

Sažeto uzorkovanje

Hrlić, Marco

Master's thesis / Diplomski rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Science / Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:217:865897>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-10-02**



Repository / Repozitorij:

[Repository of the Faculty of Science - University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO–MATEMATIČKI FAKULTET
MATEMATIČKI ODSJEK

Marco Hrlić

SAŽETO UZORKOVANJE

Diplomski rad

Voditelj rada:
Prof. dr. sc. Damir Bakić

Zagreb, 2019.

Ovaj diplomski rad obranjen je dana _____ pred ispitnim povjerenstvom u sastavu:

1. _____, predsjednik
2. _____, član
3. _____, član

Povjerenstvo je rad ocijenilo ocjenom _____.

Potpisi članova povjerenstva:

1. _____
2. _____
3. _____

Albini

Sadržaj

Sadržaj	iv
Uvod	2
1 Rijetka rješenja	3
1.1 Rijetkost i sažetost vektora	3
1.2 Minimalni broj mjerenja	10
1.3 NP-složenost ℓ_0 -minimizacije	14
2 Osnovni algoritmi sažetog uzorkovanja	17
2.1 Optimizacijske metode	17
2.2 Greedy metode	21
2.3 Granične metode	24
3 ℓ_1-minimizacija	27
3.1 Svojstvo nul-prostora	27
3.2 Stabilnost	31
3.3 Robusnost	34
3.4 Rekonstrukcija predodređenog vektora	37
4 Koherencija	41
4.1 Definicija i svojstva	41
4.2 Matrice male koherencije	43
4.3 Analiza OMP algoritma	52
4.4 Analiza ℓ_1 -minimizacije	52
4.5 Analiza graničnih metoda	54
5 Svojstvo restriktivne izometričnosti	57
5.1 Definicija i osnovna svojstva	57
5.2 Analiza ℓ_1 -minimizacije	63

<i>SADRŽAJ</i>	v
5.3 Analiza graničnih metoda	65
5.4 Analiza greedy algoritama	72
Bibliografija	85

Uvod

Prikupljanje korisnih informacija iz mjerenja česti je problem u primjeni. Ilustrativan primjer je proces uzorkovanja radio valova u kontekstu telekomunikacijskih tehnologija. Radio valove možemo shvatiti kao određene promjene elektromagnetnog polja. Niz takvih fluktuacija koje nose neku informaciju zove se *signal*. Signal putuje do antenskog sustava koji (uglavnom) periodički uzima uzorke, tj. vrši mjerenja nad elektromagnetnim poljem. Najjednostavniji matematički model ovakvog procesa je linearni problem uzorkovanja. Neka $\mathbf{x} \in \mathbb{C}^N$ reprezentira informaciju, tj. signal kojeg nose radio valovi. Antenski sustav modeliramo kao matricu mjerenja $\mathbf{A} \in \mathbb{C}^{m \times N}$ a očitana informacija neka je $\mathbf{y} \in \mathbb{C}^m$. Veza između \mathbf{x} i \mathbf{y} dana je sa

$$\mathbf{Ax} = \mathbf{y}. \quad (1)$$

Jasno, da bi rekonstruirali informaciju \mathbf{x} potrebno je riješiti sustav linearnih jednadžbi (1). Nadalje, prirodno je zahtijevati da je $m \geq N$, tj. ako je signal \mathbf{x} duljine N , onda je za očekivati da moramo uzeti barem N uzoraka ako želimo taj signal uspješno rekonstruirati. Ako je $m < N$, klasična teorija linearne algebre nam kaže da ako postoji barem jedno rješenje tada postoji beskonačno mnogo rješenja. Očito da takav sustav nije od praktične koristi. Nadalje, postoji još restrikcija na najmanji broj potrebnih mjerenja. To je takozvani Nyquist-Shannonov teorem (vidi [11]) koji kaže da frekvencija uzorkovanja vremenski neprekidnog signala mora biti dvostruko veća od najveće frekvencije koju taj signal sadrži ukoliko želimo uspješnu rekonstrukciju.

Uz određene dodatne uvjete moguće je postići uspješnu rekonstrukciju signala i u situaciji kada je broj mjerenja m puno manji od N , čak manji od broja mjerenja koji proizlazi iz Nyquist-Shannonovog teorema (vidi [15]). Nadalje, postoje i efikasni praktični algoritmi za rekonstrukciju. Uvjet koji to omogućuje je *sažetost* ili *rijetkost*. Za signal kažemo da je rijedak ako je većina njegovih komponenti nula. Takva je pretpostavka opravdana. Naime, empirijski znamo da su veliki broj signala u primjeni kompresibilni, a takve signale možemo dobro aproksimirati rijetkim signalima. Uzmimo za primjer slike pohranjene u JPEG formatu. Slika se prebaci u wavelet bazu u kojoj zadržimo samo najveće koeficijente dok ostale postavimo na nulu.

