

Sparse coding


d



Recognition



Surveillance



Search and Ranking

Bioinformatics

The curse of dimensionality:

*...increasingly demand inference with **limited samples** for very **high-dimensional data**.*

The blessing of dimensionality:

*... real data highly concentrate on **low-dimensional, sparse, or degenerate structures** in the high-dimensional space.*

But nothing is free: **Gross errors and irrelevant measurements** are now ubiquitous in massive cheap data.

◆ *Sparse representation*

- *Sparse coding*
- *Optimization for sparse coding*
- *Dictionary learning*
- *Recent advances in Computer Vision*


◆ *Sparse methods on matrices*

- *Matrix completion (pLSA, collaborative filtering)*
- *Matrix factorization (topic model, LDA, low-rank)*
- *Some applications*

Sparse coding

欠定线性方程组： $Ax = y$ 有无穷多组解

对解 x 加约束：比如 $\|x\|_0$ (x 中非零元素的个数)尽可能小



即求解如下优化问题：

$$\begin{aligned} \min \quad & \|x\|_0, \\ \text{subject to} \quad & Ax = y. \end{aligned}$$

2003~2004年, Donoho & Elad做了一个很漂亮的证明, 如果矩阵 A 满足: $\sigma(A) \geq 2\|x\|_0$ ($\sigma(A)$ 为最小的线性相关的列向量集所含的向量个数), 上文提及的0范数优化问题具有唯一的解。

2006年, Tao和Donoho的弟子Candes合作证明了在RIP条件下, 0范数优化问题与以下1范数优化问题具有相同的解(凸的):

$$\begin{aligned} \min \quad & \|x\|_1, \\ \text{subject to} \quad & Ax = y. \end{aligned}$$

RIP条件是针对矩阵列向量正交性的一种衡量。

$$(1 - \mu_N)\|x\|_2^2 \leq \|Ax\|_2^2 \leq (1 + \mu_N)\|x\|_2^2 \quad \forall x \quad \|x\|_0 \leq N$$

Sparse coding

进一步可以考虑含噪声情况:可以得到相似的结果

$$\min \|x\|_0 \quad s.t. \quad \|Ax - y\|_2^2 \leq \varepsilon$$

问题表达为:

$$\underbrace{\begin{pmatrix} y \end{pmatrix}}_{y \in \mathbb{R}^m} \approx \underbrace{\begin{pmatrix} \mathbf{d}_1 & | & \mathbf{d}_2 & | & \cdots & | & \mathbf{d}_p \end{pmatrix}}_{\mathbf{D} \in \mathbb{R}^{m \times p}} \underbrace{\begin{pmatrix} \alpha[1] \\ \alpha[2] \\ \vdots \\ \alpha[p] \end{pmatrix}}_{\alpha \in \mathbb{R}^p, \text{ sparse}}$$

Two interpretations:

- **Compressed sensing:** A as sensing matrix
- **Sparse representation:** A as overcomplete dictionary

The Sparse Decomposition Problem

$$\min_{\alpha \in \mathbb{R}^p} \underbrace{\frac{1}{2} \|\mathbf{x} - \mathbf{D}\alpha\|_2^2}_{\text{data fitting term}} + \underbrace{\lambda \psi(\alpha)}_{\text{sparsity-inducing regularization}}$$

ψ induces sparsity in α . It can be

- the ℓ_0 “pseudo-norm”. $\|\alpha\|_0 \triangleq \#\{i \text{ s.t. } \alpha[i] \neq 0\}$ (NP-hard)
- the ℓ_1 norm. $\|\alpha\|_1 \triangleq \sum_{i=1}^p |\alpha[i]|$ (convex)
- ...

This is a **selection** problem.

