

УДК 004.93'1+004.932

МЕТОД МАШИННОГО ОБУЧЕНИЯ НА ГРАФИЧЕСКИХ ДАННЫХ

Е.Н. Леонов, В.Н. Поляков

Аннотация

В работе рассматривается метод машинного обучения FuzGraph, основанный на нечеткозначном представлении графических данных. Образцы повторяющихся изображений на графике $y = f(x)$ описываются в виде модели в пространстве нечетких функций принадлежности. Эти функции, в свою очередь, являются результатом фазификации распределений плотности вероятности на параметрах модели выявляемого изображения. Метод машинного обучения FuzGraph удобен для обнаружения закономерностей на графических данных, имеющих стохастическую природу. В частности, тестирование и апробация метода проходили на актуальной для финансовых рынков задаче прогнозирования цен валют и акций по фигуре «флаг».

Введение

Исследования по теме «машиное обучение» начались в середине 50-х годов прошлого столетия [1, 2]. Впоследствии эта тематика получила свое дальнейшее развитие в рамках теории искусственного интеллекта. Существует ряд основных подходов к этому методу [2]: обучение на примерах [3, 4], искусственные нейронные сети [5], генетические алгоритмы [6], объясняющее обучение [7], эволюционные гипотезы [6, 8, 9], вывод на precedентах [4]. Хотя полной теории того, как люди и машины учатся, еще не предложено, в рамках перечисленных подходов сформулированы достаточно строгие модели обучения.

Наиболее популярная область исследований в машинном обучении – это изучение понятий и других репрезентаций на примере. Ввод для таких обучающихся программ содержит описание примеров. Вывод состоит из разных видов репрезентаций, которые кодируются обобщенно для этих примеров. Обобщенные репрезентации могут быть понятиями, функциями, правилами или деревьями описаний, которые обеспечивают удобные средства классификации новых примеров.

В работе описан метод машинного обучения на примерах, представленных в виде графических данных. В качестве модели описания (репрезентации) выборки примеров была использована нечеткозначная формализация геометрических фигур. Выбор фигур для обучения производится человеком, экспертом в предметной области. Машинное обучение сводится к расчету параметров вероятностного распределения и их дальнейшей фазификации. Принятие решений на основе полученных нечеткозначных описаний геометрических фигур осуществляется на основе системы правил, позволяющих фильтровать «хорошие» фигуры из текущего множества данных в процессе работы пилотной версии системы. Фактически классификация каждого нового случая основана на сопоставлении текущего представления с системой нечетких функций принадлежности для требуемого класса объектов. Испытание метода на графических данных котировок валют и акций показало высокий уровень совпадения прогнозов. Метод получил название FuzGraph.

1. Модель машинного обучения

Модель машинного обучения M_{ML} на произвольной совокупности графических данных представим как n -ку:

$$M_{ML} = \langle D, G, Ap, P, Af, M, R \rangle . \quad (1)$$

Здесь:

D – множество численных графических зависимостей описываемого процесса. Множество **D** представляет собой набор функциональных отношений (x, y) на области определения $x \in X$. Рассматривается простейший вариант функции от одной переменной $y = f(x)$. Зависимость носит принципиально не аналитический, а стохастический характер.

G – обучающее множество графов-образцов, отобранных экспертом. Каждый граф **g** из множества **G** строится на подмножестве численных данных $Dg \subset D$.

P – множество функций распределения, описывающих вероятностные параметры прототипической графической фигуры. Содержание этого множества (его мощность и типы элементов) задается разработчиком модели в процессе параметрического описания фигуры. Создание такого множества представляет собой во многом эвристический процесс. Множество **P** получается путем алгоритмического преобразования обучающей выборки $\{Dg\} : Ap(\{Dg\}, P)$, где **Ap** – алгоритмическая процедура расчета функций распределения вероятности.

M – множество функций принадлежности, описывающих нечеткозначные параметры прототипической графической фигуры. Функции **M** получаются путем фаззификации функций вероятностного распределения с помощью соответствующей алгоритмической процедуры **Af(P, M)**.

R – множество правил принятия решения. Обычно используется базовое правило в виде логического условия, аргументами которого являются значения функций принадлежности из **M**.

2. Реализация метода

Рассмотрим реализацию метода машинного обучения на графических данных FuzGraph на примере системы ЕМ, предназначеннной для формирования инвестиционного портфеля и выработки стратегии принятия решений на фондовом рынке. В системе для прогнозирования используется нечеткозначная модель фигуры «флаг».

В работе метод FuzGraph применялся для обучения системы на примерах, являющихся собой графические образы. Обработка параметров обучающих примеров давала набор вероятностных характеристик, по которым строились функции принадлежности и в дальнейшем производился поиск фигур на графике текущих данных.

Фигурой в теории технического анализа называется графический образ на графике котировок валют или акций, напоминающий геометрическую фигуру. Обычно в техническом анализе различают три основных вида фигур: «флаг», «треугольник», «голова – плечи». Есть и другие фигуры, но они встречаются значительно реже [10].

