


Ortogonalní projekce

Definice: Nechť W je prostor se skalárním součinem a V je jeho *podprostor* s ortonormální bazí $Z = (\mathbf{v}_1, \dots, \mathbf{v}_n)$.

Zobrazení $p_Z : W \rightarrow V$ definované $p_Z(\mathbf{u}) = \sum_{i=1}^n \langle \mathbf{u} | \mathbf{v}_i \rangle \mathbf{v}_i$ je *ortogonalní projekce* W na V .

Příklad:



Pozorování: Ortogonální projekce je lineární zobrazení.

Důkaz:

$$p_Z(\mathbf{a}\mathbf{u}) = \sum_{i=1}^n \langle \mathbf{a}\mathbf{u} | \mathbf{v}_i \rangle \mathbf{v}_i = \sum_{i=1}^n a \langle \mathbf{u} | \mathbf{v}_i \rangle \mathbf{v}_i = a \sum_{i=1}^n \langle \mathbf{u} | \mathbf{v}_i \rangle \mathbf{v}_i = a p_Z(\mathbf{u})$$

$$p_Z(\mathbf{u} + \mathbf{w}) = \sum_{i=1}^n \langle \mathbf{u} + \mathbf{w} | \mathbf{v}_i \rangle \mathbf{v}_i = \sum_{i=1}^n (\langle \mathbf{u} | \mathbf{v}_i \rangle + \langle \mathbf{w} | \mathbf{v}_i \rangle) \mathbf{v}_i =$$

$$\sum_{i=1}^n \langle \mathbf{u} | \mathbf{v}_i \rangle \mathbf{v}_i + \sum_{i=1}^n \langle \mathbf{w} | \mathbf{v}_i \rangle \mathbf{v}_i = p_Z(\mathbf{u}) + p_Z(\mathbf{w})$$

Pozorování: Ortogonální projekce je lineární zobrazení.

Lemma: Nechť p_Z je ortogonální projekce W na V , potom $\mathbf{u} - p_Z(\mathbf{u}) \perp \mathbf{v}_i$ pro každé $\mathbf{v}_i \in Z$.


Důkaz:

$$\langle \mathbf{u} - p_Z(\mathbf{u}) | \mathbf{v}_i \rangle =$$

$$\left\langle \mathbf{u} - \sum_{j=1}^n \langle \mathbf{u} | \mathbf{v}_j \rangle \mathbf{v}_j \mid \mathbf{v}_i \right\rangle =$$

$$\langle \mathbf{u} | \mathbf{v}_i \rangle - \sum_{j=1}^n \langle \mathbf{u} | \mathbf{v}_j \rangle \langle \mathbf{v}_j | \mathbf{v}_i \rangle =$$

$$\langle \mathbf{u} | \mathbf{v}_i \rangle - \langle \mathbf{u} | \mathbf{v}_i \rangle = 0$$



Projekce a vzdálenost

Pozorování: Vektor $p_Z(\mathbf{u})$ je vektor z $V = \mathcal{L}(Z)$, který je nejbližší k \mathbf{u} v tom smyslu, že minimalizuje $\|\mathbf{u} - p_Z(\mathbf{u})\|$.

Důkaz: Pro $\mathbf{w} \in V$, $\mathbf{w} \neq p_Z(\mathbf{u})$

vezměme $\mathbf{a} = \mathbf{u} - p_Z(\mathbf{u})$,

$\mathbf{b} = p_Z(\mathbf{u}) - \mathbf{w} \neq \mathbf{0}$. \perp

Protože $\mathbf{b} \in V$, máme $\langle \mathbf{a} | \mathbf{b} \rangle = 0$.

Nyní: $\|\mathbf{u} - \mathbf{w}\| = \|\mathbf{a} + \mathbf{b}\|$


$$= \sqrt{\langle \mathbf{a} + \mathbf{b} | \mathbf{a} + \mathbf{b} \rangle}$$

$$= \sqrt{\langle \mathbf{a} | \mathbf{a} \rangle + \langle \mathbf{a} | \mathbf{b} \rangle + \langle \mathbf{b} | \mathbf{a} \rangle + \langle \mathbf{b} | \mathbf{b} \rangle}$$

$$= \sqrt{\langle \mathbf{a} | \mathbf{a} \rangle + \langle \mathbf{b} | \mathbf{b} \rangle}$$

$$> \sqrt{\langle \mathbf{a} | \mathbf{a} \rangle}$$

$$= \|\mathbf{a}\| = \|\mathbf{u} - p_Z(\mathbf{u})\|$$



Důsledek: Zobrazení p_Z nezávisí na volbě báze Z .

