

BI-VZD přednáška 10

Ondřej Tichý

FIT ČVUT

2. 5. 2023

Autoři: Karel Klouda, Juan Pablo Maldonado Lopez, Daniel Vašata.
Problémy, návrhy apod. hlase v [GitLabu](#).
Verze souboru: 2. května 2023 12:15.

Co bude v dnešní přednášce

- Redukce dimenzionality
- Ortogonální projekce - metoda hlavních komponent (PCA)
- Manifold learning - lokálně lineární vnoření (LLE)

Problematika vysokých dimenzí

Z předchozích přednášek víme, že:

- U jednotkové krychle v d rozměrném prostoru s rovnoměrným rozdělením bodů se v podkrychli o hraně délky $(1 - \varepsilon)$ nalézají $(1 - \varepsilon)^d \cdot 100$ % všech bodů.
- Pro velké d je toto číslo blízké nule, což znamená, že se většina bodů nachází v okrajové slupce tlusté $\varepsilon/2$ a tedy velmi blízko hranici krychle.
- Například pro $d = 100$ se v okrajové slupce tloušťky 0.01 nachází 86.7% bodů.
- Dva body ve stejné jednotkové krychli jsou tedy typicky hodně vzdálené.

Problematika vysokých dimenzí

Z předchozích přednášek víme, že:

- U jednotkové krychle v d rozměrném prostoru s rovnoměrným rozdělením bodů se v podkrychli o hraně délky $(1 - \varepsilon)$ nalézají $(1 - \varepsilon)^d \cdot 100$ % všech bodů.
- Pro velké d je toto číslo blízké nule, což znamená, že se většina bodů nachází v okrajové slupce tlusté $\varepsilon/2$ a tedy velmi blízko hranici krychle.
- Například pro $d = 100$ se v okrajové slupce tloušťky 0.01 nachází 86.7% bodů.
- Dva body ve stejné jednotkové krychli jsou tedy typicky hodně vzdálené.
- Z pohledu strojového učení to znamená, že hustota trénovacích bodů s rostoucí dimenzí klesá. **Body jsou od sebe velmi vzdálené.**
- **Vytváření predikcí je tak méně spolehlivé**, protože model musí dělat **velké extrapolace**.

Problematika vysokých dimenzí

- Co použít větší množství dat? **Teoreticky ano.** Co je ale dostatečně velký počet?
- Pro data se 100 příznaky potřebujeme 10^{100} bodů k tomu, abychom zajistili, že v jednotkové krychli budou body cca 0.1 daleko od sebe.

Problematika vysokých dimenzí

- Co použít větší množství dat? **Teoreticky ano**. Co je ale dostatečně velký počet?
- Pro data se 100 příznaky potřebujeme 10^{100} bodů k tomu, abychom zajistili, že v jednotkové krychli budou body cca 0.1 daleko od sebe.
- To ale není úplně málo, když vezmeme v úvahu, že odhadovaný počet atomů (protonů) ve vesmíru¹ je 10^{80} .
- Je tedy zřejmé, že pokud by data byla v prostoru vysoké dimenze „hodně“ rozprostřena, může to být velký problém.

Problematika vysokých dimenzí

- Co použít větší množství dat? **Teoreticky ano**. Co je ale dostatečně velký počet?
- Pro data se 100 příznaky potřebujeme 10^{100} bodů k tomu, abychom zajistili, že v jednotkové krychli budou body cca 0.1 daleko od sebe.
- To ale není úplně málo, když vezmeme v úvahu, že odhadovaný počet atomů (protonů) ve vesmíru¹ je 10^{80} .
- Je tedy zřejmé, že pokud by data byla v prostoru vysoké dimenze „hodně“ rozprostřena, může to být velký problém.
- Jak se ale ukazuje, ve většině reálných situací tomu tak není a **data se vyskytují pouze v omezených oblastech prostoru menší dimenze**.
- Z matematického pohledu tak často předpokládáme, že se vyskytují podél takzvaných variet (angl. manifold), což jsou nelineární obdoby lineárních variet.
- Proto se tento předpoklad nazývá **hypotéza variet** (angl. **manifold hypothesis**).

¹Známý též jako **Eddingtonovo číslo**.

Hypotéza variet

Manifold hypothesis (hypotéza variet)

Většina reálných mnohorozměrných dat je ve skutečnosti rozprostřena podél variet mnohem menší dimenze.

Hypotéza variet

Manifold hypothesis (hypotéza variet)

Většina reálných mnohorozměrných dat je ve skutečnosti rozprostřena podél variet mnohem menší dimenze.

- Uvažujme opět známý **MNIST dataset** s rukou psanými číslicemi zachycenými na černobílých fotkách o rozměrech 28×28 pixelů ve stupních šedi.



- Datový bod tedy obsahuje $28 \cdot 28 = 784$ příznaků s hodnotami od 0 do 255.

Hypotéza variet

Manifold hypothesis (hypotéza variet)

Většina reálných mnohorozměrných dat je ve skutečnosti rozprostřena podél variet mnohem menší dimenze.


- Uvažujme opět známý **MNIST dataset** s rukou psanými číslicemi zachycenými na černobílých fotkách o rozměrech 28×28 pixelů ve stupních šedi.



- Datový bod tedy obsahuje $28 \cdot 28 = 784$ příznaků s hodnotami od 0 do 255.
- Pokud takový obrázek nakreslíme náhodně (např. rovnoměrně), je pravděpodobnost toho, že dostaneme něco podobného číslici, extrémně malá. Data jsou evidentně rozprostřena pouze v malinké oblasti prostoru.

Manifold hypothesis - další příklad

Dalším příkladem je dataset nazývaný **švýcarská rolka** (angl. **swiss roll**).



Zde se data vyskytují podél dvourozměrné spirálovitě zatočené oblasti.

Redukce dimenzionality

- Z hypotézy variet plyne, že dává smysl se pokoušet najít vhodné zobrazení dat z původního prostoru do nového prostoru menší dimenze.

Redukce dimenzionality

- Z hypotézy variet plyne, že dává smysl se pokoušet najít vhodné zobrazení dat z původního prostoru do nového prostoru menší dimenze.
- Z pohledu linearity takového zobrazení můžeme používané metody rozdělit na lineární projekce a manifold learning.
- **Lineární projekce** jsou víceméně vždy **ortogonální projekce** na nějaký lineární podprostor, případně na lineární varietu.

Redukce dimenziality

- Z hypotézy variet plyne, že dává smysl se pokoušet najít vhodné zobrazení dat z původního prostoru do nového prostoru menší dimenze.
- Z pohledu linearity takového zobrazení můžeme používané metody rozdělit na lineární projekce a manifold learning.
- **Lineární projekce** jsou víceméně vždy **ortogonální projekce** na nějaký lineární podprostor, případně na lineární varietu.
- **Manifold learning** reprezentují nelineární metody, které se snaží zobecnit lineární přístup k zachycení obecné nelineární struktury v datech.
- Výstupem takových metod je **nelineární** mapování bodů z původního prostoru na prostor menší dimenze.

Ortogonalní projekce na vektorový podprostor

Zabývejme se ortogonálními projekcemi na nějaký q dimenzionální vektorový podprostor \mathcal{V} vektorového prostoru \mathbb{R}^p vybaveného standardním skalárním součinem.

Ortogonalní projekce na vektorový podprostor

Zabývejme se ortogonálními projekcemi na nějaký q dimenzionální vektorový podprostor \mathcal{V} vektorového prostoru \mathbb{R}^p vybaveného standardním skalárním součinem.

Z lineární algebry víme, že každý bod $x \in \mathbb{R}^p$ je možné jednoznačně rozložit do součtu

$$x = v_x + u_x,$$

kde v_x je bod vektorového prostoru \mathcal{V} a u_x je vektor kolmý na \mathcal{V} .


Ortogonalní projekce na vektorový podprostor

Zabývejme se ortogonálními projekcemi na nějaký q dimenzionální vektorový podprostor \mathcal{V} vektorového prostoru \mathbb{R}^p vybaveného standardním skalárním součinem.

Z lineární algebry víme, že každý bod $x \in \mathbb{R}^p$ je možné jednoznačně rozložit do součtu

$$x = v_x + u_x,$$

kde v_x je bod vektorového prostoru \mathcal{V} a u_x je vektor kolmý na \mathcal{V} .




Ortogonalní projekce na vektorový podprostor

Zabývejme se ortogonálními projekcemi na nějaký q dimenzionální vektorový podprostor \mathcal{V} vektorového prostoru \mathbb{R}^p vybaveného standardním skalárním součinem.

Z lineární algebry víme, že každý bod $x \in \mathbb{R}^p$ je možné jednoznačně rozložit do součtu

$$x = v_x + u_x,$$

kde v_x je bod vektorového prostoru \mathcal{V} a u_x je vektor kolmý na \mathcal{V} .



Bod v_x se nazývá **ortogonalní projekce** bodu x na podprostor \mathcal{V} .

Ortogonalní projekce pomocí ortonormální báze

Uvažujme nyní situaci, že máme ortonormální bázi prostoru \mathbb{R}^p tvořenou vektory $\mathbf{b}_1, \dots, \mathbf{b}_p$ tak, že prvních q vektorů $\mathbf{b}_1, \dots, \mathbf{b}_q$ tvoří bázi podprostoru \mathcal{V} a zbylé vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$ jsou kolmé na \mathcal{V} .

Ortogonalní projekce pomocí ortonormální báze

Uvažujme nyní situaci, že máme ortonormální bázi prostoru \mathbb{R}^p tvořenou vektory $\mathbf{b}_1, \dots, \mathbf{b}_p$ tak, že prvních q vektorů $\mathbf{b}_1, \dots, \mathbf{b}_q$ tvoří bázi podprostoru \mathcal{V} a zbylé vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$ jsou kolmé na \mathcal{V} .

Každý bod vektorového prostoru $\mathbf{x} \in \mathbb{R}^p$ můžeme jednoznačně vyjádřit jako

$$\mathbf{x} = \tau_1 \mathbf{b}_1 + \dots + \tau_q \mathbf{b}_q + \tau_{q+1} \mathbf{b}_{q+1} + \dots + \tau_p \mathbf{b}_p,$$

kde i -tý koeficient τ_i je určen skalárním součinem \mathbf{x} a \mathbf{b}_i , tj. $\tau_i = \mathbf{x}^T \mathbf{b}_i$.

Ortogonalní projekce pomocí ortonormální báze

Uvažujme nyní situaci, že máme ortonormální bázi prostoru \mathbb{R}^p tvořenou vektory $\mathbf{b}_1, \dots, \mathbf{b}_p$ tak, že prvních q vektorů $\mathbf{b}_1, \dots, \mathbf{b}_q$ tvoří bázi podprostoru \mathcal{V} a zbylé vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$ jsou kolmé na \mathcal{V} .

Každý bod vektorového prostoru $\mathbf{x} \in \mathbb{R}^p$ můžeme jednoznačně vyjádřit jako

$$\mathbf{x} = \tau_1 \mathbf{b}_1 + \dots + \tau_q \mathbf{b}_q + \tau_{q+1} \mathbf{b}_{q+1} + \dots + \tau_p \mathbf{b}_p,$$

kde i -tý koeficient τ_i je určen skalárním součinem \mathbf{x} a \mathbf{b}_i , tj. $\tau_i = \mathbf{x}^T \mathbf{b}_i$.

