

LLE & Isomap Tutorial

Machine Learning for Graphics, Vision and Multimedia, 2006

Communication and Multimedia Laboratory

CSIE, National Taiwan University

1. Dimensionality Reduction	2
2. MDS	3
3. Isomap	4
4. LLE	5
5. Isomap & LLE Applications	8
6. References	11

許平 vivace@cmlab.csie.ntu.edu.tw

謝昌熹 isaddo@cmlab.csie.ntu.edu.tw

Dimensionality Reduction

高維度的資料往往很難描述、計算，一個常用的方法是假設這些資料並非真的存在於這麼高的維度上，也就是說，可以用一個較低維度的非線性流形 (non-linear manifold) 來模擬這些資料。流形(Manifold)，一般可以認為是局部具有歐氏空間性質的空間。而實際上歐氏空間就是流形最簡單的實例。像地球表面這樣的球面是一個稍為複雜的例子。一般的流形可以通過把許多平直的片折彎並粘連而成。

如果這個 manifold 的維度夠低，我們就可以在這個低維度的空間上視覺化原先的資料。降維的方法可以概括分成以下三種：

1. 線性方法(Linear methods)

Principal component analysis (PCA)

Singular value decomposition (SVD)

Factor analysis (FA)

2. 非線性對應(Non-linear mappings)

Generative topographic mapping (GTM)

Gaussian process latent variable models (GPLVM)

Neural network methods

3. 逼近法(Proximity)

Multidimensional scaling (MDS)

Isomap

Locally linear embeddings (LLE)

本 Tutorial 著重在第三類的方法，這些方法通常透過計算相似矩陣(similarity matrix)或距離矩陣(distance matrix)來找到各資料之間的關係。

MDS

Multidimensional scaling (MDS)是一群尋找物件之間相關性的方法的統稱，例如，給予一個 Matrix D 描述各個城市之間的距離，MDS 會嘗試找到一個最好的配置方法來描述這些城市。

通常 MDS 會定義一個 stress value，若在 m 維空間上有兩物體 X_1, X_2 ，座標分別為 $(x_{11}, x_{12}, x_{13}, \dots, x_{1m})(x_{21}, x_{22}, x_{23}, \dots, x_{2m})$ ，最簡單的方法是定義尤拉空間的距離當作兩物體的距離 d

$$f(d_{i,j}) = (\sum(x_{ia} - x_{ja})^2)^{1/2}$$

若今天有 N 個點就可以利用這個 d 來定義 stress

$$S = \sum_{i=1}^N \sum_{j=1}^N (D_{i,j} - f(d_{i,j}))$$

MDS 想要找到描述各物體之間的最好方法，在這個方法下所描述的距離，就是 $D_{i,j}$ 。至於如何找到這個描述，不同的 MDS 使用的方法都不盡相同。

以 MMDS 為例，它解一個 eigenvalue problem，輸出一組座標系，基本上這跟 PCA 是殊途同歸。

MMDS

1. start with distances $d_{i,j}$
2. define $A = a_{ij} = -\frac{1}{2}(d_{i,j})^2$
3. put $B = a_{ij} - a_{i*} - a_{*j} + a_{**}$, where $a_{i*} = \frac{1}{n} \sum_j a_{ij}$, $a_{*j} = \frac{1}{n} \sum_i a_{ij}$, $a_{**} = \frac{1}{n^2} \sum \sum a_{ij}$
4. find the eigenvalues Λ and the associated eigenvectors Γ of B
5. the coordinate matrix is $X = \Gamma \Lambda^{\frac{1}{2}}$

Isomap

Step 1

Isomap 的 input 是許多高維度的 data，並把它們當作一個 graph，只要兩個 vertex 是鄰居，就會有一條 edge 連結，至於鄰居的判定方法可以是 K-nearest neighbors 或是用直接距離再取 threshold 都可以。


Step 2

接著，利用 Floyd's Algorithm 算出每個 vertex 之間的 shortest path distances。

Step 3


最後，把 Step 2 當中的結果當作 MMDS 的 input，就可以得到一個座標軸，利用這個座標軸描述出的 data 就是一個低維度的 manifold。

Isomap 的演算法雖然簡單，但確實解決了 PCA 或其他 linear methods 在 non-linear manifold 上遇到的問題，透過"neighbor"的定義，加強了各 data 之間的連結性，而不是只以絕對距離當作衡量的方法。



Locally linear embeddings (LLE)

