



电子科技大学

University of Electronic Science and Technology of China



Subspace Clustering: A Brief Overview

Zhong Zhang



Data Mining Lab, Big Data Research Center, UESTC
Email: zhangzhong0512@163.com
<http://dm.uestc.edu.cn/>

Outline

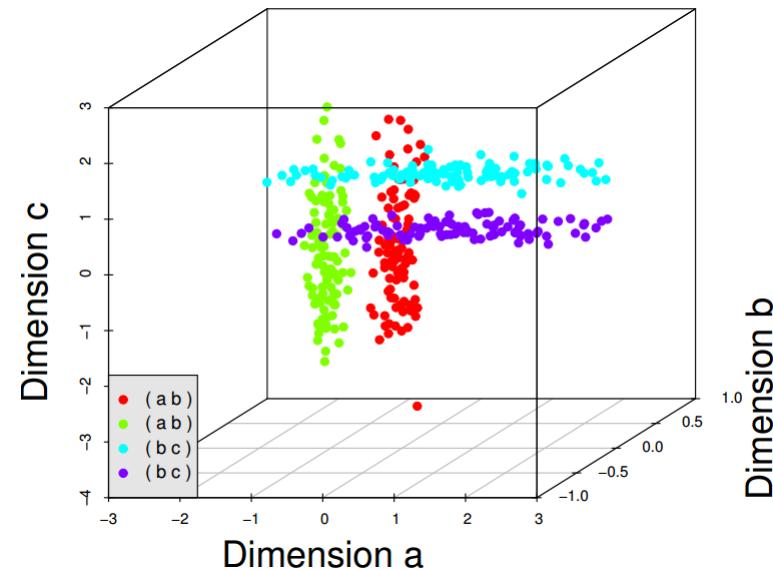
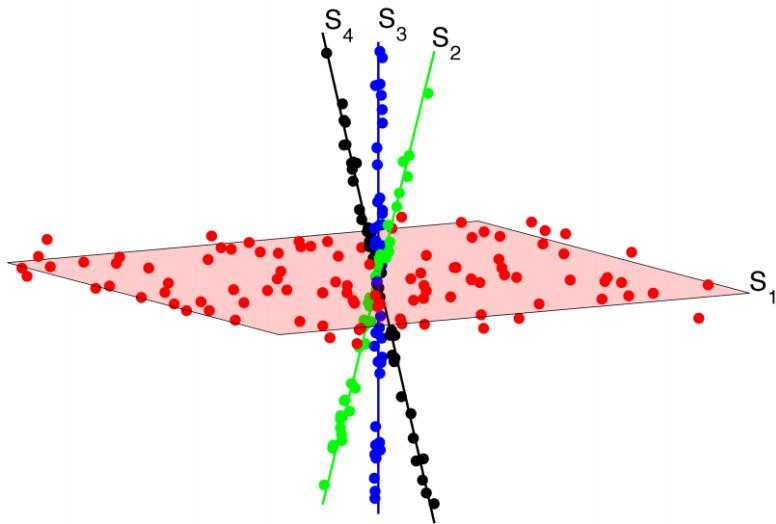


- Motivation and Application
- A Cursory Category
- CLIQUE Algorithm
- Sparse Representation
- Factorization-based methods

Motivation and Application

- What is subspace clustering?

现实中的一些高维数据，不同的属性维度生成机制是不同的，代表了不同的子空间。高维数据则由低维子空间嵌入组合而成。子空间聚类希望能够从高维数据中辨别出子空间，在子空间上实现更好的聚类效果。

