon > 0 \exists T(\varepsilon) \forall \tau > T(R(e_0, \dots, e_{\tau-1}) \geq c - \varepsilon);$$

То есть на достаточно больших временных интервалах анимат сможет стабильно получать доход не менее чем  $c$  единиц на одну сделку. Константа  $c$  добавлена для того, чтобы сделать возможным учет комиссионных биржевых сборов. Конечная задача может быть переформулирована в виде поиска такой функции принятия решения, которая бы давала достаточно большую ожидаемую полезность:

$$\text{Decision: Ticks}(\tau), \text{Deals}(\tau-1), \text{State}(\tau) \rightarrow e_{\tau} \in E$$

Ниже представлен полный план работ, предпринятый авторами при построении анимата, отвечающего установленным выше требованиям и принципам. Наиболее важные из очерченных этапов будут предметом обсуждения оставшихся глав.

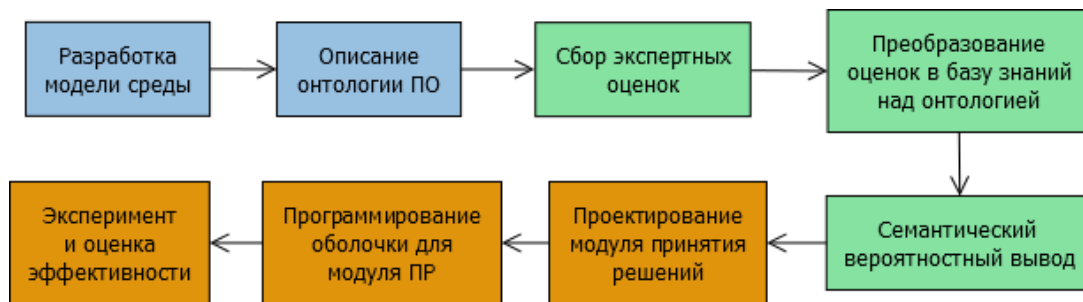


Рис. 3.1. План работ

## 4 Модель и онтология

Очевидно, что тик данных представляет из себя упорядоченную двойку

$$E = \lambda \times \mathbb{N}; \quad \lambda = \text{step} \cdot \mathbb{N};$$

$$\text{tick} = \langle p, v \rangle \in E; \quad (4.1)$$

где tick – собственно тик; p, v – его цена и объем соответственно.

Интересующая нас последовательность – просто выборка последних  $n$  тиков:

$$\text{Ticks} = \{t_k \in E\}_{k=0}^n \quad (4.2)$$

Последовательность тиков в момент времени  $\tau$  мы будем обозначать  $\text{Ticks}(\tau)$ .

Определим сразу и интегральную характеристику этой последовательности, служащую дальнейшему анализу. Пусть  $s$  есть множество тиков. Тогда средняя групповая цена по  $s$ :

$$av(s) = \frac{\sum_{t \in s} t}{|s|} \quad (4.3)$$

Каждая заявка, в отличие от тика, обладает дополнительным показателем, именуемым «направление сделки» (покупка или продажа):

$$D = \lambda \times \{\pm 1\} \times \mathbb{N};$$

$$e = \langle p, d, v \rangle \in D; \quad (4.4)$$

где  $d = +1$  для заявок на покупку и  $-1$  для заявок на продажу. Все сделки мы будем нумеровать по порядку и в каждый момент времени получим набор уже совершенных сделок:

$$\text{deals}(\tau) = (e_1, e_2, \dots, e_m), e_i \in D$$

Добавив к базовым определениям некоторые понятия, описывающие текущее внутреннее состояния анимата, мы получим уже полную картину. Такими понятиями будут:

$$1) \text{state}_{vol} = \sum_{i=0}^{\tau} d_i v_i;$$

$$2) \text{state}_{cost} = \sum_{i=0}^{\tau} p_i d_i v_i;$$

Наконец, последним штрихом будут значения экстремумов на серии тиков:

$$\text{lastmin}(\text{deals}) = \max \{i | p_i \leq p_{i-1}, p_i < p_{i+1}\};$$

$$\text{lastmax}(\text{deals}) = \max \{i | p_i \geq p_{i-1}, p_i > p_{i+1}\}; \quad (4.5)$$

