

# Rekonstrukciós eljárások

Orvosi képdiagnosztika

2019 ősz

# Modell alapú rekonstrukciós eljárások (Röntgen alapú képalkotás)

- Cél a páciensre érő sugárterhelés minimalizálása:
  - Viszont kisebb dózis zajosabb projekciókat eredményez
  - Limitált szögtartomány problémája jelentősen alulhatározottá teszi a z inverz problémát (  $\mathbf{g} = \mathbf{H} \cdot \mathbf{f}$  )
- MAP becslés alkalmazása szükséges:
  - Emlékeztetőül  $\mathbf{f}^* = \arg \max_{\mathbf{f}} \{P\{\mathbf{f}|\mathbf{g}\}\} \propto \arg \max_{\mathbf{f}} \{ (P\{g|f\} \cdot P\{f\}) \}$
  - $-\log(P\{\mathbf{g}|\mathbf{f}\}) = \Phi_{Likelihood}(\mathbf{f})$  bünteti az eltérést
  - $-\log(P\{\mathbf{f}\}) = \Phi_{Prior}(\mathbf{f})$  apriori ismeretek alapján regularizál

# Modell alapú rekonstrukciós eljárások (Röntgen alapú képalkotás)

- Likelihood tag megválasztása:
  - PET-nél Poisson modellt alkalmazunk („ritka esemény törvény”)
  - Röntgen esetén negatív logaritmálást követően Gauss modell

$$\Phi_{Likelihood}(\mathbf{f}) = 1/2 \cdot (\mathbf{g} - \mathbf{H} \cdot \mathbf{f})^T \cdot \mathbf{\Sigma}^{-1} \cdot (\mathbf{g} - \mathbf{H} \cdot \mathbf{f})$$

- $\mathbf{\Sigma}$  gyakran diagonális, ekkor  $\Sigma_{(i,i)} = \sigma_{(i)}^2$ :
  - Lényegében az i-edik vetítősugár NSR-jének a négyzete
  - Megfelelő megválasztása nehéz, aktívan kutatott feladat
- Kvadratikus függvény, minimalizációja analitikus

# Modell alapú rekonstrukciós eljárások (Röntgen alapú képalkotás)

- Regularizációs tag megválasztása:
  - Logikusnak tűnik a gradiens energiáját büntetni:  
$$\Phi_{\text{Prior}}(\mathbf{f}) = \alpha \cdot \mathbf{f}^T \cdot \mathbf{S} \cdot \mathbf{f}, \quad \mathbf{S} = \mathbf{D}^T \cdot \mathbf{D},$$
 ahol  $\mathbf{D}$  a deriválás mtr.-ja
    - Belátható, hogy ekvivalens egy regularizáció nélküli rekonstrukció alul-áteresztettjével.
    - Tehát ez a regularizáció csökkenti az effektív felbontást (mind a rekonstruált szeleteken belül, mind azok között a modalitástól függetlenül).
  - Inkább él őrző regularizációk alkalmazása javallott pl. Teljes Variancia minimalizáció, Huber büntetőfüggvény ...

# Compressive Sensing

- Nyquist mintavételnek megfelelő interpoláció:
  - Régebben láttuk a kernelét
  - De ez csak egy interpolációs lehetőség
- Compressive Sensing alapú megközelítés:
  - Nem szükséges Nyquist tétel szerint mintavételezni
  - Két általános megvalósítása létezik:
    - Megszorítjuk a rekonstruálni kívánt jel bázisát (erre lesz példa a Mátrix Inverziós Tomoszintézis)
    - Keresünk egy olyan operátort / ábrázolást ami felett ritka a rekonstruálni kívánt jel (pl. TV minimalizációs)