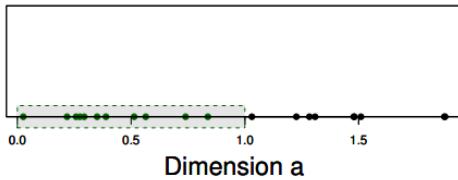


Motivation and Application

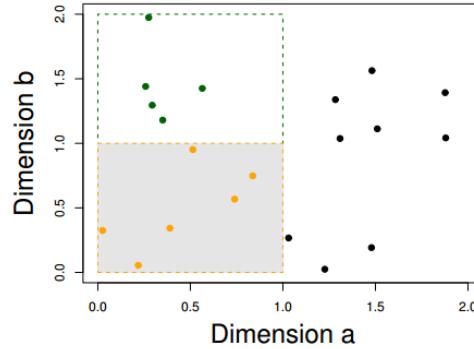


数据挖掘实验室
Data Mining Lab

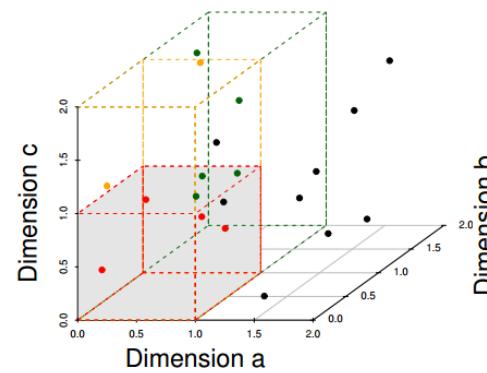
- Why subspace clustering?
 - Noise robust
 - Curse of dimensionality



(a) 11 Objects in One Unit Bin



(b) 6 Objects in One Unit Bin



(c) 4 Objects in One Unit Bin

- Interpretability of results

Motivation and Application



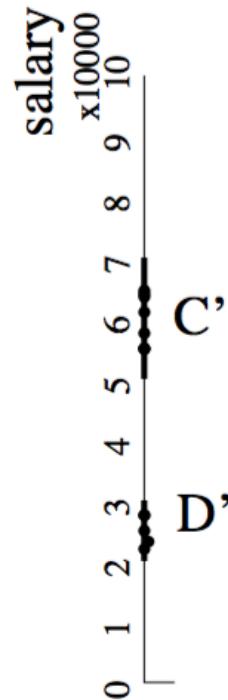
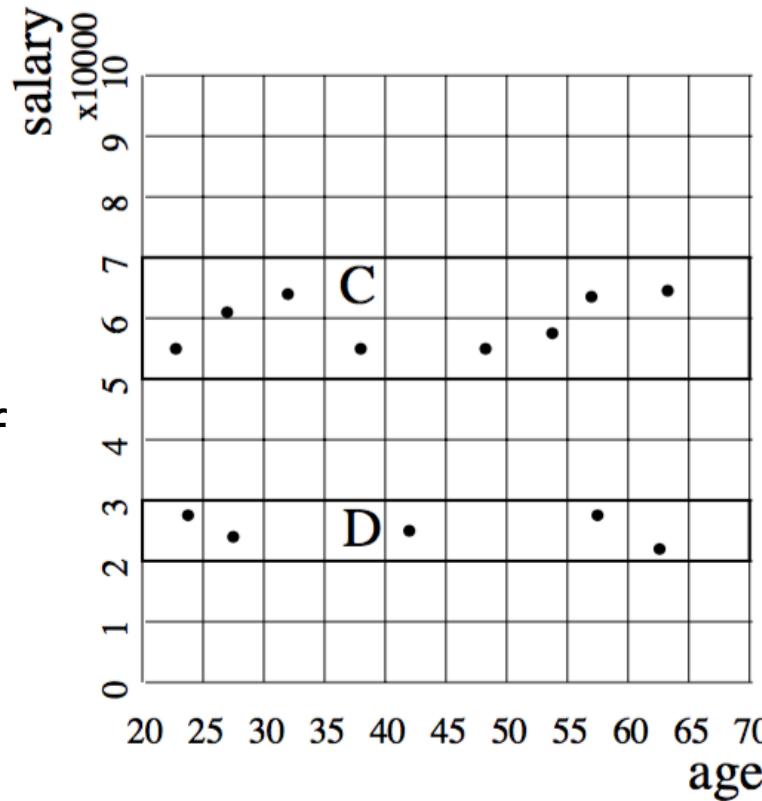
- Application
 - Computer Vision
facial recognition, image segmentation, motion detection...
 - Biological Data
gene clustering, disease classification...
 - Text Categorization
 - Data Fusion and Multi-Source Learning
 - ...

