

Скрытые марковские модели

Сергей Николенко

Machine Learning — CS Club, весна 2008

Outline

1 Скрытые марковские модели: основное

- Марковские цепи
- Возникающие задачи
- Решения задач

2 Специальные виды марковских моделей

- Смеси выпуклых распределений
- Продолжительность состояния

3 Разное

- Авторегрессивные марковские модели
- Критерии оптимизации HMM: ML, MMI, MDI
- Сравнения, начальные значения и недостающие данные

Марковские цепи

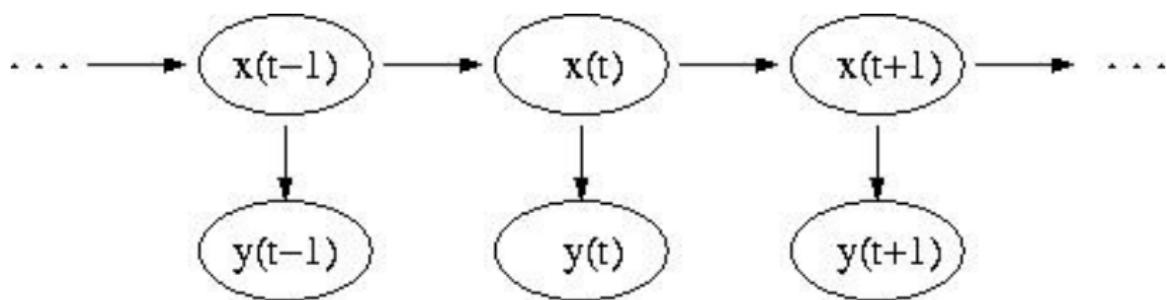
- Марковская цепь задаётся начальным распределением вероятностей $p^0(x)$ и вероятностями перехода $T(x';x)$.
- $T(x';x)$ — это распределение следующего элемента цепи в зависимости от следующего; распределение на $(t+1)$ -м шаге равно

$$p^{t+1}(x') = \int T(x';x)p^t(x)dx.$$

- В дискретном случае $T(x';x)$ — это матрица вероятностей $p(x' = i|x = j)$.

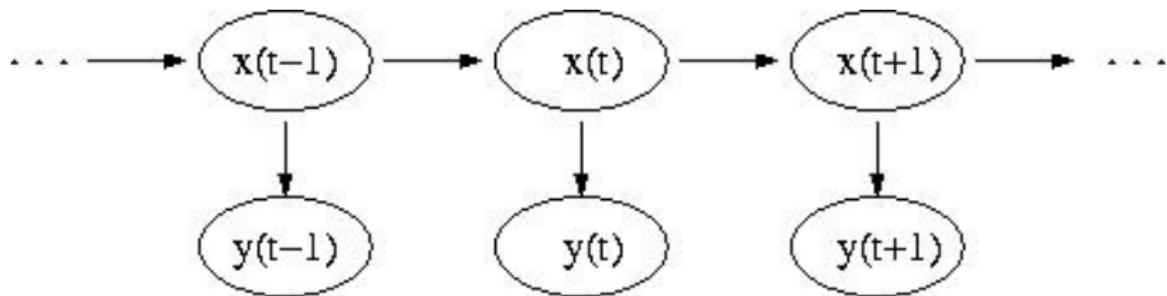
Дискретные марковские цепи

- Мы будем находиться в дискретном случае.
- Марковская модель — это когда мы можем наблюдать какие-то функции от марковского процесса.



Дискретные марковские цепи

- Здесь $x(t)$ — сам процесс (модель), а $y(t)$ — то, что мы наблюдаем.
- Задача — определить скрытые параметры процесса.



Дискретные марковские цепи

- Главное свойство — следующее состояние не зависит от истории, только от предыдущего состояния.

$$\begin{aligned} p(x(t) = x_j | x(t-1) = x_{j_{t-1}}, \dots, x(1) = x_{j_1}) &= \\ &= p(x(t) = x_j | x(t-1) = x_{j_{t-1}}). \end{aligned}$$

- Более того, эти вероятности $a_{ij} = p(x(t) = x_j | x(t-1) = x_i)$ ещё и от времени t не зависят.
- Эти вероятности и составляют матрицу перехода $A = (a_{ij})$.

Вероятности перехода

- Естественные свойства:
- $a_{ij} \geq 0$.
- $\sum_j a_{ij} = 1$.

Прямая задача

- Естественная задача: с какой вероятностью выпадет та или иная последовательность событий?
- Т.е. найти нужно для последовательности $Q = q_{i_1} \dots q_{i_k}$

$$p(Q|\text{модель}) = p(q_{i_1})p(q_{i_2}|q_{i_1}) \dots p(q_{i_k}|q_{i_{k-1}}).$$

- Казалось бы, это тривиально.
- Что же сложного в реальных задачах?

