

Ответы на вопросы

Чуйкова Екатерина

377a

Московский физико-технический институт

18.01.2019

Билет 10

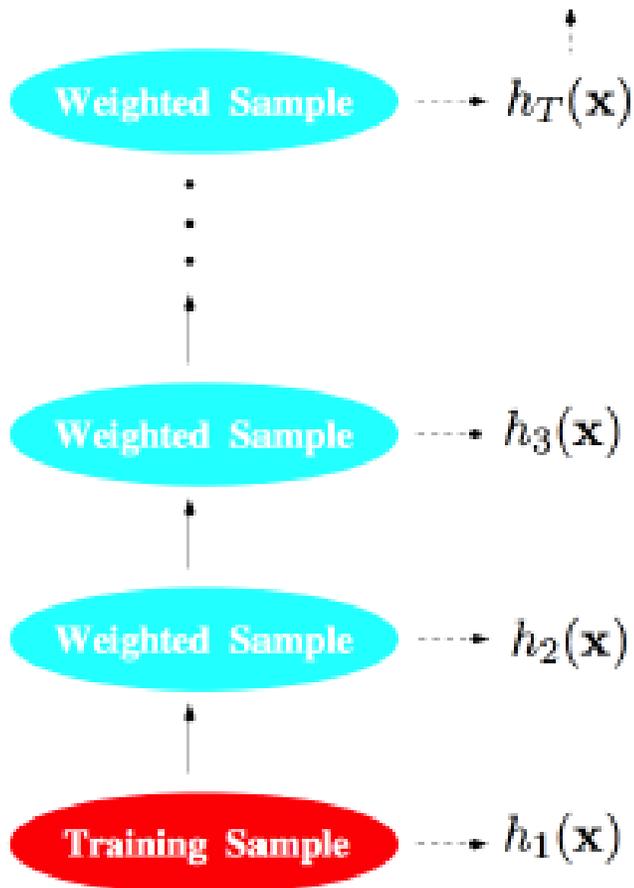
Методы построения композиций
классификаторов. Бустинг и бэггинг.

Композиция классификаторов

При решении сложных задач часто оказывается, что ни один из алгоритмов не обеспечивает желаемого качества восстановления зависимости. В таких случаях имеет смысл строить композиции алгоритмов, в которых ошибки отдельных алгоритмов взаимно компенсируются.

БУСТИНГ

$$f_T(\mathbf{x}) = \text{sign} \left[\sum_{t=1}^T \alpha_t h_t(\mathbf{x}) \right]$$



Процедура последовательного построения композиции алгоритмов машинного обучения, когда каждый следующий алгоритм стремится компенсировать недостатки композиции всех предыдущих алгоритмов

Бустинг

- Жадный алгоритм.
- Можно использовать как метод фильтрации выбросов, т.к. объекты с наибольшими весами, скорее всего, являются шумовыми выбросам
- Хорошая обобщающая способность

Бэггинг

1. Из исходной обучающей выборки длины ℓ формируются различные обучающие подвыборки той же длины ℓ с помощью бутстрепа — случайного выбора с возвращениями. При этом некоторые объекты попадают в подвыборку по несколько раз, некоторые — ни разу.
2. Производится независимое обучения каждого элементарного классификатора
3. Производится классификация основной выборки на каждом из подпространств (независимо).
4. Принимается окончательное решение о принадлежности объекта одному из классов
 - Простое большинство
 - Взвешивание классификаторов

Бэггинг

- Ошибки базовых алгоритмов взаимно компенсируются при голосовании.
- Выбросы могут не попадать в некоторые обучающие подвыборки.
- Особенно эффективен на малых выборках, когда исключение даже небольшой доли обучающих объектов приводит к построению существенно различных базовых алгоритмов.

Билет 21

Выпуклая оболочка конечного множества точек на плоскости. Алгоритм Джарвиса. Алгоритм Грэхема.