- Existing works on subspace clustering can be divided into seven main categories:
 - **Iterative**: K-subspaces^[1], CLIQUE^[2]
 - **Statistical approaches**: MPPCA^[3], MSL^[4]
 - **Factorization-based methods**
 - **Spectral clustering methods**
 - **Algebraic methods**: GPCA^[5, 6]
 - **Information-theoretic approaches**: ALC^[7]
 - **Sparse representation**

- CLIQUE algorithm combines density and grid based clustering and uses an APRIORI style technique to find clusterable subspaces

No 2-dimensional unit is dense and no clusters in the original data space.

There are three 2-dimensional dense units, two of them are connected.



- CLIQUE consists of the following steps:
 1. Identification of subspace that contain clusters
 2. Identification of clusters
 3. Generation of minimal description for the clusters

1. 找出包含密集的子空间

对n维数据空间进行划分，划分为互不相交的矩形单元，并识别其中的密集单元

空间划分： $A=\{A_1, A_2, \dots, A_d\}$ 是一组有界域， $S=A_1 \times A_2 \times \dots \times A_d$ 是d维空间， A_1, A_2, \dots, A_d 视为 S 的属性。

d维数据点集 $V=\{v_1, v_2, \dots, v_m\}$ ，其中 $v_i=\{v_{i1}, v_{i2}, \dots, v_{id}\}$ ，第j个分量 v_{ij} 是从 A_j 中抽出。

输入参数 ξ ，将空间 S 的每一维分成相同的 ξ 个区间，从而将整个空间划分为有限的 ξ^d 个网格，表示为 $\{u_1, u_2, \dots, u_d\}$ ，其中 $u_i=[l_i, h_i]$ 。

稠密单元：给定稠密阈值 τ ，若一个单元格中点的密度大于阈值，则称该单元是稠密的。

- CLIQUE使用一个“自下而上”类似于Apriori的性质来寻找稠密单元：
如果一个k维单元是密集的，那么他在k-1维空间上的投影也是密集的。
给定一个k维的候选密集单元，如果检查它的k-1维投影单元，发现任何一个不密集的，那么该k维单元也不会是密集的。
算法：首先遍历数据寻找一维密集单元，然后通过使用候选集生成算法从k-1维密集单元得到k维候选密集单元，当没有新的候选集生成时，算法终止。（类似从频繁k-1项集连接成候选频繁k项集，最终得到频繁k项集）

- 使用最小描述长度MDL剪枝

使用类似Apriori的算法可以减少需要验证的密集单元数，但对于高维数据来看，空间维度的增长依然会造成密集单元的飞速增长。CLIQUE使用了一个基于MDL的剪枝策略。

令 $x_{S_j} = \sum_{u_i \in S_j} count(u_i)$ ，其中 $count(u_i)$ 是单元 u_i 中包含点的数目， x_{S_j} 称为子空间 S_j 的覆盖。覆盖大的被选中，剩余的被剪枝。把子空间按照覆盖进行降序排列，我们希望将子空间分成选择集合I和剪枝集合P。