Pro ortogonalní rozklad $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$ tedy dostáváme

$$\mathbf{v}_x = \tau_1 \mathbf{b}_1 + \dots + \tau_q \mathbf{b}_q \quad \text{a} \quad \mathbf{u}_x = \tau_{q+1} \mathbf{b}_{q+1} + \dots + \tau_p \mathbf{b}_p.$$

Ortogonalní projekce pomocí ortonormální báze

Uvažujme nyní situaci, že máme ortonormální bázi prostoru \mathbb{R}^p tvořenou vektory $\mathbf{b}_1, \dots, \mathbf{b}_p$ tak, že prvních q vektorů $\mathbf{b}_1, \dots, \mathbf{b}_q$ tvoří bázi podprostoru \mathcal{V} a zbylé vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$ jsou kolmé na \mathcal{V} .

Každý bod vektorového prostoru $\mathbf{x} \in \mathbb{R}^p$ můžeme jednoznačně vyjádřit jako

$$\mathbf{x} = \tau_1 \mathbf{b}_1 + \dots + \tau_q \mathbf{b}_q + \tau_{q+1} \mathbf{b}_{q+1} + \dots + \tau_p \mathbf{b}_p,$$

kde i -tý koeficient τ_i je určen skalárním součinem \mathbf{x} a \mathbf{b}_i , tj. $\tau_i = \mathbf{x}^T \mathbf{b}_i$.

Pro ortogonalní rozklad $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$ tedy dostáváme

$$\mathbf{v}_x = \tau_1 \mathbf{b}_1 + \dots + \tau_q \mathbf{b}_q \quad \text{a} \quad \mathbf{u}_x = \tau_{q+1} \mathbf{b}_{q+1} + \dots + \tau_p \mathbf{b}_p.$$

Projekci \mathbf{v}_x bodu \mathbf{x} na podprostor \mathcal{V} můžeme jednoznačně reprezentovat q rozměrným vektorem koeficientů $\mathbf{t}_x = (\tau_1, \dots, \tau_q)^T \in \mathbb{R}^q$.

Maticově můžeme tento vektor získat vztahem

$$\mathbf{t}_x = \mathbf{V}^T \mathbf{x}, \quad \text{případně} \quad \mathbf{t}_x^T = \mathbf{x}^T \mathbf{V},$$

kde $\mathbf{V} \in \mathbb{R}^{p,q}$ je matice, v jejíchž sloupcích jsou zapsané vektory $\mathbf{b}_1, \dots, \mathbf{b}_q$ ortonormální báze \mathcal{V} .

Poznamenejme, že $\mathbf{V}^T \mathbf{V} = \mathbf{I}_q$, tj. identita v \mathbb{R}^q .

Redukce dimenzionality pomocí ortogonální projekce

Reprezentace bodu $x \in \mathbb{R}^p$ pomocí bodu $t_x \in \mathbb{R}^q$ představuje redukci dimenzionality z p na q .

Redukce dimenzionality pomocí ortogonální projekce

Reprezentace bodu $x \in \mathbb{R}^p$ pomocí bodu $t_x \in \mathbb{R}^q$ představuje redukci dimenzionality z p na q .

Pro dataset reprezentovaný maticí $\mathbf{X} \in \mathbb{R}^{N,p}$, která obsahuje N bodů o p příznacích zapsané v řádcích získáme **transformovaný dataset** vztahem

$$\mathbf{T}_q = \mathbf{XV}.$$

Redukce dimenzionality pomocí ortogonální projekce

Reprezentace bodu $x \in \mathbb{R}^p$ pomocí bodu $t_x \in \mathbb{R}^q$ představuje redukci dimenzionality z p na q .

Pro dataset reprezentovaný maticí $\mathbf{X} \in \mathbb{R}^{N,p}$, která obsahuje N bodů o p příznacích zapsané v řádcích získáme **transformovaný dataset** vztahem

$$\mathbf{T}_q = \mathbf{XV}.$$

Matrice $\mathbf{T}_q \in \mathbb{R}^{N,q}$ tedy obsahuje q příznaků pro N bodů, které představují souřadnice ortogonálních projekcí těchto bodů na podprostor \mathcal{V} v jeho ortonormální bázi $\mathbf{b}_1, \dots, \mathbf{b}_q$.

Redukce dimenzionality pomocí ortogonální projekce

Reprezentace bodu $x \in \mathbb{R}^p$ pomocí bodu $t_x \in \mathbb{R}^q$ představuje redukci dimenzionality z p na q .

Pro dataset reprezentovaný maticí $\mathbf{X} \in \mathbb{R}^{N,p}$, která obsahuje N bodů o p příznacích zapsané v řádcích získáme **transformovaný dataset** vztahem

$$\mathbf{T}_q = \mathbf{X}\mathbf{V}.$$

Matrice $\mathbf{T}_q \in \mathbb{R}^{N,q}$ tedy obsahuje q příznaků pro N bodů, které představují souřadnice ortogonálních projekcí těchto bodů na podprostor \mathcal{V} v jeho ortonormální bázi $\mathbf{b}_1, \dots, \mathbf{b}_q$.

Kdybychom chtěli získat odpovídající projekce (tj. body v původním prostoru), musíme provést ještě jedno vynásobení maticí \mathbf{V} :

Redukce dimenzionality pomocí ortogonální projekce

Reprezentace bodu $\mathbf{x} \in \mathbb{R}^p$ pomocí bodu $\mathbf{t}_x \in \mathbb{R}^q$ představuje redukci dimenzionality z p na q .

Pro dataset reprezentovaný maticí $\mathbf{X} \in \mathbb{R}^{N,p}$, která obsahuje N bodů o p příznacích zapsané v řádcích získáme **transformovaný dataset** vztahem

$$\mathbf{T}_q = \mathbf{X}\mathbf{V}.$$

Matrice $\mathbf{T}_q \in \mathbb{R}^{N,q}$ tedy obsahuje q příznaků pro N bodů, které představují souřadnice ortogonálních projekcí těchto bodů na podprostor \mathcal{V} v jeho ortonormální bázi $\mathbf{b}_1, \dots, \mathbf{b}_q$.

Kdybychom chtěli získat odpovídající projekce (tj. body v původním prostoru), musíme provést ještě jedno vynásobení maticí \mathbf{V} :

- Pro jeden bod

$$\mathbf{v}_x = \mathbf{V}\mathbf{t}_x = \mathbf{V}\mathbf{V}^T \mathbf{x}, \quad \text{případně} \quad \mathbf{v}_x^T = \mathbf{x}^T \mathbf{V}\mathbf{V}^T.$$

Redukce dimenzionality pomocí ortogonální projekce

Reprezentace bodu $\mathbf{x} \in \mathbb{R}^p$ pomocí bodu $\mathbf{t}_x \in \mathbb{R}^q$ představuje redukci dimenzionality z p na q .

Pro dataset reprezentovaný maticí $\mathbf{X} \in \mathbb{R}^{N,p}$, která obsahuje N bodů o p příznacích zapsané v řádcích získáme **transformovaný dataset** vztahem

$$\mathbf{T}_q = \mathbf{X}\mathbf{V}.$$

Matrice $\mathbf{T}_q \in \mathbb{R}^{N,q}$ tedy obsahuje q příznaků pro N bodů, které představují souřadnice ortogonálních projekcí těchto bodů na podprostor \mathcal{V} v jeho ortonormální bázi $\mathbf{b}_1, \dots, \mathbf{b}_q$.

Kdybychom chtěli získat odpovídající projekce (tj. body v původním prostoru), musíme provést ještě jedno vynásobení maticí \mathbf{V} :

- Pro jeden bod


$$\mathbf{v}_x = \mathbf{V}\mathbf{t}_x = \mathbf{V}\mathbf{V}^T \mathbf{x}, \quad \text{případně} \quad \mathbf{v}_x^T = \mathbf{x}^T \mathbf{V}\mathbf{V}^T.$$

- Pro celý dataset

$$\mathbf{X}_{\mathcal{V}} = \mathbf{X}\mathbf{V}\mathbf{V}^T,$$


kde výsledná matice $\mathbf{X}_{\mathcal{V}} \in \mathbb{R}^{N,p}$ představuje ortogonální projekce původních bodů na podprostor \mathcal{V} , tj. ve sloupcích je p originálních příznaků.

Vizualizace ortogonální projekce




Originální dataset X

Vizualizace ortogonální projekce






Originální dataset X



Projekce $X_{\mathcal{V}}$ datasetu na podprostor \mathcal{V}

Vizualizace ortogonální projekce

Originální dataset X Projekce $X_{\mathcal{V}}$ datasetu na podprostor \mathcal{V} Transformovaný dataset T_q

Ortogonalní projekce - pomocná pozorování

Než se podíváme na metodu hlavních komponent, vraťme se ještě k rozkladu $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$, kde vektor \mathbf{v}_x můžeme získat pomocí matice \mathbf{V} jako $\mathbf{v}_x = \mathbf{V}\mathbf{V}^T \mathbf{x}$.

Ortogonalní projekce - pomocná pozorování

Než se podíváme na metodu hlavních komponent, vraťme se ještě k rozkladu $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$, kde vektor \mathbf{v}_x můžeme získat pomocí matice \mathbf{V} jako $\mathbf{v}_x = \mathbf{V}\mathbf{V}^T \mathbf{x}$.

Označme dále matici $\mathbf{U} \in \mathbb{R}^{p,p-q}$ v jejíchž sloupcích jsou zapsané vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Analogicky jako u matice \mathbf{V} platí

$$\mathbf{u}_x = \mathbf{U}\mathbf{U}^T \mathbf{x}$$

a $\mathbf{U}^T \mathbf{U} = \mathbf{I}_{p-q}$ je identita na \mathbb{R}^{p-q} .

Ortogonalní projekce - pomocná pozorování

Než se podíváme na metodu hlavních komponent, vraťme se ještě k rozkladu $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$, kde vektor \mathbf{v}_x můžeme získat pomocí matice \mathbf{V} jako $\mathbf{v}_x = \mathbf{V}\mathbf{V}^T \mathbf{x}$.

Označme dále matici $\mathbf{U} \in \mathbb{R}^{p,p-q}$ v jejichž sloupcích jsou zapsané vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Analogicky jako u matice \mathbf{V} platí

$$\mathbf{u}_x = \mathbf{U}\mathbf{U}^T \mathbf{x}$$

a $\mathbf{U}^T \mathbf{U} = \mathbf{I}_{p-q}$ je identita na \mathbb{R}^{p-q} .

Rozklad $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$ tedy můžeme získat pomocí matic \mathbf{V} a \mathbf{U} jako

$$\mathbf{x} = \mathbf{V}\mathbf{V}^T \mathbf{x} + \mathbf{U}\mathbf{U}^T \mathbf{x}.$$

Ortogonalní projekce - pomocná pozorování

Než se podíváme na metodu hlavních komponent, vraťme se ještě k rozkladu $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$, kde vektor \mathbf{v}_x můžeme získat pomocí matice \mathbf{V} jako $\mathbf{v}_x = \mathbf{V}\mathbf{V}^T \mathbf{x}$.

Označme dále matici $\mathbf{U} \in \mathbb{R}^{p, p-q}$ v jejíchž sloupcích jsou zapsané vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Analogicky jako u matice \mathbf{V} platí

$$\mathbf{u}_x = \mathbf{U}\mathbf{U}^T \mathbf{x}$$

a $\mathbf{U}^T \mathbf{U} = \mathbf{I}_{p-q}$ je identita na \mathbb{R}^{p-q} .