# Compressed Sensing

- Hány minta szükséges egy jel rekonstrukciójához?
  - Shannon Nyquist tétel –  $f_s \geq 2 \cdot bw$ 
    - Túl általános – nem veszi figyelembe, hogy a tipikus jelek egy alacsonyabb dimenziós sokasággal (manifolddal) leírhatóak.
  - Ha ismert lenne egy jó prior, akkor kevesebb is elég lenne
    - Pl.  $P\{f\} = \delta\{f - f^*\}$  (na jó, ehhez már mérni sem kell 😊)
- Keressünk olyan ábrázolást, ahol ritka a jelünk:
  - $\mathbf{f} = \sum \psi_i x_i$ , ahol  $\{\psi_1, \dots, \psi_n\}$  egy ortonormált bázis, e felett ritka az ábrázolás, azaz  $|x_i| \approx 0$  sok  $i$ -re
  - $y_k = \mathbf{f}^T \cdot \boldsymbol{\phi}_k$  - mérések

# Compressed Sensing

- $m$  db  $\Phi$  szerinti mérésből visszaállítható  $\mathbf{f}$ , ha:

$$m \geq C \cdot \mu^2(\Phi, \Psi) \cdot S \cdot \log(n)$$

–  $\mu(\Phi, \Psi) = \sqrt{n} \max_{k,j} \{|\phi_k^T \psi_j|\}$ : a ritka ábrázoláshoz tartozó bázis, illetve az érzékelési bázis koherenciája (max. korreláció)

–  $m$ : input mérések száma

–  $n$ : visszaállítandó jel ( $\mathbf{f}$ ) dimenziója


–  $S$ : nem 0  $\psi_j^T \cdot \mathbf{f}$ -ek száma (mért jel *ritkasága*)

–  $C$ : pozitív konstans

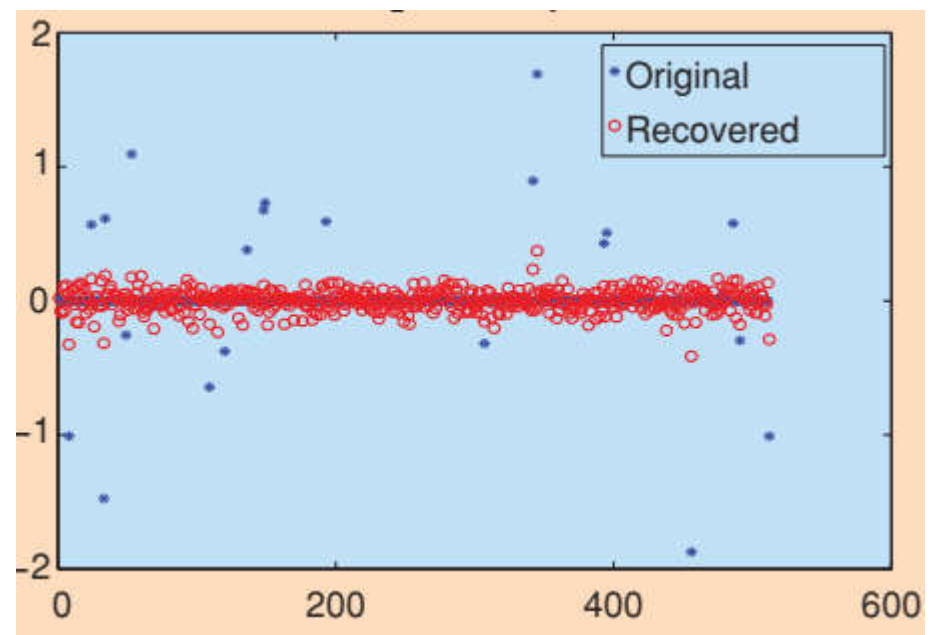
- Visszaállítás: 
$$\begin{array}{ll} \min. & \|\mathbf{x}\|_1 \\ \text{s.t.} & \mathbf{y} = \Phi^T \cdot \Psi \cdot \mathbf{x} \end{array}$$

# Példa – 1d jelek leírása

- Célfüggvénynek fontos szerepe van a történetben:
  - L2 normával pl. szinte alkalmazhatatlan



$$\begin{aligned} \min. \quad & \|\mathbf{x}\|_1 \\ \text{s.t.} \quad & \mathbf{y} = \mathbf{F} \cdot \mathbf{x} \end{aligned}$$




$$\begin{aligned} \min. \quad & \|\mathbf{x}\|_2 \\ \text{s.t.} \quad & \mathbf{y} = \mathbf{F} \cdot \mathbf{x} \end{aligned}$$