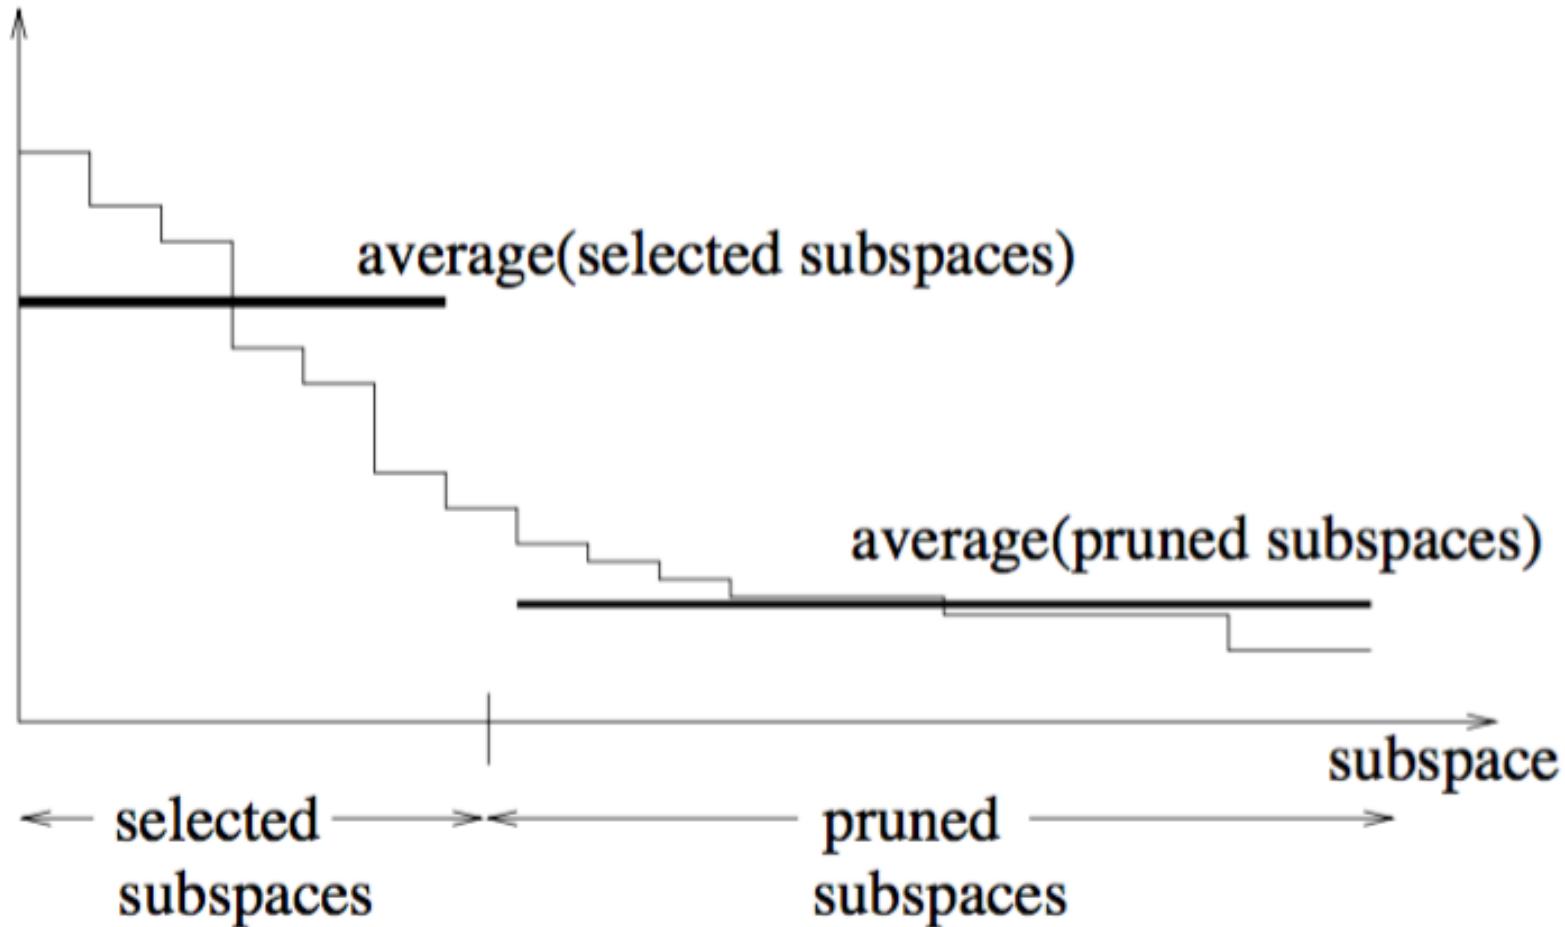
通过让编码长度最小，选择剪枝点i。

$$CL(i) = \log_2(\mu_I(i)) + \sum_{1 \leq j \leq i} \log_2(|x_{S_j} - \mu_I(i)|) + \log_2(\mu_P(i)) + \sum_{i+1 \leq j \leq n} \log_2(|x_{S_j} - \mu_P(i)|)$$

$$\mu_I(i) = \lceil (\sum_{1 \leq j \leq i} x_{S_j}) / i \rceil$$

$$\mu_P(i) = \lceil (\sum_{i+1 \leq j \leq n} x_{S_j}) / (n - i) \rceil$$

coverage



2. 识别聚类

可运用深度优先算法来发现空间中的聚类，算法描述如下：

输入：在同一个k维空间S中的密集单元集合D

输出：D的一个分割D₁，D₂，…，D_q，分割中的密集单元是相互连接的，或者说是连通的，同时没有任何两个不同单元u_i ∈ D_i，u_j ∈ D_j (i ≠ j) 是连接的。