Rozklad $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$ tedy můžeme získat pomocí matic \mathbf{V} a \mathbf{U} jako

$$\mathbf{x} = \mathbf{V}\mathbf{V}^T \mathbf{x} + \mathbf{U}\mathbf{U}^T \mathbf{x}.$$

Pro kvadrát normy navíc z ortogonality rozkladu platí následující vztahy:

$$\|\mathbf{x}\|^2 = \mathbf{x}^T \mathbf{x}$$

Ortogonalní projekce - pomocná pozorování

Než se podíváme na metodu hlavních komponent, vraťme se ještě k rozkladu $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$, kde vektor \mathbf{v}_x můžeme získat pomocí matice \mathbf{V} jako $\mathbf{v}_x = \mathbf{V}\mathbf{V}^T \mathbf{x}$.

Označme dále matici $\mathbf{U} \in \mathbb{R}^{p,p-q}$ v jejíchž sloupcích jsou zapsané vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Analogicky jako u matice \mathbf{V} platí

$$\mathbf{u}_x = \mathbf{U}\mathbf{U}^T \mathbf{x}$$

a $\mathbf{U}^T \mathbf{U} = \mathbf{I}_{p-q}$ je identita na \mathbb{R}^{p-q} .

Rozklad $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$ tedy můžeme získat pomocí matic \mathbf{V} a \mathbf{U} jako

$$\mathbf{x} = \mathbf{V}\mathbf{V}^T \mathbf{x} + \mathbf{U}\mathbf{U}^T \mathbf{x}.$$

Pro kvadrát normy navíc z ortogonalit rozkladu platí následující vztahy:

$$\|\mathbf{x}\|^2 = \mathbf{x}^T \mathbf{x} = (\mathbf{v}_x + \mathbf{u}_x)^T (\mathbf{v}_x + \mathbf{u}_x)$$

Ortogonalní projekce - pomocná pozorování

Než se podíváme na metodu hlavních komponent, vraťme se ještě k rozkladu $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$, kde vektor \mathbf{v}_x můžeme získat pomocí matice \mathbf{V} jako $\mathbf{v}_x = \mathbf{V}\mathbf{V}^T \mathbf{x}$.

Označme dále matici $\mathbf{U} \in \mathbb{R}^{p, p-q}$ v jejíchž sloupcích jsou zapsané vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Analogicky jako u matice \mathbf{V} platí

$$\mathbf{u}_x = \mathbf{U}\mathbf{U}^T \mathbf{x}$$

a $\mathbf{U}^T \mathbf{U} = \mathbf{I}_{p-q}$ je identita na \mathbb{R}^{p-q} .

Rozklad $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$ tedy můžeme získat pomocí matic \mathbf{V} a \mathbf{U} jako

$$\mathbf{x} = \mathbf{V}\mathbf{V}^T \mathbf{x} + \mathbf{U}\mathbf{U}^T \mathbf{x}.$$

Pro kvadrát normy navíc z ortogonalit rozkladu platí následující vztahy:

$$\|\mathbf{x}\|^2 = \mathbf{x}^T \mathbf{x} = (\mathbf{v}_x + \mathbf{u}_x)^T (\mathbf{v}_x + \mathbf{u}_x) = \mathbf{v}_x^T \mathbf{v}_x + \mathbf{u}_x^T \mathbf{u}_x + \mathbf{v}_x^T \mathbf{u}_x + \mathbf{u}_x^T \mathbf{v}_x$$

Ortogonalní projekce - pomocná pozorování

Než se podíváme na metodu hlavních komponent, vraťme se ještě k rozkladu $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$, kde vektor \mathbf{v}_x můžeme získat pomocí matice \mathbf{V} jako $\mathbf{v}_x = \mathbf{V}\mathbf{V}^T\mathbf{x}$.

Označme dále matici $\mathbf{U} \in \mathbb{R}^{p,p-q}$ v jejíchž sloupcích jsou zapsané vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Analogicky jako u matice \mathbf{V} platí

$$\mathbf{u}_x = \mathbf{U}\mathbf{U}^T\mathbf{x}$$

a $\mathbf{U}^T\mathbf{U} = \mathbf{I}_{p-q}$ je identita na \mathbb{R}^{p-q} .

Rozklad $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$ tedy můžeme získat pomocí matic \mathbf{V} a \mathbf{U} jako

$$\mathbf{x} = \mathbf{V}\mathbf{V}^T\mathbf{x} + \mathbf{U}\mathbf{U}^T\mathbf{x}.$$

Pro kvadrát normy navíc z ortogonality rozkladu platí následující vztahy:

$$\begin{aligned}\|\mathbf{x}\|^2 &= \mathbf{x}^T\mathbf{x} = (\mathbf{v}_x + \mathbf{u}_x)^T(\mathbf{v}_x + \mathbf{u}_x) = \mathbf{v}_x^T\mathbf{v}_x + \mathbf{u}_x^T\mathbf{u}_x + \mathbf{v}_x^T\mathbf{u}_x + \mathbf{u}_x^T\mathbf{v}_x \\ &= \|\mathbf{v}_x\|^2 + \|\mathbf{u}_x\|^2\end{aligned}$$

Ortogonalní projekce - pomocná pozorování

Než se podíváme na metodu hlavních komponent, vraťme se ještě k rozkladu $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$, kde vektor \mathbf{v}_x můžeme získat pomocí matice \mathbf{V} jako $\mathbf{v}_x = \mathbf{V}\mathbf{V}^T \mathbf{x}$.

Označme dále matici $\mathbf{U} \in \mathbb{R}^{p, p-q}$ v jejíchž sloupcích jsou zapsané vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Analogicky jako u matice \mathbf{V} platí

$$\mathbf{u}_x = \mathbf{U}\mathbf{U}^T \mathbf{x}$$

a $\mathbf{U}^T \mathbf{U} = \mathbf{I}_{p-q}$ je identita na \mathbb{R}^{p-q} .

Rozklad $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$ tedy můžeme získat pomocí matic \mathbf{V} a \mathbf{U} jako

$$\mathbf{x} = \mathbf{V}\mathbf{V}^T \mathbf{x} + \mathbf{U}\mathbf{U}^T \mathbf{x}.$$

Pro kvadrát normy navíc z ortogonalit rozkladu platí následující vztahy:

$$\begin{aligned} \|\mathbf{x}\|^2 &= \mathbf{x}^T \mathbf{x} = (\mathbf{v}_x + \mathbf{u}_x)^T (\mathbf{v}_x + \mathbf{u}_x) = \mathbf{v}_x^T \mathbf{v}_x + \mathbf{u}_x^T \mathbf{u}_x + \mathbf{v}_x^T \mathbf{u}_x + \mathbf{u}_x^T \mathbf{v}_x \\ &= \|\mathbf{v}_x\|^2 + \|\mathbf{u}_x\|^2 = \mathbf{x}^T \mathbf{V}\mathbf{V}^T \mathbf{V}\mathbf{V}^T \mathbf{x} + \mathbf{x}^T \mathbf{U}\mathbf{U}^T \mathbf{U}\mathbf{U}^T \mathbf{x} \end{aligned}$$

Ortogonalní projekce - pomocná pozorování

Než se podíváme na metodu hlavních komponent, vraťme se ještě k rozkladu $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$, kde vektor \mathbf{v}_x můžeme získat pomocí matice \mathbf{V} jako $\mathbf{v}_x = \mathbf{V}\mathbf{V}^T \mathbf{x}$.

Označme dále matici $\mathbf{U} \in \mathbb{R}^{p, p-q}$ v jejíchž sloupcích jsou zapsané vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Analogicky jako u matice \mathbf{V} platí

$$\mathbf{u}_x = \mathbf{U}\mathbf{U}^T \mathbf{x}$$

a $\mathbf{U}^T \mathbf{U} = \mathbf{I}_{p-q}$ je identita na \mathbb{R}^{p-q} .

Rozklad $\mathbf{x} = \mathbf{v}_x + \mathbf{u}_x$ tedy můžeme získat pomocí matic \mathbf{V} a \mathbf{U} jako

$$\mathbf{x} = \mathbf{V}\mathbf{V}^T \mathbf{x} + \mathbf{U}\mathbf{U}^T \mathbf{x}.$$

Pro kvadrát normy navíc z ortogonalit rozkladu platí následující vztahy:

$$\begin{aligned} \|\mathbf{x}\|^2 &= \mathbf{x}^T \mathbf{x} = (\mathbf{v}_x + \mathbf{u}_x)^T (\mathbf{v}_x + \mathbf{u}_x) = \mathbf{v}_x^T \mathbf{v}_x + \mathbf{u}_x^T \mathbf{u}_x + \mathbf{v}_x^T \mathbf{u}_x + \mathbf{u}_x^T \mathbf{v}_x \\ &= \|\mathbf{v}_x\|^2 + \|\mathbf{u}_x\|^2 = \mathbf{x}^T \mathbf{V}\mathbf{V}^T \mathbf{V}\mathbf{V}^T \mathbf{x} + \mathbf{x}^T \mathbf{U}\mathbf{U}^T \mathbf{U}\mathbf{U}^T \mathbf{x} = \mathbf{x}^T \mathbf{V}\mathbf{V}^T \mathbf{x} + \mathbf{x}^T \mathbf{U}\mathbf{U}^T \mathbf{x}. \end{aligned}$$

Metoda hlavních komponent

Otázkou zůstává, jak pro každé q najít podprostor \mathcal{V} , na který budeme projekci dělat.

Metoda hlavních komponent

Otázkou zůstává, jak pro každé q najít podprostor \mathcal{V} , na který budeme projekci dělat.

Rozumným požadavkem na hledanou metodu je, aby pro každé q **minimalizovala kvadratickou chybu projekce** datasetu \mathbf{X} na q rozměrný podprostor \mathcal{V} .

Metoda hlavních komponent

Otázkou zůstává, jak pro každé q najít podprostor \mathcal{V} , na který budeme projekci dělat.

Rozumným požadavkem na hledanou metodu je, aby pro každé q **minimalizovala kvadratickou chybu projekce** datasetu \mathbf{X} na q rozměrný podprostor \mathcal{V} .

Jak ukážeme, k získání optimálního minima je nejprve nutné provést **středování datasetu** a získat tak dataset \mathbf{X}' , který má v řádcích napsané body $\mathbf{x}'_i = \mathbf{x}_i - \bar{\mathbf{x}}$, kde $\bar{\mathbf{x}} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i$ je **výběrový průměr** datasetu \mathbf{X} .

Metoda hlavních komponent

Otázkou zůstává, jak pro každé q najít podprostor \mathcal{V} , na který budeme projekci dělat.

Rozumným požadavkem na hledanou metodu je, aby pro každé q **minimalizovala kvadratickou chybu projekce** datasetu \mathbf{X} na q rozměrný podprostor \mathcal{V} .

Jak ukážeme, k získání optimálního minima je nejprve nutné provést **středování datasetu** a získat tak dataset \mathbf{X}' , který má v řádcích napsané body $\mathbf{x}'_i = \mathbf{x}_i - \bar{\mathbf{x}}$, kde $\bar{\mathbf{x}} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i$ je **výběrový průměr** datasetu \mathbf{X} .

Při ortogonálním rozkladu $\mathbf{x}'_i = \mathbf{v}_{\mathbf{x}'_i} + \mathbf{u}_{\mathbf{x}'_i}$ bodu \mathbf{x}'_i tedy chceme minimalizovat

$$\sum_{i=1}^N \|\mathbf{x}'_i - \mathbf{v}_{\mathbf{x}'_i}\|^2 = \sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2.$$

Metoda hlavních komponent

Otázkou zůstává, jak pro každé q najít podprostor \mathcal{V} , na který budeme projekci dělat.

Rozumným požadavkem na hledanou metodu je, aby pro každé q **minimalizovala kvadratickou chybu projekce** datasetu \mathbf{X} na q rozměrný podprostor \mathcal{V} .