Скрытые марковские модели

- А сложно то, что никто нам не скажет, что модель должна быть именно такой.
- И, кроме того, мы обычно наблюдаем не $x(t)$, т.е. реальные состояния модели, а $y(t)$, т.е. некоторую функцию от них (данные).
- Давайте приведём пример.

Скрытые марковские модели: пример

- Пусть кто-то бросает монетку и сообщает нам результаты — последовательность орлов и решек.
- Но мы не знаем, что он бросает монетку, мы только знаем, что есть вот такая последовательность битов.
- Если мы предположим, что он бросает одну монетку, модель будет одна: два состояния, вероятности перехода между ними p и $1 - p$, вероятности остаться $1 - p$ и p .

Скрытые марковские модели: пример

- Но мы же можем подумать, что у него две монетки! :)
- Тогда состояния по-прежнему два, но параметров больше.
- А если три монетки?..
- В общем, задачи уже ясны.

Задачи скрытых марковских моделей

- Первая: найти вероятность последовательности наблюдений в данной модели.
- Вторая: найти «оптимальную» последовательность состояний при условии данной модели и данной последовательности наблюдений.
- Третья: найти наиболее правдоподобную модель (параметры модели).

Состояния и наблюдаемые

- $X = \{x_1, \dots, x_n\}$ — множество состояний.
- $V = \{v_1, \dots, v_m\}$ — алфавит, из которого мы выбираем наблюдаемые y (множество значений y).
- q_t — состояние во время t , y_t — наблюдаемая во время t .

Распределения

- $a_{ij} = p(q_{t+1} = x_j | q_t = x_i)$ — вероятность перехода из i в j .
- $b_j(k) = p(v_k | x_j)$ — вероятность получить данные v_k в состоянии j .
- Начальное распределение $\pi = \{\pi_j\}$, $\pi_j = p(q_1 = x_j)$.
- Данные будем обозначать через $D = d_1 \dots d_T$
(последовательность наблюдаемых, d_i принимают значения из V).

Комментарий

- Проще говоря, вот как работает HMM (hidden Markov model).
- Выберем начальное состояние x_1 по распределению π .
- По t от 1 до T :
 - Выберем наблюдаемую d_t по распределению $p(v_k|x_j)$.
 - Выберем следующее состояние по распределению $p(q_{t+1} = x_j|q_t = x_i)$.
- Таким алгоритмом можно выбрать случайную последовательность наблюдаемых.

Задачи

- Теперь можно формализовать постановку задач.
- Первая задача: по данной модели $\lambda = (A, B, \pi)$ и последовательности D найти $p(D|\lambda)$. Фактически, это нужно для того, чтобы оценить, насколько хорошо модель подходит к данным.
- Вторая задача: по данной модели λ и последовательности D найти «оптимальную» последовательность состояний $Q = q_1 \dots q_T$. Как и раньше, будет два решения: «побитовое» и общее.
- Третья задача: оптимизировать параметры модели $\lambda = (A, B, \pi)$ так, чтобы максимизировать $p(D|\lambda)$ при данном D (найти модель максимального правдоподобия). Эта задача — главная, в ней и заключается обучение скрытых марковских моделей.

Постановка первой задачи

- Формально, первая задача выглядит так. Нужно найти

$$\begin{aligned} p(D|\lambda) &= \sum_Q p(D|Q, \lambda)p(Q|\lambda) = \\ &= \sum_{q_1, \dots, q_T} b_{q_1}(d_1) \dots b_{q_T}(d_T) \pi_{q_1} a_{q_1 q_2} \dots a_{q_{T-1} q_T}. \end{aligned}$$

- Ничего не напоминает?

Суть решения первой задачи

- Правильно, это такая же задача маргинализации, как мы решаем всё время.
- Мы воспользуемся так называемой forward–backward procedure, по сути — вычислением на решётке, как в декодировании.
- Будем последовательно вычислять промежуточные величины вида

$$\alpha_t(i) = p(d_1 \dots d_t, q_t = x_i | \lambda),$$

т.е. искомые вероятности, но ещё с учётом текущего состояния.

Решение первой задачи

- Инициализируем $\alpha_1(i) = \pi_i b_i(d_1)$.
- Шаг индукции:

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^n \alpha_t(i) a_{ij} \right] b_j(d_{t+1}).$$

- После того как дойдём до шага T , подсчитаем то, что нам нужно:

$$p(D|\lambda) = \sum_{i=1}^n \alpha_T(i).$$

- Фактически, это только прямой проход, обратный нам здесь не понадобился.
- Что вычислял бы обратный проход?

