

# Алгоритм классификация на основе эмерджентных частых последовательностей и узорных структур

Данил Гиздатуллин

5 октября 2016, г. Москва

- Первый опыт работы (job)
- Завершение наивысшей, на момент опроса ступени образования (education)
- Отъезд от родителей (separation)
- Первое партнерство (partner)
- Первое замужество/женитьба (marriage)
- Рождение первого ребенка (children)
- Разрыв отношений (parting)
- Развод (divorce)

## Распределение по классам

1545 мужчины

3312 женщины

## Примеры последовательностей

- $\langle \{education, separation\}, \{work\}, \{marriage\}, \{children\} \rangle (m)$
- $\langle \{work\}, \{marriage\}, \{children\} \{education\} \rangle (f)$
- $\langle \{partner\}, \{marriage, separation\}, \{children\} \rangle (f)$

- **Подпоследовательность**  $s = \langle s_1, \dots, s_k \rangle$  – это подпоследовательность последовательности  $s' = \langle s'_1, \dots, s'_{k'} \rangle$ , обозначается как  $s \preceq s'$ , если  $k \leq k'$  и существуют  $1 \leq r_1 < r_2 < \dots < r_k \leq k'$  такие, что  $s_j \subseteq s'_{r_j}$  для всех  $1 \leq j \leq k$ .
- **Поддержка** последовательности  $s$  на наборе последовательностей  $D$  обозначается как  $\text{Support}(s, D)$  – это количество последовательностей в наборе последовательностей  $D$ , для которых  $s$  является подпоследовательностью.

$$\text{Support}(s, D) = |\{s' \mid s' \in D, s \preceq s'\}|$$

- **Частая замкнутая последовательность** – последовательный паттерн  $s$  такой, что не существует правильной суперпоследовательности  $s'$ , такой что  $s \prec s'$  и

$$\text{Support}(s, D) = \text{Support}(s', D)$$

Пусть дан следующий набор последовательностей D:

Таблица: Набор последовательностей D.

$s_1$	$\{a, b, c\}\{a, b\}\{b\}$
$s_2$	$\{a\}\{a, c\}\{a\}$
$s_3$	$\{a, b\}\{b, c\}$

- $I = \{a, b, c\}$  - алфавит
- $\langle\{a, b\}\{b\}\rangle$  содержится одновременно в последовательности  $s_1$  и последовательности  $s_3$ , но не в последовательности  $s_2$
- $Support_D(\langle\{a, b\}\{b\}\rangle) = 2$
- $\{\langle\{a\}\rangle, \langle\{c\}\rangle, \langle\{a\}\{c\}\rangle, \langle\{a, b\}\{b\}\rangle, \langle\{a, c\}\{a\}\rangle\}$  - мн-во замкнутых последовательностей.

## Growth Rate

$$growth\_rate_{D' \rightarrow D''}(X) = \begin{cases} \frac{supp_{D''}(X)}{supp_{D'}(X)}, & \text{если } supp_{D'}(X) \neq 0 \\ 0, & supp_{D''}(X) = supp(X) = 0 \\ \text{inf}, & \text{если } supp_{D''}(X) \neq 0 \text{ и } supp_{D'}(X) = 0 \end{cases}$$

## Class score

$$score(s, C) = \sum_{e \subseteq s, e \in E(c)} \frac{growth\_rate_C(e)}{growth\_rate_C(e) + 1} \cdot supp_C(e)$$

## Score normalization

$$normal\_score(s, C) = \frac{score(s, C)}{median(\{growth\_rate_C(e_i)\})}$$

## Classification rule

$$class(s) = \begin{cases} C_1, & \text{если } normal\_score(s, C_1) > normal\_score(s, C_2) \\ C_2, & \text{если } normal\_score(s, C_1) < normal\_score(s, C_2) \\ \text{отказ}, & \text{если } normal\_score(s, C_1) = normal\_score(s, C_2) \end{cases}$$

- **Непрерывная префиксная подпоследовательность** – последовательности  $s = \langle s_1, \dots, s_k \rangle$  есть последовательность  $s_1 = \langle s'_1, \dots, s'_k \rangle$ , обозначается это как  $s = s_1^*$ , если  $k \leq k'$  и  $\forall i \in k' : s_i = s'_i$ .
- **Поддержка в непрерывных префиксных подпоследовательностях**  
T - набор последовательностей

$$Support(s, T) = \frac{|\{s' | s' \in T, s^* = s'\}|}{|T|}$$

- При данной минимальной поддержке  $0 < minSup \leq 1$  задача **поиска префиксных неразрывных паттернов** – это задача поиска всех неразрывных префиксных последовательностей  $s$  таких, что  $Support(s, D) \geq minSup$ . Каждая последовательность  $s$  такая что  $Support(s, D) \geq minSup$  называется **префиксным неразрывным паттерном**.
- Неразрывный префиксный паттерн  $p$  называется **замкнутым**, если не существует неразрывного префиксного паттерна  $d$  большей длины с такой же поддержкой и  $d = p*$

## Пример

Таблица: Набор последовательностей D.

$s_1$	$\{a\}\{b\}\{d\}$
$s_2$	$\{a\}\{b\}\{c\}$
$s_3$	$\{a, b\}\{b, c\}$

$$s = \langle \{a\}\{b\} \rangle$$

- $I = \{a, b, c\}$  - алфавит
- $s_1 = s^*$ ;  $s_2 = s^*$
- $s_3 \neq s^*$
- $Supp_D(s) = \frac{2}{3}$
- $\langle \{a\}\{b\} \rangle$  - замкнутый префиксный паттерн,  $\langle \{a\} \rangle$  - нет.