Целью разработки была автоматизация известного метода предсказания котировок, основанного на фигуре «флаг». Сложность автоматизации этого метода заключается в том, что предсказание по фигурам носит визуальный, зачастую субъективный характер и до сих пор не поддавалось компьютеризации.

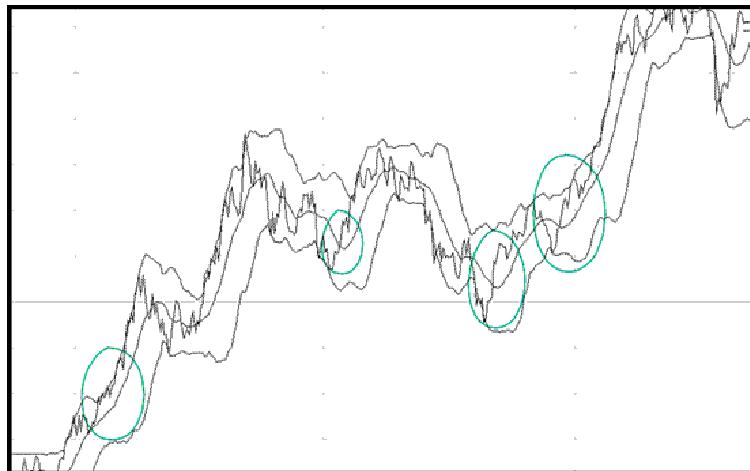


Рис. 1. Примеры образования флага на реальных графиках валют

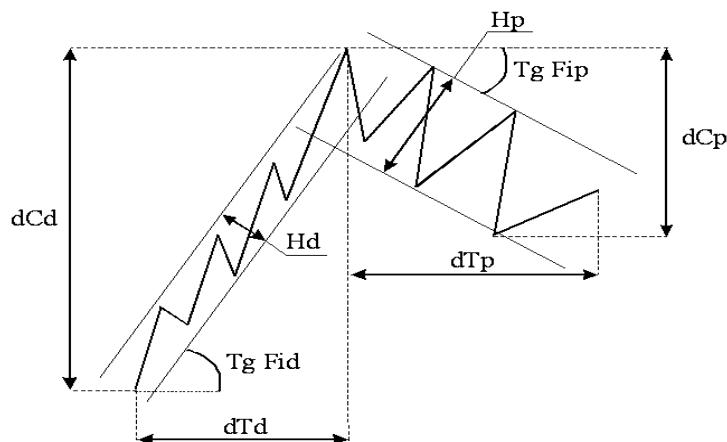


Рис. 2. Параметры модели фигуры «бычий флаг»

Система обрабатывает двумерные графики котировок финансовых инструментов. Задача такой обработки – привести сложно формализуемые графические образы к понятным системе числовым показателям.

Опишем модель фигуры «бычий флаг». Если рассматривать среднесрочные прогнозы, то флаг – это кратковременная фигура, длившаяся несколько дней (рис. 1). Обычно он возникает на динамичных рынках, где бывают резкие изменения цен. «Бычий флаг» образуется при восходящем тренде, «медвежий флаг» – при нисходящем. Своё название эта фигура получила потому, что напоминает флаг, в котором есть древко, то есть узкий и высокий участок, и полотнище, то есть сравнительно протяжённый участок колебаний цен в виде полосы с небольшим наклоном. Метод предсказания основывается на том, что обычно фигура «флаг» на графике котировок предшествует бурному росту цены (см. рис. 1).

Параметрами флага в соответствии с рис. 2 являются:

- Длина по оси времени или количество дней, в течение которых древко или полотнище образуется. Мы будем обозначать эти параметры через ΔT_d и ΔT_p для древка и полотнища соответственно.



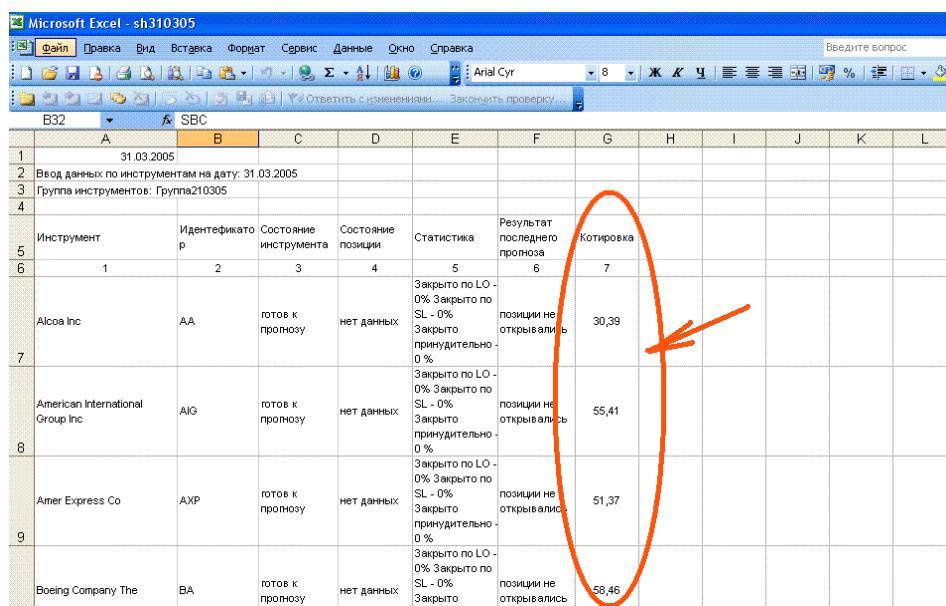
Рис. 3. Схема информационных потоков процесса анализа исторических данных в режиме машинного обучения по образцам (пункты 1, 2, 4, 5 выполняются программой, пункт 3 выполняется экспертом, пункт 6 – инженером по знаниям)