求解信号稀疏分解的优化问题:

- ① Greedy Algorithms
- ② Homotopy and LARS
- ③ Soft-thresholding based optimization

Optimization for sparse coding — Greedy Algorithms

Matching Pursuit

每次寻找与残差相关性最大的字典原子，
以此原子更新编码和残差。

$$\min_{\alpha \in \mathbb{R}^p} \underbrace{\|\mathbf{x} - \mathbf{D}\alpha\|_2^2}_{\mathbf{r}} \quad \text{s.t.} \quad \|\alpha\|_0 \leq L$$

- 1: $\alpha \leftarrow 0$
- 2: $\mathbf{r} \leftarrow \mathbf{x}$ (residual).
- 3: **while** $\|\alpha\|_0 < L$ **do**
- 4: Select the atom with maximum correlation with the residual

$$\hat{i} \leftarrow \arg \max_{i=1, \dots, p} |\mathbf{d}_i^T \mathbf{r}|$$

- 5: Update the residual and the coefficients

$$\begin{aligned} \alpha[\hat{i}] &\leftarrow \alpha[\hat{i}] + \mathbf{d}_{\hat{i}}^T \mathbf{r} \\ \mathbf{r} &\leftarrow \mathbf{r} - (\mathbf{d}_{\hat{i}}^T \mathbf{r}) \mathbf{d}_{\hat{i}} \end{aligned}$$

- 6: **end while**



Optimization for sparse coding — Greedy Algorithms

Orthogonal Matching Pursuit

每次寻找能够最大地减小目标函数的字典原子加入到编码基元中，并用正交投影更新残差。

$$\min_{\alpha \in \mathbb{R}^p} \|\mathbf{x} - \mathbf{D}\alpha\|_2^2 \quad \text{s.t.} \quad \|\alpha\|_0 \leq L$$

- 1: $\Gamma = \emptyset$.
- 2: **for** $iter = 1, \dots, L$ **do**
- 3: Select the atom which most reduces the objective

$$\hat{i} \leftarrow \arg \min_{i \in \Gamma^c} \left\{ \min_{\alpha'} \|\mathbf{x} - \mathbf{D}_{\Gamma \cup \{i\}} \alpha'\|_2^2 \right\}$$

- 4: Update the active set: $\Gamma \leftarrow \Gamma \cup \{\hat{i}\}$.
- 5: Update the residual (orthogonal projection)

$$\mathbf{r} \leftarrow (\mathbf{I} - \mathbf{D}_\Gamma (\mathbf{D}_\Gamma^T \mathbf{D}_\Gamma)^{-1} \mathbf{D}_\Gamma^T) \mathbf{x}.$$

- 6: Update the coefficients

$$\alpha_\Gamma \leftarrow (\mathbf{D}_\Gamma^T \mathbf{D}_\Gamma)^{-1} \mathbf{D}_\Gamma^T \mathbf{x}.$$

- 7: **end for**



Lasso

Nonsmooth optimization

Directional derivatives and subgradients are useful tools for studying ℓ_1 -decomposition problems:

$$\min_{\alpha \in \mathbb{R}^p} \frac{1}{2} \|\mathbf{x} - \mathbf{D}\alpha\|_2^2 + \lambda \|\alpha\|_1$$

In this tutorial, we use the **directional derivatives** to derive simple optimality conditions of the Lasso.

变为 ℓ_1 norm regularization, 直接求导获得最优条件。

拉格朗日乘子法: 未知拉格朗日乘子 λ

$$\min_{x, \lambda} \frac{1}{2} \|y - Ax\|_2^2 + \lambda \|x\|_1$$

当正则化项有比较nice的性质时, 如piecewise linear, piecewise quadratic, 即objective function是 λ 的分段线性函数, 这时能够比较好的求解。

Optimization for sparse coding – Soft-thresholding

拉格朗日乘子法: 已知拉格朗日乘子 λ , 优化无约束凸优化问题

$$\min_x \frac{1}{2} \|y - Ax\|_2^2 + \lambda \|x\|_1$$

- For this **specific** problem, coordinate descent is **convergent**.
- Supposing $\|\mathbf{d}_i\|_2 = 1$, updating the coordinate i :

$$\begin{aligned} \alpha[i] &\leftarrow \arg \min_{\beta} \frac{1}{2} \left\| \mathbf{x} - \underbrace{\sum_{j \neq i} \alpha[j] \mathbf{d}_j}_{\mathbf{r}} - \beta \mathbf{d}_i \right\|_2^2 + \lambda |\beta| \\ &\leftarrow \text{sign}(\mathbf{d}_i^T \mathbf{r}) (|\mathbf{d}_i^T \mathbf{r}| - \lambda)^+ \end{aligned}$$