# Példa – képek tömörítése

- JPEG 2000-es Wavelet alapú koordinátázás:
  - Együtthetők 2,5%-át megtartva szinte minimális rekonstrukciós hiba



# Compressed Sensing

- Keressünk az érzékelési bázistól eltérő (inhomogén), ritka bázist:
  - Képek általában homogén konstans intenzitású területek sokaságaira bonthatóak (kivéve a textúra, stb. részeket)
  - Wavelet trafók is ilyen bázisnak tekinthetőek
    - Kevésbé ritkák, mint a TV bázis

- TV-L1 / L0 dekonvolúció:

$$\begin{aligned} \min. \quad & \|\mathbf{x}\|_2 = \sum \|\mathbf{x}_i\|_2 \\ \text{s.t.} \quad & \mathbf{y} = \mathbf{\Phi}^T \cdot \mathbf{I} \cdot \mathbf{x} \end{aligned}$$

$$\begin{aligned} \min. \quad & \|\mathbf{x}\|_0 = \sum 1 - \delta(\|\mathbf{x}_i\|) \\ \text{s.t.} \quad & \mathbf{y} = \mathbf{\Phi}^T \cdot \mathbf{I} \cdot \mathbf{x} \end{aligned}$$

- $\mathbf{x}$ : rekonstruált kép gradiens vektormezője
- $\mathbf{I}$ : gradiens vektormezőből az eredeti kép integráló mátrixa

# Teljes variancia minimalizáció

- Rekonstrukció, mint optimalizálási feladat:

$$\mathbf{f}^* = \arg \min_{\mathbf{f}} \left\{ \|\mathbf{g} - \mathbf{H} \cdot \mathbf{f}\|_2^2 + \lambda \cdot \|\mathbf{D} \cdot \mathbf{f}\|_1 \right\}$$

- $\mathbf{D}$  diszkrét differencia / wavelet transzformációk mátrixia
- Lényegi változás, hogy a regularizáció L2 norma szerinti

- Alternating Direction Methode:  $\mathbf{z} = \mathbf{D} \cdot \mathbf{f}$  változóval

$$\Phi(\mathbf{f}, \mathbf{z}) \triangleq \|\mathbf{g} - \mathbf{H} \cdot \mathbf{f}\|_2^2 + \lambda \cdot \|\mathbf{z}\|_1 + \beta \cdot \|\mathbf{z} - \mathbf{D} \cdot \mathbf{f}\|_2^2$$

- Alternálva minimalizáljuk  $\mathbf{f}$ -et és  $\mathbf{z}$ -t iterációnként:

$$\mathbf{f}^{(n+1)} = \arg \min_{\mathbf{f}} \left\{ \Phi(\mathbf{f}, \mathbf{z}^{(n)}) \right\} = \arg \min_{\mathbf{f}} \left\{ \|\mathbf{g} - \mathbf{H} \cdot \mathbf{f}\|_2^2 + \beta \cdot \|\mathbf{z}^{(n)} - \mathbf{D} \cdot \mathbf{f}\|_2^2 \right\}$$

$$\mathbf{z}^{(n+1)} = \arg \min_{\mathbf{z}} \left\{ \Phi(\mathbf{f}^{(n+1)}, \mathbf{z}) \right\} = \arg \min_{\mathbf{z}} \left\{ \lambda \cdot \|\mathbf{z}\|_1 + \beta \cdot \|\mathbf{z} - \mathbf{D} \cdot \mathbf{f}^{(n+1)}\|_2^2 \right\}$$

# Teljes variancia minimalizáció

– Az iterációk első lépése kicsit átalakítva:

$$\min_{\mathbf{f}} \left\| \begin{bmatrix} \mathbf{g}^T & \sqrt{\beta} \cdot \mathbf{z}^{(n)T} \end{bmatrix} - \begin{bmatrix} \mathbf{H}^T & \sqrt{\beta} \cdot \mathbf{D}^T \end{bmatrix} \cdot \mathbf{f} \right\|_2^2$$


- Formálisan visszajutottunk az alapproblémához, csak most már biztosan túl-határozott (additív ART probléma)
- Minimalizálása erőforrásigény miatt sokszor SART-vel