Обратный проход

- Он вычислял бы условные вероятности $\beta_t(i) = p(d_{t+1} \dots d_T | q_t = x_i, \lambda).$
- Их можно вычислить, проинициализировав $\beta_T(i) = 1$, а затем по индукции:

$$\beta_t(i) = \sum_{j=1}^n a_{ij} b_j(d_{t+1}) \beta_{t+1}(j).$$

- Это нам пригодится чуть позже, при решении второй и третьей задачи.

Два варианта второй задачи

- Как мы уже упоминали, возможны два варианта.
- Первый: решать «побитово», отвечая на вопрос «какое наиболее вероятное состояние во время $j?$ ».
- Второй: решать задачу «какая наиболее вероятная последовательность состояний?».

Побитовое решение

- Рассмотрим вспомогательные переменные

$$\gamma_t(i) = p(q_t = x_i | D, \lambda).$$

- Наша задача – найти

$$q_t = \operatorname{argmax}_{1 \leq i \leq n} \gamma_t(i), \quad 1 \leq t \leq T.$$

- Как это сделать?

Побитовое решение

- Выражаем через α и β :

$$\gamma_t(i) = \frac{\alpha_t(i)\beta_t(i)}{p(D|\lambda)} = \frac{\alpha_t(i)\beta_t(i)}{\sum_{i=1}^n \alpha_t(i)\beta_t(i)}.$$

- На знаменатель можно не обращать внимания — нам нужен argmax.

Решение относительно последовательности

- Чтобы ответить на вопрос о наиболее вероятной последовательности, мы будем использовать уже знакомый алгоритм Витерби.
- То есть, по сути, то же самое динамическое программирование.
- Наши вспомогательные переменные — это

$$\delta_t(i) = \max_{q_1, \dots, q_{t-1}} p(q_1 q_2 \dots q_t = x_i, d_1 d_2 \dots d_t | \lambda).$$

Решение относительно последовательности

- Т.е. $\delta_t(i)$ — максимальная вероятность достичь состояния x_i на шаге t среди всех путей с заданными наблюдаемыми.
- По индукции:

$$\delta_{t+1}(j) = \left[\max_i \delta_t(i) a_{ij} \right] b_j(d_{t+1}).$$

- И надо ещё запоминать аргументы, а не только значения; для этого будет массив $\psi_t(j)$.

Решение относительно последовательности: алгоритм

- Проинициализируем $\delta_1(i) = \pi_i b_i(d_1)$, $\psi_1(i) = []$.
- Индукция:

$$\delta_t(j) = \max_{1 \leq i \leq n} [\delta_{t-1}(i) a_{ij}] b_j(d_t),$$

$$\psi_t(j) = \operatorname{argmax}_{1 \leq i \leq n} [\delta_{t-1}(i) a_{ij}].$$

- Когда дойдём до шага T , финальный шаг:

$$p^* = \max_{1 \leq i \leq n} \delta_T(i), \quad q_T^* = \operatorname{argmax}_{1 \leq i \leq n} \delta_T(i).$$

- И вычислим последовательность: $q_t^* = \psi_{t+1}(q_{t+1}^*)$.

Общая суть третьей задачи

- Аналитически найти глобальный максимум $p(D|\lambda)$ у нас никак не получится.
- Зато мы рассмотрим итеративную процедуру (по сути — градиентный подъём), которая приведёт к локальному максимуму.
- Это называется алгоритм Баума–Велха (Baum–Welch algorithm). Он является на самом деле частным случаем алгоритма EM.

Вспомогательные переменные

- Теперь нашими вспомогательными переменными будут вероятности того, что мы во время t в состоянии x_i , а во время $t + 1$ — в состоянии x_j :

$$\xi_t(i, j) = p(q_t = x_i, q_{t+1} = x_j | D, \lambda).$$

- Если переписать через уже знакомые переменные:

$$\xi_t(i, j) = \frac{\alpha_t(i) a_{ij} b_j(d_{t+1}) \beta_{t+1}(j)}{p(D|\lambda)} = \frac{\alpha_t(i) a_{ij} b_j(d_{t+1}) \beta_{t+1}(j)}{\sum_i \sum_j \alpha_t(i) a_{ij} b_j(d_{t+1}) \beta_{t+1}(j)}.$$

- Отметим также, что $\gamma_t(i) = \sum_j \xi_t(i, j)$.

