


СКРЫТЫЕ МАРКОВСКИЕ МОДЕЛИ


Hidden Markov Models (HMM)

Durbin R., Eddy D., Krogh A., Mitchison G.
Pairwise alignment. Biological sequence
analyses. Probabilistic models of proteins
and nucleic acids. //Cambridge University
Press, Cambridge, UK. 1998. P. 12-45.



ПЛАН (ч.1)

- 2.1. Определение
- 2.2. Графы, связанные с СММ: основной и развернутый
- 2.3. Вероятности и траектории на развернутом графе
- 2.4. Оценка параметров СММ
- 2.5. Пример: сегментация последовательностей
- 2.6. Выводы



2.1. Определение скрытой марковской модели


- А - алфавит
- Q – множество состояний; $Q = \{1, \dots, N\}$
- $\Phi: (\{0\} \cup Q) \times Q \rightarrow [0, 1]$
 - вероятность перехода из i в j ($i > 0$);
 - вероятность старта в состоянии j ($i = 0$).
- $\sigma: Q \times A \rightarrow [0, 1]$ – вероятность порождения символа

$$\sum_{j=1..N} \Phi(i, j) = 1$$

$$\sum_{a \in A} \sigma(i, a) = 1$$

ПРИМЕР (временами фальшивая монета, ВФМ)

- Прямоугольники означают **состояния**
 - Кружки означают результат бросания (**эмиссии**)
 - Стрелки – возможные **переходы** между состояниями
 - Числа около кружков – вероятности эмиссии σ_i
 - Числа около стрелок – вероятности переходов между состояниями φ_{ik}
- Сумма весов исходящих стрелок равна 1
- Сумма весов эмиссии в каждом состоянии равна 1
-
- The diagram illustrates a Hidden Markov Model (HMM) with two states represented by rectangles. State 1 (green) contains two emission symbols: 0 with probability 0.5 and 1 with probability 0.5. State 2 (blue) also contains two emission symbols: 0 with probability 0.9 and 1 with probability 0.1. Transitions between the states are labeled with probabilities: 0.1 for the transition from State 1 to State 2, and 0.2 for the transition from State 2 back to State 1. Self-loops on each state are labeled with 0.9 and 0.8 respectively, indicating the probability of staying in the same state.



Вероятности

- Вероятность порождения слова $v = a_1 \dots a_m$ при условии прохождения по траектории состояний $t = \{q_0=0, q_1, \dots, q_m\}$:

$$P(v|t) = \prod_{i=1..m} \Phi(q_{i-1}, q_i) \cdot \sigma(q_i, a_i)$$


Вероятность порождения слова $v = a_1 \dots a_m$

$$P(v) = \sum_t P(v|t)$$

- * Утв. СММ задает распределение вероятностей на словах данной длины m :


$$\sum_{v - \text{слово длины } m} P(v) = 1$$

Упражнение 4.1. Доказать !!!



Эквивалентные СММ

- СММ H_1 и H_2 называются *эквивалентными*, если они задают одно и то же распределение вероятностей.
- Пример – «раздвоение» состояний



2.2. Графы, связанные с СММ

- Пусть дана СММ $H = \langle A, Q, \Phi, \sigma \rangle$.

- Основной граф.**

- Множество вершин $Q = \{0, 1, \dots, N\}$.
- Множество ребер $E = \{(i, j, a)\}$ - для каждой пары вершин есть $|A|$ ребер, ведущих из i в j ; каждое из ребер помечено своей буквой.
- Вероятности: Каждому ребру (i, j, a) приписана вероятность




$$p(i, j, a) = \Phi(i, j) \cdot \sigma(j, a)$$


* Ребра, имеющие вероятность 0, можно опускать

- Основной граф, как правило, содержит циклы.**




Основной граф, как правило, содержит циклы.






Интерпретации:

- 1) порождение последовательностей
- 2) приписывание вероятностей последовательностям









- Вероятность порождения слова $v = a_1 \dots a_m$
 - при условии прохождения по траектории состояний $t = \{q_0=0, q_1, \dots, q_m\}$:
- $$P(t) = \prod_{i=1}^m \varphi(q_{i-1}, q_i) \cdot \sigma(q_i, a_i)$$

Вероятность порождения слова $v = a_1 \dots a_m$


$$P(v) = \sum \{ P(t) \mid \text{word}(t) = v \}$$



1



**Развернутый граф
– циклов НЕТ.**



2.3. Задачи на развернутом графе Вероятности.

- 1. Найти вероятность данного слова $v = a_1 \dots a_m$.