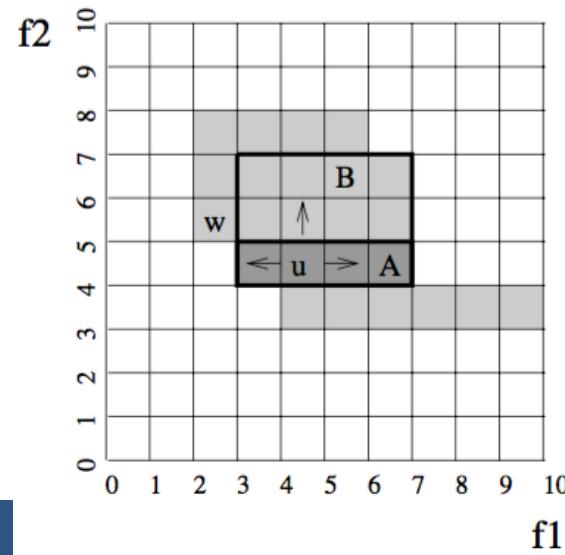
```
dfs(u, n)
u.num = n
for ( j = 1; j < k; j++) do begin
    // examine the left neighbor of u in dimension aj
    ul = {[l1, h1), …, [(ljl), (hjl)], …, [lk, hk]}
    if (ul is dense) and (ul.num is undefined)
        dfs(ul, n)
    // examine the right neighbor of u in dimension aj
    ur = {[l1, h1), …, [(ljr), (hjr)], …, [lk, hk]}
    if (ur is dense) and (ur.num is undefined)
        dfs(ur, n)
end
```

3. 为每个簇生成最小化的描述

CLIQUE使用每个子空间中的稠密单元来装配可能具有任意形状的簇，确定其覆盖相连的密集单元最大区域。其采用了一种简单的贪心方法：

从一个任意稠密单元开始，找出覆盖该单元的最大矩形区域，然后在尚未被覆盖的剩余的稠密单元上继续这一过程。当所有稠密单元都被覆盖时，贪心方法终止。

确定最小的覆盖区域，从已有的最大覆盖中，移走数目最小的多余最大空间区域，直到没有多余的最大密集区域为止。



算法总结：

第1步，根据 ϵ 的值，把原多维空间数据对象的每一维属性划分成相等的区间

第2步， $n=1$ ，经过划分得到的所有矩形单元都为候选稠密单元；

第3步，扫描原数据空间，记录 n 维子空间中落在每个候选稠密单元的数据对象个数；

第4步，根据设置的阈值找出 n 维子空间中的密集单元；

第5步，用MDL算法修剪已有的密集子空间；

第6步，由 n 维子空间中的稠密单元集，找出 $n+1$ 维子空间中的候选稠密单元集合，若 $n+1$ 维子空间中的候选稠密单元集不为空，则跳转到第3步；

第7步，用深度优先探索算法找出 n 维空间中的聚类；

第8步，运用贪婪算法找到覆盖每个子聚类的最大密集；

第9步，确定每个聚类的最小覆盖；

第10步，将聚类信息结果保存到文件中

Algorithm 1 Sparse Subspace Clustering (SSC)

Input: A data set \mathcal{X} arranged as columns of $\mathbf{X} \in \mathbb{R}^{n \times N}$.