Jak ukážeme, k získání optimálního minima je nejprve nutné provést **středování datasetu** a získat tak dataset \mathbf{X}' , který má v řádcích napsané body $\mathbf{x}'_i = \mathbf{x}_i - \bar{\mathbf{x}}$, kde $\bar{\mathbf{x}} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i$ je **výběrový průměr** datasetu \mathbf{X} .

Při ortogonálním rozkladu $\mathbf{x}'_i = \mathbf{v}_{\mathbf{x}'_i} + \mathbf{u}_{\mathbf{x}'_i}$ bodu \mathbf{x}'_i tedy chceme minimalizovat

$$\sum_{i=1}^N \|\mathbf{x}'_i - \mathbf{v}_{\mathbf{x}'_i}\|^2 = \sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2.$$

Řešení spočívá v užití ortonormální báze tvořené vlastními vektory $\mathbf{b}_1, \dots, \mathbf{b}_p$ příslušejícími k vlastním číslům matice $\frac{1}{N-1} \mathbf{X}'^T \mathbf{X}'$ seřazeným sestupně podle velikosti.

Metoda hlavních komponent

Otázkou zůstává, jak pro každé q najít podprostor \mathcal{V} , na který budeme projekci dělat.

Rozumným požadavkem na hledanou metodu je, aby pro každé q **minimalizovala kvadratickou chybu projekce** datasetu \mathbf{X} na q rozměrný podprostor \mathcal{V} .

Jak ukážeme, k získání optimálního minima je nejprve nutné provést **středování datasetu** a získat tak dataset \mathbf{X}' , který má v řádcích napsané body $\mathbf{x}'_i = \mathbf{x}_i - \bar{\mathbf{x}}$, kde $\bar{\mathbf{x}} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i$ je **výběrový průměr** datasetu \mathbf{X} .

Při ortogonálním rozkladu $\mathbf{x}'_i = \mathbf{v}_{\mathbf{x}'_i} + \mathbf{u}_{\mathbf{x}'_i}$ bodu \mathbf{x}'_i tedy chceme minimalizovat

$$\sum_{i=1}^N \|\mathbf{x}'_i - \mathbf{v}_{\mathbf{x}'_i}\|^2 = \sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2.$$

Řešení spočívá v užití ortonormální báze tvořené vlastními vektory $\mathbf{b}_1, \dots, \mathbf{b}_p$ příslušejícími k vlastním číslům matice $\frac{1}{N-1} \mathbf{X}'^T \mathbf{X}'$ seřazeným sestupně podle velikosti.

Podprostor \mathcal{V} a příslušná matice \mathbf{V} jsou pak tvořeny **prvními q vektory** této báze.

Metoda hlavních komponent

Otázkou zůstává, jak pro každé q najít podprostor \mathcal{V} , na který budeme projekci dělat.

Rozumným požadavkem na hledanou metodu je, aby pro každé q **minimalizovala kvadratickou chybu projekce** datasetu \mathbf{X} na q rozměrný podprostor \mathcal{V} .

Jak ukážeme, k získání optimálního minima je nejprve nutné provést **středování datasetu** a získat tak dataset \mathbf{X}' , který má v řádcích napsané body $\mathbf{x}'_i = \mathbf{x}_i - \bar{\mathbf{x}}$, kde $\bar{\mathbf{x}} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i$ je **výběrový průměr** datasetu \mathbf{X} .

Při ortogonálním rozkladu $\mathbf{x}'_i = \mathbf{v}_{\mathbf{x}'_i} + \mathbf{u}_{\mathbf{x}'_i}$ bodu \mathbf{x}'_i tedy chceme minimalizovat

$$\sum_{i=1}^N \|\mathbf{x}'_i - \mathbf{v}_{\mathbf{x}'_i}\|^2 = \sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2.$$

Řešení spočívá v užití ortonormální báze tvořené vlastními vektory $\mathbf{b}_1, \dots, \mathbf{b}_p$ příslušejícími k vlastním číslům matice $\frac{1}{N-1} \mathbf{X}'^T \mathbf{X}'$ seřazeným sestupně podle velikosti.

Podprostor \mathcal{V} a příslušná matice \mathbf{V} jsou pak tvořeny **prvními q vektory** této báze.

Tento postup se nazývá **metoda hlavních komponent** (angl. **principal component analysis**) (**PCA**).

Význam středování datasetu

Z přednášky o shlukování víme, že výraz

$$\sum_{i=1}^N \|\mathbf{x}_i - \boldsymbol{\mu}\|^2$$

nabývá minima, pokud $\boldsymbol{\mu} = \bar{\mathbf{x}}$, což je geometrický střed množiny bodů v datasetu.

Význam středování datasetu

Z přednášky o shlukování víme, že výraz

$$\sum_{i=1}^N \|\mathbf{x}_i - \boldsymbol{\mu}\|^2$$

nabývá minima, pokud $\boldsymbol{\mu} = \bar{\mathbf{x}}$, což je geometrický střed množiny bodů v datasetu.

Zároveň pro libovolný podprostor \mathcal{V} a příslušné matice \mathbf{V} a \mathbf{U} platí

$$\bar{\mathbf{u}} = \frac{1}{N} \sum_{i=1}^N \mathbf{u}_{\mathbf{x}_i}$$

Význam středování datasetu

Z přednášky o shlukování víme, že výraz

$$\sum_{i=1}^N \|\mathbf{x}_i - \boldsymbol{\mu}\|^2$$

nabývá minima, pokud $\boldsymbol{\mu} = \bar{\mathbf{x}}$, což je geometrický střed množiny bodů v datasetu.

Zároveň pro libovolný podprostor \mathcal{V} a příslušné matice \mathbf{V} a \mathbf{U} platí

$$\bar{\mathbf{u}} = \frac{1}{N} \sum_{i=1}^N \mathbf{u}_{x_i} = \frac{1}{N} \sum_{i=1}^N \mathbf{U}\mathbf{U}^T \mathbf{x}_i = \mathbf{U}\mathbf{U}^T \bar{\mathbf{x}}.$$

Význam středování datasetu

Z přednášky o shlukování víme, že výraz

$$\sum_{i=1}^N \|\mathbf{x}_i - \boldsymbol{\mu}\|^2$$

nabývá minima, pokud $\boldsymbol{\mu} = \bar{\mathbf{x}}$, což je geometrický střed množiny bodů v datasetu.

Zároveň pro libovolný podprostor \mathcal{V} a příslušné matice \mathbf{V} a \mathbf{U} platí

$$\bar{\mathbf{u}} = \frac{1}{N} \sum_{i=1}^N \mathbf{u}_{\mathbf{x}_i} = \frac{1}{N} \sum_{i=1}^N \mathbf{U}\mathbf{U}^T \mathbf{x}_i = \mathbf{U}\mathbf{U}^T \bar{\mathbf{x}}.$$

Protože $\mathbf{u}_{\mathbf{x}_i} = \mathbf{U}\mathbf{U}^T \mathbf{x}_i$ a $\mathbf{u}_{\mathbf{x}'_i} = \mathbf{U}\mathbf{U}^T (\mathbf{x}_i - \bar{\mathbf{x}}) = \mathbf{u}_{\mathbf{x}_i} - \bar{\mathbf{u}}$

Význam středování datasetu

Z přednášky o shlukování víme, že výraz

$$\sum_{i=1}^N \|\mathbf{x}_i - \boldsymbol{\mu}\|^2$$

nabývá minima, pokud $\boldsymbol{\mu} = \bar{\mathbf{x}}$, což je geometrický střed množiny bodů v datasetu.

Zároveň pro libovolný podprostor \mathcal{V} a příslušné matice \mathbf{V} a \mathbf{U} platí

$$\bar{\mathbf{u}} = \frac{1}{N} \sum_{i=1}^N \mathbf{u}_{\mathbf{x}_i} = \frac{1}{N} \sum_{i=1}^N \mathbf{U}\mathbf{U}^T \mathbf{x}_i = \mathbf{U}\mathbf{U}^T \bar{\mathbf{x}}.$$

Protože $\mathbf{u}_{\mathbf{x}_i} = \mathbf{U}\mathbf{U}^T \mathbf{x}_i$ a $\mathbf{u}_{\mathbf{x}'_i} = \mathbf{U}\mathbf{U}^T (\mathbf{x}_i - \bar{\mathbf{x}}) = \mathbf{u}_{\mathbf{x}_i} - \bar{\mathbf{u}}$ nabývá

$$\sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}_i} - \bar{\mathbf{u}}\|^2 = \sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2$$

minima z pohledu možných translací datasetu \mathbf{X} .

Proto, nezávisle na \mathcal{V} , vede středování k nejmenší možné kvadratické chybě projekce posunutého datasetu \mathbf{X}' na \mathcal{V} .

Vztah kvadratické chyby a rozptylu

Protože pro normu při ortogonálním rozkladu platí $\|\mathbf{x}'_i\|^2 = \|\mathbf{v}_{\mathbf{x}'_i}\|^2 + \|\mathbf{u}_{\mathbf{x}'_i}\|^2$ a tedy

$$\frac{1}{N-1} \sum_{i=1}^N \|\mathbf{x}'_i\|^2 = \frac{1}{N-1} \sum_{i=1}^N \|\mathbf{v}_{\mathbf{x}'_i}\|^2 + \frac{1}{N-1} \sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2,$$

Vztah kvadratické chyby a rozptylu

Protože pro normu při ortogonálním rozkladu platí $\|\mathbf{x}'_i\|^2 = \|\mathbf{v}_{\mathbf{x}'_i}\|^2 + \|\mathbf{u}_{\mathbf{x}'_i}\|^2$ a tedy

$$\frac{1}{N-1} \sum_{i=1}^N \|\mathbf{x}'_i\|^2 = \frac{1}{N-1} \sum_{i=1}^N \|\mathbf{v}_{\mathbf{x}'_i}\|^2 + \frac{1}{N-1} \sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2,$$


odpovídá **minimalizace** chyb projekce **maximalizaci** „rozptylu“ projektovaných bodů ve \mathcal{V} .

Vztah kvadratické chyby a rozptylu


Protože pro normu při ortogonálním rozkladu platí $\|\mathbf{x}'_i\|^2 = \|\mathbf{v}_{x'_i}\|^2 + \|\mathbf{u}_{x'_i}\|^2$ a tedy

$$\frac{1}{N-1} \sum_{i=1}^N \|\mathbf{x}'_i\|^2 = \frac{1}{N-1} \sum_{i=1}^N \|\mathbf{v}_{x'_i}\|^2 + \frac{1}{N-1} \sum_{i=1}^N \|\mathbf{u}_{x'_i}\|^2,$$

odpovídá **minimalizace** chyb projekce **maximalizaci** „rozptylu“ projektovaných bodů ve \mathcal{V} .



Projekce s větší chybou



Projekce s menší chybou

Varianční matice

- Označme p příznaků v prostoru, ze kterého pochází data, jako X_1, \dots, X_p .
- Dataset \mathbf{X} můžeme chápat jako náhodný výběr z rozdělení těchto příznaků.
- Složky $\bar{x}_1, \dots, \bar{x}_p$ vektoru \bar{x} jsou tak výběrovými průměry a tedy bodovými odhady středních hodnot příznaků.

Varianční matice

- Označme p příznaků v prostoru, ze kterého pochází data, jako X_1, \dots, X_p .
- Dataset \mathbf{X} můžeme chápat jako náhodný výběr z rozdělení těchto příznaků.
- Složky $\bar{x}_1, \dots, \bar{x}_p$ vektoru \bar{x} jsou tak výběrovými průměry a tedy bodovými odhady středních hodnot příznaků.
- **Výběrová kovariance** příznaků X_i a X_j , která je odhadem $\text{cov}(X_i, X_j)$, je tedy

$$\widehat{\text{cov}}(X_i, X_j) = \frac{1}{N-1} \sum_{k=1}^N (x_{k;i} - \bar{x}_i)(x_{k;j} - \bar{x}_j)$$

- **Varianční matice** (angl. **covariance matrix**) je matice jejíž (i, j) -tá složka je $\text{cov}(X_i, X_j)$.