- Высота по оси котировок, или количество пунктов, составляющих древко и полотнище (ΔC_d и ΔC_p).
- Тангенс угла наклона фрагмента фигуры к оси времени. Обозначается через $\operatorname{tg}(\varphi_d)$ и $\operatorname{tg}(\varphi_p)$ для древка и полотнища соответственно;
- Нормальная толщина канала, образованного древком и полотнищем, обозначается через h_d и h_p соответственно.

Процесс принятия решений по фигурам носит субъективный характер и во многом определяется наличием опыта у эксперта. В связи с этим возникло предположение, что эксперт руководствуется некоторым обобщенным образом фигуры «флаг», который можно рассматривать как функционал от одной или совокупности нечетких функций принадлежности [11]. В качестве «лобового» решения можно было бы сконструировать одну многомерную функцию принадлежности. Однако это снизило бы наглядность и, как следствие, возможность промежуточного контроля результатов компьютерного моделирования. Учитывая сравнительно большое число параметров в модели (восемь), был проведен анализ парной корреляции параметров модели и было принято эвристическое решение строить несколько двумерных функций принадлежности. Также было сделано предложение, что распределение вероятности параметров фигуры «флаг» подчиняется нормальному распределению и описывается системой функций Гаусса для двумерного нормального распределения. Вследствие числового характера исходных данных котировок валют и акций расчет характеристик для определенных таким образом нечетких функций принадлежности параметров фигуры «флаг» уже не составляет большого труда [12].

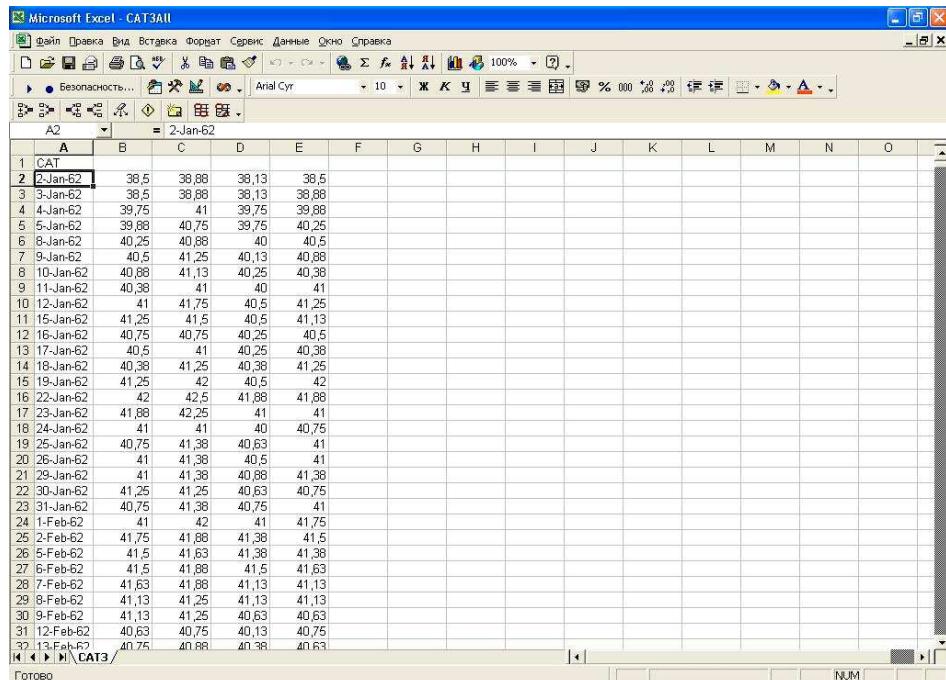
Для получения вероятностных характеристик котировок валют и акций применяется технология машинного обучения на выборке фигур, составленной опытным специалистом по рынку. Поэтому основные требования, которые предъявляются к программному комплексу, – это гибкость представления графических данных, удобный интуитивно понятный интерфейс. На рис. 3 показана схема информационных потоков, обеспечивающая работу системы и эксперта на этапе машинного обучения по образцам.

Приведенная схема в программном комплексе ЕМ реализована в несколько этапов. В первую очередь необходимо ввести данные в систему. Для этого используется программа, обрабатывающая специально сформированные шаблоны MS Excel. На рис. 4 показан пример шаблона для ввода текущих данных.



