

Лекция 4

Графические модели для работы с последовательностями слов

Потапенко Анна Александровна

26 сентября 2018

1. Задачи разметки последовательностей (Sequence labeling/tagging)

Примеры задач

Распознавание частей речи:

PRON

I

VERB

saw

DET

a

PROPN

Heffalump

NOUN

today.

Распознавание именованных сущностей:

Once upon a time, a very long time ago now, about

[last Friday], **[Winnie-the-Pooh]** lived in a forest all by

himself under the name of **[Sanders]**.

Разметка последовательностей

Дано: последовательность слов (токенов)

Найти: последовательность меток (тэгов)

Примеры задач:

- распознавание частей речи (part of speech tagging, POS)
- распознавание именованных сущностей (named entity recognition, NER)
- выделение семантических ролей (semantic role labeling)
- снятие омонимии слов (word sense disambiguation, WSD)
- неглубокий синтаксический разбор (chunking, shallow syntax parsing)

POS-тэги из Universal Dependencies

Open class words	
ADJ	adjective
ADV	adverb
INTJ	interjection
NOUN	noun
PROPN	proper noun
VERB	verb

Other	
PUNCT	punctuation
SYM	symbol
X	other

Closed class words	
ADP	adposition
AUX	auxiliary verb
CCONJ	coordinating conjunction
DET	determiner
NUM	numeral
PART	particle
PRON	pronoun
SCONJ	subordinating conjunction

<http://universaldependencies.org/>

ВІО-нотация (beginning - inside - outside)

Что может быть именованной сущностью:

люди, организации, места, дата, время, количество, ...

Набор NER тэгов в CoNLL-2003: B-PER, I-PER, B-LOC, I-LOC, B-ORG, I-ORG, B-MISC, I-MISC, O

Пример определения семантических ролей:

B_ACT	I_ACT	I_ACT	O	B_NUM_PER	O	B_LOC	I_LOC
Book	a	table	for	3	in	Domino's	pizza

Возможные подходы

1. Правилковые модели (example: EngCG tagger)
2. Одельные классификаторы для каждого токена
- 3. Графически модели (НММ, МЕММ, CRF)**
4. Нейронные сети (*следующая лекция*)

2. Скрытая марковская модель (Hidden Markov Model)

Скрытая марковская модель

Обозначения:


$\mathbf{X} = x_1, \dots, x_T$ последовательность слов

$\mathbf{Y} = y_1, \dots, y_T$ последовательность меток

Генерация текста:

1. Генерируется следующая метка при условии предыдущей
2. Генерируется слово при условии метки

Генерация текста: пример



Каждая стрелочка – это условная вероятность.

Скрытая марковская модель

$$p(\mathbf{x}, \mathbf{y}) = p(\mathbf{x}|\mathbf{y}) p(\mathbf{y}) = \prod_{t=1}^T p(x_t|y_t) p(y_t|y_{t-1})$$



наблюдаемые скрытые

Предположение Маркова:

$$p(\mathbf{y}) \approx \prod_{t=1}^T p(y_t|y_{t-1})$$

Предположение о независимости:

$$p(\mathbf{x}|\mathbf{y}) \approx \prod_{t=1}^T p(x_t|y_t)$$

Формальное определение модели

1. Множество $S = s_1, s_2, \dots, s_N$ скрытых состояний
2. Начальное состояние s_0
3. Матрица A вероятностей переходов $a_{ij} = p(s_j | s_i)$
4. Множество O выходных токенов
5. Матрица B выходных вероятностей $b_{kj} = p(o_k | s_j)$

В нашем случае, состояния – это метки, токены – это слова:

$$x_t \in O, \quad y_t \in S$$

Задачи и алгоритмы

1. Обучение модели:

$$A = ? \quad B = ?$$

(по размеченной или по неразмеченной выборке)

2. Оценивание апостериорных вероятностей:

$$p(\mathbf{y}|\mathbf{x}) = ?$$



3. Поиск наиболее вероятных меток:

$$\mathbf{y} = \operatorname{argmax}_{\mathbf{y}} p(\mathbf{y}|\mathbf{x}) = \operatorname{argmax}_{\mathbf{y}} p(\mathbf{x}, \mathbf{y})$$

3. Алгоритм Витерби: поиск наиболее вероятных меток

Мотивация

Одина и та же последовательность слов может быть получена из нескольких последовательностей (скрытых) меток:



Задача декодирования

$$p(\mathbf{x}, \mathbf{y}) = \prod_{t=1}^T p(y_t | y_{t-1}) p(x_t | y_t)$$


Вероятности перехода Выходные вероятности

Найти:

Наиболее вероятную последовательность скрытых меток

$$\mathbf{y} = \operatorname{argmax}_{\mathbf{y}} p(\mathbf{y} | \mathbf{x}) = \operatorname{argmax}_{\mathbf{y}} p(\mathbf{x}, \mathbf{y})$$


Решается динамическим программированием.