1. Solve (the optimization variable is the $N \times N$ matrix \mathbf{Z})

$$\begin{array}{ll}\text{minimize} & \|\mathbf{Z}\|_{\ell_1} \\ \text{subject to} & \mathbf{XZ} = \mathbf{X} \\ & \text{diag}(\mathbf{Z}) = \mathbf{0}.\end{array}$$

2. Form the affinity graph G with nodes representing the N data points and edge weights given by $\mathbf{W} = |\mathbf{Z}| + |\mathbf{Z}|^T$.
3. Sort the eigenvalues $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_N$ of the normalized Laplacian of G in descending order, and set

$$\hat{L} = N - \arg \max_{i=1, \dots, N-1} (\sigma_i - \sigma_{i+1}).$$

4. Apply a spectral clustering technique to the affinity graph using \hat{L} as the estimated number of clusters.

Output: Partition $\mathcal{X}_1, \dots, \mathcal{X}_{\hat{L}}$.

Why does sparse representation recover subspace ?

- Union of disjoint model

Ref: Elhamifar, Ehsan, and Rene Vidal. "Sparse subspace clustering: Algorithm, theory, and applications." *IEEE transactions on pattern analysis and machine intelligence* 35.11 (2013): 2765-2781.

- Independent subspace model

Theorem 1: Consider a collection of data points drawn from n independent subspaces $\{\mathcal{S}_i\}_{i=1}^n$ of dimensions $\{d_i\}_{i=1}^n$. Let \mathbf{Y}_i denote N_i data points in \mathcal{S}_i , where $\text{rank}(\mathbf{Y}_i) = d_i$, and let \mathbf{Y}_{-i} denote data points in all subspaces except \mathcal{S}_i . Then, for every \mathcal{S}_i and every nonzero \mathbf{y} in \mathcal{S}_i , the ℓ_q -minimization program

$$\begin{bmatrix} \mathbf{c}^* \\ \mathbf{c}_-^* \end{bmatrix} = \operatorname{argmin} \left\| \begin{bmatrix} \mathbf{c} \\ \mathbf{c}_- \end{bmatrix} \right\|_q \quad \text{s. t. } \mathbf{y} = [\mathbf{Y}_i \ \mathbf{Y}_{-i}] \begin{bmatrix} \mathbf{c} \\ \mathbf{c}_- \end{bmatrix}, \quad (46)$$

for $q < \infty$, recovers a subspace-sparse representation, i.e., $\mathbf{c}^* \neq \mathbf{0}$ and $\mathbf{c}_-^* = \mathbf{0}$.

Proof:

Assume $c_-^* \neq 0$. Then we can write $\mathbf{y} = \mathbf{Y}_i \mathbf{c}^* + \mathbf{Y}_{-i} \mathbf{c}_-^*$.

Since \mathbf{y} is a data point in subspace S_i , there exists a \mathbf{c} such that $\mathbf{y} = \mathbf{Y}_i \mathbf{c}$

So we get $\mathbf{Y}_i(\mathbf{c} - \mathbf{c}^*) = \mathbf{Y}_{-i} \mathbf{c}_-^*$.

Note that left hand side of equation corresponds to a point in the subspace S_i , while the right hand side is not.

By the independence assumption, the two subspaces S_i and S_{-i} are independent hence disjoint and intersect only at the origin.

Thus, we must have $\mathbf{Y}_{-i} \mathbf{c}_-^* = \mathbf{0}$ and $\mathbf{y} = \mathbf{Y}_i \mathbf{c}^*$, so $[\mathbf{c}^{*\top} \quad \mathbf{0}^\top]^\top$ is a feasible solution.

Finally, assumption $c_-^* \neq 0$ contradicts the solution, thus we must have $c^* \neq 0$ and $c_-^* = 0$

Sparse Representation



稀疏的本质是什么？低秩呢？

近端梯度下降 (Proximal Gradient Descent) 解L1正则化问题

假设我们要求解以下的最小化问题：

$$\min_x f(x)$$

最简单方法：求导用梯度下降！

但由于加入正则项后，导致 x 在某些点不可导，GD没法直接推广，因此需要一些技巧。

如果 $\nabla f(x)$ 满足 L-Lipschitz，即：

$$\|\nabla f(x') - \nabla f(x)\| \leq L\|x' - x\|$$

那么我们可以在点 x_k 附近把 $f(x)$ 通过二阶泰勒近似为：

$$\hat{f}(x, x_k) \doteq f(x_k) + \langle \nabla f(x_k), x - x_k \rangle + \frac{L}{2} \|x - x_k\|^2.$$