SBC						
A	B	C	D	E	F	G
1	31.03.2005					
2	Ввод данных по инструментам на дату: 31.03.2005					
3	Группа инструментов: Группа210305					
4	Инструмент	Идентификатор	Состояние инструмента	Состояние позиции	Статистика	Результат последнего прогноза
5	1	2	3	4	5	6
6	Alcoa Inc	AA	готов к прогнозу	нет данных	Закрыто по LO - 0% Закрыто по SL - 0% Закрыто принудительно - 0 %	позиции не открывались
7	American International Group Inc	AIG	готов к прогнозу	нет данных	Закрыто по LO - 0% Закрыто по SL - 0% Закрыто принудительно - 0 %	позиции не открывались
8	Amer Express Co	AXP	готов к прогнозу	нет данных	Закрыто по LO - 0% Закрыто по SL - 0% Закрыто принудительно - 0 %	позиции не открывались
9	Boeing Company The	BA	готов к прогнозу	нет данных	Закрыто по LO - 0% Закрыто по SL - 0% Закрыто	позиции не открывались
						58,46

Рис. 4. Шаблон для ввода котировок (овалом выделена область ввода данных оператором)



A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
1	CAT													
2	2-Jan-62	38,5	38,88	38,13	38,5									
3	3-Jan-62	38,5	38,88	38,13	38,88									
4	4-Jan-62	39,75	41	39,75	39,88									
5	5-Jan-62	39,88	40,75	39,75	40,25									
6	8-Jan-62	40,25	40,88	40	40,5									
7	9-Jan-62	40,5	41,25	40,13	40,88									
8	10-Jan-62	40,68	41,13	40,25	40,38									
9	11-Jan-62	40,38	41	40	41									
10	12-Jan-62	41	41,75	40,5	41,25									
11	15-Jan-62	41,25	41,5	40,5	41,13									
12	16-Jan-62	40,75	40,75	40,25	40,5									
13	17-Jan-62	40,5	41	40,25	40,38									
14	18-Jan-62	40,38	41,25	40,38	41,25									
15	19-Jan-62	41,25	42	40,5	42									
16	22-Jan-62	42	42,5	41,88	41,88									
17	23-Jan-62	41,68	42,25	41	41									
18	24-Jan-62	41	41	40	40,75									
19	25-Jan-62	40,75	41,38	40,63	41									
20	26-Jan-62	41	41,38	40,5	41									
21	29-Jan-62	41	41,38	40,88	41,38									
22	30-Jan-62	41,25	41,25	40,63	40,75									
23	31-Jan-62	40,75	41,38	40,75	41									
24	1-Feb-62	41	42	41	41,75									
25	2-Feb-62	41,75	41,88	41,38	41,5									
26	5-Feb-62	41,5	41,63	41,38	41,38									
27	6-Feb-62	41,5	41,88	41,5	41,63									
28	7-Feb-62	41,63	41,88	41,13	41,13									
29	8-Feb-62	41,13	41,25	41,13	41,13									
30	9-Feb-62	41,13	41,25	40,63	40,63									
31	12-Feb-62	40,63	40,75	40,13	40,75									
32	13-Feb-62	40,75	40,88	40,38	40,63									

Рис. 5. Файл с исходными данными за весь период обучения

Можно также ввести данные за весь период обучения. Для этого существует специальный модуль, который загружает файл MS Excel, содержащий соответствующие данные (рис. 5).



Рис. 6. Исторический график изменения котировок (акции IBM) за период 1962–2004 гг.

После того, как сформирован пул данных по инструменту, мы можем перейти к следующему пункту схемы, изображенной на рис. 3, то есть к заданию флагов на графике. Этот процесс показан на рис. 6 и 7. Эксперт, руководствуясь своими знаниями и опытом, формирует выборку флагов, которая будет служить своеобразным эталоном. В соответствии с моделью фигуры «флаг», описанной выше, производится расчет для каждого элемента выборки. Результатом служит набор значений, характеризующих экспертную выборку. В свою очередь, при помощи специальных функций формируются вероятностные данные для инструмента. Они сохраняются в базе данных и используются в дальнейшем как образец для поиска схожих фигур на двумерном графике, содержащем исходные данные. Таким образом, происходит машинное обучение на выборке фигур.

Результаты расчета параметров вероятностного распределения представлены на рис. 8.

Функции принадлежности для фигуры флаг могут быть визуализированы в трехмерном пространстве. На рис. 9–14 в качестве иллюстрации приведены графики функций принадлежности для швейцарского франка, построенные на основании статистического анализа котировок валюты за десятилетний период (1990–1999 гг.). Для большей наглядности графики приведены в виде линий уровня (слева) и в изометрической проекции (справа).