Идея

- $\sum_t \gamma_t(i)$ — это ожидаемое количество переходов из состояния x_i , а $\sum_t \xi_t(i, j)$ — из x_i в x_j .
- Теперь на шаге M мы будем переоценивать вероятности:

$\bar{\pi}_i$ = ожидаемая частота в x_i на шаге 1 = $\gamma_1(i)$,

$$\bar{a}_{ij} = \frac{\text{к-во переходов из } x_i \text{ в } x_j}{\text{к-во переходов из } x_i} = \frac{\sum_t \xi_t(i, j)}{\sum_t \gamma_t(i)}.$$

$$\bar{b}_j(k) = \frac{\text{к-во появлений в } x_i \text{ и наблюдений } v_k}{\text{к-во появлений в } x_i} = \frac{\sum_{t: d_t=v_k} \gamma_t(i)}{\sum_t \gamma_t(i)}.$$

- EM-алгоритм приведёт к цели: начать с $\lambda = (A, B, \pi)$, подсчитать $\bar{\lambda} = (\bar{A}, \bar{B}, \bar{\pi})$, снова пересчитать параметры и т.д.

Расстояние Кульбака–Лейблера

- Kullback–Leibler distance (divergence) — это информационно-теоретическая мера того, насколько далеки распределения друг от друга.

$$D_{KL}(p_1, p_2) = \sum_x p_1(x) \log \frac{p_1(x)}{p_2(x)}.$$

- Известно, что это расстояние всегда неотрицательно, равно нулю iff $p_1 \equiv p_2$.

Применимельно к НММ

- Мы определим

$$p_1(Q) = \frac{p(Q, D|\lambda)}{p(D|\lambda)}, \quad p_2(Q) = \frac{p(Q, D|\lambda')}{p(D|\lambda')}.$$

- Тогда p_1 и p_2 — распределения, и расстояние Kullback–Leibler:

$$\begin{aligned} 0 \leq D_{LK}(\lambda, \lambda') &= \sum_Q \frac{p(Q, D|\lambda)}{p(D|\lambda)} \log \frac{p(Q, D|\lambda)p(D|\lambda')}{p(Q, D|\lambda')p(D|\lambda)} = \\ &= \log \frac{p(D|\lambda')}{p(D|\lambda)} + \sum_Q \frac{p(Q, D|\lambda)}{p(D|\lambda)} \log \frac{p(Q, D|\lambda)}{p(Q, D|\lambda')}. \end{aligned}$$

Вспомогательная функция

- Введём вспомогательную функцию

$$Q(\lambda, \lambda') = \sum_Q p(Q|D, \lambda) \log p(Q|D, \lambda').$$

- Тогда из неравенства следует, что

$$\frac{Q(\lambda, \lambda') - Q(\lambda, \lambda)}{p(D|\lambda)} \leq \log \frac{p(D|\lambda')}{p(D|\lambda)}.$$

- Т.е., если $Q(\lambda, \lambda') > Q(\lambda, \lambda)$, то $p(D|\lambda') > p(D|\lambda)$.
- Т.е., если мы максимизируем $Q(\lambda, \lambda')$ по λ' , мы тем самым будем двигаться в нужную сторону.

Функция Q

- Нужно максимизировать $Q(\lambda, \lambda')$. Перепишем:

$$\begin{aligned} Q(\lambda, \lambda') &= \sum_Q p(Q|D, \lambda) \log p(Q|D, \lambda') = \\ &= \sum_Q p(Q|D, \lambda) \log \pi_{q_1} \prod_t a_{q_{t-1} q_t} b_{q_t}(d_t) = \\ &= \sum_Q p(Q|D, \lambda) \log \pi_{q_1} + \sum_Q p(Q|D, \lambda) \sum_t \log a_{q_{t-1} q_t} b_{q_t}(d_t). \end{aligned}$$

- Последнее выражение легко дифференцировать по a_{ij} , $b_i(k)$ и π_i , добавлять соответствующие множители Лагранжа и решать. Получится именно пересчёт по алгоритму Баума–Велха (проверьте!).

Outline

1 Скрытые марковские модели: основное

- Марковские цепи
- Возникающие задачи
- Решения задач

2 Специальные виды марковских моделей

- Смеси выпуклых распределений
- Продолжительность состояния

3 Разное

- Авторегрессивные марковские модели
- Критерии оптимизации HMM: ML, MMI, MDI
- Сравнения, начальные значения и недостающие данные

Специальные виды моделей

- HMM *эргодична*, если $\forall i, j \ a_{ij} > 0$.
- HMM *ациклична* (left-right model, Bakis model), если $\forall j < i \ a_{ij} = 0$ (матрица треугольная) и $\pi_1 = 1$ (начинаем всегда в состоянии 1).
- В ацикличных сетях ещё часто бывает ограничение на прыжок (constrained jump) размером Δ : $\forall j > i + \Delta \ a_{ij} = 0$ (матрица мультидиагональная).