Выпуклая оболочка

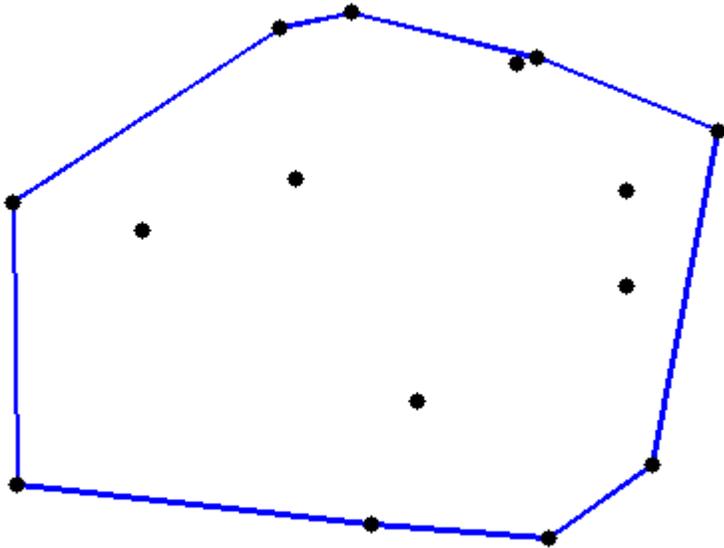
Пусть на плоскости заданы k различных точек p_1, p_2, \dots, p_k .
Множество точек

$$p = \alpha_1 p_1 + \alpha_2 p_2 + \dots + \alpha_k p_k,$$
$$(\alpha_i \in \mathbf{R}, \alpha_i \geq 0, \alpha_1 + \alpha_2 + \dots + \alpha_k = 1)$$

называется **выпуклым множеством**, порожденным точками p_1, p_2, \dots, p_k ,
а точка p - называется **выпуклой комбинацией** точек p_1, p_2, \dots, p_k .

Выпуклой оболочкой множества точек L на плоскости называется наименьшее выпуклое множество, содержащее L .

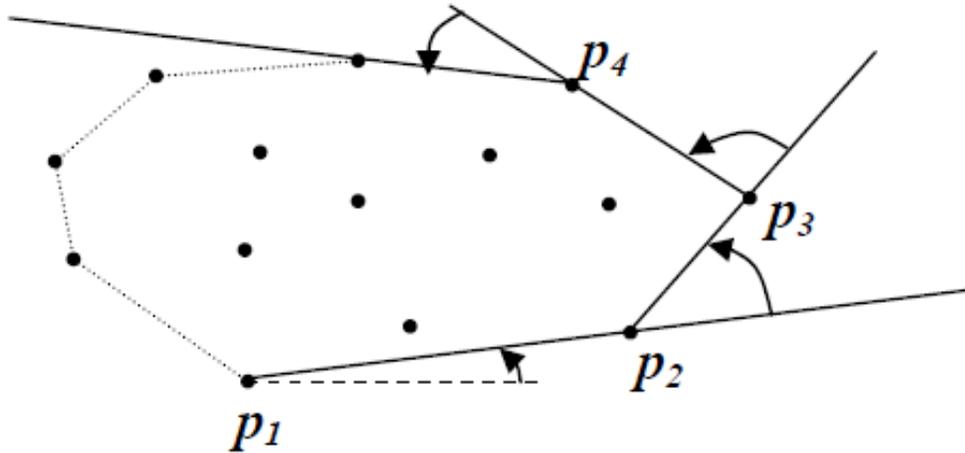
Задача построения выпуклой оболочки



Для множества L из n точек требуется построить выпуклую оболочку $conv(L)$ в виде полного описания границы.

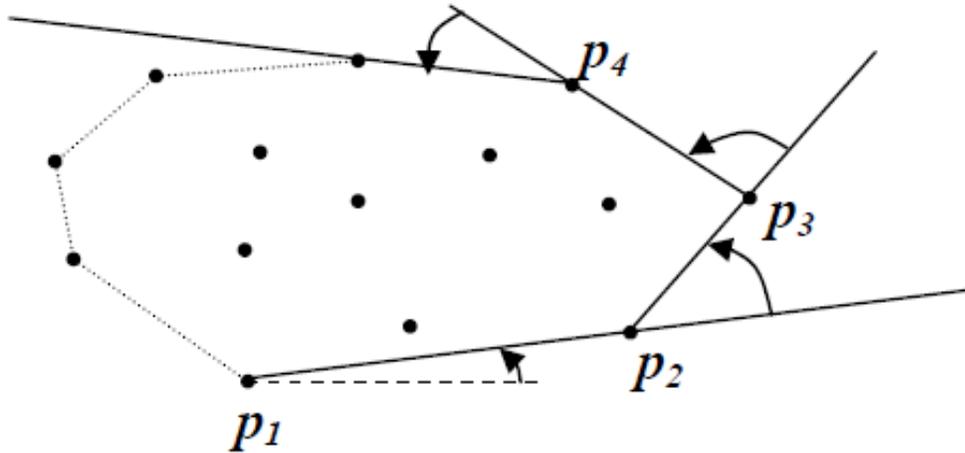
Описание границы :
упорядоченной подмножество точек из L , называемых граничными точками.
Точки из L , не являющиеся граничными, называются внутренними.