– Iterációk második lépésének optimuma egy lépésben, analitikusan meghatározható:  $\arg \min_{\mathbf{z}} \left\{ \lambda \cdot \|\mathbf{z}\|_1 + \beta \cdot \|\mathbf{z} - \mathbf{D} \cdot \mathbf{f}^{(n+1)}\|_2^2 \right\}$

- Az úgynevezett lágy küszöb operátor használatával
- A minimalizálás voxelenként történik

# Teljes variancia minimalizáció

- Jobb SNR az ML-EM és az FBP-hez képest:
  - FBP-nél kevésbé zajos, de hasonló kontrasztú kép
  - ML-EM-nél jelentősen jobb kontraszt




# Huber büntetőfüggvény

- Huber büntetőfüggvénnyel regularizálunk:

$$\Phi_{\text{Prior}}(\mathbf{f}) = \alpha \cdot L_{\text{Huber}}\{\mathbf{D} \cdot \mathbf{f}\} \quad L_{\text{Huber}}(\mathbf{x}) = \begin{cases} \|\mathbf{x}\|_2^2/2 & \|\mathbf{x}\|_2 \leq \varepsilon \\ \varepsilon \cdot \|\mathbf{x}\|_2 - \varepsilon^2/2 & \|\mathbf{x}\|_2 > \varepsilon \end{cases}$$



Pet fantom





MAP L2 prior



MAP Huber prior


# Kvadratikus és abszolútérték hiba/büntetőfüggvény

- Két hibafüggvény jelentősen eltérő eloszlást kényszerít ki:



# Élet a konvex optimalizáción túl

- CT-s szimuláció, 10 projekcióból ( $\Delta\theta=18^\circ$ ):



Konvex: L2-TV




Valóban ritkasági priorral



# Lineáris tomoszintézis

- Speciális CBCT változatnak tekinthető:
  - Detektor és a sugárforrás egymással és a flat-panel detektor oszlopaival párhuzamosan mozog.
  - Projekciók limitált szögtartományból ( $\pm 10^\circ$ - $40^\circ$ )
- Irányfüggő felbontás / képminőség:
  - Detektorral párhuzamos szeletek felbontása megegyezik a detektor felbontásával
  - Detektorra merőleges irányban nagyon rossz felbontás : limitált szögtartomány ára ...




