

PROCESS MINING

intro

Контакты



Данил Сметанев

Data Science Executive Director

+7 915 470 42 42

smetanev.danil@gmail.com



Александр Кореков

Data Science Executive Director

<https://www.linkedin.com/in/aleksandr-korekov-7225a49b/>

+7 999 926 46 00

av.korekov@gmail.com

План

- 1 Зачем всё это нужно
- 2 Какие данные и алгоритмы используем
- 3 Как оценить качество реконструкции процесса?
- 4 О некоторых алгоритмах векторного представления процессов
- 5 Use-cases из проанализированных процессов
- 6 О библиотеке sberPM

Зачем?

Process Mining

- это технология анализа и моделирования бизнес-процессов и клиентских путей на основе «цифровых следов» (логов)

Условия

- >80% процентов процесса **реализуется в информационных системах**
- Действия пользователей в ИС логируются на достаточном уровне
- В **логах** присутствуют id, событие, дата-время события

Цель




выявление инсайтов по процессу для повышения операционной эффективности и улучшения клиентского опыта

Суть анализа



Получаем данные из систем-источников



Восстанавливаем фактический процесс



Обрабатываем инструментами ML




Выявляем инсайты/ неэффективности

Применение Process Mining


- Оцифровка процесса «до» и «после» изменений
- Мониторинг изменений процесса/показателей эффективности

- Авто-рекомендации по улучшению процесса
- Моделирование «Что если?»
- Прогноз отклонений и сбоев



- Расчет производительности, затрат и стоимости процесса /этапа/конкретных исполнителей, ошибки, узкие места
 - Анализ клиентских путей
 - Автоматический хронометраж
 - Анализ отклонений
-
- Проверка соответствия требованиям ВНД и регулятора
 - Benchmark процесса (анализ лучших практик, GAP-анализ)
 - Поиск мошеннических схем

Какая природа данных?



user session

activities

$\begin{bmatrix} id, \\ activity_id, \\ attributes \end{bmatrix}$

$\begin{bmatrix} id, \\ names, \\ attributes \end{bmatrix}$

event log $L = \begin{bmatrix} \langle a, e \rangle^5, \langle a, b, c, e \rangle^{10}, \\ \langle a, b, e, f \rangle, \langle a, c, e \rangle, \\ \langle a, d, d, d, e \rangle, \langle a, d, d, e \rangle^2, \\ \langle a, d, e \rangle^{10}, \langle a, c, b, e \rangle^{10} \end{bmatrix}$

Event-log

Файл с записями о событиях в информационной системе в хронологическом порядке
На данный момент в большинстве АС ведется логирование действий сотрудников

Минимальный набор атрибутов лог-файла для проведения исследования



Идентификатор
ID экземпляра процесса, например, номер заявки



Название операции
Например: клик пользователя на кнопку



Временная метка
указывает дату и время выполнения операции


ID	Операция	Дата события	Имя исполнителя	Локация	Наименование продукта	Плановая дата	Комментарий
34781	Создание заявки	15.05.2020 11:11	Иванов И.	Дирекция	ИИД-догословный файл ЛАМ		
34781	Отправка заявки	15.05.2020 11:29	Иванов И.	Дирекция	ИИД-догословный файл ЛАМ		
34781	Поступление заявки н	15.05.2020 11:29	Иванов И.	Плановый плановый	ИИД-догословный файл ЛАМ		
34781	Назначение КС и испо	15.05.2020 12:43	Иванов И.	Плановый плановый	ИИД-догословный файл ЛАМ	12.05.2020 11:29	
34781	Отправка внутренней	15.05.2020 13:11	Иванов И.	Плановый плановый	ИИД-догословный файл ЛАМ	12.05.2020 11:29	
34781	Формирование реестр	18.05.2020 23:10	Иванов И.	Плановый плановый	ИИД-догословный файл ЛАМ	12.05.2020 11:29	
34781	Прием реестра	19.05.2020 10:51	Иванов И.	Плановый плановый	ИИД-догословный файл ЛАМ	12.05.2020 11:29	
34781	Сканирование	19.05.2020 10:43	Иванов И.	Плановый плановый	ИИД-догословный файл ЛАМ	12.05.2020 11:29	
34781	Закрытие заявки	19.05.2020 15:19	Иванов И.	Плановый плановый	ИИД-догословный файл ЛАМ	12.05.2020 11:29	Заявка закрыта. ИИД-догословный файл ЛАМ. Комментарий: заявка закрыта. Комментарий: заявка закрыта.