未知矩阵A，如何构造A，使得这一字典（矩阵）下的表示最稀疏。即为如下优化问题：

$$\min_{x_i, A} \sum_i \frac{1}{2} \|y_i - Ax_i\|_2^2 + \lambda \|x_i\|_1$$

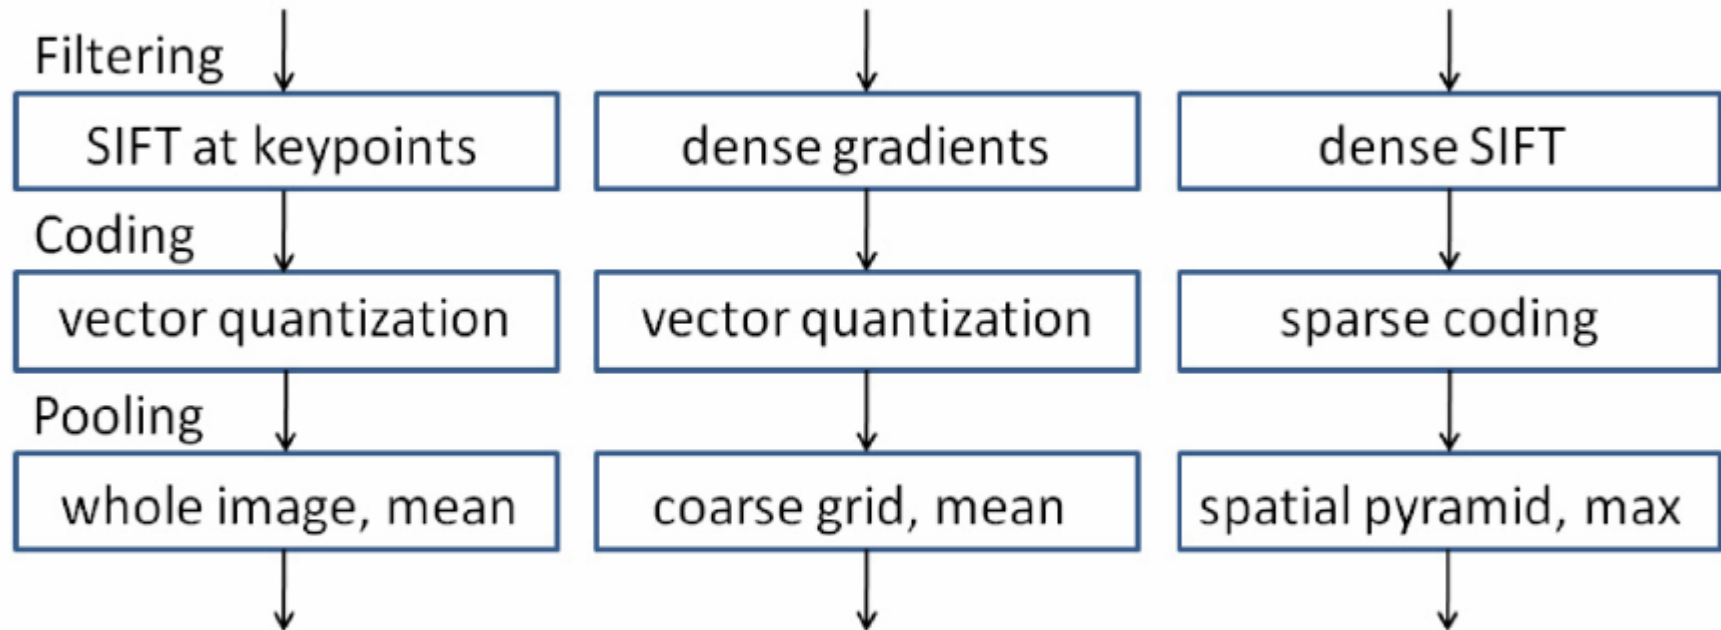
这个优化是非凸的（优化变量相乘）。

block descent (batch): 首先固定A，优化 x_i （相当于多个独立的1范数优化问题）；其次将计算出的 x_i 固定，优化A，这就是一个（可能带约束）的least square问题。如此反复，直到算法收敛到某个（局部）极小值。

$$\begin{cases} \alpha_t \leftarrow \arg \min_{\alpha \in \mathbb{R}^p} \frac{1}{2} \|\mathbf{x}_t - \mathbf{D}_{t-1} \alpha\|_2^2 + \lambda \|\alpha\|_1, \\ \mathbf{D}_t \leftarrow \arg \min_{\mathbf{D} \in \mathcal{C}} \frac{1}{t} \sum_{i=1}^t \left(\frac{1}{2} \|\mathbf{x}_i - \mathbf{D} \alpha_i\|_2^2 + \lambda \|\alpha_i\|_1 \right). \end{cases}$$

Recent advances in Computer Vision

Learning Codebooks for Image Classification



Idea

Replacing Vector Quantization by Learned Dictionaries!