Из семерки (1) следует, что для принятия эффективных решений на основе заданной модели обучения необходимо выработать соответствующие правила. Для задачи прогнозирования рынков по фигуре «флаг» решением является приказ об открытии новой позиции на основании прогноза, полученного путем анализа данных о текущих котировках, поступающих с рынка. При анализе выявляется наличие дреква и полотнища, оцениваются их качественные характеристики путем сравнения с эталоном, заданным совокупностью функций принадлежности,

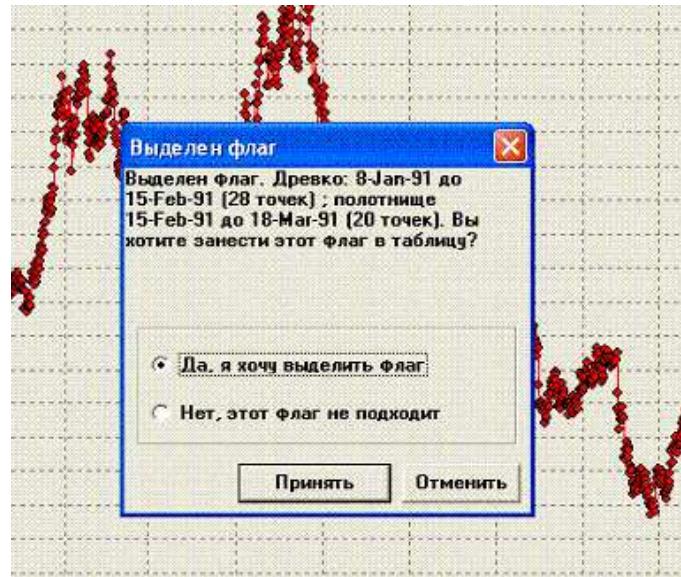


Рис. 7. Выделение флага

Статистические данные								
	dTd	dCd	Tgd	Hd	dTp	dCp	Tgp	Hr
MAX	2400	3,063E5	1,75	992,62	1900	2,037E5	-1	827,74
MIN	400	43700	0,72833	215,76	400	40000	-1,2716	224,02
SIG	1,2133EE	2,0915E1	0,26141	1,9325EE	6,6333EE	7,3911EE	0,019802	1,053E5
M	1133,3	1,4E5	1,2515	485,34	966,67	1,0667E5	-1,1146	457,13
k dTd-dC	0,98349							
k dTp-dC	0,99599							
k dTd-dT	-0,30467							
k dCd-dC	-0,39121							
k Tgd-Hc	0,078063							
k Tgp-Hr	0,11636							

Рис. 8. Пример расчета вероятностных характеристик обучающей выборки флагов (по данным котировок акций компании IBM)

и в случае положительных характеристик отдается приказ (ордер) об открытии позиции.

В качестве элементов, составляющих правила, сначала были введены бинарные условия сравнения $A = \{A_1, \dots, A_i, \dots, A_6\}$:

$$A_i = m_i \geq 0.5, \quad (2)$$

где m_i – значение функции принадлежности на текущую дату.

Затем были сформулированы непосредственно правила, которые составили следующее множество:

$$R = \{R_{\otimes}, R_{\oplus}, R_{c1}, \dots, R_{cn}\}, \quad (3)$$

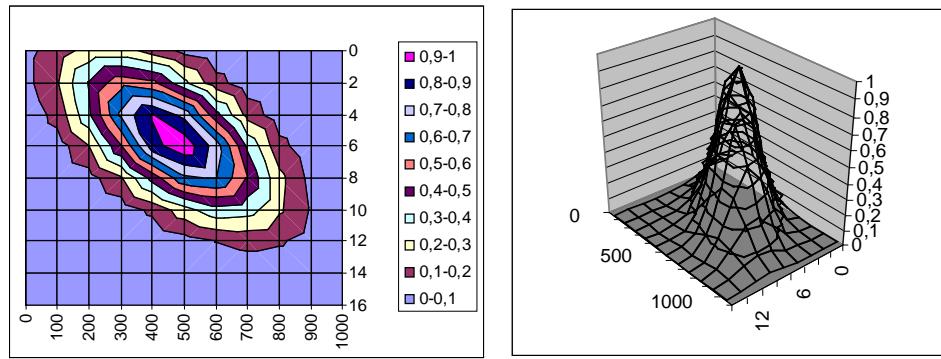


Рис. 9. Функция принадлежности $m_1(\Delta C_{\text{Д}}, \Delta T_{\text{Д}})$. По осям ординат отмечены изменение котировок (в пунктах) и длительность (в днях) для древка

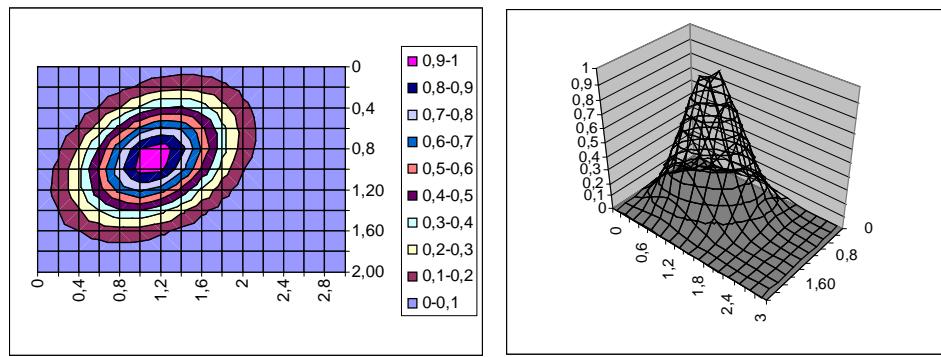


Рис. 10. Функция принадлежности $m_2(\text{tg}(\varphi_{\text{Д}}), h_{\text{Д}})$. Данные по осям ординат в безразмерных единицах