Метод Джарвиса (заворачивание подарка)



- Пусть найдена наименьшая в лексикографическом порядке точка p_1 заданного множества L . Эта точка заведомо граничная, т.е. является вершиной выпуклой оболочки.
- Пусть точка p_2 - это точка, имеющая наименьший положительный полярный угол относительно точки p_1 как начала координат.
- Следующая граничная точка p_3 выбирается таким образом, чтобы вектор p_2p_3 имел наименьший положительный угол относительно вектора p_1p_2 .
- Аналогично ищутся остальные граничные точки.

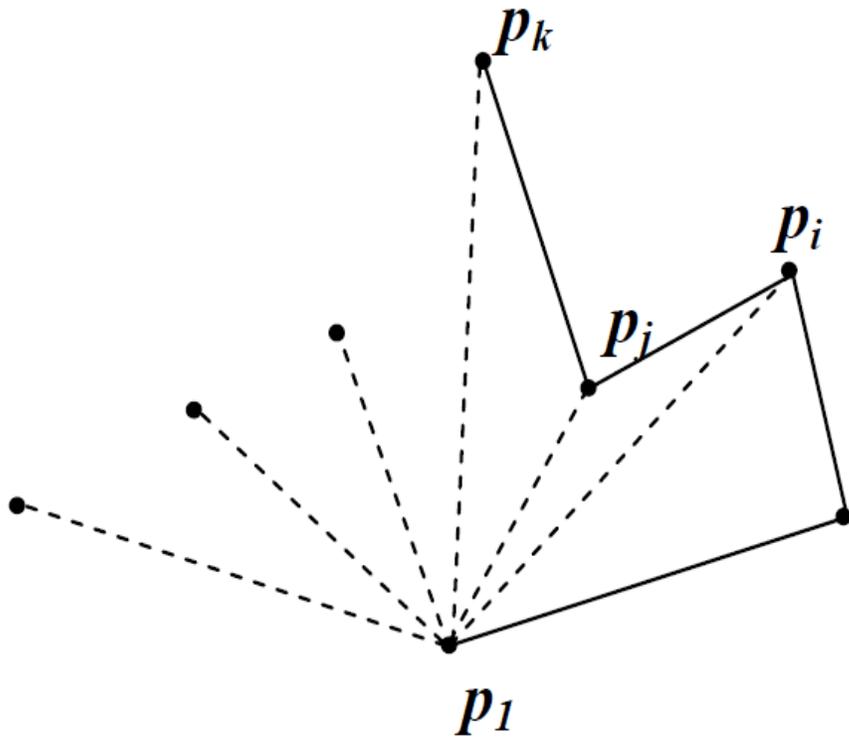
Метод Джарвиса (заворачивание подарка)



Алгоритм Джарвиса затрачивает на нахождение одной граничной точки линейное время.