Recent advances in Computer Vision

Learning Codebooks for Image Classification

Let an image be represented by a set of low-level descriptors \mathbf{x}_i at N locations identified with their indices $i = 1, \dots, N$.

- hard-quantization:

$$\mathbf{x}_i \approx \mathbf{D}\alpha_i, \quad \alpha_i \in \{0, 1\}^P \quad \text{and} \quad \sum_{j=1}^P \alpha_i[j] = 1$$

- soft-quantization:


$$\alpha_i[j] = \frac{e^{-\beta\|\mathbf{x}_i - \mathbf{d}_j\|_2^2}}{\sum_{k=1}^P e^{-\beta\|\mathbf{x}_i - \mathbf{d}_k\|_2^2}}$$

- sparse coding:


$$\mathbf{x}_i \approx \mathbf{D}\alpha_i, \quad \alpha_i = \arg \min_{\alpha} \frac{1}{2} \|\mathbf{x}_i - \mathbf{D}\alpha\|_2^2 + \lambda \|\alpha\|_1$$

Recent advances in Computer Vision

图像分类普通的字典和SC学到的字典对比:普通字典包含大量的纹理细节信息,视词内容仍然为低层图像内容;SC字典包含都是边缘线条信息,基向量内容已经变成抽象高层图像特征,这使得稀疏编码后特征的区分能力更强。



普通字典



SC字典

Recent advances in Computer Vision


Learning Codebooks for Image Classification

Table from Boureau et al. [2010]

Method	Caltech-101, 30 training examples		15 Scenes, 100 training examples	
	Average Pool	Max Pool	Average Pool	Max Pool
Results with basic features, SIFT extracted each 8 pixels				
Hard quantization, linear kernel	51.4 ± 0.9 [256]	64.3 ± 0.9 [256]	73.9 ± 0.9 [1024]	80.1 ± 0.6 [1024]
Hard quantization, intersection kernel	64.2 ± 1.0 [256] (1)	64.3 ± 0.9 [256]	80.8 ± 0.4 [256] (1)	80.1 ± 0.6 [1024]
Soft quantization, linear kernel	57.9 ± 1.5 [1024]	69.0 ± 0.8 [256]	75.6 ± 0.5 [1024]	81.4 ± 0.6 [1024]
Soft quantization, intersection kernel	66.1 ± 1.2 [512] (2)	70.6 ± 1.0 [1024]	81.2 ± 0.4 [1024] (2)	83.0 ± 0.7 [1024]
Sparse codes, linear kernel	61.8 ± 1.3 [1024]	71.5 ± 1.1 [1024] (3)	76.9 ± 0.6 [1024]	83.1 ± 0.6 [1024] (3)
Sparse codes, intersection kernel	70.3 ± 1.3 [1024]	71.8 ± 1.0 [1024] (4)	83.2 ± 0.4 [1024]	84.1 ± 0.5 [1024] (4)
Results with macrofeatures and denser SIFT sampling				
Hard quantization, linear kernel	55.6 ± 1.6 [256]	70.9 ± 1.0 [1024]	74.0 ± 0.5 [1024]	80.1 ± 0.5 [1024]
Hard quantization, intersection kernel	68.8 ± 1.4 [512]	70.9 ± 1.0 [1024]	81.0 ± 0.5 [1024]	80.1 ± 0.5 [1024]
Soft quantization, linear kernel	61.6 ± 1.6 [1024]	71.5 ± 1.0 [1024]	76.4 ± 0.7 [1024]	81.5 ± 0.4 [1024]
Soft quantization, intersection kernel	70.1 ± 1.3 [1024]	73.2 ± 1.0 [1024]	81.8 ± 0.4 [1024]	83.0 ± 0.4 [1024]
Sparse codes, linear kernel	65.7 ± 1.4 [1024]	75.1 ± 0.9 [1024]	78.2 ± 0.7 [1024]	83.6 ± 0.4 [1024]
Sparse codes, intersection kernel	73.7 ± 1.3 [1024]	75.7 ± 1.1 [1024]	83.5 ± 0.4 [1024]	84.3 ± 0.5 [1024]