Непрерывные плотности наблюдаемых

- У нас были дискретные наблюдаемые с вероятностями $B = (b_j(k))$.
- Но в реальной жизни всё сложнее: зачастую мы наблюдаем непрерывные сигналы, а не дискретные величины, и дискретизовать их или плохо, или неудобно.
- При этом саму цепь можно оставить дискретной, т.е. перейти к непрерывным $b_j(D)$.

Специальный вид плотности

- Не для всех плотностей найдены алгоритмы пересчёта (обобщения алгоритма Баума–Велха).
- Наиболее общий результат верен, когда $b_j(D)$ можно представить в виде

$$b_j(D) = \sum_{m=1}^M c_{jm} \mathcal{P}(D, \mu_{jm}, \sigma_{jm}),$$

где c_{jm} — коэффициенты смеси ($\sum_m c_{jm} = 1$), а \mathcal{P} — выпуклое распределение со средним μ и вариацией σ (гауссиан подойдёт).

- К счастью, такой конструкцией можно приблизить любое непрерывное распределение, поэтому это можно широко применять.

Вспомогательные переменные

- $\gamma_t(j, m)$ — вероятность быть в состоянии j во время t , причём за D отвечает m -й компонент смеси.
- Формально говоря,

$$\gamma_t(j, m) = \left[\frac{\alpha_t(j)\beta_t(j)}{\sum_{j=1}^N \alpha_t(j)\beta_t(j)} \right] \left[\frac{c_{jm}\mathcal{P}(d_t, \mu_{jm}, \sigma_{jm})}{\sum_{m=1}^M c_{jm}\mathcal{P}(d_t, \mu_{jm}, \sigma_{jm})} \right].$$

- Если $M = 1$, то это уже известные нам $\gamma_t(j)$.

Алгоритм для этого случая

- Нужно научиться пересчитывать $b_j(D)$, т.е. пересчитывать c_{jm} , μ_{jm} и σ_{jm} .
- Это делается так:

$$\bar{c}_{jm} = \frac{\sum_{t=1}^T \gamma_t(j, m)}{\sum_{t=1}^T \sum_{m=1}^M \gamma_t(j, m)},$$

$$\bar{\mu}_{jm} = \frac{\sum_{t=1}^T \gamma_t(j, m) \cdot d_t}{\sum_{t=1}^T \gamma_t(j, m)},$$

$$\bar{\sigma}_{jm} = \frac{\sum_{t=1}^T \gamma_t(j, m) \cdot (d_t - \bar{\mu}_{jm})(d_t - \bar{\mu}_{jm})^t}{\sum_{t=1}^T \gamma_t(j, m)}.$$

Проблема

- Как моделировать продолжительность нахождения в том или ином состоянии?
- В дискретном случае вероятность пробыть в состоянии i d шагов:

$$p_i(d) = a_{ii}^{d-1}(1 - a_{ii}).$$

- Однако для большинства физических сигналов такое экспоненциальное распределение не соответствует действительности. Мы бы хотели явно задавать плотность пребывания в данном состоянии.
- Т.е. вместо коэффициентов перехода в себя a_{ii} — явное задание распределения $p_i(d)$.

Вспомогательные переменные

- Введём переменные

$\alpha_t(i) = p(d_1 \dots d_t, x_i \text{ заканчивается во время } t | \lambda).$

- Всего за первые t шагов посещено r состояний $q_1 \dots q_r$, и мы там оставались d_1, \dots, d_r . Т.е. ограничения:

$$q_r = x_i, \quad \sum_{s=1}^r d_s = t.$$

Вычисление $\alpha_t(i)$

- Тогда получается

$$\begin{aligned}\alpha_t(i) = & \sum_q \sum_d \pi_{q_1} p_{q_1}(d_1) p(d_1 d_2 \dots d_{d_1} | q_1) \\ & a_{q_1 q_2} p_{q_2}(d_2) p(d_{d_1+1} \dots d_{d_1+d_2} | q_2) \dots \\ & \dots a_{q_{r-1} q_r} p_{q_r}(d_r) p(d_{d_1+\dots+d_{r-1}+1} \dots d_t | q_r).\end{aligned}$$

Вычисление $\alpha_t(i)$

- По индукции

$$\alpha_t(j) = \sum_{i=1}^n \sum_{d=1}^D \alpha_{t-d}(j) a_{ij} p_j(d) \prod_{s=t-d+1}^t b_j(d_s),$$

где D — максимальная остановка в любом из состояний.