Всю доступную (описанную выше) информацию мы включим в переменную текущего состояния, обозначим её  $\text{State}$ . Для каждого момента времени  $\tau$  соответственно определим  $\text{State}(\tau)$ . Функция  $\text{Decision}$  должна на основе предоставленных ей внешней средой данных на момент времени  $\tau$ , а также на основе внутреннего состояния анимата, принять адекватное текущей обстановке решение-сделку  $e$ :

$$\text{Decision: } \text{Ticks}(\tau), \text{Deals}(\tau-1), \text{State}(\tau) \rightarrow e_\tau \in E$$

Для реализации принципа MEU нам следует определить понятие полезности. Пусть имеет место последовательность решений  $e_0, e_1, \dots, e_{\tau-1}$ . Эффективность этого ряда решений можно оценить с помощью суммарных излишек, полученных по окончанию всех сделок с учетом заключающей операции, избавляющей робота от  $\text{state}_{vol}$  – текущих лотов:

$$r(e_0, \dots, e_\tau) = p_\tau \left( \sum_{i=0}^{\tau} d_i v_i \right) - \sum_{i=0}^{\tau} p_i d_i v_i; \quad (4.6)$$

Для достаточно больших  $T$ , хотелось бы в среднем видеть как минимум прибыль равную биржевому комиссионному сбору, обозначим его как  $c$ :

$$R(e_0, \dots, e_T) = \frac{r(e_0, \dots, e_T)}{T+1} \xrightarrow{T \rightarrow \infty} R_0 \geq c \quad (4.7)$$

Таким образом, задача может быть поставлена в виде поиска функции  $\text{Decision}$ , такой что:

$$e_\tau = \text{Decision}(\text{Ticks}(\tau), \text{Deals}(\tau-1), \text{State}(\tau)), \forall \tau \in \mathbb{N}^\#$$

$$\forall \varepsilon > 0 \exists T(\varepsilon) : \forall \tau > T(\varepsilon) (R(e_0, \dots, e_\tau) \geq c - \varepsilon);$$
(4.8)

## 5 Обучение

Процесс обучения не может быть запущен без наличия так называемой обучающей выборки, которая подобна накопленному экспериментальному материалу. Решения эксперта, наложенные на дескриптор текущего состояния среды, в котором это решение было принято, были через призму понятий онтологии. Мы получили связующую таблицу, соответствующую представлению «матрица объект-признак» (см. Табл. 5.2).

Далее мы дадим полный список входящих в дескриптор признаков, наряду со шкалами преобразования реальных характеристик в набор значений этих признаков. Для удобства описания будем использовать функцию Хевисайда:

$$\theta(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$$
(5.1)

**Таблица. 5.2.** Примерный вид таблицы с обучающей выборкой  
(колонки grvol и buy соответствуют решению, принятому экспертом)