Structured sparsity

- 由于稀疏字典的过完备性，冗余基的存在使稀疏解不唯一，相似特征可能被量化的不同的子空间中，出现相似特征的输出编码一致性问题。



Structured sparsity

- 字典原子杂乱，无序，不利于编码的分析处理和字典的扩展




Structured sparsity

- 结构稀疏性对字典作出约束，使其符合一定的规范
- 学习过程中使字典原子嵌入的预先指定的结构中，比如分组稀疏，树结构稀疏等
- 相似图像具有相似的稀疏模式

Structured sparsity

树结构等级字典，对任何输入信号 x 的稀疏编码中，非零系数的父节点总是非零的，而零系数的所有支节点都是零。

低频特征更靠近根节点
高频特征更接近叶子节点



◆ *Sparse representation*

- *Sparse coding*
- *Optimization for sparse coding*
- *Dictionary learning for signal reconstruction*
- *Recent advances in Computer Vision*

◆ *Sparse methods on matrices*

- *Matrix completion (pLSA, collaborative filtering)*
- *Matrix factorization (topic model, LDA, low-rank)*
- *Some applications*

➤在很多的具体问题中，信号或者数据往往可以用矩阵来表示，使得对数据的理解、建模、处理和分析更为方便。然而这些数据经常面临缺失、损坏、受噪声污染等等问题。如何在各种情况下得到干净、准确、结构性良好的数据，就是矩阵重建所要解决的问题。

➤大致来讲，矩阵重建分为矩阵填充（Matrix Completion）和矩阵恢复（Matrix Recovery）两大类。前者主要研究如何在数据不完整的情况下将缺失数据进行填充，后者主要研究在某些数据受到严重损坏的情况下恢复出准确的矩阵。

矩阵填充 (Matrix Completion) 考虑的是这样一个问题，对于某个矩阵，我们只能采样得到矩阵的一部分元素，其它一部分或者大部分元素由于各种原因丢失了或无法得到，如何将这些空缺的元素合理准确地填充。即求解如下优化问题：

$$\begin{aligned} \min \quad & \text{rank}(X), \\ \text{subject to} \quad & X_{ij} = M_{ij}, (i, j) \in \Omega, \end{aligned}$$

这个模型的意义是说，将空缺的元素填充之后使得矩阵的结构尽可能好，即秩尽可能低。然而不幸的是，这是一个NP-Hard的问题，在理论和实践中，均只存在指数复杂度（相对于矩阵维数 n ）的算法

我们知道，一个矩阵的秩 r 与它的非零奇异值的个数相同。于是有一个选择是用矩阵的奇异值的和，即核范数，来近似地替代矩阵的秩：

$$\begin{aligned} \min \quad & \|X\|_*, \\ \text{subject to} \quad & X_{ij} = M_{ij}, (i, j) \in \Omega, \end{aligned}$$

由于核范数是凸的而零范数并非数学意义上的范数，于是原来的问题就转化为一个凸优化问题，但它仍然是一个比较难计算的问题，可以考虑通过各种迭代法，尤其是梯度法进行求解。关于这种近似理论上的可靠性，有一些相关证明。

Matrix completion

Algorithm	表达	备注
Singular Value Thresholding	$\min \quad \tau \ X\ _* + \frac{1}{2} \ X\ _F^2,$ $\text{subject to } P_\Omega(X) = P_\Omega(M),$	求解原问题的近似问题
Accelerated Proximal Gradient	$\min \quad F(X) = \frac{1}{2} \ P_\Omega(X - M)\ _F^2 + \mu \ X\ _*.$	无约束优化问题
ALM	$\min \quad \ A\ _*,$ $\text{subject to } A + E = D, P_\Omega(E) = 0.$	部分增广拉格朗日函数
.....