Přibližné řešení neřešitelných soustav

Pozorování: Vektor $p_Z(\mathbf{u})$ je vektor z $V = \mathcal{L}(Z)$, který je nejbližší k \mathbf{u} v tom smyslu, že minimalizuje $\|\mathbf{u} - p_Z(\mathbf{u})\|$.

Pokud soustava $\mathbf{Ax} = \mathbf{b}$ nemá řešení, tj. když $\mathbf{b} \notin \mathcal{S}(\mathbf{A})$, pak můžeme promítnout \mathbf{b} do $\mathcal{S}(\mathbf{A})$ a získat \mathbf{b}' .

Soustava $\mathbf{Ax} = \mathbf{b}'$ má nyní řešení. V důsledku pozorování takové \mathbf{x} minimalizuje chybu $\|\mathbf{b} - \mathbf{b}'\| = \|\mathbf{b} - \mathbf{Ax}\|$.

To je princip tzv. *metody nejmenších čtverců*.

Gram-Schmidtova ortonormalizace

Algoritmus, který převede libovolnou bázi $(\mathbf{u}_1, \dots, \mathbf{u}_n)$ prostoru V se skalárním součinem na ortonormální bázi $(\mathbf{v}_1, \dots, \mathbf{v}_n)$:

```
for  $i = 1, \dots, n$  do
     $\mathbf{w}_i = \mathbf{u}_i - \sum_{j=1}^{i-1} \langle \mathbf{u}_i | \mathbf{v}_j \rangle \mathbf{v}_j$ 
     $\mathbf{v}_i = \frac{1}{\|\mathbf{w}_i\|} \mathbf{w}_i$ 
end
```


Gram-Schmidtova ortonormalizace — ukázka

for $i = 1, \dots, n$ **do**

$$\mathbf{w}_i = \mathbf{u}_i - \sum_{j=1}^{i-1} \langle \mathbf{u}_i | \mathbf{v}_j \rangle \mathbf{v}_j$$


$$\mathbf{v}_i = \frac{1}{\|\mathbf{w}_i\|} \mathbf{w}_i$$

end



Gram-Schmidtova ortonormalizace — ukázka

```
for  $i = 1, \dots, n$  do  
     $w_i = u_i - \sum_{j=1}^{i-1} \langle u_i | v_j \rangle v_j$   
     $v_i = \frac{1}{\|w_i\|} w_i$   
end
```




Gram-Schmidtova ortonormalizace — ukázka

for $i = 1, \dots, n$ **do**

$$\mathbf{w}_i = \mathbf{u}_i - \sum_{j=1}^{i-1} \langle \mathbf{u}_i | \mathbf{v}_j \rangle \mathbf{v}_j$$

$$\mathbf{v}_i = \frac{1}{\|\mathbf{w}_i\|} \mathbf{w}_i$$

end




$i = 1$:

$$\mathbf{w}_1 = \mathbf{u}_1 - \sum_{j=1}^0 \langle \mathbf{u}_1 | \mathbf{v}_j \rangle \mathbf{v}_j = \mathbf{u}_1 = (1, 0, 0)^T$$

$$\mathbf{v}_1 = \frac{1}{\|\mathbf{w}_1\|} \mathbf{w}_1 = \frac{1}{1} (1, 0, 0)^T = (1, 0, 0)^T$$

Gram-Schmidtova ortonormalizace — ukázka

```
for  $i = 1, \dots, n$  do  
     $w_i = u_i - \sum_{j=1}^{i-1} \langle u_i | v_j \rangle v_j$   
     $v_i = \frac{1}{\|w_i\|} w_i$   
end
```