- Тогда, как и раньше,

$$p(d|\lambda) = \sum_{i=1}^n \alpha_T(i).$$

Вспомогательные переменные

- Для пересчёта потребуются ещё три переменные:

$\alpha_t^*(i) = p(d_1 \dots d_t, x_i \text{ начинается во время } t+1 | \lambda),$

$\beta_t(i) = p(d_{t+1} \dots d_T | x_i \text{ заканчивается во время } t, \lambda),$

$\beta_t^*(i) = p(d_{t+1} \dots d_T | x_i \text{ начинается во время } t+1, \lambda).$

Вспомогательные переменные

- Соотношения между ними:

$$\alpha_t^*(j) = \sum_{i=1}^n \alpha_t(i) a_{ij},$$

$$\alpha_t(i) = \sum_{d=1}^D \alpha_{t-d}^*(i) p_i(d) \prod_{s=t-d+1}^t b_i(d_s),$$

$$\beta_t(i) = \sum_{j=1}^n a_{ij} \beta_t^*(j),$$

$$\beta_t^*(i) = \sum_{d=1}^D \beta_{t+d}(i) p_i(d) \prod_{s=t+1}^{t+d} b_i(d_s).$$

Формулы пересчёта

- Приведём формулы пересчёта.
- π_i — просто вероятность того, что x_i был первым состоянием:

$$\hat{\pi}_i = \frac{\pi_i \beta_0^*(i)}{p(d|\lambda)}.$$

- a_{ij} — та же формула, что обычно, только вместе с α есть ещё и β , которая говорит, что новое состояние начинается на следующем шаге:

$$\hat{a}_{ij} = \frac{\sum_{t=1}^T \alpha_t(i) a_{ij} \beta_t^*(j)}{\sum_{k=1}^n \sum_{t=1}^T \alpha_t(i) a_{ik} \beta_t^*(k)}.$$

Формулы пересчёта

- $b_i(k)$ — отношение ожидания количества событий $d_t = v_k$ в состоянии x_i к ожиданию количества любого v_j в состоянии x_i :

$$\hat{b}_i(k) = \frac{\sum_{t=1, d_t=v_k}^T (\sum_{\tau < t} \alpha_{\tau}^{*}(i) \beta_{\tau}^{*}(i) - \sum_{\tau < t} \alpha_{\tau}(i) \beta_{\tau}(i))}{\sum_{k=1}^m \sum_{t=1, d_t=v_k}^T (\sum_{\tau < t} \alpha_{\tau}^{*}(i) \beta_{\tau}^{*}(i) - \sum_{\tau < t} \alpha_{\tau}(i) \beta_{\tau}(i))}.$$

- $p_i(d)$ — отношение ожидания количества раз, которые x_i случилось с продолжительностью d , к количеству раз, которые x_i вообще случалось:

$$\hat{p}_i(d) = \frac{\sum_{t=1}^T \alpha_t^{*}(i) p_i(d) \beta_{t+d}(i) \prod_{s=t+1}^{t+d} b_i(d_s)}{\sum_{d=1}^D \sum_{t=1}^T \alpha_t^{*}(i) p_i(d) \beta_{t+d}(i) \prod_{s=t+1}^{t+d} b_i(d_s)}.$$

За и против

- Такой подход очень полезен, когда $p_i(d)$ далеко от экспоненциального.
- Однако он сильно увеличивает вычислительную сложность (в D^2 раз).
- И, кроме того, становится гораздо больше параметров, т.е. нужно, вообще говоря, больше данных, чтобы эти параметры надёжно оценить.

Параметрическая продолжительность состояния

- Чтобы уменьшить количество параметров, можно иногда считать, что $p_i(d)$ — классическое распределение с не слишком большим количеством параметров.
- Например, $p_i(d)$ может быть равномерным, или нормальным ($p_i(d) = \mathcal{N}(d, \mu_i, \sigma_i^2)$), или гамма-распределением:

$$p_i(d) = \frac{\eta_i^{\gamma_i} d^{\gamma_i - 1} e^{-\eta_i d}}{\Gamma(\gamma_i)}.$$

Outline

1 Скрытые марковские модели: основное

- Марковские цепи
- Возникающие задачи
- Решения задач

2 Специальные виды марковских моделей

- Смеси выпуклых распределений
- Продолжительность состояния

3 Разное

- Авторегрессивные марковские модели
- Критерии оптимизации HMM: ML, MMI, MDI
- Сравнения, начальные значения и недостающие данные

Общая идея

- Речь идёт о моделях, в которых следующие компоненты вектора наблюдаемых зависят от предыдущих с некоторыми коэффициентами.
- Т.е. $d = (d_1, \dots, d_K)$ — вектор наблюдаемых, и модель такая:

$$d_k = - \sum_{i=1}^p a_i d_{k-i} + e_k,$$

где e_k — гауссианы с нулевым средним и вариацией σ^2 ,
 a_i — коэффициенты авторегрессии.