Varianční matice

- Označme p příznaků v prostoru, ze kterého pochází data, jako X_1, \dots, X_p .
- Dataset \mathbf{X} můžeme chápat jako náhodný výběr z rozdělení těchto příznaků.
- Složky $\bar{x}_1, \dots, \bar{x}_p$ vektoru $\bar{\mathbf{x}}$ jsou tak výběrovými průměry a tedy bodovými odhady středních hodnot příznaků.
- **Výběrová kovariance** příznaků X_i a X_j , která je odhadem $\text{cov}(X_i, X_j)$, je tedy

$$\widehat{\text{cov}}(X_i, X_j) = \frac{1}{N-1} \sum_{k=1}^N (x_{k;i} - \bar{x}_i)(x_{k;j} - \bar{x}_j) = \frac{1}{N-1} \sum_{k=1}^N x'_{k;i} x'_{k;j}$$

- **Varianční matice** (angl. **covariance matrix**) je matice jejíž (i, j) -tá složka je $\text{cov}(X_i, X_j)$.

Varianční matice

- Označme p příznaků v prostoru, ze kterého pochází data, jako X_1, \dots, X_p .
- Dataset \mathbf{X} můžeme chápat jako náhodný výběr z rozdělení těchto příznaků.
- Složky $\bar{x}_1, \dots, \bar{x}_p$ vektoru \bar{x} jsou tak výběrovými průměry a tedy bodovými odhady středních hodnot příznaků.
- **Výběrová kovariance** příznaků X_i a X_j , která je odhadem $\text{cov}(X_i, X_j)$, je tedy

$$\widehat{\text{cov}}(X_i, X_j) = \frac{1}{N-1} \sum_{k=1}^N (x_{k;i} - \bar{x}_i)(x_{k;j} - \bar{x}_j) = \frac{1}{N-1} \sum_{k=1}^N x'_{k;i} x'_{k;j} = \frac{1}{N-1} (\mathbf{X}'^T \mathbf{X}')_{ij}.$$

- **Varianční matice** (angl. **covariance matrix**) je matice jejíž (i, j) -tá složka je $\text{cov}(X_i, X_j)$.

Varianční matice

- Označme p příznaků v prostoru, ze kterého pochází data, jako X_1, \dots, X_p .
- Dataset \mathbf{X} můžeme chápat jako náhodný výběr z rozdělení těchto příznaků.
- Složky $\bar{x}_1, \dots, \bar{x}_p$ vektoru \bar{x} jsou tak výběrovými průměry a tedy bodovými odhady středních hodnot příznaků.
- **Výběrová kovariance** příznaků X_i a X_j , která je odhadem $\text{cov}(X_i, X_j)$, je tedy

$$\widehat{\text{cov}}(X_i, X_j) = \frac{1}{N-1} \sum_{k=1}^N (x_{k;i} - \bar{x}_i)(x_{k;j} - \bar{x}_j) = \frac{1}{N-1} \sum_{k=1}^N x'_{k;i} x'_{k;j} = \frac{1}{N-1} (\mathbf{X}'^T \mathbf{X}')_{ij}.$$

- **Varianční matice** (angl. **covariance matrix**) je matice jejíž (i, j) -tá složka je $\text{cov}(X_i, X_j)$.

Varianční matice

- Označme p příznaků v prostoru, ze kterého pochází data, jako X_1, \dots, X_p .
- Dataset \mathbf{X} můžeme chápat jako náhodný výběr z rozdělení těchto příznaků.
- Složky $\bar{x}_1, \dots, \bar{x}_p$ vektoru \bar{x} jsou tak výběrovými průměry a tedy bodovými odhady středních hodnot příznaků.
- **Výběrová kovariance** příznaků X_i a X_j , která je odhadem $\text{cov}(X_i, X_j)$, je tedy

$$\widehat{\text{cov}}(X_i, X_j) = \frac{1}{N-1} \sum_{k=1}^N (x_{k;i} - \bar{x}_i)(x_{k;j} - \bar{x}_j) = \frac{1}{N-1} \sum_{k=1}^N x'_{k;i} x'_{k;j} = \frac{1}{N-1} (\mathbf{X}'^T \mathbf{X}')_{ij}.$$

- **Varianční matice** (angl. **covariance matrix**) je matice jejíž (i, j) -tá složka je $\text{cov}(X_i, X_j)$.
- **Výběrová varianční matice** (angl. **sample covariance matrix**) je matice jejíž (i, j) -tá složka je $\widehat{\text{cov}}(X_i, X_j)$ a je vlastně bodovým odhadem varianční matice.
- Z předešlého tedy platí, že výběrová varianční matice je $\frac{1}{N-1} \mathbf{X}'^T \mathbf{X}'$.
- V dalším textu budeme pro jednoduchost používat pojem varianční matice i pro tuto výběrovou varianční matici.
- Varianční matice je **symetrická** a na diagonále má **nezáporné hodnoty** (výběrové rozptyly).

Optimalita PCA

Jelikož je varianční matice **symetrická**, je také **diagonalizovatelná** a z příslušných vlastních vektorů můžeme sestavit **ortonormální bázi** prostoru \mathbb{R}^p .

Optimalita PCA

Jelikož je varianční matice **symetrická**, je také **diagonalizovatelná** a z příslušných vlastních vektorů můžeme sestavit **ortonormální bázi** prostoru \mathbb{R}^p . Protože je také **pozitivně semi-definitní** (viz přednáška o lineární regresi), jsou všechna vlastní čísla **nezáporná**.

Optimalita PCA

Jelikož je varianční matice **symetrická**, je také **diagonalizovatelná** a z příslušných vlastních vektorů můžeme sestavit **ortonormální bázi** prostoru \mathbb{R}^p . Protože je také **pozitivně semi-definitní** (viz přednáška o lineární regresi), jsou všechna vlastní čísla **nezáporná**.

Označme si vlastní čísla seřazená sestupně podle velikosti jako $\lambda_1 \geq \dots \geq \lambda_p \geq 0$ a příslušné vlastní vektory jako $\mathbf{b}_1, \dots, \mathbf{b}_p$.

Optimalita PCA

Jelikož je varianční matice **symetrická**, je také **diagonalizovatelná** a z příslušných vlastních vektorů můžeme sestavit **ortonormální bázi** prostoru \mathbb{R}^p . Protože je také **pozitivně semi-definitní** (viz přednáška o lineární regresi), jsou všechna vlastní čísla **nezáporná**.

Označme si vlastní čísla seřazená sestupně podle velikosti jako $\lambda_1 \geq \dots \geq \lambda_p \geq 0$ a příslušné vlastní vektory jako $\mathbf{b}_1, \dots, \mathbf{b}_p$.

Platí tedy $\mathbf{X}'^T \mathbf{X}' \mathbf{b}_i = (N - 1) \lambda_i \mathbf{b}_i$.

Optimalita PCA

Jelikož je varianční matice **symetrická**, je také **diagonalizovatelná** a z příslušných vlastních vektorů můžeme sestavit **ortonormální bázi** prostoru \mathbb{R}^p . Protože je také **pozitivně semi-definitní** (viz přednáška o lineární regresi), jsou všechna vlastní čísla **nezáporná**.

Označme si vlastní čísla seřazená sestupně podle velikosti jako $\lambda_1 \geq \dots \geq \lambda_p \geq 0$ a příslušné vlastní vektory jako $\mathbf{b}_1, \dots, \mathbf{b}_p$.

Platí tedy $\mathbf{X}'^T \mathbf{X}' \mathbf{b}_i = (N - 1) \lambda_i \mathbf{b}_i$.

Podprostor \mathcal{V} nyní vyrobíme z prvních q vektorů této báze. Příslušná matice \mathbf{V} má ve sloupcích zapsané vektory $\mathbf{b}_1, \dots, \mathbf{b}_q$ a matice \mathbf{U} potom zbylé vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Optimalita PCA

Jelikož je varianční matice **symetrická**, je také **diagonalizovatelná** a z příslušných vlastních vektorů můžeme sestavit **ortonormální bázi** prostoru \mathbb{R}^p . Protože je také **pozitivně semi-definitní** (viz přednáška o lineární regresi), jsou všechna vlastní čísla **nezáporná**.

Označme si vlastní čísla seřazená sestupně podle velikosti jako $\lambda_1 \geq \dots \geq \lambda_p \geq 0$ a příslušné vlastní vektory jako $\mathbf{b}_1, \dots, \mathbf{b}_p$.

Platí tedy $\mathbf{X}'^T \mathbf{X}' \mathbf{b}_i = (N - 1) \lambda_i \mathbf{b}_i$.

Podprostor \mathcal{V} nyní vyrobíme z prvních q vektorů této báze. Příslušná matice \mathbf{V} má ve sloupcích zapsané vektory $\mathbf{b}_1, \dots, \mathbf{b}_q$ a matice \mathbf{U} potom zbylé vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Pro výraz, který jsme chtěli minimalizovat platí:

$$\sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2 = \sum_{i=1}^N \mathbf{x}'_i{}^T \mathbf{U} \mathbf{U}^T \mathbf{x}'_i$$

Optimalita PCA

Jelikož je varianční matice **symetrická**, je také **diagonalizovatelná** a z příslušných vlastních vektorů můžeme sestavit **ortonormální bázi** prostoru \mathbb{R}^p . Protože je také **pozitivně semi-definitní** (viz přednáška o lineární regresi), jsou všechna vlastní čísla **nezáporná**.

Označme si vlastní čísla seřazená sestupně podle velikosti jako $\lambda_1 \geq \dots \geq \lambda_p \geq 0$ a příslušné vlastní vektory jako $\mathbf{b}_1, \dots, \mathbf{b}_p$.

Platí tedy $\mathbf{X}'^T \mathbf{X}' \mathbf{b}_i = (N - 1) \lambda_i \mathbf{b}_i$.

Podprostor \mathcal{V} nyní vyrobíme z prvních q vektorů této báze. Příslušná matice \mathbf{V} má ve sloupcích zapsané vektory $\mathbf{b}_1, \dots, \mathbf{b}_q$ a matice \mathbf{U} potom zbylé vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Pro výraz, který jsme chtěli minimalizovat platí:

$$\sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2 = \sum_{i=1}^N \mathbf{x}'_i{}^T \mathbf{U} \mathbf{U}^T \mathbf{x}'_i = \sum_{i=1}^N \sum_{j=q+1}^p \mathbf{x}'_i{}^T \mathbf{b}_j \mathbf{b}_j^T \mathbf{x}'_i$$

Optimalita PCA

Jelikož je varianční matice **symetrická**, je také **diagonalizovatelná** a z příslušných vlastních vektorů můžeme sestavit **ortonormální bázi** prostoru \mathbb{R}^p . Protože je také **pozitivně semi-definitní** (viz přednáška o lineární regresi), jsou všechna vlastní čísla **nezáporná**.

Označme si vlastní čísla seřazená sestupně podle velikosti jako $\lambda_1 \geq \dots \geq \lambda_p \geq 0$ a příslušné vlastní vektory jako $\mathbf{b}_1, \dots, \mathbf{b}_p$.

Platí tedy $\mathbf{X}'^T \mathbf{X}' \mathbf{b}_i = (N - 1) \lambda_i \mathbf{b}_i$.