Matrix factorization

矩阵恢复是指当矩阵的某些元素被严重破坏后，自动识别出被破坏的元素，恢复出原矩阵。同样，假定原矩阵有非常良好的结构，即是低秩的；另外，假定只有很少一部分元素被严重破坏，即噪声是稀疏的但大小可以任意。于是矩阵恢复可用如下优化问题来描述：

$$\begin{aligned} \min \quad & \text{rank}(A) + \lambda \|E\|_0, \\ \text{subject to} \quad & A + E = D, \end{aligned}$$

用矩阵的核范数近似秩，矩阵的1范数来近似零范数，转化为凸优化问题：

$$\begin{aligned} \min \quad & \|A\|_* + \lambda \|E\|_1, \\ \text{subject to} \quad & A + E = D. \end{aligned}$$

Matrix factorization

Algorithm	表达	备注
Iterative Thresholding	$\min_{A,E} \ A\ _* + \lambda \ E\ _1 + \frac{1}{2\tau} \ A\ _F^2 + \frac{1}{2\tau} \ E\ _F^2,$ subject to $A + E = D,$	此问题的解近似于原问题
Accelerated Proximal Gradient	$\min F(A, E) = \frac{1}{2} \ D - A - E\ _F^2 + \mu(\ A\ _* + \lambda\ E\ _1).$	无约束优化问题
ALM	$L(A, E, Y, \mu) = \ A\ _* + \lambda\ E\ _1 + \langle Y, D - A - E \rangle + \frac{\mu}{2} \ D - A - E\ _F^2.$	部分增广拉格朗日函数
.....

Some applications

- ▶ 矩阵填充的一个著名应用是Netflix推荐系统。Netflix是世界上最大的在线影片租赁服务商，从2006年10月份开始举办Netflix大奖赛。它公开了大约一亿个1~5级的匿名电影评级，来自大约48万个客户对1.8万部电影的评价，比赛要求参赛者预测Netflix客户分别喜欢什么影片。
- ▶ 这是一个典型的矩阵填充问题，即矩阵的每一行对应某个用户对电影的评级，每一列表示某电影在所有用户中的评级，但是每个用户只可能对一部分电影进行评价，所以我们可以通过矩阵填充得出用户对每部电影的喜好程度。
- ▶ 假设现在有 m 个用户和 n 部电影，如果把所有评分列成一张大表，可以得到矩阵 $D \in R^{m \times n}$ 。

Some applications

➤ 评级矩阵。

	★	★★		★★
	★★★		??	
	★★★		★	★

$$D \in \mathbb{R}^{m \times n}$$

movies

	2	1			4			5		
	5	4				?		1	3	
		3		5		2				
4		?			5		3		?	
		4		1 3				5		
		2				1	?		4	
	1				5		5		4	
		2		?	5		?	4		
	3		3		1		5	2	1	
	3				1			2	3	
	4			5 1				3		
		3				3	?		5	
2	?		1		1					
		5			2	?		4	4	
	1		3		1	5		4	5	
1		2			4				5	?

users

Some applications

➤由AT&T实验室成员组成的BellKors Pragmatic Chaos提出的 collaborative filtering 算法比较有效的解决了上述问题，并赢得了100万美元。表示为数学形式即为矩阵填充问题：

$$\begin{aligned} \min \quad & \|X\|_*, \\ \text{subject to} \quad & X_{ij} = M_{ij}, (i, j) \in \Omega, \end{aligned}$$

➤解释起来就是，存在一个latent factor空间，不同的用户群体位于这个latent factor空间的不同位置，体现了不同用户的喜好。如果可以把用户喜好连同潜在的latent factor一同计算出来，预测也自然水到渠成了。从某种角度来看，奇异值分解过程也就是上述的剥离latent factor和用户喜好的过程。



Singular Value Decomposition

- ▶ For an arbitrary matrix X there exists a factorization (Singular Value Decomposition = **SVD**) as follows:

$$X = U \Sigma V^T \in \mathcal{R}^{n \times m}$$

- ▶ Where

- (i) $U \in \mathcal{R}^{n \times k}$ $\Sigma \in \mathcal{R}^{k \times k}$ $V \in \mathcal{R}^{m \times k}$

- (ii) $U'U = I$ $V'V = I$

Orthonormal
columns

- (iii) $\Sigma = \text{diag}(\sigma_1, \dots, \sigma_k)$, $\sigma_i \geq \sigma_{i+1}$