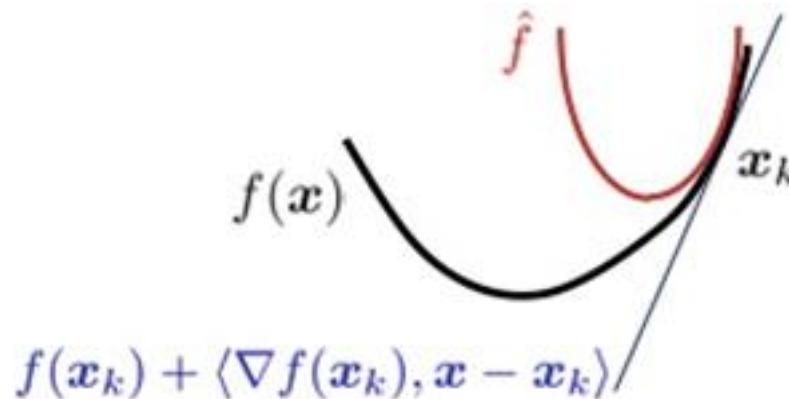
重新排列得到：

$$\begin{aligned}\hat{f}(x, x_k) &\doteq f(x_k) + \langle \nabla f(x_k), x - x_k \rangle + \frac{L}{2} \|x - x_k\|^2 \\ &= \frac{L}{2} \|x - (x_k - \frac{1}{L} \nabla f(x_k))\|_2^2 + \varphi(x_k).\end{aligned}$$

$\varphi(x_k)$ 是与 x 无关的常数可忽略，显然 $\hat{f}(x, x_k)$ 的最小值在

$$x_{k+1} = x_k - \frac{1}{L} \nabla f(x_k)$$

从这个角度看的话，GD的每次迭代是在最小化原目标函数的一个二次近似函数 $\hat{f}(x, x_k)$



在很多最小化问题中，我们往往会加入非光滑的惩罚项 $g(x)$ ，比如常见的 L_1 惩罚： $g(x)=||x||_1$ 。这个时候，GD就不好直接推广了。但上面的二次近似思想却可以推广到这种情况：

$$\begin{aligned} x_{k+1} &= \arg \min_x \hat{F}(x, x_k) \\ &= \arg \min_x \frac{L}{2} \|x - (x_k - \frac{1}{L} \nabla f(x_k))\|_2^2 + g(x) \end{aligned}$$

$$\text{令 } z = (x_k - \frac{1}{L} \nabla f(x_k))$$

则: $\text{prox}_{ug}(z) = \arg \min_x \frac{1}{2} \|x - z\|_2^2 + \mu g(x)$ 。

当 $g(x)=||x||_1$ 时, 易得:

$$\text{prox}_{ug}(z) = \text{sign}(z) \max\{|z| - \mu, 0\}$$

- Overview of NMF

Let $\mathbf{X} \in \mathbb{R}^{M \times N}$, each column represents a data point, each row represents one attribute.

NMF aims to find two non-negative matrix factors:

$$\mathbf{X} \approx \mathbf{U}\mathbf{V}^T$$

Optimization problem:

$$\min_{\mathbf{U}, \mathbf{V}} \|\mathbf{X} - \mathbf{U}\mathbf{V}^T\|_F^2, \text{ s.t. } \mathbf{U} \geq 0, \mathbf{V} \geq 0$$

Factorization-based methods



- Multi-View NMF

Let $\{\mathbf{X}^{(1)}, \mathbf{X}^{(2)}, \dots, \mathbf{X}^{(nv)}\}$ denote the data of all the views, for $\mathbf{X}^{(v)}$ we have factorizations:

$$\mathbf{X}^{(v)} \approx \mathbf{U}^{(v)}(\mathbf{V}^{(v)})^T$$

To learn the joint consensus matrix \mathbf{V}^* , we have objective function:

$$\sum_{v=1}^{n_v} \|\mathbf{X}^{(v)} - \mathbf{U}^{(v)}(\mathbf{V}^{(v)})^T\|_F^2 + \sum_{v=1}^{n_v} \lambda_v \|\mathbf{V}^{(v)} - \mathbf{V}^*\|_F^2$$

$$s.t. \forall 1 \leq k \leq K, \|U_{\cdot,k}^{(v)}\|_1 = 1 \text{ and } \mathbf{U}^{(v)}, \mathbf{V}^{(v)}, \mathbf{V}^* \geq 0$$