+ любые доп. атрибуты:

исполнитель, роль пользователя, продукт, локация, текстовый комментарий

Проблема: как определить истинную структуру процесса?


$$\text{event log } L = \left[\begin{array}{l} \langle a, e \rangle^5, \langle a, b, c, e \rangle^{10}, \\ \langle a, b, e, f \rangle, \langle a, c, e \rangle, \\ \langle a, d, d, d, e \rangle, \langle a, d, d, e \rangle^2, \\ \langle a, d, e \rangle^{10}, \langle a, c, b, e \rangle^{10} \end{array} \right]$$



Как может помочь Process Mining?

1

Реконструкция графа
процесса



2


Расчет метрик качества
реконструкции графа

Quality Criteria:

1. Fitness
2. Simplicity
3. Precision
4. Generalization


Metrics:

1. Parsing Measure
2. Partial Fitness Complete
3. Behavioral precision B_p and recall
4. Extended Cardoso Metric
5. Extended Cyclomatic Metric
6. Advanced behavioral appropriateness
7. Structural similarity
8. Behavioral recall r_B^p , specificity s_B^n and precision
9. И другое



3

Моделирование изменений
в процессах



*Абсолютно бессмысленная картинка про
сравнение реализаций процесса*

Basic algos: Alpha, Alpha+, Heuristics



Проблема

Лог-файл представляет собой «плоскую» таблицу, истинная структура процесса неизвестна



Идея

Представить процесс в виде символьной / числовой матрицы и эвристически описать процесс



Семейство альфа-алгоритмов

Direct succession: $X > Y$

- Если за какой-нибудь X непосредственно следует за Y

Causality: $X \rightarrow Y$

- Если $X > Y$ и нет отношений $Y > X$

Parallel: $X || Y$

- Если $X > Y$ и есть отношения $Y > X$

Unrelated: $X \# Y$

- Если нет отношений $X > Y$ и нет отношений $Y > X$



Эвристический майнер

$$a \Rightarrow b = \frac{|a > b| - |b > a|}{|a > b| + |b > a| + 1}$$

$$d \Rightarrow d = \frac{|d > d|}{|d > d| + 1}$$

Альфа-алгоритм

$$\text{event log } L = [\langle a, b, c, d \rangle^3, \langle a, c, b, d \rangle^2, \langle a, e, d \rangle^1]$$




$\Rightarrow W$	A	B	C	D	E
A	#	$\rightarrow$	$\rightarrow$	#	$\rightarrow$
B	$\leftarrow$	#		$\rightarrow$	#
C	$\leftarrow$		#	$\rightarrow$	#
D	#	$\leftarrow$	$\leftarrow$	#	$\leftarrow$
E	$\leftarrow$	#	#	$\rightarrow$	#



$(\{a\}, \{b, e\}), (\{a\}, \{c, e\}),$
 $(\{b, e\}, \{d\}), (\{c, e\}, \{d\})$

Альфа-алгоритм


$(\{a\}, \{b, e\}), (\{a\}, \{c, e\}),$
 $(\{b, e\}, \{d\}), (\{c, e\}, \{d\})$



Альфа-алгоритм: ограничения

Corner cases with non-existent processes



$$\text{event log } L = [\langle a, c, d \rangle, \langle b, c, e \rangle, \langle a, c, e \rangle]$$





Альфа-алгоритм: ограничения

Corner cases with loops

1. Циклы длиной «1» $\text{event log } L = [\langle a, c \rangle, \langle a, b, c \rangle, \langle a, b, b, c \rangle, \langle a, b, b, b, c \rangle]$



2. Циклы длиной «2» $\text{event log } L = [\langle a, b, d \rangle, \langle a, b, c, b, d \rangle, \langle a, b, c, b, c, b, d \rangle]$



Эвристический майнер

event log $L = \left[\langle a, e \rangle^5, \langle a, b, c, e \rangle^{10}, \langle a, b, e \rangle, \langle a, c, e \rangle, \right.$
 $\left. \langle a, d, d, d, e \rangle, \langle a, d, d, e \rangle^2, \langle a, d, e \rangle^{10}, \langle a, c, b, e \rangle^{10} \right]$