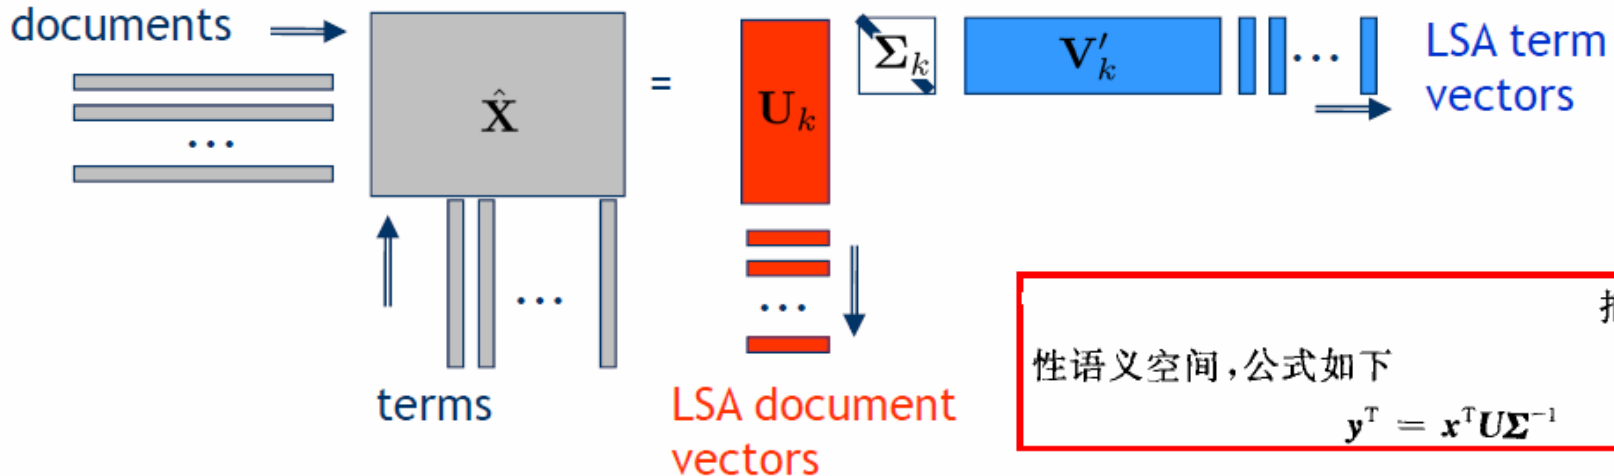
Singular
values
(ordered)

- (iv) $k = \text{rank}(X)$

Some applications

Latent Semantic Analysis (Indexing)

▶ The LSA via SVD can be summarized as follows:



把文档变换到隐性语义空间,公式如下

$$y^T = x^T U \Sigma^{-1}$$

▶ Document **similarity**

$$\langle ||, || \rangle$$

▶ Folding-in **queries**

$$\hat{q} = \Sigma_k^{-1} V_k q$$

Some applications

Index Words	Titles								
	T1	T2	T3	T4	T5	T6	T7	T8	T9
book			1	1					
dads						1			1
dummies		1						1	
estate							1		1
guide	1					1			
investing	1	1	1	1	1	1	1	1	1
market	1		1						
real							1		1
rich						2			1
stock	1		1						1
value				1	1				


SVD

book	0.15	-0.27	0.04
dads	0.24	0.38	-0.09
dummies	0.13	-0.17	0.07
estate	0.18	0.19	0.45
guide	0.22	0.09	-0.46
investing	0.74	-0.21	0.21
market	0.18	-0.30	-0.28
real	0.18	0.19	0.45
rich	0.36	0.59	-0.34
stock	0.25	-0.42	-0.28
value	0.12	-0.14	0.23

3.91	0	0
0	2.61	0
0	0	2.00

	T1	T2	T3	T4	T5	T6	T7	T8	T9
0.35	0.22	0.34	0.26	0.22	0.49	0.28	0.29	0.44	
-0.32	-0.15	-0.46	-0.24	-0.14	0.55	0.07	-0.31	0.44	
-0.41	0.14	-0.16	0.25	0.22	-0.51	0.55	0.00	0.34	