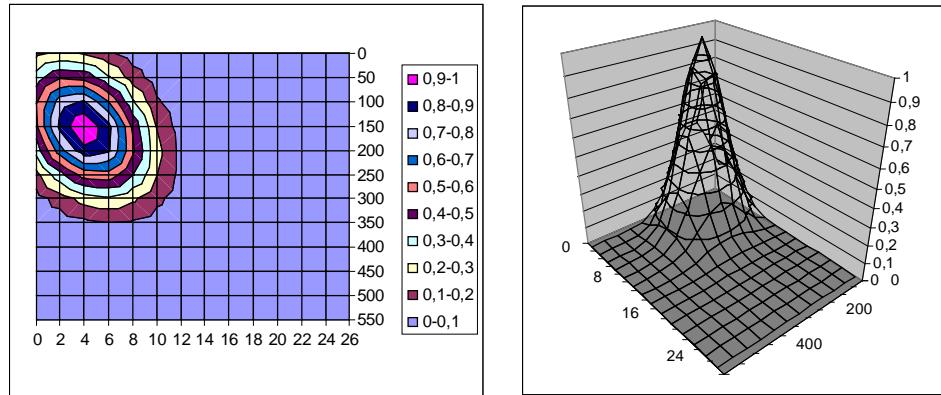


Рис. 11. Функция принадлежности $m_3(\Delta C_{\text{П}}, \Delta T_{\text{П}})$. По осям ординат отмечены изменение котировок (в пунктах) и длительность (в днях) для полотнища

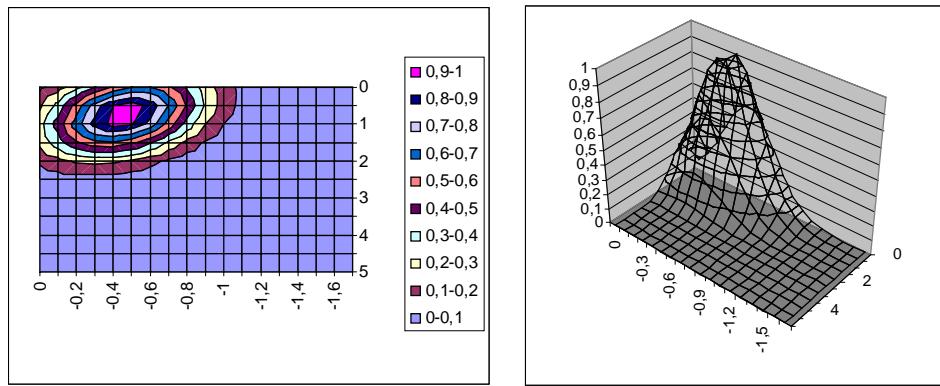


Рис. 12. Функция принадлежности $m_4(\operatorname{tg}(\varphi_{II}), h_{II})$. Данные по осям ординат в безразмерных единицах

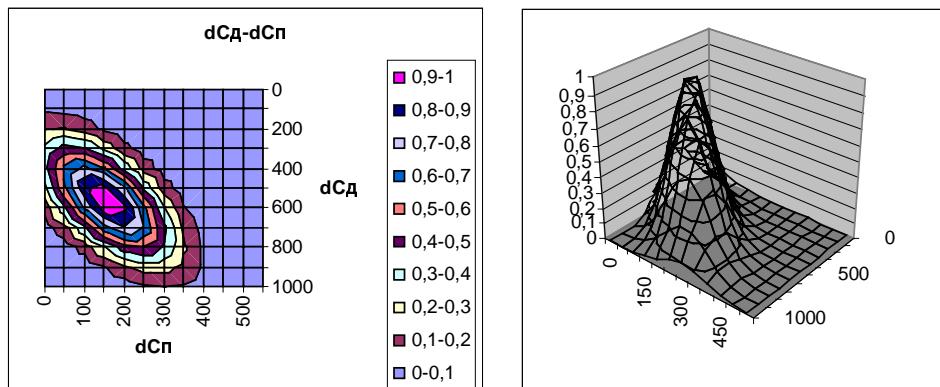


Рис. 13. Функция принадлежности $m_5(\Delta C_d, \Delta C_p)$. По осям ординат отмечены изменения котировок (в пунктах) для древка и для полотнища

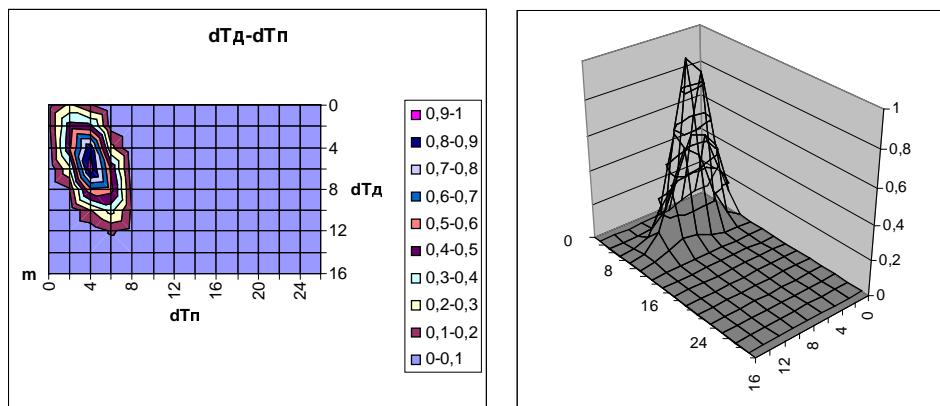


Рис. 14. Функция принадлежности $m_6(\Delta T_d, \Delta T_p)$. По осям ординат отмечены длительность (в днях) для древка и для полотнища

