

DBM

Лобачева Екатерина

2 мая 2012

Постановка задачи



- Вход:

A, B, X – химические элементы

$$F = \left\{ \underbrace{f_1, \dots, f_{32}}_A, \underbrace{f_{33}, \dots, f_{64}}_B, \underbrace{f_{65}, \dots, f_{96}}_X \right\}$$

- Выход: 7 классов

- ✓ 1-5 – определенные структуры
- ✓ 6 – другая структура
- ✓ 7 – не существует


Особенности задачи

- Многоклассовая классификация.
- Плохое признаковое пространство.
- Размеченная выборка ≈ 2000 ,
Неразмеченная ≈ 10000 .

Модель ВМ

Параметры:

$$\theta = \{W, L, J, b^v, b^h\}$$




$$E(v, h | \theta) = -v^T W h - v^T L v - h^T J h - v^T b^v - h^T b^h$$

Модель RBM

Параметры:

$$\theta = \{W, b^v, b^h\}$$



$$E(v, h|\theta) = -v^T W h - v^T b^v - h^T b^h$$

$$p(v, h|\theta) = \frac{1}{Z(\theta)} \exp(-E(v, h|\theta))$$

Вывод в RBM

- Вход:

Параметры модели – W .

- Выход:

Выборка из $p(v, h, W)$.

$$RBM \Rightarrow \begin{cases} p(v_i = 1|h, W) = \frac{1}{1 + \exp\left(-\sum_j W_{ij}h_j\right)} \\ p(h_j = 1|v, W) = \frac{1}{1 + \exp\left(-\sum_i W_{ij}v_i\right)} \end{cases}$$

Схема Гиббса

- Вход: W , начальное приближение v^0 .
- Выход: Выборка $\{v, h\}$ из $p(v, h|W)$.
 1. $h^0 \sim p(h|v^0, W)$;
 2. для $iter = 1 : \#iter$
 3. $v^{iter} \sim p(v|h^{iter-1}, W)$;
 4. $h^{iter} \sim p(h|v^{iter}, W)$;
 5. $v = v^{\#iter}$, $h = h^{\#iter}$.

Обучение RBM

- Вспомним:

$$E(v, h|W) = -v^T W h \quad p(v, h|W) = \frac{1}{Z(W)} \exp(-E(v, h|W))$$

$$p(v|W) = \frac{1}{Z(W)} \sum_h \exp(-E(v, h|W))$$

- Вход: $\hat{V} = \{\hat{v}^1, \dots, \hat{v}^N\}$

- Задача: $p(\hat{V}|W) \rightarrow \max_W$

Экспоненциальное семейство распределений

- Общий вид:

$$p(x|\theta) = \frac{1}{Z(\theta)} f(x) \exp(\theta^T u(x))$$

- Фишка:

$$(\log Z(\theta))' = Eu(x)$$



$$\nabla_{\theta} \log p(\hat{x}|\theta) = u(\hat{x}) - Eu(x)$$

Экспоненциальное семейство распределений

Для выборки $\hat{X} = \{\hat{x}^1, \dots, \hat{x}^N\}$

$$\frac{1}{N} \nabla_{\theta} \log p(\hat{X}|\theta) = E_{data} u(x) - E_{model} u(x),$$

где

$$p_{data}(x) = \frac{1}{N} \sum_{i=1}^N \delta(x - \hat{x}_i)$$

$$p_{model}(x) = p(x|\theta)$$

Экспоненциальное семейство распределений

Аналогично для наблюдаемых x и ненаблюдаемых t :

$$p(x, t | \theta) = \frac{1}{Z(\theta)} f(x, t) \exp(\theta^T u(x, t))$$

$$\frac{1}{N} \nabla_{\theta} \log p(\hat{X} | \theta) = E_{data} u(x, t) - E_{model} u(x, t) ,$$

где $p_{data}(x, t) = \frac{1}{N} \sum_{i=1}^N p(t | \hat{x}_i, \theta) \delta(x - \hat{x}_i)$, $p_{model}(x, t) = p(x, t | \theta)$.

Обучение RBM

$p(v, h|W)$ из экспоненциального семейства



$$\frac{1}{N} \nabla_w \log p(\hat{V}|W) = E_{data}(vh^T) - E_{model}(vh^T)$$

причем

$$E_{data}(vh^T) = \sum_{n=1}^N \hat{v}^n h^{nT}$$

$$\{v_{model}, h_{model}\}: E_{model}(vh^T) = \sum_{m=1}^M v_{model}^m h_{model}^{mT}$$

Алгоритм обучения RBM

• Вход: $\hat{V} = \{\hat{v}^1, \dots, \hat{v}^N\}$

• Выход: W

1. Инициализация W_0 ;

2. для $iter = 1 : \#iter$

3. для $n = 1 : N$

4. $h^n \sim p(h | \hat{v}^n, W_{iter-1})$;

5. $v_{model}^n \sim p(v | h^n, W_{iter-1}), h_{model}^n \sim p(h | v_{model}^n, W_{iter-1})$;

6. $E_{data}(vh^T) = \sum_{n=1}^N \hat{v}^n h^{nT}$;

7. $E_{model}(vh^T) = \sum_{n=1}^N v_{model}^n h_{model}^{nT}$;

8. $W_{iter} = W_{iter-1} + \alpha_{iter} (E_{data}(vh^T) - E_{model}(vh^T))$.