$i = 2 :$

$$w_2 = u_2 - \langle u_2 | v_1 \rangle v_1 = (1, 1, 0)^T - 1 \cdot (1, 0, 0)^T = (0, 1, 0)^T$$

$$v_2 = \frac{1}{\|w_2\|} w_2 = \frac{1}{1} (0, 1, 0)^T = (0, 1, 0)^T$$

Gram-Schmidtova ortonormalizace — ukázka

```
for  $i = 1, \dots, n$  do  
     $\mathbf{w}_i = \mathbf{u}_i - \sum_{j=1}^{i-1} \langle \mathbf{u}_i | \mathbf{v}_j \rangle \mathbf{v}_j$   
     $\mathbf{v}_i = \frac{1}{\|\mathbf{w}_i\|} \mathbf{w}_i$   
end
```



$i = 3 :$


$$\begin{aligned} \mathbf{w}_3 &= \mathbf{u}_3 - \langle \mathbf{u}_3 | \mathbf{v}_1 \rangle \mathbf{v}_1 - \langle \mathbf{u}_3 | \mathbf{v}_2 \rangle \mathbf{v}_2 = \\ &= (2, 1, 2)^T - 2 \cdot (1, 0, 0)^T - 1 \cdot (0, 1, 0)^T = (0, 0, 2)^T \end{aligned}$$

$$\mathbf{v}_3 = \frac{1}{\|\mathbf{w}_3\|} \mathbf{w}_3 = \frac{1}{2} (0, 0, 2)^T = (0, 0, 1)^T$$

Gram-Schmidtova ortonormalizace — jiné pořadí


```
for  $i = 1, \dots, n$  do  
     $w_i = u_i - \sum_{j=1}^{i-1} \langle u_i | v_j \rangle v_j$   
     $v_i = \frac{1}{\|w_i\|} w_i$   
end
```

Pro jiné pořadí se výpočty budou hrnsit!



Gram-Schmidtova ortonormalizace — jiné pořadí

```
for  $i = 1, \dots, n$  do  
     $\mathbf{w}_i = \mathbf{u}_i - \sum_{j=1}^{i-1} \langle \mathbf{u}_i | \mathbf{v}_j \rangle \mathbf{v}_j$   
     $\mathbf{v}_i = \frac{1}{\|\mathbf{w}_i\|} \mathbf{w}_i$   
end
```




$i = 1 :$

$$\mathbf{w}_1 = \mathbf{u}_1 = (2, 1, 2)^T$$

$$\mathbf{v}_1 = \frac{1}{\|\mathbf{w}_1\|} \mathbf{w}_1 = \frac{1}{3}(2, 1, 2)^T = \left(\frac{2}{3}, \frac{1}{3}, \frac{2}{3}\right)^T$$

Gram-Schmidtova ortonormalizace — jiné pořadí

```
for  $i = 1, \dots, n$  do
     $\mathbf{w}_i = \mathbf{u}_i - \sum_{j=1}^{i-1} \langle \mathbf{u}_i | \mathbf{v}_j \rangle \mathbf{v}_j$ 
     $\mathbf{v}_i = \frac{1}{\|\mathbf{w}_i\|} \mathbf{w}_i$ 
end
```




$i = 2 :$

$$\mathbf{w}_2 = \mathbf{u}_2 - \langle \mathbf{u}_2 | \mathbf{v}_1 \rangle \mathbf{v}_1 = (1, 1, 0)^T - 1 \cdot \left(\frac{2}{3}, \frac{1}{3}, \frac{2}{3}\right)^T = \left(\frac{1}{3}, \frac{2}{3}, -\frac{2}{3}\right)^T$$

$$\mathbf{v}_2 = \frac{1}{\|\mathbf{w}_2\|} \mathbf{w}_2 = \frac{1}{1} \left(\frac{1}{3}, \frac{2}{3}, -\frac{2}{3}\right)^T$$

Gram-Schmidtova ortonormalizace — jiné pořadí

```
for  $i = 1, \dots, n$  do  
     $w_i = u_i - \sum_{j=1}^{i-1} \langle u_i | v_j \rangle v_j$   
     $v_i = \frac{1}{\|w_i\|} w_i$   
end
```