price_up boolean	price_speed real	upperavg boolean	upperlongavg boolean	upperlongavg boolean	grvol smallint	buy boolean	posvol integer	posshort boolean	posprofit integer	win boolean	grpricespeed smallint	grposprofit smallint	grposvol smallint	grminstrike smallint	grmaxstrike smallint	gravgaway smallint	grlo smz
TRUE	1	TRUE	TRUE	TRUE	0	FALSE	0	FALSE	0	TRUE	8	9	6	0	1	7	8
FALSE	1.25	TRUE	TRUE	TRUE	0	TRUE	1	TRUE	5	TRUE	5	11	5	0	0	6	7
FALSE	3.21406	FALSE	TRUE	TRUE	2	FALSE	0	FALSE	0	TRUE	4	9	6	1	0	6	6
FALSE	2.30787	FALSE	FALSE	TRUE	2	TRUE	3	TRUE	10	TRUE	5	12	5	3	0	5	6
FALSE	5	FALSE	FALSE	TRUE	2	FALSE	0	FALSE	0	TRUE	3	9	6	5	0	5	6
FALSE	0.963391	FALSE	FALSE	FALSE	3	TRUE	3	TRUE	5	TRUE	6	11	5	5	0	5	5
TRUE	0.925069	FALSE	FALSE	TRUE	0	TRUE	2	FALSE	10	TRUE	8	12	7	0	0	6	6
TRUE	1.2931	TRUE	TRUE	TRUE	2	FALSE	3	FALSE	81	TRUE	9	15	7	0	6	8	9
FALSE	1.19048	TRUE	TRUE	TRUE	2	TRUE	0	FALSE	0	TRUE	6	9	6	0	0	8	8
TRUE	0.507614	TRUE	TRUE	TRUE	0	FALSE	3	FALSE	40	TRUE	8	14	7	0	6	9	9
TRUE	0.825673	TRUE	TRUE	TRUE	2	FALSE	2	FALSE	75	TRUE	8	15	7	0	7	9	9
TRUE	0	TRUE	TRUE	TRUE	1	FALSE	1	TRUE	0	TRUE	7	9	5	0	7	8	9
TRUE	0	TRUE	TRUE	TRUE	2	TRUE	3	TRUE	0	TRUE	7	9	5	0	7	7	9
TRUE	15	TRUE	TRUE	TRUE	2	TRUE	0	FALSE	0	TRUE	13	9	6	0	10	8	10
TRUE	1.36351	TRUE	TRUE	TRUE	0	FALSE	3	FALSE	5	TRUE	9	11	7	0	11	8	10
FALSE	0.967773	TRUE	TRUE	TRUE	0	TRUE	2	FALSE	2	FALSE	6	8	7	0	0	7	9
TRUE	2.14286	TRUE	TRUE	TRUE	1	FALSE	3	FALSE	13	TRUE	9	12	7	0	1	7	9
TRUE	5.71429	TRUE	TRUE	TRUE	1	TRUE	1	FALSE	80	TRUE	11	15	6	0	7	8	10
TRUE	6.66667	TRUE	TRUE	TRUE	3	FALSE	3	FALSE	66	TRUE	11	15	7	0	10	9	10
TRUE	7.2969	TRUE	TRUE	TRUE	2	TRUE	3	TRUE	45	FALSE	11	4	5	0	12	9	10
TRUE	29.0216	TRUE	TRUE	TRUE	2	FALSE	0	FALSE	0	TRUE	14	9	6	0	13	10	10
TRUE	73.7463	TRUE	TRUE	TRUE	2	TRUE	3	TRUE	25	FALSE	14	4	5	0	13	10	10
TRUE	96.7742	TRUE	TRUE	TRUE	2	FALSE	0	FALSE	0	TRUE	14	9	6	0	13	9	10
TRUE	16.4366	TRUE	TRUE	TRUE	2	TRUE	3	TRUE	25	FALSE	13	4	5	0	13	9	10
FALSE	3.48554	TRUE	TRUE	TRUE	2	FALSE	1	FALSE	10	FALSE	4	6	6	0	0	8	10
FALSE	11.396	TRUE	TRUE	TRUE	0	FALSE	2	TRUE	20	TRUE	2	13	5	0	0	6	10
TRUE	12.0048	TRUE	TRUE	TRUE	2	TRUE	3	TRUE	3	TRUE	12	10	5	0	0	6	10
FALSE	4	FALSE	TRUE	TRUE	2	FALSE	1	FALSE	5	FALSE	3	7	6	0	0	6	9

и функцию выбора из множества (делений шкалы):

$$\text{scale}(x, \text{vals}) = \begin{cases} 0, & \text{vals} = \emptyset; \\ 0, & x \leq \min(\text{vals}); \\ 1 + \text{scale}(x, \text{vals} \setminus \{\min(\text{vals})\}), & \text{otherwise} \end{cases}$$
(5.3)

1) price\_up – признак выросшей цены.

$$\text{price\_up}(\text{State}) = \theta(p_{t_i} - p_{e_k})$$

2) uppershortavg, upperavg, upperlongavg, upperlongavg – признаки, описывающие положения цены относительно средних:

$$\text{uppershortavg}(\text{State}) = \theta(p_{t_i} - av_s)$$

3) grvol – объем будущей сделки, представляемой принятым решением

$$\text{grvol}(\text{State}) = \text{scale}(|v_{e_i}|, \{1, 2, 4, 6, 10, 20, 30\})$$

4) buy – направление будущей сделки:

$$\text{buy}(\text{State}) = \theta(v_{e_i})$$

5) posshort – направление текущей открытой позиции:

$$\text{posshort}(\text{State}) = \theta(\text{state}_{vol})$$

6) win – наличие выигрыша с момента последней нулевой позиции:

$$\text{win}(\text{State}) = \theta(p_t \cdot \text{state}_{vol} - \text{state}_{cost})$$