LLE 演算法使用幾何上的直覺，假設有 N 個 data \vec{X}_i , $i = 1 \sim N$ ，每一個都是 D 維，這些 data 是從某一個 manifold 上取出來的。只要 data 數目夠多，雖然我們並不知道這個 manifold 長什麼樣子，但是我們可以預期在一個局部的範圍內，每個 data 跟他的鄰居可以形成一塊 patch，而這個 patch 會非常接近原本的 manifold。



Step1

我們可以利用各個鄰居的線性組合來重建每個 data，以用來描述這些 patch。
重建時的 error 可以寫成 cost function

$$\epsilon(W) = \sum_i \left| \vec{X}_i - \sum_j W_{ij} \vec{X}_j \right|^2$$

把每個 data 與其鄰居的重建結果相減，其中 W_{ij} 是矩陣 W 的一個元素，表示

第 j 個 data 對第 i 個 data 的影響力(weight)，爲了計算出 W_{ij} ，我們需要把 cost 最小化，並且符合了兩個條件

1. 只有 \vec{x}_i 的鄰居對 \vec{x}_i 有影響，也就是說如果 j 不是 i 的鄰居，則 $W_{ij} = 0$ 。
2. 這個 Weight 矩陣每列的總合爲 1， $\sum_j W_{ij} = 1$ 。

Step 2

這個問題是有固定解的。這裡我們先考慮其中一個 data \vec{x} ，假設他有 K 個鄰居 $\vec{\eta}_j$ ， $j = 1 \sim K$ ，我們可以把 cost 寫成

$$\varepsilon = \left| \vec{x} - \sum_j w_j \vec{\eta}_j \right|^2 = \left| \sum_j w_j (\vec{x} - \vec{\eta}_j) \right|^2$$

把整個絕對值展開的話，可以觀察到每一項都是 $w_i w_j$ 的形式，係數則是 $(\vec{x} - \vec{\eta}_j)(\vec{x} - \vec{\eta}_k)$ ，也就是說我們可以寫成

$$\left| \sum_j w_j (\vec{x} - \vec{\eta}_j) \right|^2 = \sum_{jk} w_j w_k C_{jk}$$

其中 $C_{jk} = (\vec{x} - \vec{\eta}_j)(\vec{x} - \vec{\eta}_k)$ ，作者把這個 C 矩陣稱爲 local covariance matrix。

根據拉格蘭日乘數法(註一)，如果把 w_j 當作變數， $\sum_j W_{ij} = 1$ 當作限制 (constrain function g)，想求 ε 的最小值。則 Lagrange 方程式對每個 w_j 作偏微分要是 0，可以寫成

$$\frac{\partial}{\partial w_j} (\varepsilon + \lambda(g - 1)) = 0$$

總共有 N 個偏微分的式子，因此這是一個 N 元 N 次方程組，整理過後可以得到。

$$w_j = \sum_k C_{jk}^{-1} (\vec{x} \cdot \vec{\eta}_k + \lambda)$$

Step 3

假設這些 data 會坐落或是接近一個平滑的非線性低維度的 manifold 上，什麼是好的估計模擬呢？就是能找到一個線性的轉換(包括平移、旋轉、伸縮)把原本 data 的鄰居從高維度的座標系轉換成這個 manifold 的座標系上。

根據這個概念，LLE 建立一個保留鄰居關係的轉換。在演算法的第三步，每個高維的 data X_i 會被對應到一個低維的 vector Y_i ，而這些 Y_i 可以形成這個 manifold，且它的維度是 d 。($d \ll D$)

Y_i 的選擇必須要能夠最小化 cost function

$$\min_Y \Phi(Y) = \sum_i \left| \vec{Y}_i - \sum_j W_{ij} \vec{Y}_j \right|^2$$

如果把絕對值展開，會有三個 component，可以發現這是一個 $Y_i Y_j$ 的 quadratic form，對任意 a, b ， $Y_a Y_b$ 的係數只會出現在 (1) $i = a, j = b$ (2) $i = b, j = a$ 這兩種情況。對第一個 component，如果 $a = b$ 則係數是 1，其餘情況是 0，對第二個 component 會分別產生 W_{ab} 與 W_{ba} 係數，對第三個 component，會有 $W_{1a} W_{1b} + W_{2a} W_{2b} + \dots$ 的係數，整理以上結果，可以把係數寫成

$$M_{ij} = \delta_{ij} - W_{ij} - W_{ji} + \sum_k W_{ki} W_{kj}$$

也就是說

$$\Phi(Y) = \sum_{ij} M_{ij} (\vec{Y}_i \cdot \vec{Y}_j)$$

根據 Rayleitz-Ritz theorem，如果這個 manifold 只有 d 維的自由度，那麼從第 $d+1$ 之後的每個 eigenvector 都是對應到 eigenvalue 0，因此只要保留 M 矩陣的前 d 個 eigenvector，就可以形成我們想要的 manifold。