где $R_{\otimes} = A_1 \wedge A_2 \dots \wedge A_i \dots \wedge A_6$ – конъюнктивная форма, сконструированная на множестве А (жесткое правило);

$R_{\oplus} = A_1 \vee A_2 \dots \vee A_i \dots \vee A_6$ – дизъюнктивная форма, сконструированная на множестве А (мягкое правило);

R_{cj} – произвольные дизъюнктивно-конъюнктивные формы, сконструированные на множестве А (полужесткие правила).

Лучшие правила выбираются из множества R эмпирическим путем в процессе тестирования модели и анализа результатов прогнозирования.

Системы ЕМ реализована в среде программирования Delphi 5.0 с использованием СУБД MS SQL для хранения данных.

3. Результаты тестирования

Метод FuzGraph проходил апробацию на данных котировок валют на рынке Forex и данных котировок акций американских компаний, входящих в индекс Доу-Джонс (DJ).

Первоначально эффективность метода машинного обучения оценивалась на примере швейцарского франка на рынке Forex. При этом обучающие данные выбирались на историческом периоде котировок CHF/USD за 1990–1999 гг. Метод тестировался на периоде 2000–2002 гг., на котором экспертом были отобраны эталонные и «ложные» флаги. Для жесткого правила эффективность прогнозов «на отказ» на тестовой выборке данных за 2000–2002 гг. составляла 100%, то есть ни одного «ложного» флага программой выбрано не было. Вместе с тем эффективность прогнозов «на точность» была сравнительно низкой: программа предсказала только 12.5% случаев, отмеченных вручную экспертом. В то же время мягкое правило срабатывает гораздо чаще: эффективность прогнозов «на точность» составила 100%, но платой за это явилась большее количество ошибочных прогнозов. В случае применения «мягкого» правила система пропустила 22.2% «ложных» флагов. Задачи прогнозирования рынков очень чувствительны к ошибкам классификации «на отказ», так как потери от неудачных позиций могут наносить ощутимый ущерб рыночным игрокам. Поэтому в реальных системах предпочтительным является использование более жестких правил.

При тестировании системы ЕМ на компаниях индекса DJ эффективность оценивалась по другой методике. Система также обучалась на исторической выборке, но эталонная выборка экспертом для тестирования не формировалась. Все «флаги», отобранные программой, делились по факту на «хорошие» и «плохие», и вычислялось итоговое соотношение эффективности прогноза для лучшей обучающей выборки. «Хорошим» считался «флаг», для которого прогноз сбывался, «плохим» – для которого прогноз оказывался неудачным. В случае неудачного результата ($N_x/N < 0.5$) проводилось повторное обучение.

В табл. 1 приведены результаты тестирования метода в режиме *in vitro* на реальных данных. Эти результаты получены с применением одного из полужестких правил.

Для всех компаний, вошедших в тестовый пул, с помощью метода FuzGraph удалось получить позитивные тестовые результаты. Отметим, что самый худший результат (58%) получен для компании Boeing (BA) после третьей итерации. Первые две итерации давали совсем негативный результат. Самый лучший результат (89%) получен для компании American International Group Inc (AIG) с первой попытки обучения.

С практической точки зрения важной особенностью метода является то, что после обучения система начинает фильтровать «флаги» очень жестко. В результате предъявления таких строгих требований отбираются только лучшие прогнозы.

Табл. 1

Результаты тестирования для компаний из индекса Доу-Джонс

Компания	Обучающая выборка за период, гг.	Число флагов в обучающей выборке	Число итераций обучения	Период тестирования, гг.	Число обнаруженных флагов N	Число «хороших» флагов N_X	Число «плохих» флагов, N_{Π}	Соотношение $N_X/N, \%$	Число флагов на год
AA	1962–1980	40	5	1982–2004	40	32	8	75	1.7
AIG	1984–1993	30	1	1994–2004	9	8	1	89	0.8
BA	1964–1978	27	3	1983–2004	64	37	27	58	3
C	1981–1991	14	7	1992–2004	43	28	15	65	3.3
CAT	1962–1974	47	2	1977–2004	10	7	3	70	0.3
DIS	1977–1980	24	1	1986–1998	37	25	12	68	2.8
GE	1982–1987	10	3	1988–2004	64	41	23	64	3.8
GM	1982–1994	66	2	1995–2004	13	8	5	61.5	1.3
HD	1984–1996	43	1	1997–2004	5	4	1	85	0.6
HON	1970–1983	35	1	1994–2004	23	16	7	69.6	2.1
HPQ	1966–1979	39	1	1980–2004	10	6	4	60	0.4

Следствием этой стратегии является относительно редкая встречаемость флагов в тестовой выборке. Среднее количество выявленных программой флагов за год колеблется для тестовой выборки компаний в пределах от 0.3 (Caterpillar/CAT) до 3.8 (General Electric/GE). Такая редкая встречаемость также является следствием выбора категории данных для проведения тестирования, так как метод тестиировался на среднесрочных данных (Daily).