## Пример хранения

$s_1 : \langle a, b, c \rangle$

$s_2 : \langle a, b, c \rangle$

$s_3 : \langle a, b, d \rangle$

## Дерево



# Пример получения гипотез


## Пример последовательностей

$s_1 : \langle a, b, c \rangle - \text{class } 0$

$s_2 : \langle a, b, c \rangle - \text{class } 0$

$s_3 : \langle a, b, d \rangle - \text{class } 1$

## Префиксное дерево



## Гипотезы

$\langle \{a\}, \{b\}, \{c\} \rangle - \text{гипотеза класса } 0$

$\langle \{a\}, \{b\}, \{d\} \rangle - \text{гипотеза класса } 1$

# Использование гипотез для классификации

$$\text{Class} = \begin{cases} +, \exists h_{\oplus}, h_{\oplus} \sqsubseteq g_{\theta} \text{ и } \nexists h_{\ominus}, h_{\ominus} \sqsubseteq g_{\theta} \\ -, \nexists h_{\oplus}, h_{\oplus} \sqsubseteq g_{\theta} \text{ и } \exists h_{\ominus}, h_{\ominus} \sqsubseteq g_{\theta} \\ \text{неопределен, } \exists h_{\oplus}, h_{\oplus} \sqsubseteq g_{\theta} \text{ и } \exists h_{\ominus}, h_{\ominus} \sqsubseteq g_{\theta} \\ \text{неопределен, } \nexists h_{\oplus}, h_{\oplus} \sqsubseteq g_{\theta} \text{ и } \nexists h_{\ominus}, h_{\ominus} \sqsubseteq g_{\theta} \end{cases}$$

## Growth Rate

$$\text{GrowthRate}(g, K_{\oplus}, K_{\ominus}) = \frac{\text{Sup}_{K_{\oplus}}(g)}{\text{Sup}_{K_{\ominus}}(g)}$$

## Эмерджентные паттерны

Паттерн называется **эмерджентным**, если он удовлетворяет минимальному значению  $\text{Growth Rate}(\Theta_{min})$ , заданному заранее

$$\text{GrowthRate}(g, K_{\oplus}, K_{\ominus}) > \Theta_{min}$$

# Использование эмерджентных паттернов для классификации

$s$  - НОВЫЙ объект

$$normal\_score_{\oplus}(s) = \frac{\sum_{p \in P_{\oplus}} GrowthRate(p, K_{\oplus}, K_{\ominus})}{median(GrowthRate(P_{\oplus}))} : p \sqsubseteq s$$

$$normal\_score_{\ominus}(s) = \frac{\sum_{p \in P_{\ominus}} GrowthRate(p, K_{\ominus}, K_{\oplus})}{median(GrowthRate(P_{\ominus}))} : p \sqsubseteq s$$

Классификация с использованием эмерджентных паттернов

$$Class = \begin{cases} +, & \text{если } normal\_score_{\oplus}(s) > score_{\ominus}(s) \\ -, & \text{если } normal\_score_{\oplus}(s) < score_{\ominus}(s) \\ \text{неопределен,} & \text{если } normal\_score_{\oplus}(s) = normal\_score_{\ominus}(s) \end{cases}$$

# Алгоритм поиска неразрывных префиксных паттернов и классификации

- 1 Строим префиксное дерево на основе всех наших последовательностей.
- 2 Для каждой вершины рассчитываем Growth Rate.
- 3 Для классификации новой последовательности идем по нашему префиксному дереву и считаем Score для каждого класса.
- 4 Сравниваем значение Score для разных классов и классифицируем новую последовательность.


# Пример работы алгоритма

## Последовательности данных


$class\_0 : \{\langle\{a\}; \{b\}; \{c\}\rangle; \langle\{b\}; \{a\}; \{c\}\rangle; \langle\{b\}; \{a\}; \{c\}\rangle; \langle\{b\}; \{c\}\rangle\}$

$class\_1 : \{\langle\{a\}; \{c\}; \{b\}\rangle; \langle\{b\}; \{c\}; \{a\}\rangle; \langle\{b\}; \{c\}; \{a\}\rangle\}$

## Префиксное дерево



## Считаем Growth Rate



## Новая последовательность

$\langle \{b\}; \{c\}; \{a\} \rangle - ???$

$$Score_0 = 0$$

$$Score_1 = 2.67 + \infty = \infty$$

# Эксперименты и результаты




Рис.: TPR, FPR классификация на неразрывных предсказанных паттернах

# Паттерны для классификации (Женщины)

$(\langle\{work, separation\}, \{marriage\}, \{children\}, \{education\}\rangle, [inf, 0.006])$

$(\langle\{separation, partner\}, \{marriage\}\rangle, [inf, 0.006])$

$(\langle\{work, separation\}, \{marriage\}, \{children\}\rangle, [inf, 0.008])$

$(\langle\{work, separation\}, \{marriage\}\rangle, [inf, 0.009])$

# Паттерны для классификации (Мужчины)

(⟨{*education*}, {*marriage*}, {*work*}, {*children*}, {*separation*}⟩, [10.6, 0.006])

(⟨{*education*}, {*marriage*}, {*work*}, {*children*}⟩, [12.7, 0.007])

(⟨{*educ*}, {*work*}, {*part*}, {*mar*}, {*sep*}, {*ch*}⟩, [10.6, 0.006])

- 1 В данной работе было изучено применение методов анализа последовательностей к задачам демографического направления. В частности задаче поиска паттернов, характеризующих отдельные классы данных.
- 2 Был разработан и реализован новый метод анализа паттернов специального типа (неразрывных и префиксных).
- 3 Получены и проинтерпретированы паттерны поведения для разных демографических групп (классов).
- 4 Разработан и протестирован классификатор на языке Python на основе эмерджентных частых последовательностей и узорных структур