Распределение

- Можно показать, что плотность d для больших k стабилизируется на

$$p(d) = (2\pi\sigma^2)^{-K/2} e^{-\frac{1}{2\sigma^2}\delta(d,a)},$$

где (положив $a_0 = 1$)

$$\delta(d,a) = r_a(0)r(0) + 2 \sum_{i=1}^p r_a(i)r(i),$$

$$r_a(i) = \sum_{j=0}^{p-i} a_j a_{j+i}, \quad r(i) = \sum_{j=0}^{K-i-1} d_j d_{j+i}.$$

Комментарий к распределению

- На самом деле $r(i)$ — автокорреляция выборки, а $r_a(i)$ — автокорреляция коэффициентов авторегрессии.
- Автокорреляция — это корреляция процесса с самим собой в предыдущие периоды времени; используется в статистике и обработке сигналов для поиска паттернов в данных.
- По определению, для процесса X_t $R(t, s) = \frac{E[(X_t - \mu)(X_s - \mu)]}{\sigma^2}$, а если процесс стационарный (не зависит от конкретного времени), то

$$R(k) = \frac{E[(X_t - \mu)(X_{t+k} - \mu)]}{\sigma^2}.$$

- В обработке сигналов (а мы в ней) часто используют автокорреляцию без нормализации, т.е. для дискретного сигнала $R(j) = \sum_k x_j x_{j-k}$.

Скрытая марковская модель

- Как применить авторегрессивную модель?
- Очень просто: сначала нормализуем вектор наблюдений:

$$\hat{d} = \frac{d}{\sqrt{K\sigma^2}}, \quad p(\hat{d}) = \left(\frac{2\pi}{K}\right)^{-K/2} e^{-\frac{\kappa}{2}\delta(\hat{d}, a)}.$$

- А затем рассмотрим смесь

$$b_j(D) = \sum_{m=1}^M c_{jm} b_{jm}(D),$$

где b_{jm} задаётся вектором авторегрессии a_{jm} (т.е. его коэффициентами $r_{a_{jm}}$).

Алгоритм пересчёта

- Надо научиться пересчитывать r_{ajm} . Для этого схема такая: сначала научимся пересчитывать r_{jm} , потом из них получим a_{jm} , а потом по ним пересчитаем r_{ajm} .

-

$$\bar{r}_{jm} = \frac{\sum_{t=1}^T \gamma_t(j, m) \cdot r_t}{\sum_{t=1}^T \gamma_t(j, m)},$$

где

$$\gamma_t(j, m) = \left[\frac{\alpha_t(j) \beta_t(j)}{\sum_{j=1}^N \alpha_t(j) \beta_t(j)} \right] \left[\frac{c_{jm} b_{jm}(d_t)}{\sum_{m=1}^M c_{jm} b_{jm}(d_t)} \right].$$

Постановка задачи

- Мы раньше предполагали, что наша марковская модель хорошо описывает процесс.
- На самом деле это не всегда так.
- Давайте попробуем решить более практическую задачу: есть несколько сигналов, и мы должны их описать марковскими моделями так, чтобы как можно точнее отделять их друг от друга.

ML

- Стандартная идея в том, что мы хотим научиться сравнивать модели, т.е. для разных моделей λ_ν , $\nu = 1..V$, научиться оценивать $p(d^\nu | \lambda_\nu)$, а потом выбрать из них максимум.
- Это так называемый ML criterion (от maximum likelihood).

MMI

- Альтернатива — метод максимальной взаимной информации (maximum mutual information, MMI).
- В простейшей ситуации этот метод применяется, чтобы выяснить, какие параметры больше всего влияют на различие заданных классов.
- Если есть данные $x = (x_1, \dots, x_n)$ и набор классов G , по которым их классифицируют, то нужно подсчитать информацию между x_i и классом C :

$$I(x_i, C) = H(C) - H(C|x_i),$$

т.е. максимизировать

$$H(C|x_i) = - \sum_{c \in G} \sum_{v_j} p(c, x_i = v_j) \log p(c|x_i = v_j).$$

MMI

- Для марковских моделей это выражается как максимизация среднего расстояния между данными d и полным набором моделей $\lambda = (\lambda_1, \dots, \lambda_V)$:

$$I_v = \max_{\lambda} \left[\log p(d|\lambda_v) - \log \sum_w p(d^w|\lambda_w) \right],$$

т.е. мы отделяем правильную модель μ от других моделей на последовательности d .