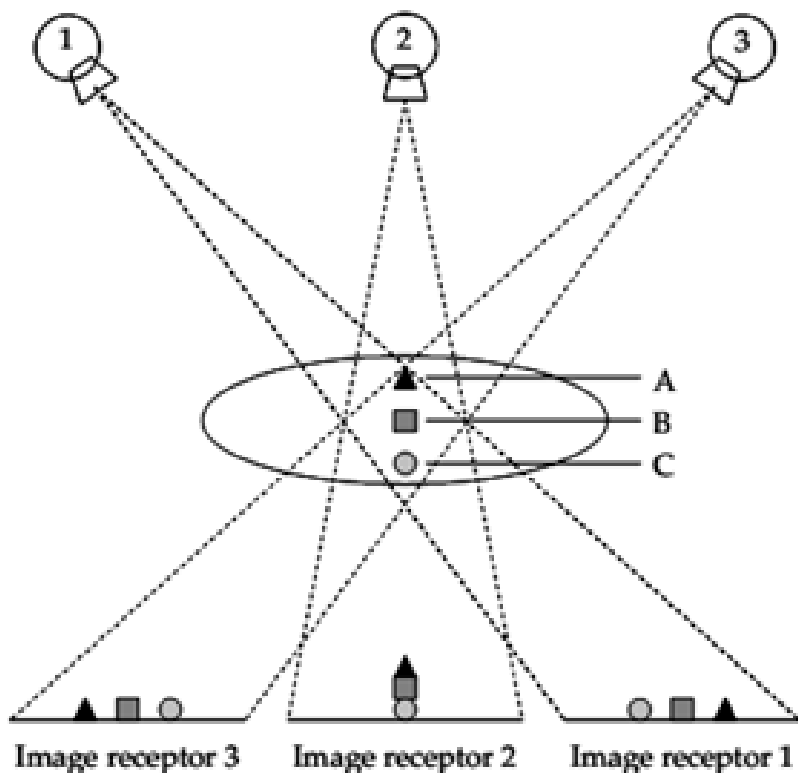
# Shift And Add

## (Lineáris tomoszintézis esetén)

- A térfogat 0 vastagságú szeleteinek vetületei a felvételi geometria és a szelet magasságának függvényében eltolódnak.
- SAA rekonstrukciója egy adott szeletnek:
  1. Projekciók eltolása úgy, hogy a rekonstruálni kívánt sík vetülete minden projekción azonos legyen
  2. Eltolt projekciók összegzése
- Mind az összegzés, mind az eltolás LTI művelet:
  - Soros kaszkádjuk, tehát a rekonstrukció egy MIMO LTI rendszer (bemenetek a projekciók, kimenetek a szeletek)
  - Létezik PSF/MTF-je, mellyel analitikusan minősíthető

# Shift And Add (Lineáris tomoszintézis esetén)

- SAA szeleteken fókuszbba kerülnek a rekonstruálni kívánt sík képleteinek vetületei
  - De jelentős átmosódás marad a térfogat többi síkjáról



Piros ellipszis: szeleten belüli képlet vetülete  
Kék ellipszis: szeleten kívüli képletek bemosódása

# Mátrix Inverziós Tomoszintézis

- Alapötletet ugyanaz a megfigyelés adja, mint ami az SAA algoritmusét:

$$\mathbf{g}_{(:,i)}^{(1)} = \mathbf{f}_{(:,i)}^{(1)} * \mathbf{t}_{(1,1)} + \mathbf{f}_{(:,i)}^{(2)} * \mathbf{t}_{(1,2)} + \dots + \mathbf{f}_{(:,i)}^{(n)} * \mathbf{t}_{(1,n)}$$

$$\mathbf{g}_{(:,i)}^{(2)} = \mathbf{f}_{(:,i)}^{(1)} * \mathbf{t}_{(2,1)} + \mathbf{f}_{(:,i)}^{(2)} * \mathbf{t}_{(2,2)} + \dots + \mathbf{f}_{(:,i)}^{(n)} * \mathbf{t}_{(2,n)}$$

⋮

$$\mathbf{g}_{(:,i)}^{(m)} = \mathbf{f}_{(:,i)}^{(1)} * \mathbf{t}_{(m,1)} + \mathbf{f}_{(:,i)}^{(2)} * \mathbf{t}_{(m,2)} + \dots + \mathbf{f}_{(:,i)}^{(n)} * \mathbf{t}_{(m,n)}$$

$\mathbf{g}_{(:,i)}^{(j)}$  j-edik projekció i-edik oszlopának intenzitásaiból képzett vektor

# Mátrix Inverziós Tomoszintézis

- Alapötletet ugyanaz a megfigyelés adja, mint ami az SAA algoritmusét:

$$\mathbf{g}_{(:,i)}^{(1)} = \mathbf{f}_{(:,i)}^{(1)} * \mathbf{t}_{(1,1)} + \mathbf{f}_{(:,i)}^{(2)} * \mathbf{t}_{(1,2)} + \dots + \mathbf{f}_{(:,i)}^{(n)} * \mathbf{t}_{(1,n)}$$

$$\mathbf{g}_{(:,i)}^{(2)} = \mathbf{f}_{(:,i)}^{(1)} * \mathbf{t}_{(2,1)} + \mathbf{f}_{(:,i)}^{(2)} * \mathbf{t}_{(2,2)} + \dots + \mathbf{f}_{(:,i)}^{(n)} * \mathbf{t}_{(2,n)}$$

⋮

$$\mathbf{g}_{(:,i)}^{(m)} = \mathbf{f}_{(:,i)}^{(1)} * \mathbf{t}_{(m,1)} + \mathbf{f}_{(:,i)}^{(2)} * \mathbf{t}_{(m,2)} + \dots + \mathbf{f}_{(:,i)}^{(n)} * \mathbf{t}_{(m,n)}$$

$\mathbf{f}_{(:,i)}^{(j)}$  j-edik modellezett és rekonstruálni kívánt 0 vastagságú szelet projekciójának i-edik oszlopának intenzitásaiból képzett vektor