$i = 3 :$

$$\begin{aligned} w_3 &= u_3 - \langle u_3 | v_1 \rangle v_1 - \langle u_3 | v_2 \rangle v_2 = \\ &= (1, 0, 0)^T - \frac{2}{3} \cdot \left(\frac{2}{3}, \frac{1}{3}, \frac{2}{3}\right)^T - \frac{1}{3} \cdot \left(\frac{1}{3}, \frac{2}{3}, -\frac{2}{3}\right)^T = \left(\frac{4}{9}, -\frac{4}{9}, -\frac{2}{9}\right)^T \end{aligned}$$

$$v_3 = \frac{1}{\|w_3\|} w_3 = \frac{1}{2/3} \left(\frac{4}{9}, -\frac{4}{9}, -\frac{2}{9}\right)^T = \left(\frac{2}{3}, -\frac{2}{3}, -\frac{1}{3}\right)^T$$

Gram-Schmidtova ortonormalizace

Algoritmus, který převede libovolnou bázi $(\mathbf{u}_1, \dots, \mathbf{u}_n)$ prostoru V se skalárním součinem na ortonormální bázi $(\mathbf{v}_1, \dots, \mathbf{v}_n)$:

```
for  $i = 1, \dots, n$  do
    1.  $\mathbf{w}_i = \mathbf{u}_i - \sum_{j=1}^{i-1} \langle \mathbf{u}_i | \mathbf{v}_j \rangle \mathbf{v}_j$ 
    2.  $\mathbf{v}_i = \frac{1}{\|\mathbf{w}_i\|} \mathbf{w}_i$ 
end
```

Správnost:

▶ Díky 1. a předchozímu lemmatu: $\mathbf{w}_i \perp \mathbf{v}_j$ pro každé $j < i$,
odtud $\mathbf{v}_i \perp \mathbf{v}_j$ pro $j \neq i$

▶ Díky 2.: $\|\mathbf{v}_i\| = \left\| \frac{1}{\|\mathbf{w}_i\|} \mathbf{w}_i \right\| = \frac{\|\mathbf{w}_i\|}{\|\mathbf{w}_i\|} = 1$.

▶ Díky lemmatu o výměně:


$$\mathcal{L}(\mathbf{v}_1, \dots, \mathbf{v}_{i-1}, \mathbf{u}_i) = \mathcal{L}(\mathbf{v}_1, \dots, \mathbf{v}_{i-1}, \mathbf{w}_i) = \mathcal{L}(\mathbf{v}_1, \dots, \mathbf{v}_i)$$

Důsledek: Nechť V je podprostor prostoru W se skalárním součinem. Každou ortonormální bázi podprostoru V lze rozšířit na ortonormální bázi prostoru W .

Lineární zobrazení, které zachovávají skalární součin

Definice: Lineární zobrazení f mezi prostory V a W je *isometrie*, pokud zachovává skalární součin, neboli $\langle \mathbf{u} | \mathbf{w} \rangle = \langle f(\mathbf{u}) | f(\mathbf{w}) \rangle$.


Příklad: Identita zachovává vektory, tedy i skalární součin.



Lineární zobrazení, které zachovávají skalární součin

Definice: Lineární zobrazení f mezi prostory V a W je *isometrie*, pokud zachovává skalární součin, neboli $\langle \mathbf{u} | \mathbf{w} \rangle = \langle f(\mathbf{u}) | f(\mathbf{w}) \rangle$.

Příklad: Osová souměrnost zachovává skalární součin.



Lineární zobrazení, které zachovávají skalární součin

Definice: Lineární zobrazení f mezi prostory V a W je *isometrie*, pokud zachovává skalární součin, neboli $\langle \mathbf{u} | \mathbf{w} \rangle = \langle f(\mathbf{u}) | f(\mathbf{w}) \rangle$.

Věta: Lineární zobrazení mezi prostory V a W je izometrie *právě když* zachovává související normu, tj. $\|\mathbf{u}\| = \|f(\mathbf{u})\|$.

Důkaz: Protože norma závisí na skalárním součinu, máme \Rightarrow .