$\Rightarrow W$	A	B	C	D	E
A	0	0.92	0.92	0.93	0.83
B	-0.92	0	0	0	0.92
C	-0.92	0	0	0	0.92
D	-0.93	0	0	0.8	0.93
E	-0.83	-0.92	-0.92	-0.93	0


$$a \Rightarrow b = \frac{|a > b| - |b > a|}{|a > b| + |b > a| + 1}$$

$$d \Rightarrow d = \frac{|d > d|}{|d > d| + 1}$$

Эвристический майнер

$$event\ log\ L = \left[\begin{array}{l} \langle a, e \rangle^5, \langle a, b, c, e \rangle^{10}, \langle a, b, e \rangle, \langle a, c, e \rangle, \\ \langle a, d, d, d, e \rangle, \langle a, d, d, e \rangle^2, \langle a, d, e \rangle^{10}, \langle a, c, b, e \rangle^{10} \end{array} \right]$$

$\Rightarrow W$	A	B	C	D	E
A	0	0.92	0.92	0.93	0.83
B	-0.92	0	0	0	0.92
C	-0.92	0	0	0	0.92
D	-0.93	0	0	0.8	0.93
E	-0.83	-0.92	-0.92	-0.93	0



Алгоритмы «без разметки»: Correlation miner



Проблема Неизвестен истинный id процесса – это может быть, например, как id сессии, так и id юзера. Или процесс проходит сквозь несколько систем без единого id



Идея У событий, связанных прямым переходом будет высокая частота a->b и низкое время перехода



Концепция



$$P/S_{i,j} = \frac{\sum_{(e,f) \in \Omega_{i,j}} b(e,f)}{|\Omega_{i,j}|}$$




Результат

	A	B	C	D	E
A	0.00	0.47	0.97	0.73	0.88
B	0.53	0.00	1.00	0.67	0.90
C	0.03	0.00	0.00	0.33	0.57
D	0.26	0.33	0.67	0.00	0.70
E	0.12	0.10	0.43	0.30	0.00



Heuristics


$$c_{ij} = \frac{D_{i,j}}{P/S_{i,j}} \cdot \frac{1}{\min(|E_i|, |E_j|)}$$




	A	B	C	D	E
A	0	74	109	108	220
B	54	0	214	164	69
C	6	0	0	87	42
D	0	106	150	0	124
E	0	102	62	96	0

$$\text{minimize} \sum_{x_{ij} \in \mathcal{X}} c_{ij} \cdot x_{ij}$$


Сравнение майнеров




 **Alpha miner**




 **Alpha+**




 **Heuristics**



 **DFG**



 **Correlation**



 **Inductive**

Критерии качества

Fitness

Насколько точно модель может воспроизвести все пути из лога

$$fitness = \frac{1}{2} \left(1 - \frac{missed}{consumed} \right) + \frac{1}{2} \left(1 - \frac{remaining}{produced} \right)$$

Simplicity

Оценивает «простоту» модели – количество «дублирующихся» и «лишних» задач

$$simplicity = \frac{N \text{ transitions} - Duplicates - Redundant}{N \text{ transitions}}$$

Generalization

Оценивает количество «возможных» переходов, которых в явном виде нет в исходных данных

$$generalization = 1 - \frac{1}{\sum_i \sqrt{node_i \text{ nb of occurrences}}}$$

Precision

Оценивает все возможные переходы и встречались ли они в исходных данных

$$precision = 1 - \frac{total \text{ edges} - used \text{ edges}}{total \text{ edges}}$$

Сети Петри

Сеть Петри – двудольный ориентированный граф, содержащий вершины двух типов:

- места/узлы/вершины (обозначаются кружками)
- переходы (обозначаются прямоугольниками)

Сеть Петри – это тройка $N = (P, T, F)$

P — узлы, T — переходы, F — дуги; $P \cap T = \emptyset$

Сеть Петри используется для двух вещей:



- 1) Описание процесса: допустимые переходы и условия ветвления
- 2) Реконструкция графа: убираем редкие и неважные переходы и оставляем суть



Формально, в Process Mining используется не Petri Net, а Workflow Net*









Рис.1 Рандомные картинки из Интернета по запросу «Petri Net»

Примеры

Marking




Enabled Transitions



Token firing algo


Token firing – динамика в сети Петри – это последовательность исполнения (*firing*) переходов (*transitions*)




Пример:

- 1) Transition **t1** firing: 1 token убираем из places **p1** и **p2** и добавляем 1 token в **p3**
- 2) Transition **t2** firing: убираем 1 token из **p3** и добавляем 1 в **p2**