(註一)以二維方程式為例，要找 $f(x, y)$ 極值的條件是：

$$\frac{\partial f}{\partial x} = \frac{\partial f}{\partial y} = 0$$

但是如果 x, y 的範圍一開始就被另一個函數 $g(x, y) = 0$ 所限制，Lagrange 提出以 $f(x, y) + \lambda g(x, y)$ 對 x 和 y 的偏微分為 0，來代替 $\frac{\partial f}{\partial x} = \frac{\partial f}{\partial y} = 0$ 作為在 $g(x, y) = 0$ 上面尋找 $f(x, y)$ 極值的條件。式中引入的 λ 是一個待定的數，稱為乘數，因為是乘在 g 的前面而得名。



Isomap & LLE Applications

Image Spaces and Video Trajectories: Using Isomap to Explore Video Sequences

Robert Pless

ICCV 2003

在這一篇 paper 中作者把 video 中的每個 frame 當作 Isomap 的 input，很顯然的這些 input 都是高維的 data，經過 Isomap 的轉換之後，會變成一群較低維度的 data，最後再按照 video 中的順序連起來，就可以形成一個軌道，作者認為這個軌道可以提供許多有用的資訊，例如在影片分段的例子中，把鳥的飛行影片轉換後，觀察軌道可以發現存在兩種不同的飛行模式，而正好可以對應到展翅與滑翔兩種動作。




Representation Analysis and Synthesis of Lip Images Using Dimensionality Reduction

Michal Aharon and Ron Kimmel

IJCV 2005

在這篇 paper 中作者把說話的嘴型當作 LLE 的 input，然後形成一個低維度的 manifold，接著找到每個單字在 manifold 上面形成的曲線，透過分析這些曲線可以達到讀唇語的效果。



“Coffee”



“Cola”

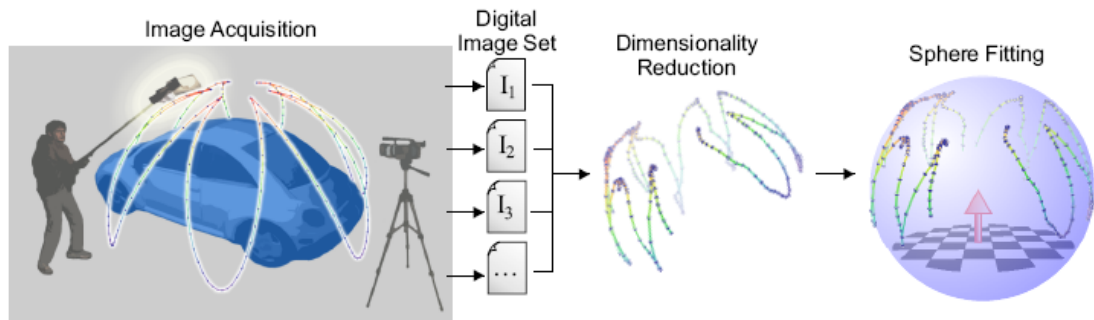


“Champagne”



Light Waving: Estimating Light Positions From Photographs Alone
 Holger Winnemöller, Ankit Mohan, Jack Tumblin, Bruce Gooch
 Eurographics 2005

在這篇 paper 中作者拍攝同一個角度但不同光源的物體，將這些照片當作 Isomap 的 input，distance 的算法則是使用常見的 L2-norm，找到低維度的 manifold 之後，再把它 fit 到一個球表面上，藉此重建 light position，用來當作 rendering 或 relighting 的光源參考。



	Teapot	Beetle Toy	Beetle Car	Hoberman	Telephone
Sample					
Side	Star, many arms	Spiral, Down	3 Concentric Circles	Star, 4 arms	Star, 4 arms
Top-Down					

References

1. Stephen Borgatti, [Multidimensional Scaling](#).
2. Joshua Tenenbaum, Vin de Silva, John Langford, [A Global Geometric Framework for Nonlinear Dimensionality Reduction](#), Science, 2000.
3. Sam Roweis, Lawrence Saul, [Nonlinear Dimensionality Reduction by Locally Linear Embedding](#), Science, 2000.
4. Lawrence Saul, Sam Roweis, [An Introduction to Locally Linear Embedding](#).
5. Lawrence Saul, Sam Roweis, [Think Globally, Fit Locally: Unsupervised Learning of Low Dimensional Manifolds](#), Journal of Machine Learning Research, 2003.
6. [Unsupervised Learning of Image Manifolds by Semidefinite Programming](#)