- А теперь можно просуммировать по всем моделям и таким образом надеяться, что получится самый «разделённый» набор:

$$I = \max_{\lambda} \sum_{v=1}^V \left[\log p(d^v|\lambda_v) - \log \sum_w p(d^v|\lambda_w) \right],$$

MDI

- Третий подход: предположим, что сигнал не обязательно марковский, но у него есть некоторые ограничения (на корреляцию, например).
- Надо найти такие параметры, которые минимизируют разделяющую информацию (discrimination information, DI) между набором распределений Q , удовлетворяющих ограничениям, и набором марковских распределений p_λ :

$$D(Q||p_\lambda) = \int q(y) \ln \frac{q(y)}{p(y)} dy.$$

- Т.е. мы предполагаем, что сигнал из Q , и ищем такую λ , чтобы расстояние до соответствующего элемента q было минимальным.
- Тоже по сути модифицированный алгоритм Баума–Велхा.

Как сравнивать HMM?

- Вспомним пример с монеткой и рассмотрим две модели:

$$\lambda_1 = (A_1, B_1, \pi_1), \lambda_2 = (A_2, B_2, \pi_2):$$

$$A_1 = \begin{pmatrix} p & 1-p \\ 1-p & p \end{pmatrix}, B_1 = \begin{pmatrix} q & 1-q \\ 1-q & q \end{pmatrix}, \pi_1 = (1/2 \ 1/2),$$

$$A_2 = \begin{pmatrix} r & 1-r \\ 1-r & r \end{pmatrix}, B_2 = \begin{pmatrix} s & 1-s \\ 1-s & s \end{pmatrix}, \pi_2 = (1/2 \ 1/2),$$

- Чтобы модели производили в среднем одинаковые последовательности наблюдений, нужно, чтобы $E[d_t = v_k | \lambda_1] = E[d_t = v_k | \lambda_2]$, т.е.

$$pq + (1-p)(1-q) = rs + (1-r)(1-s).$$

- Модели с $p = 0.6$, $q = 0.7$ и $r = 0.2$, $s = 13/30$ дадут одинаковые результаты.

Как сравнивать HMM?

- Нужна метрика. Определим расстояние между моделями

$$D(\lambda_1, \lambda_2) = \frac{1}{T} (\log p(d^{(2)} | \lambda_1) - \log p(d^{(2)} | \lambda_2)),$$

где $d^{(2)}$ порождено моделью λ_2 , т.е. мы проверяем, насколько хорошо λ_1 соответствует наблюдениям по модели λ_2 по сравнению с самой λ_2 .

- Это, конечно, несимметричное расстояние, поэтому обычно берут

$$D_s(\lambda_1, \lambda_2) = \frac{D(\lambda_1, \lambda_2) + D(\lambda_2, \lambda_1)}{2}.$$

Начальные значения параметров

- Алгоритм Баума–Велха, по сути своей градиентный, конечно, даёт только локальный максимум.
- Значит, важно, как выбирать начальные значения параметров.
- Для π и A на самом деле особой проблемы нет: обычно хорошо работают или случайные, или равномерные начальные значения.
- Для B хорошие начальные оценки могут быть весьма полезны в дискретном случае и практически необходимы в непрерывном.
- Как их получить?

Начальные значения параметров

- В непрерывном случае у нас распределение было смесью других распределений:

$$b_j(D) = \sum_{m=1}^M c_{jm} \mathcal{P}(D, \mu_{jm}, \sigma_{jm}).$$

- Как бы нам оценить начальные параметры μ_{jm} , σ_{jm} , имея данные всех наблюдений?
- Можно применить кластеризацию. Мы просто кластеризуем данные D (по каждому времени j отдельно) и получим неплохие начальные значения.

Интерполяция

- Данных часто не хватает. Параметров бывает слишком много.
- Один из путей — интерполяция. Выбрать вместе с λ модель поменьше λ' , для которой данных достаточно, и считать интерполированную модель

$$\hat{\lambda} = \epsilon\lambda + (1 - \epsilon)\lambda'.$$

Интерполяция

- Главное — правильно оценить ϵ (это функция количества имеющихся тестовых данных).
- Есть специальные подходы, при которых данные делятся на $\mathcal{D} = \mathcal{D}_1 \cup \mathcal{D}_2$, потом \mathcal{D}_1 используется для тренировки, а \mathcal{D}_2 — для оценки ϵ . Разбиение можно со временем двигать.
- Другой путь — добавлять специальные ограничения (например, $b_j(k) \geq \epsilon$).

Спасибо за внимание!

- Lecture notes и слайды будут появляться на моей homepage:

<http://logic.pdmi.ras.ru/~sergey/index.php?page=teaching>

- Присылайте любые замечания, решения упражнений, новые численные примеры и прочее по адресам:

sergey@logic.pdmi.ras.ru, snikolenko@gmail.com

- Заходите в ЖЖ [smartnik](#).