Fitness example



Fitness example



Сравнение алгоритмов







ML-задачи в Process Mining

- 1 «Сжатие» большого процесса
- 2 Идентификация Bottlenecks в процессах
- 3 Оценка влияния Bottlenecks на метрики процесса
- 4 Предсказание переходов по клиентскому пути
- 5 Поиск «оптимального пути» процесса



A very simple approach: processWord2Vec


$$\log L = \begin{bmatrix} \langle a, e \rangle^5, \\ \langle a, b, c, e \rangle^{10}, \\ \langle a, b, e, f \rangle, \\ \langle a, c, e \rangle, \\ \langle a, d, d, d, e \rangle, \\ \langle a, d, d, e \rangle^2, \\ \langle a, d, e \rangle^{10}, \\ \langle a, c, b, e \rangle^{10} \end{bmatrix}$$



Graph2Vec (1/2)

Алгоритм работы:

1. Составляем пары – $[(a,b), (b,c), (a,d) \dots]$
2. Представляем в виде графа с помощью – все возможные комбинации ребер и нод
3. Идем циклом по каждой ноде:
 - 3.1. Находим у ноды n всех соседей.
 - 3.2. Находим степень каждого соседа
 - 3.3. Объединяем множество всех степеней соседей и нашей ноды n
 - 3.4. Множество переводим в строку
 - 3.5. В виде словаря представляем ноде строку
4. Полученный строки мы объединяем в «предложение», которые будем подавать в Doc2Vec.
5. Получаем вектор для реализации процесса



Graph2Vec (2/2)

$$L = [\langle a, b, c \rangle^1, \langle a, d, c, b \rangle^1, \langle a, b, b, c, b \rangle^1]$$

Алгоритм работы:

1. Составляем пары:

$\langle a, b, c \rangle - (a, b), (b, c)$

$\langle a, d, c, b \rangle - (a, d), (d, c), (c, b)$

$\langle a, b, b, c, b \rangle - (a, b), (b, b), (b, c), (c, b)$

2. Для каждой реализации процесса находим у соседей каждой ноды (1: A – 1, B-2, C-1, 2: A – 1, D-2, C – 2, B-1, 3: A-1, B-4, C-2)

3. Объединим множество всех степеней свободы и каждой ноды, в каждой реализации процесса:

1, 2, 1 - > [1, 1_2, 2, 2_2_1, 1, 1_2]

1, 2, 2, 1 - > [1, 1_2, 2, 2_2_1, 2, 2_2_1, 1, 1_2]

1, 4, 4, 1, 4 - > [1, 1_4, 4, 1_4_4, 4, 4_4_1, 1, 4_1_4, 4, 1_4]

4. Используем лист степеней свободы в doc2vec и предсказываем последовательность этапов


[1, 1_2, 2, 2_2_1, 1, 1_2] predict $\langle a, b, c \rangle$

[1, 1_2, 2, 2_2_1, 2, 2_2_1, 1, 1_2] predict $\langle a, d, c, b \rangle$

[1, 1_4, 3, 1_4_4, 4, 4_4_1, 1, 4_1_4, 4, 1_4] predict $\langle a, b, b, c, b \rangle$

5. Получаем вектора для каждой реализации процесса

Word2Mat(1/2)



Получение эмбединга каждого этапа процесса

Использована идея агрегации из Word2Mat¹: эмбединг каждого этапа процесса преобразуется к квадратной матрице, далее они перемножаются, и полученная матрица «растягивается» к исходному размеру

¹<https://openreview.net/forum?id=H1MgjoR9tQ>

Word2Mat (2/2)

High-Order Proximity Embedding (HOPE)²

$$\mathbf{S} = \mathbf{M}_g^{-1} \cdot \mathbf{M}_l$$

Table 1: General Formulation for High-order Proximity Measurements

Proximity Measurement	$\mathbf{M}_g$	$\mathbf{M}_l$
Katz	$\mathbf{I} - \beta \cdot \mathbf{A}$	$\beta \cdot \mathbf{A}$
Personalized Pagerank	$\mathbf{I} - \alpha \mathbf{P}$	$(1 - \alpha) \cdot \mathbf{I}$
Common neighbors	$\mathbf{I}$	$\mathbf{A}^2$
Adamic-Adar	$\mathbf{I}$	$\mathbf{A} \cdot \mathbf{D} \cdot \mathbf{A}$

source эмбединги $U^s = \left[\sqrt{\sigma_1} \mathbf{v}_1^s, \dots, \sqrt{\sigma_k} \mathbf{v}_k^s \right]$

target эмбединги $U^t = \left[\sqrt{\sigma_1} \mathbf{v}_1^t, \dots, \sqrt{\sigma_k} \mathbf{v}_k^t \right]$