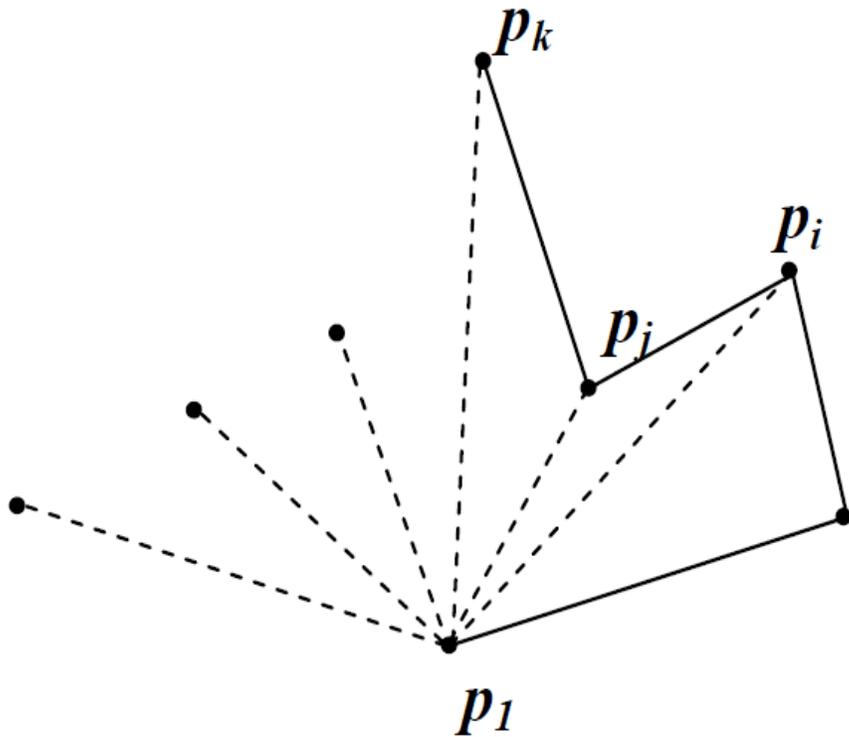
Общее время выполнения алгоритма в худшем случае $O(nh)$, где h - число вершин выпуклой оболочки.

Метод Грэхема



- Пусть найдена наименьшая в лексикографическом порядке точка p_1 ($O(n)$).
- Упорядочим лексикографически все остальные точки в соответствии с полярными углами векторов p_1p_i и длинами этих векторов
 1. Тройка $p_i p_j p_k$ образует правый поворот. Удалить среднюю точку p_j тройки из списка вершин и проверить вновь образовавшуюся текущую тройку $p_{i-1} p_i p_k$.
 2. Тройка $p_i p_j p_k$ образует левый поворот. Продолжить просмотр, перейдя к проверке тройки $p_j p_k p_{k+1}$.

Метод Грэхема



- Поиск p_1 - $O(n)$.
- Время обхода составляет $O(n)$.
- Сортировка массива точек занимает время $O(n \log n)$

Общее время работы алгоритма $O(n \log n)$.

Билет 35

Векторные представления предложений и текстов. Основные модели (TF-IDF, усреднение, нейронные модели). Механизм Self-attention.

TF-IDF

Вес некоторого слова пропорционален частоте употребления этого слова в документе и обратно пропорционален частоте употребления слова во всех документах коллекции.

$$\text{tf-idf}(t, d, D) = \text{tf}(t, d) \times \text{idf}(t, D)$$

TF-IDF

TF (*term frequency* — частота слова) - Оценивается важность слова в пределах одного документа

$$\text{tf}(t, d) = \frac{n_t}{\sum_k n_k}$$

n_t — число вхождений слова t в документ
 $\sum_k n_k$ — общее число слов в данном документе

IDF (*inverse document frequency* — обратная частота документа) - уменьшает вес широкоупотребительных слов

$$\text{idf}(t, D) = \log \frac{|D|}{|\{d_i \in D \mid t \in d_i\}|}$$

$|D|$ — число документов в коллекции
 $|\{d_i \in D \mid t \in d_i\}|$ — число документов из коллекции D , в которых встречается t

Усреднение Word2Vec

Mary is hungry for apples.

John is happy he is not hungry for apples.

Lookup

Word	Vector
Mary	[.24, 1.16, .12, ..., 1.97, .23, .12]
is	[.55, .11, .15, ..., .65, 1.30, 2.42]
hungry	...
happy	...
for	...
apples	...
not	...
John	[.68, 2.02, .24, ..., 1.12, .43, .27]
he	[.21, 1.07, 1.01, ..., 0.94, .07, .16]

Average

[.24, 1.16, .12, ..., 1.97, .23, .12]
[.43, 1.46, .55, ..., 1.13, .53, .78]

Self-attention