\Leftarrow porovnejme:

$$\begin{aligned} \|\mathbf{u} + a\mathbf{w}\|^2 &= \|\mathbf{u}\|^2 + a\langle \mathbf{w} | \mathbf{u} \rangle + \bar{a}\langle \mathbf{u} | \mathbf{w} \rangle + a\bar{a}\|\mathbf{w}\|^2 \\ \|f(\mathbf{u} + a\mathbf{w})\|^2 &= \|f(\mathbf{u})\|^2 + a\langle f(\mathbf{w}) | f(\mathbf{u}) \rangle + \bar{a}\langle f(\mathbf{u}) | f(\mathbf{w}) \rangle + a\bar{a}\|f(\mathbf{w})\|^2 \end{aligned}$$

pro $a = 1$ máme: $\langle \mathbf{w} | \mathbf{u} \rangle + \langle \mathbf{u} | \mathbf{w} \rangle = \langle f(\mathbf{w}) | f(\mathbf{u}) \rangle + \langle f(\mathbf{u}) | f(\mathbf{w}) \rangle$


pro $a = i$ máme: $\langle \mathbf{w} | \mathbf{u} \rangle - \langle \mathbf{u} | \mathbf{w} \rangle = \langle f(\mathbf{w}) | f(\mathbf{u}) \rangle - \langle f(\mathbf{u}) | f(\mathbf{w}) \rangle$

$$\Rightarrow \langle \mathbf{u} | \mathbf{w} \rangle = \langle f(\mathbf{u}) | f(\mathbf{w}) \rangle$$

Maticová charakterizace bijektivních izometrií

Věta: Necht' V a W jsou prostory se skalárním součinem konečné dimenze a X, Y jsou jejich ortonormální báze. Lineární zobrazení $f : V \rightarrow W$ je bijektivní izometrie, právě když $[f]_{XY}$ je unitární.

Příklad:



Všimněte si, že součin unitárních matic je unitární.

Maticová charakterizace bijektivních izometrií

Věta: Necht' V a W jsou prostory se skalárním součinem konečné dimenze a X, Y jsou jejich ortonormální báze. Lineární zobrazení $f : V \rightarrow W$ je bijektivní izometrie, právě když $[f]_{XY}$ je unitární.

Důkaz: Lineární bijekce implikuje stejné dimenze a naopak.

Protože X je ortonormální: $\langle \mathbf{u} | \mathbf{w} \rangle = [\mathbf{w}]_X^H [\mathbf{u}]_X$

Protože Y je ortonormální: $\langle f(\mathbf{u}) | f(\mathbf{w}) \rangle = [f(\mathbf{w})]_Y^H [f(\mathbf{u})]_Y$
 $= [\mathbf{w}]_X^H [f]_{XY}^H [f]_{XY} [\mathbf{u}]_X$

Všimněte si, že maticová rovnost $\mathbf{x}^T \mathbf{y} = \mathbf{x}^T \mathbf{A} \mathbf{y}$ platí pro všechny vhodné vektory \mathbf{x} a \mathbf{y} pouze v případě, je-li \mathbf{A} jednotková matice.

V našem případě je f izometrie pokud


$[\mathbf{w}]_X^H [\mathbf{u}]_X = [\mathbf{w}]_X^H [f]_{XY}^H [f]_{XY} [\mathbf{u}]_X$ platí pro všechna \mathbf{u} a \mathbf{w} ,
což platí právě když $[f]_{XY}^H [f]_{XY} = \mathbf{I}$, neboli je-li $[f]_{XY}$ unitární.

Ortogonalní doplněk

Definice: *Ortogonalní doplněk* podmnožiny V prostoru se skalárním součinem W je $V^\perp = \{u \in W : \forall v \in V : u \perp v\}$.

Příklad:

Ten doplněk je jen prostor všech podmnožin vektorů na daném prostoru




Pozorování: Pokud $U \subseteq V$, pak $U^\perp \supseteq V^\perp$.

Důkaz: $V^\perp = \{u \in W : \forall v \in V : u \perp v\}$
 $\subseteq \{u \in W : \forall v \in U : u \perp v\} = U^\perp$

Ortogonalní doplněk

Definice: *Ortogonalní doplněk* podmnožiny V prostoru se skalárním součinem W je $V^\perp = \{\mathbf{u} \in W : \forall \mathbf{v} \in V : \mathbf{u} \perp \mathbf{v}\}$.

Příklad:



Pozorování: Pokud $U \subseteq V$, pak $U^\perp \supseteq V^\perp$.

Pozorování: Každý ortogonalní doplněk je podprostorem W .


