

# Классификация потока финансовых новостей с целью выявления динамики цен биржевых инструментов

Кулага Роман Александрович

Московский Физико-Технический Институт (Государственный Университет)  
Кафедра «Интеллектуальные системы», ФУПМ  
Научный руководитель: д.ф.-м.н. К.В. Воронцов

Москва 2018

## 1 Постановка задачи

- Определение понятия скачка цены
- Исходные данные и их предобработка
- Принципы формирования обучающей выборки
- Измерение качества решения


## 2 Модели и эксперименты

- Базовая модель
- Модель с агрегированием документов
- Модель с использованием битермов
- Модель регрессии

# Определение понятия скачка цены

Пусть  $t_0$  — момент времени внутри торговой сессии (например, время выхода новости),  $\Delta T$  — длительность временного интервала,  $P(t)$  — цена инструмента в момент времени  $t$ .  
Введем функцию, характеризующую величину скачка цены в интервале между  $t_0$  и  $t_0 + \Delta T$ :

$$\Delta P(t_0, \Delta T) = \max_{t=t_0, \dots, t_0+\Delta T} \frac{|P(t) - P(t_0)|}{P(t_0)}$$



# Исходные данные и их предобработка

## Источники данных

- Новостные заголовки из ряда крупных англоязычных источников (в т.ч. «CNN», «CNBC», «Yahoo Finance») с точным временем публикации
- Исторические данные по ценам с секундной точностью из «Yahoo Finance». Из цен вычитается трендовая составляющая.

## Предобработка текста

- 1 Удаление пунктуации
- 2 Разбиение на отдельные слова
- 3 Приведение к нижнему регистру
- 4 Лемматизация
- 5 Фильтрация стоп-слов
- 6 Токенизация

## Формирование обучающей выборки

В качестве объекта может выступать:

- Отдельно взятая новость
- Объект, полученный агрегированием новостей за определенный временной интервал

Каждому объекту выборки автоматической разметкой ставится в соответствие:

- В модели классификации — класс («1», если наблюдается скачок цены и «0» иначе)
- В модели регрессии — величина скачка цены  $\Delta P(t, \Delta T)$


# Метрики бинарной классификации

Были выбраны:

- ROC (Receiver Operating Characteristic) кривая и ROC-AUC
- PR (Precision Recall) кривая и PR-AUC

Для получения численных оценок используется кросс-валидация K-Fold.

# Базовая модель



Объекты (документы) — отдельные новости.

Формирование обучающей выборки:

- 1 Обходим все новостные заголовки; пусть  $t_0$  - время публикации текущей новости
- 2 Если  $\Delta P(t_0, \Delta T) > P_{threshold}$ , помечаем все новости в интервалах  $T_b$  и  $T_a$  классом «1» и удаляем из выборки новости между  $t_0 + T_a$  и  $t_0 + T_i$ .
- 3 Оставшиеся новости помечаем классом «0»

# Признаковое описание

Обработка факторов:

- 1 Удаляем слова  $w$  с низкой документной частотой:  $N_d(w) < N_d^{min}$
- 2 Для каждого документа  $d \in D$  применяется TF-IDF взвешивание

Формируем категориальные признаки  $d_{cat}$  каждого документа  $d$ :

- 1 Сортируем униграммы по убыванию  $tfidf(w, d)$
- 2 Берем не более  $N_{cat}$  первых и заполняем вектор  $d_{cat}$  их токенами, а пустые места — специальным значением  $-1$ .


## Результаты эксперимента

Общие параметры:  $T_b = 3$  мин,  $T_a = 5$  мин,  $T_i = 60$  мин;  $N_{cat} = 25$ .  
 Для ширины окна  $\Delta T$  рассматриваем две конфигурации:

- $\Delta T = 10$  мин (имеет предсказательную силу)
- $\Delta T = 3$  мин (не имеет предсказательной силы)

$\Delta T$ , мин	$N_{obj}$	$N_1/N_{obj}$	Алгоритм	ROC-AUC	PR-AUC
10	1186095	0.164	Random Forest	0.58	0.24
			LogRegression	0.58	0.23
			Linear SVM	0.58	0.23
			XGBoost	<b>0.61</b>	0.26
			CatBoost	0.60	<b>0.31</b>
3	937689	0.259	Random Forest	0.58	0.40
			LogRegression	0.59	0.40
			Linear SVM	0.59	0.40
			XGBoost	0.63	0.44
			CatBoost	<b>0.64</b>	<b>0.48</b>

# Модель с агрегированием документов




Формирование объектов:


- 1 Обходим всю коллекцию новостей; пусть  $t_0$  — время публикации текущей новости.
- 2 Если  $\Delta P(t_0, \Delta T) > P_{threshold}$ , агрегируем все новости в интервалах  $T_b$  и  $T_a$  в один объект, помечаем его классом «1» и удаляем из выборки новости между  $t_0 + T_a$  и  $t_0 + T_i$ .
- 3 Из случайных неразмеченных интервалов длиной  $T_b + T_a$  формируем новые объекты и помечаем классом «0»