7) grproprofit – выигрыш с момента последней нулевой позиции:

$$\text{grproprofit}(\text{State}) = \text{scale}\left(\frac{p_t \cdot \text{state}_{vol} - \text{state}_{cost}}{\text{state}_{vol}}, \{-35, -25, -16, -12, -8, -4, -1, 1, 4, 8, 12, 16, 25, 35\}\right)$$

8) grposvol – текущий объём позиции

$$\text{grposvol}(\text{State}) = \text{scale}(\text{state}_{vol}, \{-15, -11, -8, -5, -2, 1, 4, 7, 10, 14\})$$

9) grminstrike, grmaxstrike – «пробои» локального экстремума:

$$\text{grminstrike}(\text{State}) = \text{scale}(\text{extr}_{\min}, \{3, 13, 23, 33, 43, 53, 63, 83, 103, 113, 133, 153\})$$

10) grminstrike, grmaxstrike – «пробои» локального экстремума:

$$\text{grminstrike}(\text{State}) = \text{scale}(\text{extr}_{\min}, \{3, 13, 23, 33, 43, 53, 63, 83, 103, 113, 133, 153\})$$

11) grshortavgaway, gravgaway, grlongavgaway, grvlongavgaway – величина отклонения текущей цены от средней:

$$\text{gravgaway}(\text{State}) = \text{scale}(av_g, \{-100, -60, -35, -20, -5, 5, 20, 35, 60, 100\})$$

12) grdtick1, grdtick2, ..., grdtick6 – средние по группе тиков:

$$\text{grdtick1}(\text{State}) = \text{scale}(\text{group}_1, \{-85, -75, -65, -55, -45, -35, -25, -16, -7, -2, 2, 7, 16, 25, 35, 45, 55, 65, 75, 85\})$$

## 6 Семантический вероятностный вывод

Теперь мы готовы к началу этапа обучения. Для извлечений закономерностей, которыми руководствуется эксперт при принятии решений, мы применим семантический вероятностный вывод. Последний подразумевает поиск правил типа  $A_1 \& \dots \& A_n \Rightarrow B[p]$ , где  $A_i$  – некоторые суждения относительно выбранной онтологии, а  $B$  – заключение, дающее одну из компонент решения (см. [2], [3]). Здесь  $p$  – вероятность правила, которая может быть воспринята как степень его достоверности.

Рассмотрим множество всех предикатов *Predicates*, доступное нам в онтологии, наряду с выделенным, предсказываемым предикатом *Conc*. Семантический вероятностный вывод начинается с генерации базового множества гипотез вида

$$\text{Hyp}_0 = \{A_{i_1} \& \dots \& A_{i_d} \Rightarrow \text{Conc}[p = 0] \mid \text{Conc} \neq A_{i_s} \in \text{Predicates}\} \quad (6.1)$$

где  $d$  – величина, далее именуемая как глубина полного перебора.

Пусть  $\text{Reg} = A_{i_1} \& \dots \& A_{i_n} \Rightarrow \text{Conc}[p]$  – элемент из множества  $\text{Hyp}_k$ . На каждом последующем шаге алгоритм действует следующим образом:

- 1) Производится сбор статистических данных для каждого участвующего в *Reg*, не умаляя общности, рассмотрим  $B = A_{i_1}$ . Для проверки статистических критериев и степени достоверности строится матрица корреляций:

$$M_B = \begin{pmatrix} m_{00} & m_{01} \\ m_{10} & m_{11} \end{pmatrix} \quad (6.2)$$

Для этого из всей обучающей выборки берется только та её часть, на которой истинны предикаты  $A_{i_2}, \dots, A_{i_n}$  – назовем её *Obj*.

$m_{00}$  – количество элементов *Obj*, на которых не верно  $B$  и не верно *Conc*.

$m_{01}$  – количество элементов *Obj*, на которых не верно  $B$  и верно *Conc*.

$m_{10}$  – количество элементов  $Obj$ , на которых верно  $B$  и не верно  $Conc$ .

$m_{11}$  – количество элементов  $Obj$ , на которых верно  $B$  и верно  $Conc$ .