Důkaz: $\mathbf{u} \perp \mathbf{v} \implies \langle a\mathbf{u} | \mathbf{v} \rangle = a\langle \mathbf{u} | \mathbf{v} \rangle = 0 \implies (a\mathbf{u}) \perp \mathbf{v}$

$\mathbf{u}, \mathbf{w} \perp \mathbf{v} \implies \langle \mathbf{u} + \mathbf{w} | \mathbf{v} \rangle = \langle \mathbf{u} | \mathbf{v} \rangle + \langle \mathbf{w} | \mathbf{v} \rangle = 0 \implies (\mathbf{u} + \mathbf{w}) \perp \mathbf{v}$

Ortogonalní doplněk

Definice: *Ortogonalní doplněk* podmnožiny V prostoru se skalárním součinem W je $V^\perp = \{u \in W : \forall v \in V : u \perp v\}$.

Příklad:



*jenom nulový vektor dokáže
být na sebe kolmý*

Pozorování: Pokud $U \subseteq V$, pak $U^\perp \supseteq V^\perp$.

Pozorování: Každý orthogonalní doplněk je podprostorem W .

Pozorování: Pro jakékoli $V \subseteq W : V \cap V^\perp = \{0\}$

Důkaz: Jestliže $u \in V \cap V^\perp$, pak $\langle u|u \rangle = 0$, tedy $u = 0$.

Pro prostory určené maticí: $\text{Ker}(\mathbf{A}) = (\mathcal{R}(\mathbf{A}))^\perp$

$$\text{Pro reálnou maticí } \mathbf{A} = \begin{pmatrix} 1 & 3 & 4 & 5 \\ 2 & 6 & 3 & 0 \\ 3 & 9 & 15 & 9 \end{pmatrix} \sim \dots \sim \begin{pmatrix} 1 & 3 & 4 & 5 \\ 0 & 0 & 1 & -2 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

Proto $\mathcal{R}(\mathbf{A}) = \mathcal{L}\{(1, 3, 4, 5)^T, (0, 0, 1, -2)^T\} = \mathcal{L}\{\mathbf{x}^1, \mathbf{x}^2\}$,
a také $\text{Ker}(\mathbf{A}) = \mathcal{L}\{(-13, 0, 2, 1)^T, (-3, 1, 0, 0)^T\} = \mathcal{L}\{\mathbf{y}^1, \mathbf{y}^2\}$.

Tvrzení: Pro $\mathbf{A} \in \mathbb{R}^{m \times n}$ libovolné $\mathbf{u} \in \mathcal{R}(\mathbf{A})$ a $\mathbf{v} \in \text{Ker}(\mathbf{A})$ splňují $\mathbf{u} \perp \mathbf{v}$ vzhledem ke standardnímu skalárnímu součinu.

Příklad:

$$\mathbf{u} = \mathbf{x}^1 - 2\mathbf{x}^2 = (1, 3, 4, 5)^T - 2(0, 0, 1, -2)^T = (1, 3, 2, 9)^T$$

$$\mathbf{v} = \mathbf{y}^1 + 3\mathbf{y}^2 = (-13, 0, 2, 1)^T + 3(-3, 1, 0, 0)^T = (-22, 3, 2, 1)^T$$

$$\langle \mathbf{u} | \mathbf{v} \rangle = 1 \cdot (-22) + 3 \cdot 3 + 2 \cdot 2 + 9 \cdot 1 = 0$$

$$\langle \mathbf{u} | \mathbf{v} \rangle = \langle \mathbf{x}^1 - 2\mathbf{x}^2 | \mathbf{y}^1 + 3\mathbf{y}^2 \rangle =$$

$$= \langle \mathbf{x}^1 | \mathbf{y}^1 \rangle + 3\langle \mathbf{x}^1 | \mathbf{y}^2 \rangle - 2\langle \mathbf{x}^2 | \mathbf{y}^1 \rangle - 6\langle \mathbf{x}^2 | \mathbf{y}^2 \rangle = \mathbf{0}$$

*Takhle to
vychází vždy!*

Pro prostory určené maticí: $\text{Ker}(\mathbf{A}) = (\mathcal{R}(\mathbf{A}))^\perp$

$$\text{Pro reálnou maticí } \mathbf{A} = \begin{pmatrix} 1 & 3 & 4 & 5 \\ 2 & 6 & 3 & 0 \\ 3 & 9 & 15 & 9 \end{pmatrix} \sim \dots \sim \begin{pmatrix} 1 & 3 & 4 & 5 \\ 0 & 0 & 1 & -2 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

Proto $\mathcal{R}(\mathbf{A}) = \mathcal{L}\{(1, 3, 4, 5)^T, (0, 0, 1, -2)^T\} = \mathcal{L}\{\mathbf{x}^1, \mathbf{x}^2\}$,
a také $\text{Ker}(\mathbf{A}) = \mathcal{L}\{(-13, 0, 2, 1)^T, (-3, 1, 0, 0)^T\} = \mathcal{L}\{\mathbf{y}^1, \mathbf{y}^2\}$.