Intuitivno je jasno da nema potrebe za uzimanjem svih N uzoraka ako je signal rijedak, tj. većina uzoraka će biti nula. Problem leži u činjenici da ne znamo koji su elementi signala nula, a koji ne, te to uvodi nelinearnost u problem. To lako vidimo pošto skup s -rijetkih vektora (najviše s ne-nul komponenti) ne formira linearan skup. Naime, zbroj dva s -rijetka vektora je generalno $2s$ -rijedak vektor. Pokazat ćemo da je metoda za rekonstrukciju koja se prirodno nameće NP-težak problem.

Dva osnovna pitanja sažetog uzorkovanja na koja ćemo pokušati dati odgovor u ovom radu su:

1. Kako odabrati matricu mjerenja $\mathbf{A} \in \mathbb{C}^{m \times N}$?
2. Kako rekonstruirati vektor \mathbf{x} iz mjerenja $\mathbf{y} = \mathbf{A}\mathbf{x}$?

Ispostavlja se da je konstrukcija eksplicitnih matrica mjerenja \mathbf{A} zahtjevan problem, koji još uvijek nije razriješen. Napredak je ostvaren upotrebom teorije slučajnih matrica i teorije vjerojatnosti. Mi se nećemo baviti takvim stohastičkim konstrukcijama, već ćemo istražiti koja su to svojstva matrice mjerenja dovoljna za uspješnu rekonstrukciju. Nadalje, proučit ćemo nekoliko najpopularnijih algoritama rekonstrukcije koji se koriste u sažetom uzorkovanju. Započet ćemo s osnovnom teorijom rijetkih vektora, pokazat ćemo NP-složenost prirodne rekonstrukcijske metode, dati pregleda ostalih praktičnih algoritama rekonstrukcije te pregled uvjeta koji garantiraju rekonstrukciju. Sadržaj ovog rada prati knjigu *A Mathematical Introduction to Compressive Sensing* [5] te je naglasak na matematičkoj teoriji. Za dobar pregled primjene sažetog uzorkovanja vidi [10] i [12].

Poglavlje 1

Rijetka rješenja

1.1 Rijetkost i sažetost vektora

Uvedimo potrebnu notaciju. Neka je $[N]$ oznaka za skup $\{1, 2, \dots, N\}$ gdje je $N \in \mathbb{N}$. Sa $\text{card}(S)$ označujemo kardinalitet skupa S . Nadalje, \bar{S} je komplement od S u $[N]$, tj. $\bar{S} = [N] \setminus S$.

Definicija 1.1.1. *Nosač vektora $\mathbf{x} \in \mathbb{C}^N$ je skup indeksa njegovih ne-nul elemenata, tj.*

$$\text{supp}(\mathbf{x}) := \{j \in [N] : x_j \neq 0\}.$$

Za vektor $\mathbf{x} \in \mathbb{C}^N$ kažemo da je s -rijedak ako vrijedi

$$\|\mathbf{x}\|_0 := \text{card}(\text{supp}(\mathbf{x})) \leq s.$$

Primijetimo,

$$\|\mathbf{x}\|_p^p := \sum_{j=1}^N |x_j|^p \xrightarrow{p \rightarrow 0} \sum_{j=1}^N \mathbf{1}_{\{x_j \neq 0\}} = \text{card}(\{j \in [N] : x_j \neq 0\}) = \|\mathbf{x}\|_0.$$

Gdje smo koristili da je $\mathbf{1}_{\{x_j \neq 0\}} = 1$ ako je $x_j \neq 0$ te $\mathbf{1}_{\{x_j \neq 0\}} = 0$ ako je $x_j = 0$. Drugim riječima, $\|\mathbf{x}\|_0$ je limes p -te potencije ℓ_p -kvazinorme vektora \mathbf{x} kada p teži k nuli. Kvazinorma definira se jednako kao standardna ℓ_p -norma, jedino što nejednakost trokuta oslabimo, tj. zahtijevamo

$$\|\mathbf{x} + \mathbf{y}\| \leq C(\|\mathbf{x}\| + \|\mathbf{y}\|)$$

za neku konstantu $C \geq 1$. Funkciju $\|\cdot\|_0$ često nazivamo ℓ_0 -norma vektora \mathbf{x} , iako ona nije niti norma niti kvazinorma. U praksi, teško je tražiti rijetkost vektora, pa je

stoga prirodno zahtijevati slabiji uvjet *kompresibilnosti*.