Решение. Рассмотрим граф $\text{Tr}(H, m, v)$ – редукцию развернутого графа, в котором для каждой тройки (i, j, k) оставлено только ребро (i, j, a_k, k) . Решаем задачу Больцмана для $\text{Tr}(H, m, v)$


$$\text{Время} \sim N^2 \cdot m$$

- 2. Дан набор V слов длины m . Найти суммарную вероятность слов из набора V .

$$\text{Время} \sim N^2 \cdot m \cdot |V|$$

- 3.* Набор слов V длины m задан конечным автоматом с r состояниями. Найти суммарную вероятность слов из набора V .

$$\text{Время} - ?$$




Вероятности

- 3.* Набор слов V длины t задан конечным автоматом с r состояниями. Найти суммарную вероятность слов из набора V .

Время - ?

Пример. Набор V задается профилем
(позиционно-зависимой системой весов).

Напомним: Для любого конечного множества слов можно построить автомат, допускающий это множество и содержащий $\sim L$ состояний, где L – суммарная длина слов (автомат Ахо-Корасик).



Задачи на развернутом графе. Разметка

- Дано слово $v = a_1 \dots a_m$.
- 4. Найти траекторию $t = \{q_0, q_1, \dots, q_m\}$ для которой вероятность $P(v|t)$ максимальна.
 - Решение. Задача Беллмана на графике $\text{Tr}(H, m, v)$.
[Viterby]


Обозначение: **TrMaxGlob(v)**.

$$\text{TrMaxGlob}(v) = \operatorname{argmax}\{t | P(v, t)\}$$

Обозначение: $T(v, k)$ – вершина k -го слоя, через которую проходит траектория $\text{TrMaxGlob}(v)$

$$\text{TrMaxGlob}(v) = \dots = \{0, T(v, 1), \dots, T(v, m)\}$$

**Варианты: все наилучшие траектории, все траектории, которые *ненамного* отличаются от лучшей.



Задачи на развернутом графе

Разметка


- Дано слово $v = a_1 \dots a_m$.
- 5. Для каждой вершины (i, k) найти $P(i, k | v)$ – сумму вероятностей $P(t)$ по всем v -траекториям, проходящим через вершину (i, k) .
 - Решение. Задача о вероятности прохождении через вершину для графа вероятностей $\text{Tr}(H, m, v)$ – вычисление сумм Больцмана для всех вершин [*forward-backward*]

Термин: *апостериорная* вероятность вершины (i, k) .

Обозначение: $B(v, k) = \operatorname{argmax}\{i | P(i, k | v)\}$.


(вершина, имеющая максимальную ап.в. в своем слое).

Обозначение: **TrMaxLoc(v)** =
= $\{0, B(v, 1), \dots, B(v, m)\}$




Немного поиграем

- Привести пример, когда траектория forward-backward имеет нулевую вероятность
- Привести пример, когда траектории Viterby и forward-backward не имеют общих вершин.



Что максимизирует траектория forward-backward ?



Вероятность $Prob(q)$ траектории $q = \{q_0, q_1, \dots, q_T\}$ определяется естественным образом — как произведение вероятностей по траектории.


Пусть $q = \{q_0, q_1, \dots, q_T\}$ и $r = \{r_0, r_1, \dots, r_T\}$ — две траектории. Для простоты считаем, что все траектории имеют одно и то же начальное и конечное состояния.

Пусть $id(q, r)$ — количество позиций x таких, что $q_x = r_x$, $x = 1, \dots, T - 1$. Например, для зелёной и синей траекторий на рисунке количество таких позиций равно 1.

С каждой фиксированной траекторией R можно связать случайную величину $id(q, R)$.

Обозначим $E(R) = \sum_q Prob(q) \cdot id(q, R).$

Говоря неформально, $E(R)$ — это среднее число общих вершин у случайной траектории и заданной траектории R .



2.4. Оценка параметров СММ


- Есть две постановки задачи.

- 1) Обучающая выборка - множество пар $\langle v, t \rangle$ (v – слово, t – траектория).
- 2) Обучающая выборка - множество слов (траектории неизвестны).

В обоих случаях предполагается известными сами модели,

т.е. конечные автоматы описаны, но неизвестны вероятности переходов и вероятности эмиссии букв.

- * В крайнем случае, можно считать, что все переходы допустимы. Это увеличивает множество параметров, а значит и требует увеличения размеров обучающей выборки.




Оценка параметров СММ при известных траекториях

- Используется техника оценки параметров **методом наибольшего правдоподобия.**
- Пусть дан набор независимых наблюдений $\{x^1, \dots, x^n\}$; все x^i - независимые наблюдения.
Пусть вероятность наблюдения x задаются формулой $Prob(x) = P(x|\theta)$, зависящей от параметра θ .