Tvrzení: Pro $\mathbf{A} \in \mathbb{R}^{m \times n}$ libovolné $\mathbf{u} \in \mathcal{R}(\mathbf{A})$ a $\mathbf{v} \in \text{Ker}(\mathbf{A})$ splňují $\mathbf{u} \perp \mathbf{v}$ vzhledem ke standardnímu skalárnímu součinu.


Důkaz: Označme $\mathbf{x}^1, \dots, \mathbf{x}^r$ bázi $\mathcal{R}(\mathbf{A})$, a podobně $\mathbf{y}^1, \dots, \mathbf{y}^{n-r}$ bázi $\text{Ker}(\mathbf{A})$, kde $r = \text{rank}(\mathbf{A})$.

Potom $\mathbf{u} = \sum_{i=1}^r a_i \mathbf{x}^i$ a $\mathbf{v} = \sum_{j=1}^{n-r} b_j \mathbf{y}^j$ splňují

$$\langle \mathbf{u} | \mathbf{v} \rangle = \left\langle \sum_{i=1}^r a_i \mathbf{x}_i \mid \sum_{j=1}^{n-r} b_j \mathbf{y}_j \right\rangle = \sum_{i=1}^r \sum_{j=1}^{n-r} a_i b_j \langle \mathbf{x}_i | \mathbf{y}_j \rangle = 0.$$

Vlastnosti ortogonálního doplňku

Věta: Pro konečně generovaný prostor W se skalárním součinem a podprostor V platí: $(V^\perp)^\perp = V$ a $\dim(V) + \dim(V^\perp) = \dim(W)$.



Vlastnosti ortogonálního doplňku

Věta: Pro konečně generovaný prostor W se skalárním součinem a podprostor V platí: $(V^\perp)^\perp = V$ a $\dim(V) + \dim(V^\perp) = \dim(W)$.

Důkaz: Zvolíme nějakou ortonormální bázi X prostoru V a doplníme ji na ortonormální bázi Z prostoru W .

Označme $Y = Z \setminus X$, $X = (\mathbf{x}_1, \dots, \mathbf{x}_k)$, $Y = (\mathbf{y}_1, \dots, \mathbf{y}_l)$.

Každé $\mathbf{u} \in \mathcal{L}(X) = V$ je kolmé ke každému $\mathbf{v} \in \mathcal{L}(Y)$:

$$\langle \mathbf{u} | \mathbf{v} \rangle = \left\langle \sum_{i=1}^n a_i \mathbf{x}_i \mid \sum_{j=1}^n b_j \mathbf{y}_j \right\rangle = \sum_{i=1}^n \sum_{j=1}^n a_i \bar{b}_j \langle \mathbf{x}_i | \mathbf{y}_j \rangle = 0$$

protože Z je ortonormální báze. Proto $\mathcal{L}(Y) \subseteq V^\perp$.

Nyní vezměme $\mathbf{w} \in V^\perp$ a uvažme $[\mathbf{w}]_Z$. Protože Z je ortonormální, koeficienty \mathbf{w} vzhledem k Z jsou Fourierovy koeficienty dané skalárním součinem \mathbf{w} s prvky báze Z .

Protože $\mathbf{w} \in V^\perp$, máme $\langle \mathbf{w} | \mathbf{x}_i \rangle = 0$ pro každé $\mathbf{x}_i \in X$, tedy $\mathbf{w} \in \mathcal{L}(Y)$, t.j. $V^\perp \subseteq \mathcal{L}(Y)$, a tedy $V^\perp = \mathcal{L}(Y)$.

Nyní: $\dim(V) + \dim(V^\perp) = |X| + |Y| = |Z| = \dim(W)$

a také: $(V^\perp)^\perp = \mathcal{L}(Z \setminus Y) = \mathcal{L}(X) = V$.