Замечания: RBM

- Увеличение числа шагов по схеме Гиббса при генерации $\{v_{model}, h_{model}\}$ улучшает качество, но увеличивает время. Поэтому лучше увеличивать их число по мере приближения к оптимуму.
- Для оценки статистик лучше брать вероятности $h^n, v_{model}, h_{model}$.
- Чувствителен к подбору параметров обучения $(W_0, \alpha_{iter}, \dots)$.

Модель DBM

Параметры:

$$\theta = \{W^1, W^2\}$$



$$E(v, h^1, h^2 | \theta) = -v^T W^1 h^1 - h^{1T} W^2 h^2$$

$$p(v, h^1, h^2 | \theta) = \frac{1}{Z(\theta)} \exp(-E(v, h^1, h^2 | \theta))$$

Обучение DBM

- Задача: $p(\hat{V}|\theta) \rightarrow \max_{\theta}$

- Аналогично:

$p(v, h^1, h^2|\theta)$ из экспоненциального семейства



$$\frac{1}{N} \nabla_{\theta} \log p(\hat{V}|\theta) = E_{data} u(v, h^1, h^2) - E_{model} u(v, h^1, h^2)$$

$$u(v, h^1, h^2) = \begin{pmatrix} v h^{1T} & h^1 h^{2T} \end{pmatrix}$$

$$p_{data}(v, h^1, h^2) = \frac{1}{N} \sum_{i=1}^N p(h^1, h^2 | \hat{v}_i, \theta) \delta(v - \hat{v}_i),$$

$$p_{model}(v, h^1, h^2) = p(v, h^1, h^2 | \theta).$$

Оценка E_{data}

$p(h^1, h^2 | \hat{v}, \theta)$: Схема Гиббса \longrightarrow Вариационный подход

$$\log p(\hat{v} | \theta) = \underbrace{\int \log \frac{p(\hat{v}, h^1, h^2 | \theta)}{q(h^1, h^2 | \mu^1, \mu^2)} q(h^1, h^2 | \mu^1, \mu^2) dh^1 dh^2}_{L(q)} + KL(q \| p(h^1, h^2 | \hat{v}, \theta))$$

Факторизованное семейство:

$$q(h^1, h^2 | \mu^1, \mu^2) = q(h^1 | \mu^1) q(h^2 | \mu^2) = \prod_j q(h_j^1 | \mu_j^1) \prod_k q(h_k^2 | \mu_k^2)$$

Оценка E_{data}

$$KL(q\|p(h^1, h^2|\hat{v}, \theta)) > 0 \implies L(q) \rightarrow \max_{\mu^1, \mu^2}$$

$$\mu_j^{1n} = \frac{1}{1 + \exp\left(-\sum_i W_{ij}^1 v_j^n - \sum_k W_{jk}^2 \mu_k^{2n}\right)}$$

$$\mu_k^{2n} = \frac{1}{1 + \exp\left(-\sum_j W_{jk}^2 \mu_j^{1n}\right)}$$

$$E_{data}(v h^{1T}) = \sum_{n=1}^N \hat{v}^n \mu^{1nT}$$

$$E_{data}(h^1 h^{2T}) = \sum_{n=1}^N \mu^{1n} \mu^{2nT}$$

Оценка E_{model}

$p(v, h^1, h^2 | \theta)$: Схема Гиббса \longrightarrow Продолжающиеся цепи Гиббса



Инициализируем M цепей: $(v_0^m, h_0^{1m}, h_0^{2m})$

На каждой итерации один шаг по схеме Гиббса:

$$(v_{\text{iter}}^m, h_{\text{iter}}^{1m}, h_{\text{iter}}^{2m})$$

$$E_{\text{model}}(vh^{1T}) = \sum_{m=1}^M v_{\text{iter}}^m h_{\text{iter}}^{1mT} \quad E_{\text{model}}(h^1 h^{2T}) = \sum_{m=1}^M h_{\text{iter}}^{1m} h_{\text{iter}}^{2mT}$$

Предобучение весов



Алгоритм обучения DBM

• Вход: $\hat{V} = \{\hat{v}^1, \dots, \hat{v}^N\}$

• Выход: W^1, W^2

1. Предобучение W^1, W^2

2. Инициализация M цепей Гиббса

3. для $iter = 1 : \#iter$

4. Оценить E_{data} с помощью вариационного подхода

5. Оценить E_{model} с помощью цепей Гиббса

6.
$$W_{iter}^1 = W_{iter-1}^1 + \alpha_{iter} \left(E_{data} \left(v h^{1T} \right) - E_{model} \left(v h^{1T} \right) \right)$$