# Mátrix Inverziós Tomoszintézis

- Alapötletet ugyanaz a megfigyelés adja, mint ami az SAA algoritmusét:

$$\mathbf{g}_{(:,i)}^{(1)} = \mathbf{f}_{(:,i)}^{(1)} * \mathbf{t}_{(1,1)} + \mathbf{f}_{(:,i)}^{(2)} * \mathbf{t}_{(1,2)} + \dots + \mathbf{f}_{(:,i)}^{(n)} * \mathbf{t}_{(1,n)}$$

$$\mathbf{g}_{(:,i)}^{(2)} = \mathbf{f}_{(:,i)}^{(1)} * \mathbf{t}_{(2,1)} + \mathbf{f}_{(:,i)}^{(2)} * \mathbf{t}_{(2,2)} + \dots + \mathbf{f}_{(:,i)}^{(n)} * \mathbf{t}_{(2,n)}$$

⋮

$$\mathbf{g}_{(:,i)}^{(m)} = \mathbf{f}_{(:,i)}^{(1)} * \mathbf{t}_{(m,1)} + \mathbf{f}_{(:,i)}^{(2)} * \mathbf{t}_{(m,2)} + \dots + \mathbf{f}_{(:,i)}^{(n)} * \mathbf{t}_{(m,n)}$$

$\mathbf{t}_{(j,i)}$  i-edik rekonstruálandó szelet vetületének j-edik projekcióbéli impulzusválaszát leíró vektor, mivel csak eltolást modellez, ezért egy dirac-delta diszkretizáltja.

# Mátrix Inverziós Tomoszintézis

- Jelentősen egyszerűsödik a feladat, ha a vektor egyenletrendszer frekvenciatérben vizsgáljuk:

$$\mathbf{g}_{(j)}(\omega) = \mathbf{T}(\omega) \cdot \mathbf{f}_{(j)}(\omega) \quad \Rightarrow \quad \mathbf{f}_{(j)}(\omega) = \mathbf{T}(\omega)^\dagger \cdot \mathbf{g}_{(j)}(\omega)$$

$$- \mathbf{g}_{(j)}(\omega) = \left[ FT_\omega \left\{ \mathbf{g}_{(:,j)}^{(1)} \right\} \quad FT_\omega \left\{ \mathbf{g}_{(:,j)}^{(2)} \right\} \quad \dots \quad FT_\omega \left\{ \mathbf{g}_{(:,j)}^{(m)} \right\} \right]^T$$

$$- \mathbf{f}_{(j)}(\omega) = \left[ FT_\omega \left\{ \mathbf{f}_{(:,j)}^{(1)} \right\} \quad FT_\omega \left\{ \mathbf{f}_{(:,j)}^{(2)} \right\} \quad \dots \quad FT_\omega \left\{ \mathbf{f}_{(:,j)}^{(n)} \right\} \right]^T$$

$$- \mathbf{T}(\omega) = \left\{ FT_{(\omega)} \left\{ \mathbf{t}_{(j,i)} \right\} \right\}$$

- Összegezve a MITS alapötlete, hogy lineáris tomo esetén a frekvenciatérbeli felírás jelentősen kompaktabb az inverz probléma képtérbeli felírásánál.

# Mátrix Inverziós Tomoszintézis gyakorlati megvalósítása


- Diszkretizálás és a DFT okozta problémák:
  - Mintavételezés:  $t_{(i,j)}$  mintavételezése az egész rendszer viselkedését jelentősen befolyásolja:
    - Energiája nem változhat(na) a mintavételezés hatására, de ez elkerülhetetlen...
    - Hogyan mintavételezzünk?  
Legjobb, ha u.ú., ahogyan a detektor is teszi
  - DFT által okozott spektrumszivárgás is jelentős probléma:
    - Klasszikus megoldás, az ablakozás natívan nem adekvát.