- 2) Вычисляется условная вероятность гипотезы: если  $M$  – матрица корреляции для любого из предикатов (см. 6.2), то она

$$p' = \frac{m_{11}}{m_{10} + m_{11}} \quad (6.3)$$

- 3)  $Reg$  проверяется на соответствие следующим условиям:

I. Выполнено условие увеличения предсказательной силы гипотезы (сравниваем новую (6.3) и старую условные вероятности):  $p' > p$

II. Гипотеза  $Reg$  в смысле матрицы (6.2) удовлетворяет статистическим критериям Фишера и Юла [2, 3].

- 4) Если все условия п. 3 выполняются, рассматриваемая гипотеза плавно перетекает в разряд вероятностных закономерностей:

I. Добавляем найденную закономерность в список:

$$Regs_{Conc} := Regs_{Conc} \cup \{Reg\} \quad (6.4)$$

II. В качестве новых гипотез добавляем все возможные обогащения текущей посылки доступными предикатами:

$$Hyp_{k+1} := Hyp_{k+1} \cup \{A_{i_1} \& \dots \& A_{i_n} \& A_{i_{n+1}} \Rightarrow Conc[p'] \mid A_{i_{n+1}} \in Predicates \setminus \{A_{i_1}, \dots, A_{i_n}\}\}$$

- 5) Переходим на шаг  $k+1$ , в случае если  $Hyp_{k+1}$  оказалось пустым – останов.

Для каждой характеристики экспертного решения (направление и объем будущей сделки), описанных в (4.4), с помощью системы Discovery был получен набор закономерностей.

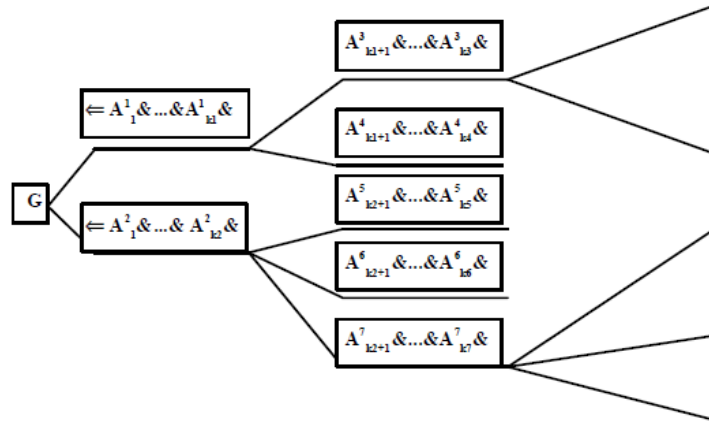


Рис. 6.5. CBV для атома G

## 7 Имитация

Чуть ранее мы получили две группы правил, описывающие соответственно компоненты  $d$  (направление) и  $v$  (объем) будущего решения-сделки  $e = (p, d, v)$ . Пусть далее  $Regs$  – всё множество обнаруженных на стадии обучения правил.

- 1) Правила вида  $A_1 \& \dots \& A_n \Rightarrow (x = c_x)$   $[p]$  будем называть правилами, выполняющими предсказание признака  $x$ .  $Regs_x$  будем обозначать множество всех правил (см. (6.4)) такого вида, что:

$$Regs_x = \{r \in Regs \mid r = [A_1 \& \dots \& A_n \Rightarrow (x = c_x)]\} \quad (7.1)$$

- 2) Если на текущем состоянии онтологии  $Ticks(\tau)$ ,  $Deals(\tau)$ ,  $State(\tau)$  истина посылка правила  $R = A_1 \& \dots \& A_n \Rightarrow (x = a_x)$ , то такое правило мы будем называть применимым в момент времени  $\tau$ . Множество всех правил, применимых в момент времени  $\tau$ , будем обозначать как  $Appl(\tau)$ :

$$Appl(\tau) = \{r \in Regs \mid r = [A_1 \& \dots \& A_n \Rightarrow B], A_i(\tau) = T\} \quad (7.2)$$

Для имитации действия эксперта логичнее всего выбрать правило  $R$ , отвечающее следующим требованиям (наиболее правдоподобное правило):

- 1)  $R$  имеет смысл в текущей сложившейся обстановке. Иначе говоря, посылка правила согласуется с текущим состоянием, а само правило является применимым (из 7.2).
- 2)  $R$  среди всех применимых в данный момент правил наиболее точно описывает предполагаемые действия эксперта и согласуется с ними наилучшим образом. В этом случае  $R$  обязано иметь наибольшую вероятность среди всех правил этого класса:

$$R_d(\tau) = \arg \max_r \{p(r) | r \in \text{Appl}(\tau) \cap \text{Regs}_d\}$$

$$R_v(\tau) = \arg \max_r \{p(r) | r \in \text{Appl}(\tau) \cap \text{Regs}_v\} \quad (7.3)$$

Напомним, что здесь  $p$  – вероятность правила  $r$ .