Наша цель:

Найти значение параметра θ , которое «наиболее соответствует» наблюдениям $\{x^1, \dots, x^n\}$;



Метод наибольшего правдоподобия


- Пусть дан набор наблюдений $\{x^1, \dots, x^n\}$;
все x^i – независимые наблюдения.

Пусть вероятность наблюдения x задаются формулой
 $Prob(x) = P(x|\theta)$, зависящей от параметра θ .

Наша цель:

Найти значение параметра θ , которое «наиболее соответствует» наблюдениям $\{x^1, \dots, x^n\}$.

- ИДЕЯ:
- $\theta^* = \operatorname{argmax}_\theta P(x^1 \dots x^n | \theta) = \operatorname{argmax}_\theta \{\sum_j \log P(x^j | \theta)\}$
- Неформально: ищем такой набор параметров, при котором обучающая выборка имеет максимальную вероятность.**




- Можно показать, что при большом количестве наблюдений справедливы оценки
$$a_{kl} = A_{kl} / \sum_l A_{kl}; \quad e_k(b) = E_k(b) / \sum_b E_k(b');$$
 - A_{kl} – наблюденное количество переходов из состояния k в состояние l ;
 - $E_k(b)$ – количество символов b , порожденных в состоянии k .
- * При малых размерах выборки используют технику псевдоотсчетов (= регуляризация), добавляя к наблюденным значениям поправку, связанную с априорной гипотезой о вероятностях.



Если параметры неизвестны...

- Итеративный алгоритм Баума-Велча.
 1. Выберем некоторые наборы параметров СММ (обычно они генерируются случайно).
 2. Найдем для них оптимальные пути во всех представленных примерах
 3. По найденным оптимальным путям определим новые параметры
 4. Перейдем к шагу 2.
- Показано, что алгоритм сходится (отношение правдоподобия растет на каждой итерации)
- Есть опасность нахождения локального, а не глобального экстремума.



Перевычисление параметров по Бауму-Велчу-1

Перелистнем...

- Пусть дана СММ $H = \langle A, Q, \Phi, \sigma \rangle$ с N состояниями и набор слов V_1, \dots, V_R . Положим:
- $F(s, t)$ – это оценка **количество переходов** из состояния s в состояние t (исходя из выборки слов V_1, \dots, V_R . при заданной СММ $H = \langle A, Q, \Phi, \sigma \rangle$);
- $E(s, b)$ – оценка **количество эмиссий** символа b , когда СММ находилась в состоянии s (исходя из выборки слов V_1, \dots, V_R . при заданной СММ $H = \langle A, Q, \Phi, \sigma \rangle$).

Перевычисление параметров по Бауму-Велчу-2


Перелистнем...

- $F(s, t)$ – это оценка **количество переходов** из состояния s в состояние t (исходя из выборки слов v_1, \dots, v_R . при заданной СММ $H = \langle A, Q, \Phi, \sigma \rangle$);
- $E(s, b)$ – оценка **количество эмиссий** символа b , когда СММ находилась в состоянии s (исходя из выборки слов v_1, \dots, v_R . при заданной СММ $H = \langle A, Q, \Phi, \sigma \rangle$).

■ Сведение к оценкам по одному слову:

$$F(s, t) = \sum_{j=1, \dots, R} F_1(s, t, v_j);$$

$$E(s, b) = \sum_{j=1, \dots, R} E_1(s, b, v_j).$$



Перевычисление параметров по Бауму-Велчу-З

Перелистнем...

- **Оценки по одному слову:**

$$F_1(s, t; v) = (1/\Pr(v)) \bullet$$

- $(\sum_{k=0, \dots, m-1} \Pr(v; \pi_k=s, \pi_{k+1}=t))$

$$E_1(s, t; v) = (1/\Pr(v)) \bullet (\sum_{k: x_k=b} \Pr(v; \pi_k=s))$$




Перевычисление параметров по Бауму-Велчу

Перелистнем и это!

- Вероятность


$$\prod_{j=1, \dots, R} \Pr(v_j)$$

не убывает !



2.5. Пример: СЕГМЕНТАЦИЯ ПОСЛЕДОВАТЕЛЬНОСТЕЙ ОБЩАЯ ПОСТАНОВКА ЗАДАЧИ

- Дан текст, в котором перемежаются фрагменты с различными свойствами. Определить границы фрагментов.



СЕГМЕНТАЦИЯ ПОСЛЕДОВАТЕЛЬНОСТЕЙ. Примеры.

- Дан текст, в котором перемежаются фрагменты на двух языках с одинаковым алфавитом. Определить границы фрагментов.
- Дан аминокислотная последовательность трансмембранных белка. Известно, что частоты встречаемости аминокислот в трансмембранных и в растворимых частях белка различаются (аналог разных монет). Определить по последовательности где находятся трансмембранные участки.
- Дана геномная последовательность. Статистические свойства кодирующих областей отличаются от свойств некодирующих областей. Найти кодирующие области.
 - ...
 - ...