используя SVD разложение $\mathbf{S} = \mathbf{V}^s \Sigma \mathbf{V}^{tT}$

Weighted Adjacency Matrix

$$\mathbf{S} = \mathbf{A} \odot \mathbf{Q} \mathbf{Q}^T$$

$\mathbf{A}_{p \times p} = (a_{ij})$ - матрица смежности для графа процесса.

$\mathbf{Q}_{p \times q}$ - взвешенная матрица метрик.


source эмбединги $U^s = \left[\sqrt{\sigma_1} \mathbf{v}_1^s, \dots, \sqrt{\sigma_k} \mathbf{v}_k^s \right]$

target эмбединги $U^t = \left[\sqrt{\sigma_1} \mathbf{v}_1^t, \dots, \sqrt{\sigma_k} \mathbf{v}_k^t \right]$


используя SVD разложение $\mathbf{S} = \mathbf{V}^s \Sigma \mathbf{V}^{tT}$

²<https://dl.acm.org/doi/pdf/10.1145/2939672.2939751>


Сравнение алгоритмов





proc2vec





HOPE




proc2vec



HOPE



Process Mining for Customer Journey (1/2)



- ▶ Большое количество переходов
- ▶ Нет основного пути, каждая цепочка уникальна
- ▶ Мало малоиспользуемых активностей

Process Mining for Customer Journey (2/2)




Процесс

Клиентский путь в мобильном приложении
Сбера

AS IS

- 2351 АКТИВНОСТЬ
- НЕВОЗМОЖНО АНАЛИЗИРОВАТЬ
- НЕ ВИДЕН ОСНОВНОЙ ПУТЬ




Задача алгоритма

Реконструировать процесс

Минимизировать число шагов до успеха

Провести клиента до оплаты за минимальное время

Исключить циклы



Доступные Open source решения



Python. Библиотека от Сбера с фокусом на использование ML для аналитики клиентских путей, в ней чуть меньше фичей по классическому process mining, больше аналитических тулзов (метрики, графики, ML)



Python. Библиотека on Fraunhofer Institute for Applied Information Technology (FIT) с фокусом на классический process mining – поддерживает больше методов PM и анализа качества реконструкции графа



pm4py для тех, кто ценит R



Java. Продукт от Eindhoven University of Technology – с интерфейсом и свистелками

(картинки кликабельные)

Python-решения: SberPM vs PM4PY

Объем лог-файла (ids / rows)	Library	Считывание лог-файла	Alpha	Alpha+	HeuMiner	HeuMiner + metrics	Token Replay
10к / 77к	 SBER PROCESS MINING	0,8 sec	0,03 sec	0,06 sec	0,06 sec	0,1 sec	1,26 sec
	PM4PY	0,66 sec	0,17 sec	1,37 sec	1,15 sec	-	1,30 sec
250к / 1,6m	 SBER PROCESS MINING	23,4 sec	0,84 sec	1,61 sec	1,68 sec	2,8 sec	34 sec
	PM4PY	15,1 sec	2,67 sec	10,5 sec	13,4 sec	-	6 sec
1m / 6,7m	 SBER PROCESS MINING	95 sec	3,2 sec	6,2 sec	6,0 sec	10 sec	118 sec
	PM4PY	80 sec	13 sec	34 sec	32 sec	-	13 sec

Что ещё?

https://github.com/SberProcessMining/Sber_Process_Mining

SberPM is an open-source Python library for conducting a comprehensive analysis of business processes with the use of process mining and machine learning techniques.

<https://habr.com/ru/company/sberbank/blog/554378/>

<https://sashakorekov.medium.com/>

Обзорные статьи по использованию sberPM

https://icpmconference.org/2020/wp-content/uploads/sites/4/2020/10/ICPM_2020_paper_141.pdf

An In-depth Analysis of Reimbursement Processes Using Process Mining Techniques

<http://www.processmining.org/>

Process Mining Group, Math&CS department, Eindhoven University of Technology