Podprostor \mathcal{V} nyní vyrobíme z prvních q vektorů této báze. Příslušná matice \mathbf{V} má ve sloupcích zapsané vektory $\mathbf{b}_1, \dots, \mathbf{b}_q$ a matice \mathbf{U} potom zbylé vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Pro výraz, který jsme chtěli minimalizovat platí:

$$\sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2 = \sum_{i=1}^N \mathbf{x}'_i{}^T \mathbf{U} \mathbf{U}^T \mathbf{x}'_i = \sum_{i=1}^N \sum_{j=q+1}^p \mathbf{x}'_i{}^T \mathbf{b}_j \mathbf{b}_j^T \mathbf{x}'_i = \sum_{j=q+1}^p \sum_{i=1}^N \mathbf{b}_j^T \mathbf{x}'_i \mathbf{x}'_i{}^T \mathbf{b}_j$$

Optimalita PCA

Jelikož je varianční matice **symetrická**, je také **diagonalizovatelná** a z příslušných vlastních vektorů můžeme sestavit **ortonormální bázi** prostoru \mathbb{R}^p . Protože je také **pozitivně semi-definitní** (viz přednáška o lineární regresi), jsou všechna vlastní čísla **nezáporná**.

Označme si vlastní čísla seřazená sestupně podle velikosti jako $\lambda_1 \geq \dots \geq \lambda_p \geq 0$ a příslušné vlastní vektory jako $\mathbf{b}_1, \dots, \mathbf{b}_p$.

Platí tedy $\mathbf{X}'^T \mathbf{X}' \mathbf{b}_i = (N - 1) \lambda_i \mathbf{b}_i$.

Podprostor \mathcal{V} nyní vyrobíme z prvních q vektorů této báze. Příslušná matice \mathbf{V} má ve sloupcích zapsané vektory $\mathbf{b}_1, \dots, \mathbf{b}_q$ a matice \mathbf{U} potom zbylé vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Pro výraz, který jsme chtěli minimalizovat platí:

$$\begin{aligned} \sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2 &= \sum_{i=1}^N \mathbf{x}'_i{}^T \mathbf{U} \mathbf{U}^T \mathbf{x}'_i = \sum_{i=1}^N \sum_{j=q+1}^p \mathbf{x}'_i{}^T \mathbf{b}_j \mathbf{b}_j^T \mathbf{x}'_i = \sum_{j=q+1}^p \sum_{i=1}^N \mathbf{b}_j^T \mathbf{x}'_i \mathbf{x}'_i{}^T \mathbf{b}_j \\ &= \sum_{j=q+1}^p \mathbf{b}_j^T \mathbf{X}'^T \mathbf{X}' \mathbf{b}_j \end{aligned}$$

Optimalita PCA

Jelikož je varianční matice **symetrická**, je také **diagonalizovatelná** a z příslušných vlastních vektorů můžeme sestavit **ortonormální bázi** prostoru \mathbb{R}^p . Protože je také **pozitivně semi-definitní** (viz přednáška o lineární regresi), jsou všechna vlastní čísla **nezáporná**.

Označme si vlastní čísla seřazená sestupně podle velikosti jako $\lambda_1 \geq \dots \geq \lambda_p \geq 0$ a příslušné vlastní vektory jako $\mathbf{b}_1, \dots, \mathbf{b}_p$.

Platí tedy $\mathbf{X}'^T \mathbf{X}' \mathbf{b}_i = (N - 1) \lambda_i \mathbf{b}_i$.

Podprostor \mathcal{V} nyní vyrobíme z prvních q vektorů této báze. Příslušná matice \mathbf{V} má ve sloupcích zapsané vektory $\mathbf{b}_1, \dots, \mathbf{b}_q$ a matice \mathbf{U} potom zbylé vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Pro výraz, který jsme chtěli minimalizovat platí:

$$\begin{aligned} \sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2 &= \sum_{i=1}^N \mathbf{x}'_i{}^T \mathbf{U} \mathbf{U}^T \mathbf{x}'_i = \sum_{i=1}^N \sum_{j=q+1}^p \mathbf{x}'_i{}^T \mathbf{b}_j \mathbf{b}_j^T \mathbf{x}'_i = \sum_{j=q+1}^p \sum_{i=1}^N \mathbf{b}_j^T \mathbf{x}'_i \mathbf{x}'_i{}^T \mathbf{b}_j \\ &= \sum_{j=q+1}^p \mathbf{b}_j^T \mathbf{X}'^T \mathbf{X}' \mathbf{b}_j = \sum_{j=q+1}^p (N - 1) \lambda_j \mathbf{b}_j^T \mathbf{b}_j \end{aligned}$$

Optimalita PCA

Jelikož je varianční matice **symetrická**, je také **diagonalizovatelná** a z příslušných vlastních vektorů můžeme sestavit **ortonormální bázi** prostoru \mathbb{R}^p . Protože je také **pozitivně semi-definitní** (viz přednáška o lineární regresi), jsou všechna vlastní čísla **nezáporná**.

Označme si vlastní čísla seřazená sestupně podle velikosti jako $\lambda_1 \geq \dots \geq \lambda_p \geq 0$ a příslušné vlastní vektory jako $\mathbf{b}_1, \dots, \mathbf{b}_p$.

Platí tedy $\mathbf{X}'^T \mathbf{X}' \mathbf{b}_i = (N - 1) \lambda_i \mathbf{b}_i$.

Podprostor \mathcal{V} nyní vyrobíme z prvních q vektorů této báze. Příslušná matice \mathbf{V} má ve sloupcích zapsané vektory $\mathbf{b}_1, \dots, \mathbf{b}_q$ a matice \mathbf{U} potom zbylé vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Pro výraz, který jsme chtěli minimalizovat platí:

$$\begin{aligned} \sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2 &= \sum_{i=1}^N \mathbf{x}'_i{}^T \mathbf{U} \mathbf{U}^T \mathbf{x}'_i = \sum_{i=1}^N \sum_{j=q+1}^p \mathbf{x}'_i{}^T \mathbf{b}_j \mathbf{b}_j^T \mathbf{x}'_i = \sum_{j=q+1}^p \sum_{i=1}^N \mathbf{b}_j^T \mathbf{x}'_i \mathbf{x}'_i{}^T \mathbf{b}_j \\ &= \sum_{j=q+1}^p \mathbf{b}_j^T \mathbf{X}'^T \mathbf{X}' \mathbf{b}_j = \sum_{j=q+1}^p (N - 1) \lambda_j \mathbf{b}_j^T \mathbf{b}_j = (N - 1) (\lambda_{q+1} + \dots + \lambda_p). \end{aligned}$$

Optimalita PCA

Jelikož je varianční matice **symetrická**, je také **diagonalizovatelná** a z příslušných vlastních vektorů můžeme sestavit **ortonormální bázi** prostoru \mathbb{R}^p . Protože je také **pozitivně semi-definitní** (viz přednáška o lineární regresi), jsou všechna vlastní čísla **nezáporná**.

Označme si vlastní čísla seřazená sestupně podle velikosti jako $\lambda_1 \geq \dots \geq \lambda_p \geq 0$ a příslušné vlastní vektory jako $\mathbf{b}_1, \dots, \mathbf{b}_p$.

Platí tedy $\mathbf{X}'^T \mathbf{X}' \mathbf{b}_i = (N - 1) \lambda_i \mathbf{b}_i$.

Podprostor \mathcal{V} nyní vyrobíme z prvních q vektorů této báze. Příslušná matice \mathbf{V} má ve sloupcích zapsané vektory $\mathbf{b}_1, \dots, \mathbf{b}_q$ a matice \mathbf{U} potom zbylé vektory $\mathbf{b}_{q+1}, \dots, \mathbf{b}_p$.

Pro výraz, který jsme chtěli minimalizovat platí:

$$\begin{aligned} \sum_{i=1}^N \|\mathbf{u}_{\mathbf{x}'_i}\|^2 &= \sum_{i=1}^N \mathbf{x}'_i{}^T \mathbf{U} \mathbf{U}^T \mathbf{x}'_i = \sum_{i=1}^N \sum_{j=q+1}^p \mathbf{x}'_i{}^T \mathbf{b}_j \mathbf{b}_j^T \mathbf{x}'_i = \sum_{j=q+1}^p \sum_{i=1}^N \mathbf{b}_j^T \mathbf{x}'_i \mathbf{x}'_i{}^T \mathbf{b}_j \\ &= \sum_{j=q+1}^p \mathbf{b}_j^T \mathbf{X}'^T \mathbf{X}' \mathbf{b}_j = \sum_{j=q+1}^p (N - 1) \lambda_j \mathbf{b}_j^T \mathbf{b}_j = (N - 1) (\lambda_{q+1} + \dots + \lambda_p). \end{aligned}$$

Lze ukázat, že pro jakýkoliv q rozměrný podprostor je tento součet roven výrazu $(N - 1)(\gamma_1 \lambda_1 + \dots + \gamma_p \lambda_p)$, kde $0 \leq \gamma_i \leq 1$ a $\sum_i \gamma_i = p - q$, a tedy **nikdy nemůže být menší**.

Hlavní komponenty

Dataset \mathbf{X} obsahující body $\mathbf{x}_1, \dots, \mathbf{x}_N \in \mathbb{R}^p$ můžeme chápat jako náhodný výběr z rozdělení příznaků $\mathbf{X} = (X_1, \dots, X_p)^T$.

Středovaný dataset \mathbf{X}' obsahující body $\mathbf{x}'_1, \dots, \mathbf{x}'_N \in \mathbb{R}^p$ odpovídá náhodnému výběru z rozdělení posunutých příznaků $\mathbf{X}' = (X'_1, \dots, X'_p)^T$.

Hlavní komponenty

Dataset \mathbf{X} obsahující body $\mathbf{x}_1, \dots, \mathbf{x}_N \in \mathbb{R}^p$ můžeme chápat jako náhodný výběr z rozdělení příznaků $\mathbf{X} = (X_1, \dots, X_p)^T$.

Středovaný dataset \mathbf{X}' obsahující body $\mathbf{x}'_1, \dots, \mathbf{x}'_N \in \mathbb{R}^p$ odpovídá náhodnému výběru z rozdělení posunutých příznaků $\mathbf{X}' = (X'_1, \dots, X'_p)^T$.

Transformovaný dataset $\mathbf{T}_q = \mathbf{X}'\mathbf{V}$, obsahuje body $\mathbf{t}_{x'_1}, \dots, \mathbf{t}_{x'_N} \in \mathbb{R}^q$ a odpovídá náhodnému výběru z rozdělení příznaků $\mathbf{T} = (T_1, \dots, T_q)^T$, kde

$$T_i = b_{i;1}X'_1 + \dots + b_{i;p}X'_p = \mathbf{b}_i^T \mathbf{X}' \quad \text{a tedy} \quad \mathbf{T} = \mathbf{V}^T \mathbf{X}'.$$

Hlavní komponenty

Dataset \mathbf{X} obsahující body $\mathbf{x}_1, \dots, \mathbf{x}_N \in \mathbb{R}^p$ můžeme chápat jako náhodný výběr z rozdělení příznaků $\mathbf{X} = (X_1, \dots, X_p)^T$.

Středovaný dataset \mathbf{X}' obsahující body $\mathbf{x}'_1, \dots, \mathbf{x}'_N \in \mathbb{R}^p$ odpovídá náhodnému výběru z rozdělení posunutých příznaků $\mathbf{X}' = (X'_1, \dots, X'_p)^T$.