Суть нашей функции принятия решений будет состоять в выборе решений максимально приближенных к экспертным, согласно наиболее правдоподобным правилам. Полагая, что  $\text{Conc}(R)$  – значение заключения правила  $R$ , результирующая функция Decision с учетом (7.3):


$$\text{Decision} : \text{Ticks}(\tau), \text{Deals}(\tau - 1), \text{State}(\tau) \mapsto (p_r, \text{Conc}(R_d), \text{Conc}(R_v))$$

## 8 Эксперимент

Весь предложенный в данной работе план был реализован и получил своё конечное оформление как комплекс компьютерных программ.

**Таблица 8.1.** Результаты эксперимента

Сделок (всего)	Маржа, пп.	Удельная маржа (пп. / сделка)
29391	32420	1,1031
5075691	6958065	1,3709
10034243	17677530	1,7617



**Рис. 8.2.** Визуализация данных Таблицы 8.1. По оси X – число сделок.

Первый вариант эксперимента включал в себя режим совершения сделок без подключения к реальным торгам. В качестве данных, эмулирующих активность среды, был использован тиковый архив, взятый с [5]. На момент написания работы, пункт цены выбранного инструмента (фьючерс на индекс РТС) был эквивалентен 0.65 рублям.

В силу принципиальной неформализуемости экспертных решений, мы вынуждены ограничиться лишь эмпирическими соображениями в процедуре верификации подхода. Приведенные в этом разделе данные подтверждают эффективность избранной стратегии. Взглянув на рис. 8.2 нетрудно заметить и стабильность получаемых результатов, что в свою очередь ведет нас к предположению о близости получаемого значения  $R$  из (4.7) к реальному предельному значению,  $R_0 \approx 1.76$ . Константа  $c$  в свою очередь имеет значение  $\approx 0.77$  (0.5 рублей – биржевая комиссия за сделку), что говорит о существенной эффективности метода.



## 9 Заключение

Представленная в данной работе техника позволяет анализировать закрытые системы, прибегая к машинному обучению. Черный ящик, наподобие нашего эксперта, может при надлежащей сноровке быть изучен и преобразован в совокупность индуктивных знаний. Знания, в свою очередь, могут использоваться в самых разнообразных целях: в описательных, в целях модернизации исследуемого объекта, а также для имитации его деятельности.

В качестве основных результатов можно отметить такие ключевые моменты, как разработка специфической для выбранной среды онтологии, проектирование и реализация обучающей стратегии, программирование конечного продукта-анимата. Ответом на поставленную в (4.8) задачу служит функция принятия решений, основанная на стратегии имитации посредством обучения. Эксперимент показал перспективность данного направления исследований.

Дальнейшие планы могут включать в себя:

- 1) Распространение идей машинного обучения на другие трудно формализуемые области;
- 2) Построение техник обоснования корректности индуктивного подхода извлечения знаний;
- 3) Проектирование более сложных и комплексных аниматов на базе стратегии имитации;
- 4) Решение технических проблем, on-line реализация анимата.

Отметим, что предложенная схема абсолютно универсальна и специфика выбранной области имеет значение только при процедуре её концептуализации (на шаге построения онтологии). Природа подобных роботов ограничивается только человеческой фантазией.

## 10 Литература

- 1) С.Рассел, П.Норвинг. Искусственный интеллект. Современный подход. – Москва, изд. дом «Вильямс», 2006. – 1407 с.
- 2) Демин А.В., Витяев Е.Е. Логическая модель адаптивной системы управления. – Нейроинформатика, 2008, том 3, №1. – с. 79-107.
- 3) Витяев Е.Е. Извлечение знаний из данных. Компьютерное познание. Модели когнитивных процессов. – Новосибирск: НГУ, 2006. – 293 с.
- 4) Р. Карнап. Логические основания вероятности (Logical Foundations of Probability, 1950); Континуум индуктивных методов (The Continuum of Inductive Methods, 1951).
- 5) <http://www.finam.ru/analysis/profile041CA00007/default.asp> – источник исторически достоверных тиковых данных на сайте компании-брокера.