Factorization-based methods



- JSNMF1

Objective function:

$$\min_{\mathbf{W}, \mathbf{H}} (1 - \alpha) \|\mathbf{X} - \mathbf{W}\mathbf{H}\|_F^2 + (\alpha) \|\mathbf{Y} - \mathbf{V}\mathbf{H}\|_F^2$$

$$s.t \quad \mathbf{V}, \mathbf{W}, \mathbf{H} \succcurlyeq 0.$$

Solution:

$$\mathbf{W} = \mathbf{W} \odot \frac{\mathbf{X}\mathbf{H}^T}{\mathbf{W}\mathbf{H}\mathbf{H}^T} \quad \mathbf{H} = \mathbf{H} \odot \frac{(1 - \alpha)\mathbf{W}^T\mathbf{X} + (\alpha)\mathbf{V}^T\mathbf{Y}}{((1 - \alpha)\mathbf{W}^T\mathbf{W} + \alpha\mathbf{V}^T\mathbf{V})\mathbf{H}}$$
$$\mathbf{V} = \mathbf{V} \odot \frac{\mathbf{Y}\mathbf{H}^T}{\mathbf{V}\mathbf{H}\mathbf{H}^T}$$

Factorization-based methods



- JSNMF2

$$\mathbf{X} \approx \underbrace{[\mathbf{W} \mid \mathbf{U}]}_{\mathbf{F}} \mathbf{H} = \mathbf{F}\mathbf{H}$$

$$\mathbf{Y} \approx \underbrace{[\mathbf{W} \mid \mathbf{V}]}_{\mathbf{G}} \mathbf{L} = \mathbf{G}\mathbf{L}$$

\mathbf{W} is a $M \times K$ matrix whose columns span the common subspace

\mathbf{U} and \mathbf{V} represent the remaining subspaces having dimension of $M \times (R_1 - K)$ and $M \times (R_2 - K)$ respectively

Objective function:

$$\min D \triangleq \frac{1}{2} \left\{ \|\mathbf{X} - [\mathbf{W} \mid \mathbf{U}]\mathbf{H}\|_F^2 + \lambda \|\mathbf{Y} - [\mathbf{W} \mid \mathbf{V}]\mathbf{L}\|_F^2 \right\}$$

subject to $\mathbf{W}, \mathbf{U}, \mathbf{V}, \mathbf{H}, \mathbf{L} \geq 0$

- JSNMF3

$$W_i = \begin{bmatrix} W_{i,c} & W_{i,d} \end{bmatrix} \quad H_i = \begin{bmatrix} H_{i,c} & H_{i,d} \end{bmatrix}$$

Objective function:

$$\begin{aligned} \min_{W_1, H_1, W_2, H_2 \geq 0} & \frac{1}{n_1} \|X_1 - W_1 H_1^\top\|_F^2 + \frac{1}{n_2} \|X_2 - W_2 H_2^\top\|_F^2 \\ & + \alpha \|W_{1,c} - W_{2,c}\|_F^2 + \beta \|W_{1,d}^\top W_{2,d}\|_{1,1} \end{aligned}$$

subject to $\|(W_1)_{\cdot l}\|_2 = 1, \|(W_2)_{\cdot l}\|_2 = 1$ for $l = 1, \dots, k$.

矩阵分解是用来寻找多个数据源共同子空间的有力工具，常用套路是将矩阵分解为两个基矩阵与系数矩阵的乘积，并且多个数据源共享基矩阵或系数矩阵，再添加相应约束、正则项等。

优点是表示简单，特定情境下分解的矩阵有对应解释，噪声不敏感。

缺点也很明显，求解很困难，涉及矩阵的优化求解，通常难以得到最优解，通常是固定某个变量，再优化另一个变量。