# Результаты эксперимента (Catboost Classifier)


$\Delta T$ , мин	$N_{obj}$	$N_1$	$N_1/N_{obj}$	$N_{cat}$	ROC-AUC	PR-AUC
10	4838	1338	0.277	60	<b>0.66</b>	<b>0.42</b>
3	5696	1696	0.298	60	<b>0.72</b>	<b>0.54</b>




(a) ROC,  $\Delta T = 10$  мин



(b) PR,  $\Delta T = 10$  мин



(c) ROC,  $\Delta T = 3$  мин



(d) PR,  $\Delta T = 3$  мин

# Модель на основе битермов

## Определение битермов

**Битермы** представляют собой все различные пары слов в рамках одной фразы (в нашем случае - комбинации слов внутри одного новостного заголовка).

Например, предложение вида «A B C D» содержит в себе битермы «A;B», «A;C», «A;D», «B;C», «B;D», «C;D».

## Определение Significance Score

Пусть две униграммы  $A$  и  $B$  образуют битерм  $(A; B)$ ,  $f(A, B)$  — документная частота битерма, а  $\mu_0(A, B)$  — мат ожидание случайной величины  $f(A, B)$  в предположении, что термы  $A$  и  $B$  встречаются вместе независимо.

Будем говорить, что  $sig(A, B) = \frac{f(A, B) - \mu_0(A, B)}{\sqrt{f(A, B)}}$  — значение

**Significance Score** для битерма  $(A; B)$ .

## Построение категориальных факторов

Фильтруются битермы  $b$ :


- 1 С низкой документной частотой:  $N_d(b) < N_d^{min}$
- 2 Неинформативные:  $sig(b) < S^{min}$

Формирование категориальных факторов:


- 1 Сортируем битермы внутри документа по убыванию  $sig(b)$
- 2 Берем не более  $N_{cat}$  первых

# Результаты эксперимента (CatBoost Classifier)


$\Delta T$ , мин	$N_{obj}$	$N_1$	$N_1/N_{obj}$	$N_{cat}$	ROC-AUC	PR-AUC
10	4838	1338	0.277	60	<b>0.79</b>	<b>0.61</b>
3	5696	1696	0.298	60	<b>0.82</b>	<b>0.72</b>




(e) ROC,  $\Delta T = 10$  мин



(f) PR,  $\Delta T = 10$  мин



(g) ROC,  $\Delta T = 3$  мин



(h) PR,  $\Delta T = 3$  мин


# Модель регрессии

Предлагается разбить модель классификации документа на 2 этапа:

- 1 Модель регрессии предсказывает для документа величину скачка цены  $\Delta \hat{P}(t_0, \Delta T)$
- 2 Документ относится к классу «1», если  $\Delta \hat{P}(t_0, \Delta T) > P_{threshold}$ , иначе — к классу «0».

Признаковое описание — категориальные признаки на основе битермов.

# Автоматическая разметка величины скачка цены



Введем новый временной параметр  $\tau$ , задающий границы для небольшого сдвига  $\delta t$ .

$$\text{Введем } \delta P_{\tau}(t_0, \Delta T) = \max_{\delta t \in [-\tau, \tau]} [\Delta P(t_0 + T_b + \delta t, \Delta T)]$$

## Формирование объектов


Обходим все новости; пусть  $t_0$  - время публикации текущей новости:

- 1 Агрегируем новости в интервале  $T_b + T_a$
- 2 Присваиваем новому объекту ответ  $\delta P_\tau(t_0, \Delta T)$
- 3 Если  $\delta P_\tau(t_0, \Delta T) > P_{threshold}$ , удаляем из выборки все новости между  $t_0 + T_a + T_b$  и  $t_0 + T_b + T_i$


Затем считаем  $P_{0.3}$  — 30-ый процентиль по всем  $\delta P_\tau(t, \Delta T)$  — и удаляем объекты, для которых  $P_{0.3} \leq \delta P_\tau(t, \Delta T) \leq P_{threshold}$

# Результаты эксперимента (Catboost Regressor)


$\Delta T$ , мин	$\tau$ , с	$N_{obj}$	$N_1$	$N_1/N_{obj}$	$N_{cat}$	ROC-AUC	PR-AUC
10	20	3799	1014	0.267	60	<b>0.86</b>	<b>0.70</b>
3	20	4016	1160	0.289	60	<b>0.88</b>	<b>0.74</b>




(i) ROC,  $\Delta T = 10$  мин



(j) PR,  $\Delta T = 10$  мин



(k) ROC,  $\Delta T = 3$  мин



(l) PR,  $\Delta T = 3$  мин

## Результаты, выносимые на защиту

- 1 Предложена формализация задачи предсказания скачка цены финансового инструмента по новостному потоку.
- 2 Предложены три модели (на основе агрегирования документов, на основе битермов, а также модель регрессии), показано их преимущество по сравнению с базовой моделью.
- 3 Сделана реализация, пригодная для практической эксплуатации.