7.
$$W_{iter}^2 = W_{iter-1}^2 + \alpha_{iter} \left(E_{data} \left(h^1 h^{2T} \right) - E_{model} \left(h^1 h^{2T} \right) \right)$$

Оценка качества обучения

- Задача: $p(\hat{V}|\theta) \rightarrow \max_w$

- Проверяем: $p(\hat{V}|\theta), p(V_{generate}|\theta)$

- Вариационная оценка:

$$\log p(v|\theta) \geq L(q) = \underbrace{-\sum_h q(h|\mu)E(v, h|\theta)}_F + H(q) - \log Z(q)$$

$$L(q) \rightarrow \max_{\mu} \implies F$$

Схема Гиббса для оценки Z

- Даны: $p_A(t) = \frac{\tilde{p}_A(t)}{Z_A}$ $p_B(t) = \frac{\tilde{p}_B(t)}{Z_B}$

- Если они близки:

$$\frac{Z_B}{Z_A} = \frac{\int \tilde{p}_B(t) dt}{Z_A} = \int \frac{\tilde{p}_B(t)}{Z_A} dt = \int \frac{\tilde{p}_B(t)}{\tilde{p}_A(t)} p_A(t) dt \approx \frac{1}{M} \sum_{i=1}^M \frac{\tilde{p}_B(t^m)}{\tilde{p}_A(t^m)}$$

- Иначе:

$$0 = \beta_1 < \beta_2 < \dots < \beta_l = 1 \quad \implies \quad \tilde{p}_l(t) = [\tilde{p}_A(t)]^{1-\beta_l} [\tilde{p}_B(t)]^{\beta_l}$$

$$\frac{Z_B}{Z_A} = \frac{Z_l}{Z_1} = \frac{Z_l}{Z_{l-1}} * \dots * \frac{Z_2}{Z_1}$$

Оценка Z: RBM

$$p_B(v, h|W) = \frac{\exp(-E(v, h|W))}{Z_B(W)} \quad \tilde{p}_B(v, h|W) = \exp(-E(v, h|W))$$

$p_A(v, h|W)$ - равномерное

Выборка из $\tilde{p}_l(v, h|W) = \tilde{p}_B^{\beta_l}(v, h|W)$ по схеме Гиббса:

$$p(h_j = 1|v, W) = \frac{1}{1 + \exp\left(-\sum_i W_{ij} v_i\right)}$$

$$p(v_i = 1|h, W) = \frac{1}{1 + \exp\left(-\sum_j W_{ij} h_j\right)}$$

Оценка Z: DBM

$$p_B(v, h^1, h^2 | \theta) = \frac{\exp(-E(v, h^1, h^2 | \theta))}{Z_B(\theta)} \quad \tilde{p}_B(v, h^1, h^2 | \theta) = \exp(-E(v, h^1, h^2 | \theta))$$

$p_A(v, h^1, h^2 | \theta)$ - равномерное

$$\tilde{p}_B(v, h^2 | \theta) = \sum_{h^1} \exp(-E(v, h^1, h^2 | \theta)) = \prod_j \left(1 + \exp\left(\sum_i W_{ij}^1 v_i + \sum_k W_{jk}^2 h_k^2\right)\right)$$


$$\tilde{p}_l(v_i = 1 | \theta, h^2, v_{\setminus i})$$

$$\tilde{p}_l(h_k^2 = 1 | \theta, h_{\setminus k}^2, v)$$

Эксперименты: RBM и DBM

Порождающая модель:

Обучение



Генерация по схеме Гиббса





Сравнение обучающих и полученных
объектов

Задача

«Линии»

10000 картинок 10^*10



RBM

- Веса лучше всего инициализировать случайными значениями из $N(x|0, \sigma^2)$, где $\sigma^2 \leq 0.1$.
- Примерное время работы при $\dim(v)=100$, $N=10000$, без деления выборки.

dim(h)	1 шаг	ceil(iter/10) шагов
50	160	1809
100	236	2890
200	496	4497

RBM и «ЛИНИИ»

- $\dim(h)=80$, без деления выборки.

Вид	t	p_learn	p_generate
1 шаг	302	6.5173e-009	2.5784e-006
ceil(iter/10) шагов	2167	2.3352e-007	1.7733e-007


- $\dim(h)=80$, с делением выборки.

Вид	t	p_learn	p_generate
1 шаг	236	4.4137e-006	2.4552e-005
ceil(iter/10) шагов	1356	9.5253e-008	6.4714e-005


RBM и «ЛИНИИ»

Без деления выборки:

- 1 шаг:



- $\text{ceil}(\text{iter}/10)$ шагов:



RBM и «ЛИНИИ»

С делением выборки:

- 1 шаг:



- $\text{ceil}(\text{iter}/10)$ шагов:



Химическая задача

- Обучение DBM с непрерывными переменными;
- Оценка значений переменных последнего скрытого слоя;
- Использование переменных последнего скрытого слоя как новых признаков;