Алгоритм Витерби

Пусть $Q_{t,s}$ - самая вероятная последовательность скрытых состояний длины t с окончанием в состоянии S
а $q_{t,s}$ - вероятность этой последовательности.

Тогда $q_{t,s}$ можно подсчитать динамически:

$$q_{t,s} = \max_{s'} q_{t-1,s'} \cdot p(s|s') \cdot p(o_t|s)$$


Transition probabilities Output probabilities

$Q_{t,s}$ можно восстановить по argmax-ам.

Алгоритм Витерби

Input: observations of length T , state-graph of length N

Output: best-path

for each state s from 1 to N do

$$q[1, s] \leftarrow p(s|s_0) \cdot p(o_1|s)$$

$$\text{backpointers}[1, s] \leftarrow 0$$

for each time step t from 2 to T do

for each state s from 1 to N do

$$q[t, s] \leftarrow \max_{s'=1}^N q[t-1, s'] \cdot p(s|s') \cdot p(o_t|s)$$

$$\text{backpointers}[t, s] \leftarrow \operatorname{argmax}_{s'=1}^N q[t-1, s'] \cdot p(s|s')$$

$$s \leftarrow \operatorname{argmax}_{s'=1}^N q[T, s']$$

return the backtrace path from backpointers $[T, s]$

Пример: вероятности переходов

Рассматриваются следующие POS-теги:
ADJ, NOUN, VERB.

Пусть в начальный момент вероятности всех тегов равны $1/3$. Затем:

from \ to	ADJ	NOUN	VERB
ADJ	0.4	0.4	0.2
NOUN	0.2	0.4	0.4
VERB	0.1	0.6	0.3

Сумма вероятностей в каждой строке равна 1.


Пример: выходные вероятности

Рассмотрим такие вероятности:


tag\word	a	bear	fly	honey	likes	sweet
ADJ	0.2	0.1	0.1	0.1	0.1	0.4
NOUN	0.1	0.2	0.2	0.2	0.2	0.1
VERB	0.1	0.2	0.2	0.1	0.3	0.1

Вероятности в каждой строке суммируются в 1.


Вероятности скрытых состояний до likes




Возможные переходы в состояние ADJ




Лучший переход в состоянии ADJ




Вероятность ADJ при условии likes




Возможные переходы в состояние NOUN




Лучший переход в состояние NOUN




Вероятность NOUN при условии likes




Варианты переходов в состояние VERB



Лучший переход в состоянии VERB



Вероятность VERB после likes



Вероятности скрытых состояний после likes

→ ADJ
 $q=0.25$

ADJ
 $q=0.25 \cdot 0.4 \cdot 0.1$

→ NOUN
 $q=0.5$

NOUN
 $q=0.5 \cdot 0.4 \cdot 0.2$

→ VERB
 $q=0.25$

VERB
 $q=0.5 \cdot 0.4 \cdot 0.3$


a

bear

likes

honey

Запоминаем лучшие переходы!




a

bear


likes

honey


Восстановление пути




Восстановление пути




Восстановление пути



Восстановление пути





Восстановление пути



3. Обучение НММ по размеченным и неразмеченным данным

Как обучить модель?



Метод максимума правдоподобия приводит к частотным оценкам вероятностей:

$$a_{ij} = p(s_j | s_i) = \frac{c(s_i \rightarrow s_j)}{c(s_i)}$$

$$b_{ik} = p(o_k | s_i) = \frac{c(s_i \rightarrow o_k)}{c(s_i)}$$

Метод максимума правдоподобия

То же самое немного в других обозначениях:

$$a_{ij} = p(s_j | s_i) = \frac{\sum_{t=1}^T [y_{t-1} = s_i, y_t = s_j]}{\sum_{t=1}^T [y_t = s_i]}$$

Техническая деталь: предложения склеиваются спец. токенами в единый корпус длины T .

А можно ли как-то обучать НММ по неразмеченной выборке (только тексты)?