Transformovaný dataset $\mathbf{T}_q = \mathbf{X}'\mathbf{V}$, obsahuje body $\mathbf{t}_{x'_1}, \dots, \mathbf{t}_{x'_N} \in \mathbb{R}^q$ a odpovídá náhodnému výběru z rozdělení příznaků $\mathbf{T} = (T_1, \dots, T_q)^T$, kde

$$T_i = b_{i;1}X'_1 + \dots + b_{i;p}X'_p = \mathbf{b}_i^T \mathbf{X}' \quad \text{a tedy} \quad \mathbf{T} = \mathbf{V}^T \mathbf{X}'.$$

Tyto nové příznaky nazýváme hlavní komponenty (angl. **principal components**) a konkrétně T_i nazýváme i -tou **hlavní komponentou** (angl. i th **principal component**).

Hlavní komponenty mají **významnou statistickou interpretaci**, jak si nyní ukážeme.

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i}$$

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k$$

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k = \mathbf{b}_i^T \left(\frac{1}{N} \sum_{k=1}^N \mathbf{x}'_k \right)$$

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k = \mathbf{b}_i^T \left(\frac{1}{N} \sum_{k=1}^N \mathbf{x}'_k \right) = 0,$$

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k = \mathbf{b}_i^T \left(\frac{1}{N} \sum_{k=1}^N \mathbf{x}'_k \right) = 0,$$

$$\widehat{\text{cov}}(T_i, T_j) = \frac{1}{N-1} \sum_{k=1}^N t_{\mathbf{x}'_k; i} t_{\mathbf{x}'_k; j}$$

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k = \mathbf{b}_i^T \left(\frac{1}{N} \sum_{k=1}^N \mathbf{x}'_k \right) = 0,$$

$$\widehat{\text{cov}}(T_i, T_j) = \frac{1}{N-1} \sum_{k=1}^N t_{\mathbf{x}'_k; i} t_{\mathbf{x}'_k; j} = \frac{1}{N-1} (\mathbf{T}_q^T \mathbf{T}_q)_{ij}$$

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k = \mathbf{b}_i^T \left(\frac{1}{N} \sum_{k=1}^N \mathbf{x}'_k \right) = 0,$$

$$\widehat{\text{cov}}(T_i, T_j) = \frac{1}{N-1} \sum_{k=1}^N t_{\mathbf{x}'_k; i} t_{\mathbf{x}'_k; j} = \frac{1}{N-1} (\mathbf{T}_q^T \mathbf{T}_q)_{ij} = \frac{1}{N-1} (\mathbf{V}^T \mathbf{X}'^T \mathbf{X}' \mathbf{V})_{ij}$$

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k = \mathbf{b}_i^T \left(\frac{1}{N} \sum_{k=1}^N \mathbf{x}'_k \right) = 0,$$

$$\begin{aligned} \widehat{\text{cov}}(T_i, T_j) &= \frac{1}{N-1} \sum_{k=1}^N t_{\mathbf{x}'_k; i} t_{\mathbf{x}'_k; j} = \frac{1}{N-1} (\mathbf{T}_q^T \mathbf{T}_q)_{ij} = \frac{1}{N-1} (\mathbf{V}^T \mathbf{X}'^T \mathbf{X}' \mathbf{V})_{ij} \\ &= \frac{1}{N-1} \mathbf{b}_i^T \mathbf{X}'^T \mathbf{X}' \mathbf{b}_j \end{aligned}$$

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k = \mathbf{b}_i^T \left(\frac{1}{N} \sum_{k=1}^N \mathbf{x}'_k \right) = 0,$$

$$\begin{aligned} \widehat{\text{cov}}(T_i, T_j) &= \frac{1}{N-1} \sum_{k=1}^N t_{\mathbf{x}'_k; i} t_{\mathbf{x}'_k; j} = \frac{1}{N-1} (\mathbf{T}_q^T \mathbf{T}_q)_{ij} = \frac{1}{N-1} (\mathbf{V}^T \mathbf{X}'^T \mathbf{X}' \mathbf{V})_{ij} \\ &= \frac{1}{N-1} \mathbf{b}_i^T \mathbf{X}'^T \mathbf{X}' \mathbf{b}_j = \lambda_j \mathbf{b}_i^T \mathbf{b}_j \end{aligned}$$

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k = \mathbf{b}_i^T \left(\frac{1}{N} \sum_{k=1}^N \mathbf{x}'_k \right) = 0,$$

$$\begin{aligned} \widehat{\text{cov}}(T_i, T_j) &= \frac{1}{N-1} \sum_{k=1}^N t_{\mathbf{x}'_k; i} t_{\mathbf{x}'_k; j} = \frac{1}{N-1} (\mathbf{T}_q^T \mathbf{T}_q)_{ij} = \frac{1}{N-1} (\mathbf{V}^T \mathbf{X}'^T \mathbf{X}' \mathbf{V})_{ij} \\ &= \frac{1}{N-1} \mathbf{b}_i^T \mathbf{X}'^T \mathbf{X}' \mathbf{b}_j = \lambda_j \mathbf{b}_i^T \mathbf{b}_j = \begin{cases} 0 & \text{pro } i \neq j, \\ \lambda_j & \text{pro } i = j. \end{cases} \end{aligned}$$

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k = \mathbf{b}_i^T \left(\frac{1}{N} \sum_{k=1}^N \mathbf{x}'_k \right) = 0,$$

$$\begin{aligned} \widehat{\text{cov}}(T_i, T_j) &= \frac{1}{N-1} \sum_{k=1}^N t_{\mathbf{x}'_k; i} t_{\mathbf{x}'_k; j} = \frac{1}{N-1} (\mathbf{T}_q^T \mathbf{T}_q)_{ij} = \frac{1}{N-1} (\mathbf{V}^T \mathbf{X}'^T \mathbf{X}' \mathbf{V})_{ij} \\ &= \frac{1}{N-1} \mathbf{b}_i^T \mathbf{X}'^T \mathbf{X}' \mathbf{b}_j = \lambda_j \mathbf{b}_i^T \mathbf{b}_j = \begin{cases} 0 & \text{pro } i \neq j, \\ \lambda_j & \text{pro } i = j. \end{cases} \end{aligned}$$

Platí tedy:

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k = \mathbf{b}_i^T \left(\frac{1}{N} \sum_{k=1}^N \mathbf{x}'_k \right) = 0,$$

$$\begin{aligned} \widehat{\text{cov}}(T_i, T_j) &= \frac{1}{N-1} \sum_{k=1}^N t_{\mathbf{x}'_k; i} t_{\mathbf{x}'_k; j} = \frac{1}{N-1} (\mathbf{T}_q^T \mathbf{T}_q)_{ij} = \frac{1}{N-1} (\mathbf{V}^T \mathbf{X}'^T \mathbf{X}' \mathbf{V})_{ij} \\ &= \frac{1}{N-1} \mathbf{b}_i^T \mathbf{X}'^T \mathbf{X}' \mathbf{b}_j = \lambda_j \mathbf{b}_i^T \mathbf{b}_j = \begin{cases} 0 & \text{pro } i \neq j, \\ \lambda_j & \text{pro } i = j. \end{cases} \end{aligned}$$

Platí tedy:

- Rozptyl i -té hlavní komponenty je tedy roven i -tému vlastnímu číslu λ_i .

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k = \mathbf{b}_i^T \left(\frac{1}{N} \sum_{k=1}^N \mathbf{x}'_k \right) = 0,$$

$$\begin{aligned} \widehat{\text{cov}}(T_i, T_j) &= \frac{1}{N-1} \sum_{k=1}^N t_{\mathbf{x}'_k; i} t_{\mathbf{x}'_k; j} = \frac{1}{N-1} (\mathbf{T}_q^T \mathbf{T}_q)_{ij} = \frac{1}{N-1} (\mathbf{V}^T \mathbf{X}'^T \mathbf{X}' \mathbf{V})_{ij} \\ &= \frac{1}{N-1} \mathbf{b}_i^T \mathbf{X}'^T \mathbf{X}' \mathbf{b}_j = \lambda_j \mathbf{b}_i^T \mathbf{b}_j = \begin{cases} 0 & \text{pro } i \neq j, \\ \lambda_j & \text{pro } i = j. \end{cases} \end{aligned}$$

Platí tedy:

- Rozptyl i -té hlavní komponenty je tedy roven i -tému vlastnímu číslu λ_i .
- Výběrem q hlavních komponent tedy vybereme směry, ve kterých mají data největší rozptyl!

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k = \mathbf{b}_i^T \left(\frac{1}{N} \sum_{k=1}^N \mathbf{x}'_k \right) = 0,$$

$$\begin{aligned} \widehat{\text{cov}}(T_i, T_j) &= \frac{1}{N-1} \sum_{k=1}^N t_{\mathbf{x}'_k; i} t_{\mathbf{x}'_k; j} = \frac{1}{N-1} (\mathbf{T}_q^T \mathbf{T}_q)_{ij} = \frac{1}{N-1} (\mathbf{V}^T \mathbf{X}'^T \mathbf{X}' \mathbf{V})_{ij} \\ &= \frac{1}{N-1} \mathbf{b}_i^T \mathbf{X}'^T \mathbf{X}' \mathbf{b}_j = \lambda_j \mathbf{b}_i^T \mathbf{b}_j = \begin{cases} 0 & \text{pro } i \neq j, \\ \lambda_j & \text{pro } i = j. \end{cases} \end{aligned}$$

Platí tedy:

- Rozptyl i -té hlavní komponenty je tedy roven i -tému vlastnímu číslu λ_i .
- Výběrem q hlavních komponent tedy vybereme směry, ve kterých mají data největší rozptyl!
- Různé komponenty (příznaky T_i) jsou nekorelované!

Statistická interpretace hlavních komponent

Pro výběrové průměry a výběrové kovariance hlavních komponent platí

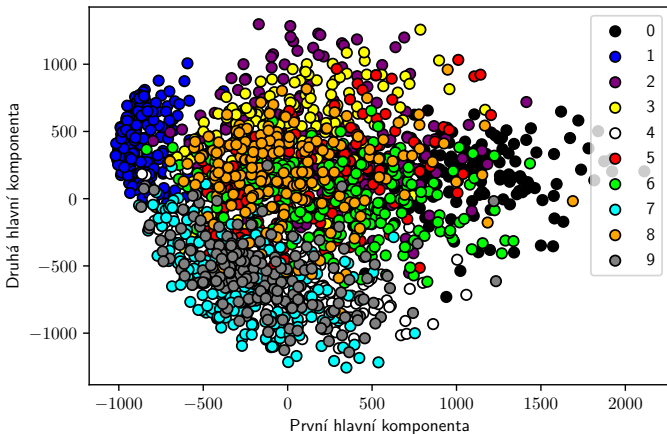
$$\bar{T}_i = \frac{1}{N} \sum_{k=1}^N t_{\mathbf{x}'_k; i} = \frac{1}{N} \sum_{k=1}^N \mathbf{b}_i^T \mathbf{x}'_k = \mathbf{b}_i^T \left(\frac{1}{N} \sum_{k=1}^N \mathbf{x}'_k \right) = 0,$$

$$\begin{aligned} \widehat{\text{cov}}(T_i, T_j) &= \frac{1}{N-1} \sum_{k=1}^N t_{\mathbf{x}'_k; i} t_{\mathbf{x}'_k; j} = \frac{1}{N-1} (\mathbf{T}_q^T \mathbf{T}_q)_{ij} = \frac{1}{N-1} (\mathbf{V}^T \mathbf{X}'^T \mathbf{X}' \mathbf{V})_{ij} \\ &= \frac{1}{N-1} \mathbf{b}_i^T \mathbf{X}'^T \mathbf{X}' \mathbf{b}_j = \lambda_j \mathbf{b}_i^T \mathbf{b}_j = \begin{cases} 0 & \text{pro } i \neq j, \\ \lambda_j & \text{pro } i = j. \end{cases} \end{aligned}$$

Platí tedy:


- Rozptyl i -té hlavní komponenty je tedy roven i -tému vlastnímu číslu λ_i .
- Výběrem q hlavních komponent tedy vybereme směry, ve kterých mají data největší rozptyl!
- Různé komponenty (příznaky T_i) jsou nekorelované!
- Podíl rozptylu „vysvětlený“ i -tou komponentou je $\frac{\lambda_i}{\lambda_1 + \dots + \lambda_p}$.