- 左奇异矩阵表示给定主题下的词项概率分布，右奇异矩阵表示给定主题下文档的概率分布。
- 这样将文档和词都转化到了主题空间，即实现了降维，有利于进一步的聚类、相似查询等操作。




Some applications

LSA不是概率生成模型，LSA以最优低秩逼近为优化的目标，而pLSA以观测值的似然值为优化目标。pLSA是LSA的概率扩展。

Documents


Terms



$$\hat{P}_{\text{ML}}(w|d) = \frac{n(d, w)}{\sum_{w'} n(d, w')}$$

Documents

Terms




$$\hat{P}_{\text{pLSA}}(w|d) = \sum_z P(w|z; \theta) P(z|d; \pi)$$


Extension 2: Topic Models for Images



“beach”



Latent Dirichlet Allocation (LDA)




Some applications

由矩阵填充还可以用于视频去噪。根据某一像素值是否背离同一位置处所有像素的“均值”判定该点是否可靠，进而用矩阵填充来得到那些被噪声污染的像素。



Robust recovery: Given $y = Lx_0 + e_0$, $L \in \mathbb{R}^{m \times n}$, $m \ll n$, recover x_0 .





Some applications — Background modeling from video

Static camera
surveillance video



200 frames,
72 x 88 pixels,

Significant foreground
motion


Video D



Low-rank appx. A




Sparse error E




APPLICATIONS – 2D image matching and 3D modeling

D




$\tau \in 2D$ homographies


$D \circ \tau$



A



E



Some applications — Document analysis

- Web document corpus analysis [Min et al.]

$$\min \|A\|_* + \lambda \|E\|_1 \text{ subj } D = A + E, E \geq 0.$$

- D: tf-idf matrix, 42186 x 18320, 90.3h on an HPC cluster

Terms in Matrix A

中国	旅游	新华	网	月
日	电	记者	最	国家
至	年	达	将	目前
增加	要	世界	使	海
间	航线	计划	条	发展
并	说	已	公司	开通

Terms in Matrix E

韩国	韩	中韩	航空	年内
南方	协议	博览会	网络	加强
完善	客运			

ID:

新华网上海3月30日电(记者冯亦珍)大韩航空公司在30日开幕的上海世界旅游资源博览会上表示,大韩航空非常重视中国市场,计划在5年内,使大韩航空的中国航线增加到50条,并计划开发中国旅客经韩国中转至美国的业务。

大韩航空上海支店副总经理金昌洙说,大韩航空的业绩持续稳步增长,与在中国地区的业务发展密不可分。大韩航空自1989年开通到中国的航线,截至目前已在中国的21个城市开通了30条航线,每周运营的航班最多时达126班,其中往返于上海与韩国之间的航线达4条,每周共计70个航班,平均载客率达78%。大韩航空公司还与中国的国际航空、东方航空、南方航空、上海航空公司开展代码共享合作,进一步加强了在中国市场的竞争力。

金昌洙表示,中韩的航空会谈即将举行。届时,

THE BIG PICTURE – Connection between rank and sparsity

	<i>Sparse Vector</i>	<i>Low-Rank Matrix</i>
Degeneracy of	individual signal	a batch of signals
Measure	L0 norm	Rank
Convex Surrogate	L1 norm	Nuclear norm
Compressed Sensing	$y = Ax$	$Y = A(X)$
Error Correction	$y = Ax + e$	$Y = A(X) + E$
Sparsity-Rank Tradeoff	$Y = A(X) + B(E) + Z$	

References

- [1] Emmanuel Candes, Justin Romberg, and Terence Tao. Stable Signal Recovery from Incomplete and Inaccurate Measurements. Communications on Pure and Applied Mathematics. 2006.
- [2] http://www.di.ens.fr/~mairal/tutorial_iccv09/
- [3] <http://perception.csl.uiuc.edu/matrix-rank/home.html>
- [4] <http://www.cvpr2009.org/call-for-short-courses>
- [5] <http://www.cnblogs.com/LeftNotEasy/archive/2011/01/19/svd-and-applications.html>
- [6] Deng Cai. Learning with Local Consistency. Chinese Workshop on Machine Learning and Applications. 2010.
- [7] <http://www.cvchina.info/2010/06/01/sparse-representation-vector-matrix-tensor-1/>
- [8] http://www.cvchina.info/2010/07/13/sparse_representation_vector_matrix_tensor2/