Алгоритм Баума-Велша (Baum-Welch)

E-step: оценка апостериорных вероятностей на скрытые переменные:

$$p(y_{t-1} = s_i, y_t = s_j)$$

Решается динамическим программированием: алгоритм вперед-назад (forward-backward)

M-step: оценки максимума правдоподобия на параметры:

$$a_{ij} = p(s_j | s_i) = \frac{\sum_{t=1}^T p(y_{t-1} = s_i, y_t = s_j)}{\sum_{t=1}^T p(y_t = s_i)}$$

Резюме по алгоритмам в НММ

Обучение:

- ✓ по размеченным данным: метод максимума правдоподобия (частотные оценки вероятностей)
- по неразмеченным данным: алгоритм Баума-Велша (EM-алгоритм):
 - E-шаг: алгоритм вперед-назад для оценивания апостериорных вероятностей на параметры

Применение:

- ✓ алгоритм Витерби для поиска максимально вероятной последовательности меток


4. Другие графические модели: MEMM, CRF

Hidden Markov Model (HMM)

$$p(\mathbf{y}, \mathbf{x}) = \prod_{t=1}^T p(y_t | y_{t-1}) p(x_t | y_t)$$




Генеративная
модель



Maximum Entropy Markov Model (MEMM)

$$p(\mathbf{y}|\mathbf{x}) = \prod_{t=1}^T p(y_t|y_{t-1}, x_t)$$


Дискриминативная
модель



Maximum Entropy Markov Model (MEMM)

$$p(y_t | y_{t-1}, x_t) = \frac{1}{Z_t(y_{t-1}, x_t)} \exp \left(\sum_{k=1}^K \theta_k f_k(y_t, y_{t-1}, x_t) \right)$$

↑
Нормализация

↑
вес

↑
признак

Maximum Entropy Markov Model (MEMM)

$$p(y_t | y_{t-1}, x_t) = \frac{1}{Z_t(y_{t-1}, x_t)} \exp \left(\sum_{k=1}^K \theta_k f_k(y_t, y_{t-1}, x_t) \right)$$

↑
Нормализация

↑
вес

↑
признак

Conditional Random Field (линейный случай)


$$p(\mathbf{y} | \mathbf{x}) = \frac{1}{Z(x)} \prod_{t=1}^T \exp \left(\sum_{k=1}^K \theta_k f_k(y_t, y_{t-1}, x_t) \right)$$

Conditional Random Field (общий случай)

$$p(\mathbf{y}|\mathbf{x}) = \frac{1}{Z(x)} \prod_{a=1}^A \Psi_a(y_a, x_a)$$

↑
Потенциалы

Неориентированный граф:



Генерация признаков

Удобно использовать следующие типы признаков:

Label-observation:

$$1. f(y_t, y_{t-1}, x_t) = [y_t = y] g_m(x_t)$$

$$2. f(y_t, y_{t-1}, x_t) = [y_t = y][y_{t-1} = y']$$

$$3. f(y_t, y_{t-1}, x_t) = [y_t = y][y_{t-1} = y'] g_m(x_t)$$


Откуда брать функции $g_m(x_t)$?

Примеры таких функций

	$w_t = v$	$\forall v \in$
	part-of-speech tag for w_t is j	\forall tags j
	w_t is in a phrase of syntactic type j	\forall tags j
Capitalized	w_t matches $[A-Z][a-z]^+$	
AllCaps	w_t matches $[A-Z]^+$	
EndsInDot	w_t matches $[\^\.]^+.*\.$	
	w_t matches a dash	
	w_t appears in a list of stop words	
	w_t appears in list of capitals	

Часто достаточно парных взаимодействий


1. $f(y_t, y_{t-1}, x_t) = [y_t = y] g_m(x_t)$
2. $f(y_t, y_{t-1}, x_t) = [y_t = y][y_{t-1} = y']$



Зависимость признаков от всех слов

Будем считать, что текущий вход x_t содержит не только текущее слово w_t , но еще и соседние: w_{t-1} и w_{t+1} .

Или вообще все слова последовательности:



Такой трюк возможен только в дискриминативной модели.

Готовые реализации CRF

CRF++	https://sourceforge.net/projects/crfpp/
MALLET	http://mallet.cs.umass.edu/
GRMM	http://mallet.cs.umass.edu/grmm/
CRFSuite	http://www.chokkan.org/software/crfsuite/
FACTORIE	http://www.factorie.cc

Резюме

Вероятностные графические модели:

- Hidden Markov Models (генеративная, направленная)
- Maximum Entropy Markov Models (дискриминативная, направленная)
- Conditional Random Field (дискриминативная, ненаправленная)

Практика:

- POS: обучение HMM, Витерби (*первая домашка*)
- NER: CRF из готового пакета + генерация фичей...

Или: bi-LSTM (*следующая лекция и вторая домашка*)