Příklad: MNIST





Vykreslení v dvou hlavních komponentách s vyznačením třídy nám dává nějakou informaci o existujících shlucích.

Příklad: MNIST



Pro hlavní komponenty je zde velmi obtížné interpretovat jejich vztah ke třídám!

Příklad: Švýcarská rolka



PCA transformace švýcarské rolky do dvou dimenzí a pak do tří.

Závěrečný komentář

- K numerickému výpočtu PCA je možné jednak využít přímý spektrální rozklad matice $\frac{1}{N-1} \mathbf{X}'^T \mathbf{X}'$ nebo rozklad matice \mathbf{X}' na singulární hodnoty (singular value decomposition - SVD), který je v zásadě numericky stabilnější.

Závěrečný komentář

- K numerickému výpočtu PCA je možné jednak využít přímý spektrální rozklad matice $\frac{1}{N-1} \mathbf{X}'^T \mathbf{X}'$ nebo rozklad matice \mathbf{X}' na singulární hodnoty (singular value decomposition - SVD), který je v zásadě numericky stabilnější.
- Počet komponent q je možné volit na základě „elbow“ grafů, ve kterých nakreslíme počet komponent proti celkovému rozptylu vysvětlenému danými komponentami a hledáme bod zlomu.

Závěrečný komentář

- K numerickému výpočtu PCA je možné jednak využít přímý spektrální rozklad matice $\frac{1}{N-1} \mathbf{X}'^T \mathbf{X}'$ nebo rozklad matice \mathbf{X}' na singulární hodnoty (singular value decomposition - SVD), který je v zásadě numericky stabilnější.
- Počet komponent q je možné volit na základě „elbow“ grafů, ve kterých nakreslíme počet komponent proti celkovému rozptylu vysvětlenému danými komponentami a hledáme bod zlomu.
- Pokud zvolíme $q = p$, tak nezahodíme žádnou informaci, ale pouze přejdeme do reprezentace dat v ortonormální bázi.

Závěrečný komentář

- K numerickému výpočtu PCA je možné jednak využít přímý spektrální rozklad matice $\frac{1}{N-1}\mathbf{X}'^T\mathbf{X}'$ nebo rozklad matice \mathbf{X}' na singulární hodnoty (singular value decomposition - SVD), který je v zásadě numericky stabilnější.
- Počet komponent q je možné volit na základě „elbow“ grafů, ve kterých nakreslíme počet komponent proti celkovému rozptylu vysvětlenému danými komponentami a hledáme bod zlomu.
- Pokud zvolíme $q = p$, tak nezahodíme žádnou informaci, ale pouze přejdeme do reprezentace dat v ortonormální bázi.
- V takovém případě budou sloupce matice \mathbf{T}_q na sebe kolmé, protože

$$\mathbf{T}_q^T \mathbf{T}_q = \mathbf{V}^T \mathbf{X}'^T \mathbf{X}' \mathbf{V} = (N - 1)\mathbf{\Lambda},$$

kde $\mathbf{\Lambda}$ je matice, na jejíž diagonále jsou vlastní čísla $\lambda_1, \dots, \lambda_p$ matice $\frac{1}{N-1}\mathbf{X}'^T\mathbf{X}'$ a mimo diagonálu 0.

Manifold learning

- Problémem ortogonální projekce (a tedy i PCA) je situace, kdy jsou v datech nelineární závislosti způsobené například komplikovanými interakcemi mezi příznaky.

Manifold learning

- Problémem ortogonální projekce (a tedy i PCA) je situace, kdy jsou v datech nelineární závislosti způsobené například komplikovanými interakcemi mezi příznaky.
- V takovém případě je dobré se místo na **globální** vlastnosti rozdělení dat soustředit na ty **lokální**.
- O to se obecně snaží metody z **manifold learning**. Ukažme si jednu z nich.

Manifold learning

- Problémem ortogonální projekce (a tedy i PCA) je situace, kdy jsou v datech nelineární závislosti způsobené například komplikovanými interakcemi mezi příznaky.
- V takovém případě je dobré se místo na **globální** vlastnosti rozdělení dat soustředit na ty **lokální**.
- O to se obecně snaží metody z **manifold learning**. Ukažme si jednu z nich.
- **Lokálně lineární vnoření** (angl. **locally linear embedding**), zkracujeme **LLE**, sleduje, jak jednotlivé trénovací body závisí lineárně na svém okolí a potom hledá méně dimenzionální reprezentaci, která tyto lokální vztahy zachová.

Metoda LLE (1/3)

- Uvažujme i -tý trénovací bod \mathbf{x}_i (i -tý řádek matice \mathbf{X}).
- Pro dané k spočteme jeho k nejbližších sousedů (\mathbf{x}_i mezi ně nepočítáme).

Metoda LLE (1/3)

- Uvažujme i -tý trénovací bod \mathbf{x}_i (i -tý řádek matice \mathbf{X}).
- Pro dané k spočteme jeho k nejbližších sousedů (\mathbf{x}_i mezi ně nepočítáme).
- Dále najdeme váhy $w_{i,j}$ takové aby:
 - ▶ $w_{i,j} = 0$ pro j takové, že \mathbf{x}_j není mezi k nejbližšími sousedy \mathbf{x}_i ,
 - ▶ $\sum_j w_{i,j} = 1$,
 - ▶ vzdálenost mezi \mathbf{x}_i a $\sum_j w_{i,j} \mathbf{x}_j$ byla nejmenší možná.

Metoda LLE (1/3)

- Uvažujme i -tý trénovací bod \mathbf{x}_i (i -tý řádek matice \mathbf{X}).
- Pro dané k spočteme jeho k nejbližších sousedů (\mathbf{x}_i mezi ně nepočítáme).
- Dále najdeme váhy $w_{i,j}$ takové aby:
 - ▶ $w_{i,j} = 0$ pro j takové, že \mathbf{x}_j není mezi k nejbližšími sousedy \mathbf{x}_i ,
 - ▶ $\sum_j w_{i,j} = 1$,
 - ▶ vzdálenost mezi \mathbf{x}_i a $\sum_j w_{i,j} \mathbf{x}_j$ byla nejmenší možná.
- Toto provedeme pro všechny body najednou. To ekvivalentně znamená, že hledáme

$$\arg \min_{w_{i,j}} \sum_{i=1}^N \left\| \mathbf{x}_i - \sum_j w_{i,j} \mathbf{x}_j \right\|^2,$$

za výše uvedené podmínky $w_{i,j} = 0$ pro j takové, že \mathbf{x}_j není mezi k nejbližšími sousedy \mathbf{x}_i , a současně $\sum_j w_{i,j} = 1$.

Metoda LLE (2/3)

- Jako \mathbf{W}^* označme matici která obsahuje optimální hodnoty vah $w_{i,j}^*$.
- V dalším kroku se pro každé $\mathbf{x}_i \in \mathbb{R}^p$ snažíme najít q rozměrnou reprezentaci $\mathbf{z}_i \in \mathbb{R}^q$ takovou, že je vzdálenost mezi \mathbf{z}_i a $\sum_j w_{i,j}^* \mathbf{z}_j$ nejmenší možná.

Metoda LLE (2/3)

- Jako \mathbf{W}^* označme matici která obsahuje optimální hodnoty vah $w_{i,j}^*$.
- V dalším kroku se pro každé $\mathbf{x}_i \in \mathbb{R}^p$ snažíme najít q rozměrnou reprezentaci $\mathbf{z}_i \in \mathbb{R}^q$ takovou, že je vzdálenost mezi \mathbf{z}_i a $\sum_j w_{i,j}^* \mathbf{z}_j$ nejmenší možná.
- Tímto způsobem získáme matici \mathbf{Z}^* , která má v řádcích zapsané výsledné optimální body \mathbf{z}_i^* , což představuje finální vnoření.

Metoda LLE (2/3)

- Jako \mathbf{W}^* označme matici která obsahuje optimální hodnoty vah $w_{i,j}^*$.
- V dalším kroku se pro každé $\mathbf{x}_i \in \mathbb{R}^p$ snažíme najít q rozměrnou reprezentaci $\mathbf{z}_i \in \mathbb{R}^q$ takovou, že je vzdálenost mezi \mathbf{z}_i a $\sum_j w_{i,j}^* \mathbf{z}_j$ nejmenší možná.
- Tímto způsobem získáme matici \mathbf{Z}^* , která má v řádcích zapsané výsledné optimální body \mathbf{z}_i^* , což představuje finální vnoření.
- Postup je tedy dvoufázový:
 - ▶ Nejprve se na základě originálních dat spočítají váhy, které nějakým způsobem zachycují lokální strukturu těch dat.
 - ▶ Výsledná reprezentace se potom nalezne s využitím těchto vah, jako d dimenzionální reprezentace, která tu lokální strukturu zachovává nejlépe.

Metoda LLE (3/3)

- **Nalezení vah:** Hledáme $\mathbf{W}^* \in \mathbb{R}^{N,N}$ takové, že

$$\mathbf{W}^* = \arg \min_{\mathbf{W}} \sum_{i=1}^N \left\| \mathbf{x}_i - \sum_j w_{i,j} \mathbf{x}_j \right\|^2$$

za podmínky $w_{i,j} = 0$ pro j takové, že \mathbf{x}_j není mezi k nejbližšími sousedy \mathbf{x}_i , a současně $\sum_j w_{i,j} = 1$.

Metoda LLE (3/3)

- **Nalezení vah:** Hledáme $\mathbf{W}^* \in \mathbb{R}^{N,N}$ takové, že


$$\mathbf{W}^* = \arg \min_{\mathbf{W}} \sum_{i=1}^N \left\| \mathbf{x}_i - \sum_j w_{i,j} \mathbf{x}_j \right\|^2$$

za podmínky $w_{i,j} = 0$ pro j takové, že \mathbf{x}_j není mezi k nejbližšími sousedy \mathbf{x}_i , a současně $\sum_j w_{i,j} = 1$.

- **Nalezení vnoření:** Najdeme matici $\mathbf{Z}^* \in \mathbb{R}^{N,q}$ takovou, že

$$\mathbf{Z}^* = \arg \min_{\mathbf{Z}} \sum_{i=1}^N \left\| \mathbf{z}_i - \sum_j w_{i,j}^* \mathbf{z}_j \right\|^2.$$


Příklad: Švýcarská rolka



Lokálně lineární vnoření švýcarské rolky do dvou dimenzí pro $k = 15$ sousedů.

Závěrečné poznámky


V případě, že je počet použitých nejbližších sousedů k větší než dimenze p původního prostoru příznaků, jsou body z okolí lineárně závislé. Pro tento případ je výhodné použít **modifikované LLE**.



Modifikované LLE


Závěrečné poznámky

V případě, že je počet použitých nejbližších sousedů k větší než dimenze p původního prostoru příznaků, jsou body z okolí lineárně závislé. Pro tento případ je výhodné použít **modifikované LLE**.




Modifikované LLE


Existují také další metody jako např. Multi-dimensional Scaling (MDS), Isomap, t-distributed Stochastic Neighbor Embedding (t-SNE).



MDS



Isomap



t-SNE