Заключение

Предложенный метод машинного обучения на графических данных FuzGraph имеет ряд преимуществ:

- Простота настройки и перенастройки, то есть при изменении входной информации перерасчет статистических данных и повторное включение в работу системы требует минимум затрат.
- Параметрический характер модели. Метод позволяет учитывать факторы, недоступные эксперту вследствие субъективности его оценки.
- Гибкость и вариативность. Используемый подход позволяет унифицировано работать с множеством разнообразных инструментов.
- Компактное описание характеристик. Увеличивает наглядность модели и позволяет контролировать промежуточные результаты компьютерного моделирования.

Предварительная апробация метода на фактических данных в режиме *in vitro* показала его эффективность. Очевидно, что метод FuzGraph может быть также использован и для других приложений, в которых необходимо распознавать типичные графические образы на больших выборках стохастических данных: при анализе радиосигналов, в задачах анализа речи и других акустических сигналов, в системах контроля и мониторинга состояния сложных промышленных объектов, в медицине.

Summary

E.N. Leonov, V.N. Polyakov. The method of machine learning based on graphical data.

This paper is devoted to a new method of machine learning based on graphical data (named FuzGraph). The method is founded on fuzzy representation of graphical data. Set of samples of similar images on the figure $y = f(x)$ are described as combination of fuzzy functions. These functions are results of fuzzification of density of probability of some geometric parameters of the revealed images. The method is convenient for detection of laws on the graphical data having the stochastic nature. Testing and approbation of the method were passed on the problem of forecasting of the prices of currencies and stocks in a figure "flag", which is actual for the financial markets.

Литература

1. *Samuel A.* Some Studies in Machine Learning Using the Game of Checkers // IDM J. Research and Development. – 1959. – No 3. – P. 211–229.
2. *Nilsson Nils. J.* Introduction to Machine Learning [Электронный ресурс]. – Stanford, CA: Stanford University, 1996. – Режим доступа: <http://robotics.stanford.edu/people/nilsson/mlbook.html>, свободный.
3. *Carbonell J.G.* Learning by analogy: Formulating and generalizing plans from past experience // Machine Learning: An Artificial Intelligence Approach / R. Michalski , J. Carbonell, T. Mitchell (eds.). – Palo Alto, CA: Tioga Publishing Co., 1983. – P. 137–161.
4. *Kolodner J.* Case-Based Reasoning. – San Mateo, CA: Morgan Kaufmann Publ., 1993. – 668 p.
5. *McCulloch W.S., Pitts W.H.* A Logical Calculus of the Ideas Immanent in Nervous Activity // Bulletin of Mathematical Biophysics. – Chicago: University of Chicago Press, 1943. – V. 5. – P. 115–133.
6. *Holland J.H.* Adaptation in Natural and Artificial Systems. – Ann Arbor, MI: The University of Michigan Press, 1975. – 183 p.
7. *DeJong G., Mooney R.* Explanation-Based Learning: An Alternative View // Machine Learning. – 1968. – No 1. – P. 145–176. Reprinted in Shavlik J., Dietterich T. Readings in Machine Learning. – San Francisco: Morgan Kaufmann, 1990. – P. 452–467.
8. *Koza J.* Genetic Programming: On the programming of Computers by Means of Natural Selection. – Cambridge: MIT Press, 1992. – 840 p.
9. *Koza J.* Genetic Programming II: Automatic Discovery of Reusable programs. – Cambridge: MIT Press, 1994. – 746 p.
10. *Элдер А.* Как играть и выигрывать на бирже. – М.: Изд. дом «КРОН-пресс», 1996. – 332 с.
11. *Аверкин А.Н., Батыршин И.З., Блишун А.Ф., Силов В.Б., Тарасов В.Б.* Нечеткие множества в моделях управления и искусственного интеллекта / Под ред. Д.А. Попелова. – М.: Наука, 1986. – 312 с.
12. *Поляков В., Шевченко А.* Технология принятия решений на валютных и фондовых рынках с использованием нечеткозначной модели фигуры «флаг» // Тр. восьмой нац. конф. по искусственному интеллекту. КИИ-2002. Коломна, Россия, 7–12 окт. 2002 г. – М.: Физматлит, 2002. – Т. 1. – С. 343–352.

Леонов Евгений Николаевич – инженер-программист ЗАО «Ситроникс телеком солюшнс», аспирант Московского Государственного института стали и сплавов (технологического университета).

E-mail: brainstud@mail.ru

Поляков Владимир Николаевич – кандидат технических наук, доцент кафедры АСУ Московского Государственного института стали и сплавов (технологического университета).