# Mátrix Inverziós Tomoszintézis spektrumszivárgás

- Felvételi elrendezés miatt oszloponként történik az inverz szűrés, elegendő a függőleges cirkularitás:
  - A projekciók extrapolációja nem úszható meg, ellenkező esetben a „csavarodás artefekt történik”.
  - Extrapoláció szükséges mértéke  $t_{(j,i)}$  tartóinak a maximuma, ezzel elérhető, hogy csak extrapolált terület csavarodhat be.
- Probléma projekciók extrapolálásával kezelhető:
  - Extrapoláció olyan képterülettel terjeszti ki a projekciókat, mely a „legsimább” átmenetet és cirkuláris projekciót generál.

# Mátrix Inverziós Tomoszintézis spektrumszivárgás



Extrapoláció nélkül



Extrapoláció alkalmazásával

# Mátrix Inverziós Tomoszintézis

## Dekonvolúció numerikus problémái

- $\mathbf{T}(\omega)^\dagger$  zajérzékenysége jelentős problémaforrás

– Kondíciós szám  $cond(\mathbf{T}(\omega)) = \sigma_{\max} / \sigma_{\min}$  származtatása:

$$cond(\mathbf{T}) = \max_{\mathbf{e}, \mathbf{b}} \left\{ \frac{\|\mathbf{T}^{-1} \cdot \mathbf{e}\|_2 / \|\mathbf{T}^{-1} \cdot \mathbf{b}\|_2}{\|\mathbf{e}\|_2 / \|\mathbf{b}\|_2} = \frac{\|\mathbf{T}^{-1} \cdot \mathbf{e}\|_2 / \|\mathbf{e}\|_2}{\|\mathbf{T}^{-1} \cdot \mathbf{b}\|_2 / \|\mathbf{b}\|_2} \right\}$$

- Legyen  $\mathbf{T} = \mathbf{U} \cdot \mathbf{\Sigma} \cdot \mathbf{V}^*$  SVD felbontás, ekkor  $\mathbf{T}^\dagger = \mathbf{V} \cdot \mathbf{\Sigma}^\dagger \cdot \mathbf{U}^*$

- Mivel  $\mathbf{U}$  és  $\mathbf{V}$  oszlopvektorai ortonormált bázisok, ezért

$$\max_{\mathbf{e}} \left\{ \|\mathbf{T}^{-1} \cdot \mathbf{e}\|_2 / \|\mathbf{e}\|_2 \right\} = 1/\sigma_{\min} \quad \text{és} \quad \min_{\mathbf{b}} \left\{ \|\mathbf{T}^{-1} \cdot \mathbf{b}\|_2 / \|\mathbf{b}\|_2 \right\} = 1/\sigma_{\max}$$

- Zajcsökkentő regularizáció célja  $cond(\mathbf{T})$  minimalizálása


# Mátrix Inverziós Tomoszintézis

## Dekonvolúció zajérzékenysége

- $\mathbf{T}(\omega)^\dagger$  előállítása csonkolt SVD-vel:
  - $\mathbf{T}^\dagger = \mathbf{V} \cdot \mathbf{\Sigma}^\dagger \cdot \mathbf{U}^*$ , ahol  $\mathbf{\Sigma}^\dagger_{(i,i)} = \begin{cases} 1/\sigma_i & |\sigma_i| > \varepsilon \\ 0 & |\sigma_i| \leq \varepsilon \end{cases}$
  - Kísértetiesen hasonlít a csonkolt dekonvolúcióra:
    - Joggal, a különbség annyi, hogy ott a DFT mátrixával diagonalizálunk, míg SVD esetén a bal, illetve jobb oldali sajátvektor mtrx.-okkal „diagonalizálunk”
- $\mathbf{T}(\omega)$  regularizált Moore- Penrose pseudo inverze a Wiener dekonvolúció általánosítottja


# Mátrix Inverziós Tomoszintézis

## Kondíció lineáris tomoszintézis esetén




Korlátolt szögtartomány miatt alacsony frekvencia esetén a projekciókon kisebb a változás, aminek következménye a nagyobb zajérzékenység.

# Mátrix inverziós tomoszintézis Csonkolt SVD hatása




Jól látható, hogy a magasfrekvenciás tartomány zaja dominál a direkt dekonvolúciónál, míg a Csonkolt SVD jelentősen javít a helyzeten.

# Limitált szögtartomány ( $\pm 40^\circ$ , 50 projekció) - MAP becslés



Analitikus - MITS



Ritkasági regularizáció