

Nonnegative Matrix Factorization with Earth Mover's Distance Metric for Image Analysis

Roman Sandler; Michael Lindenbaum

IEEE Transactions on Pattern Analysis and Machine Intelligence

Year: 2011, Volume: 33, Issue: 8

Pages: 1590 – 1602



本文说还是 NMF 非负矩阵分解，说的是有一个矩阵，其中每一列是一个数据点的 histogram 的特征向量

$$V \in \mathcal{R}^{N \times M},$$



我们要把它分解成两个非负的矩阵的乘积

$$V \approx HW, \quad s.t. \quad W \geq 0, H \geq 0.$$



我们希望分解前后的矩阵能越像越好，所以最小化他们之间的距离

$$\min_{H,W} Dist_{\phi}(V, HW) \quad s.t. \quad W \geq 0, H \geq 0,$$



既然 V 中间都是 histogram，那么最好的距离测度就是 earth mover's distance 了。所以这里用 EMD 替换传统的 L2 norm distance

$$\min_{H,W} EMD(V, HW) \quad s.t. \quad W \geq 0, H \geq 0.$$



什么是 EMD 呢？它是用来算俩 histogram 的距离的

$$(h^s, h^t)$$



俩 histogram，一个 h^s 提供很多 supply bin，一个提供 h^t 很多个 demand bin，从 bin i 到 bin j 需要 $d(i, j)$ 的力气

$$EMD(h^s, h^t) = \min_f \sum_{i,j} f(i, j) d(i, j) \quad s.t. \quad \begin{aligned} f(i, j) &\geq 0, \\ \sum_j f(i, j) &\leq h_i^s, \\ \sum_i f(i, j) &\leq h_j^t, \end{aligned}$$

现在我们把俩 histogram 变成 V 和 (HW) 的 m 列

$$h^s = V_m \quad \text{and} \quad h^t = (HW)_m.$$

$$EMD(V_m, (HW)_m) = \min_f \sum_{i,j} f(i,j)d(i,j)$$

$$\text{s.t. } f_m(i,j) \geq 0,$$

$$\sum_j f_m(i,j) = V(i,m),$$

$$\sum_i f_m(i,j) = \sum_k H(j,k)W(k,m).$$

这说了俩 histogram，那么对于 histogram 组成的矩阵，就是一列一列的 EMD 的和

$$\min_{H,W} \sum_{m=1}^M EMD(V_m, (HW)_m) = \sum_{m=1}^M \min_f \sum_{i,j} f_m(i,j)d(i,j)$$

$$\text{s.t. } W \geq 0, H \geq 0.$$

$$f_m(i,j) \geq 0,$$

$$\sum_j f_m(i,j) = V(i,m),$$

$$\sum_i f_m(i,j) = \sum_k H(j,k)W(k,m).$$

怎么接这个问题呢？还是轮殴

- 先摠住 H，搞 f 和 W

$$\min_{f,W} \sum_m \sum_{i,j} f_m(i,j)d(i,j) \quad \text{s.t. } f_m(i,j) \geq 0,$$

$$\sum_j f_m(i,j) = V(i,m),$$

$$\sum_i f_m(i,j) = \sum_k H(j,k)W(k,m).$$

这个问题还是通过作为一个线性规划的问题解。只不过把变量设定为[f, w]

- 然后摠住 W ，搞 f 和 H

$$\begin{aligned} \min_{f, H} \sum_m \sum_{i, j} f_m(i, j) d(i, j) \quad \text{s.t.} \quad & f_m(i, j) \geq 0, \\ & \sum_j f_m(i, j) = V(i, m), \\ & \sum_i f_m(i, j) = \sum_k H(j, k) W(k, m). \end{aligned}$$

这个问题还是通过作为一个线性规划的问题解。只不过把变量设定为 $[f, H]$

启发：

1. 可以用 graph 来求其流形特征： $\sum_m \text{EMD}(I_m, HW_m) - \sum_{\{m, n\}} \text{EMD}(H_w m, H_w n)$
 A_{mn} , 也就是说，如果在一个 graph 上， $I_n I_m$ 是相邻的 ($A_{mn} > 0$)，那么 $H_w m, H_w n$ 应该也是相邻的， $\text{EMD}(H_w m, H_w n)$ 应该小。
2. 这个问题也可以通过 LP 来解： $f_m(i, j)$ 和 $f_{mn}(i, j)$
3. 另外，如果是用来做分类，那么做 graph 的时候只求 H ，而 w 要单独求。
4. 这篇文章的创新点就是用 EMD 来做 NMF，我们也可以用别的 distance/similarity 来做，比如 Correntropy Criterion。
5. 把 EMD 跟 convolutional 表达结合起来