ПОДХОД к РЕШЕНИЮ ЗАДАЧИ

- Дано СММ $H = \{A, Q, \Phi, \sigma\}$, причем

$$Q = Q_1 + Q_2 + \dots + Q_k,$$


причем

(*) вероятности перехода между состояниями, лежащими в различных классах Q_j , существенно меньше, чем вероятности переходов внутри одного класса.

Пусть дана символьная последовательность v , предположительно описываемая данной СММ.

Восстановим по v траекторию состояний (одним из двух способов – как $\text{Trmaxglob}(v)$ или $\text{Trmaxloc}(v)$).

В этих траекториях состояния из одного класса будут идти блоками (см. (*)). Это и будет искомая сегментация (разбиение на блоки).




УТОЧНЕНИЕ ГРАНИЦ

- Обычно, классы Q_1, Q_2, \dots, Q_k описывают основные «состояния» процесса (текста).

В то же время, вблизи границ свойства процесса (текста) могут меняться.


Чтобы учесть это, приходится вводить новые состояния модели, что увеличивает ее сложность.


Альтернатива: грубо предсказать положение границ с помощью основной модели, а потом уточнять их локально (например, перебором вариантов максимизируя некоторый критерий).



Пример сегментации. Предсказание кодирующих областей в прокариотах

- Реальная схема НММ для поиска кодирующих областей сложнее. Например, она учитывает неравномерность следования кодонов друг за другом.





Оценка качества сегментации

Посимвольное сравнение

- Дано: тестовая выборка троек вида
 - слово,
 - истинная траектория состояний,
 - восстановленная траектория состояний.


Обозначения:

L – суммарная длина слов

N_{corr} – количество позиций, в которых истинное и восстановленное состояния совпадают

Однородные классы:

$$Q = N_{corr}/L$$



Оценка качества сегментации

Посимвольное сравнение

Неоднородные классы:

Виды позиций:

Positive (P) – редкий, Negative (N) – частый
предсказано реально обозн.кол-ва

P	P	TP
P	N	FP
N	P	FN
N	N	TN

Точность:

Достоверность:

$$\text{Acc}(v) = \text{Num(TP)} / (\text{Num(TP+FN)})$$

$$\text{Conf}(v) = \text{Num(TP)} / (\text{Num(TP+FP)})$$



Оценка качества сегментации Посегментное сравнение

- Дано: тестовая выборка троек вида
 - слово,
 - истинная траектория состояний,
 - восстановленная траектория состояний.
- ***Каждая траектория разбита на сегменты***
- ***Каждому сегменту соответствует класс состояний***



Оценка качества сегментации


Посегментное сравнение

Сопоставление сегментов

Сегмент $[p_1, p_2]$ истинного разбиения **соответствует** сегменту $[q_1, q_2]$ восстановленного разбиения, если длина общей части этих сегментов составляет не менее $r\%$ каждого из сегментов ($r > 50\%$) и им сопоставлен один и тот же класс состояний.

Утв. 1. Если сегмент $[p_1, p_2]$ соответствует сегменту $[q_1, q_2]$, то и сегмент $[q_1, q_2]$ соответствует сегменту $[p_1, p_2]$.

Утв. 2. Каждый сегмент одного разбиения соответствует не более, чем одному сегменту другого разбиения.



Оценка качества сегментации Посегментное сравнение

- Обозначения:

$N_{SegmTrue}$ – общее количество сегментов в истинном разбиении

$N_{SegmAlg}$ – общее количество сегментов в алгоритмическом разбиении

N_{corr} – количество позиций, в которых истинное и восстановленное состояния совпадают


- **Однородные классы:**

Точность:

$$Acc(v) = N_{Corr}/N_{SegmTrue}$$

Достоверность:

$$Conf(v) = N_{Corr}/N_{SegmAlg}$$



Оценка качества сегментации

Посегментное сравнение

- **Неоднородные классы.**

Positive – редкий, Negative – частый (P, N).


предсказано	реально	обозн.кол-ва
P	соответствует P	TP

Точность:

$$\text{Acc}(\nu) = TP / NSegmTrue$$

Достоверность:


$$\text{Conf}(\nu) = TP / NSegmAlg$$



Скрытые марковские модели

Выводы

- 1. СММ – удобный и наиболее общий из используемых сейчас способов задавать вероятности.
- Алгоритмически – это задачи ДП на ациклическом графе (графе траекторий)
- Польза от СММ – точка зрения, которая подсказывает, как подбирать параметры



Задача++ .

- Сформулировать задачу построения оптимального глобального выравнивания на языке скрытых Марковских моделей (СММ).