Definicija 1.1.2. ℓ_p -grešku najbolje s -rijetke aproksimacije vektora $\mathbf{x} \in \mathbb{C}^N$ definiramo sa

$$\sigma_s(\mathbf{x})_p := \inf \left\{ \|\mathbf{x} - \mathbf{z}\|_p, \mathbf{z} \in \mathbb{C}^N \text{ je } s\text{-rijedak} \right\}.$$

Primijetimo da se infimum postiže za svaki s -rijedak vektor $\mathbf{z} \in \mathbb{C}^N$ koji ima nenul elemente koji su jednaki sa s najvećih komponenti vektora \mathbf{x} . Iako takav $\mathbf{z} \in \mathbb{C}^N$ nije jedinstven, on postiže infimum za svaki $p > 0$. Neformalno, mogli bi reći da je vektor $\mathbf{x} \in \mathbb{C}^N$ *kompresibilan* ako greška njegove najbolje s -rijetke aproksimacije brzo konvergira u 0 kada s teži u N . Da bi to formalno iskazali, od koristi će biti ocjena za $\sigma_s(\cdot)_p$. Pošto nam za to neće biti važan poredak elemenata vektora \mathbf{x} , uvodimo sljedeću definiciju koja će nam olakšati račun.

Definicija 1.1.3. *Nerastući poredak vektora $\mathbf{x} \in \mathbb{C}^N$ je vektor $\mathbf{x}^* \in \mathbb{R}^N$ takav da je*

$$x_1^* \geq x_2^* \geq x_3^* \geq \dots \geq 0$$

te postoji permutacije $\pi : [N] \rightarrow [N]$ takva da $x_j^ = |x_{\pi(j)}|$ za sve $j \in [N]$.*

Propozicija 1.1.4. *Za sve $q > p > 0$ i za svaki $\mathbf{x} \in \mathbb{C}^N$ vrijedi*

$$\sigma_s(\mathbf{x})_q \leq \frac{1}{s^{1/p-1/q}} \|\mathbf{x}\|_p.$$

Dokaz. Neka je $\mathbf{x}^* \in \mathbb{R}^N$ nerastući poredak vektora $\mathbf{x} \in \mathbb{C}^N$. Tada slijedi

$$\begin{aligned} \sigma_s(\mathbf{x})_q^q &= \sum_{j=s+1}^N (x_j^*)^q = \sum_{j=s+1}^N (x_j^*)^p (x_j^*)^{q-p} \leq (x_s^*)^{q-p} \sum_{j=s+1}^N (x_j^*)^p \\ &\leq \left(\frac{1}{s} \sum_{j=1}^s (x_j^*)^p \right)^{\frac{q-p}{p}} \left(\sum_{j=s+1}^N (x_j^*)^p \right) \leq \left(\frac{1}{s} \|\mathbf{x}\|_p^p \right)^{\frac{q-p}{p}} \|\mathbf{x}\|_p^p \\ &= \frac{1}{s^{q/p-1}} \|\mathbf{x}\|_p^q. \end{aligned}$$

Prva nejednakost slijedi iz činjenice da je $x_j^* \leq x_s^*$ za svaki $j \geq s+1$. Druga nejednakost je također posljedica nerasta komponenti od \mathbf{x}^* . Potenciranjem obje strane sa $1/q$ slijedi tvrdnja. \square

Primijetimo da ako je \mathbf{x} iz jedinične ℓ_p -kugle za neki mali $p > 0$, onda prethodna propozicija garantira kovergenciju od $\sigma_s(\mathbf{x})_q$ kada s teži u N , gdje ℓ_p -kuglu definiramo

kao

$$B_p^N := \{ \mathbf{z} \in \mathbb{C}^N : \|\mathbf{z}\|_p \leq 1 \}.$$

Vratimo se sada ocjeni iz propozicije 1.1.4. Sljedeći teorem daje najmanju konstantu $c_{p,q}$ takvu da vrijedi $\sigma_s(\mathbf{x})_q \leq c_{p,q} s^{-1/p+1/q} \|\mathbf{x}\|_p$ te zapravo predstavlja jaču tvrdnju.

Teorem 1.1.5. *Za svaki $q > p > 0$ i za svaki $\mathbf{x} \in \mathbb{C}^N$ vrijedi*

$$\sigma_s(\mathbf{x})_q \leq \frac{c_{p,q}}{s^{1/p-1/q}} \|\mathbf{x}\|_p$$

gdje je

$$c_{p,q} := \left[\left(\frac{p}{q} \right)^{p/q} \left(1 - \frac{p^{1-p/q}}{q} \right) \right]^{1/p} \leq 1.$$

Istaknimo za česti odabir $p = 1$ i $q = 2$

$$\sigma_s(\mathbf{x})_2 \leq \frac{1}{2\sqrt{s}} \|\mathbf{x}\|_1.$$

Dokaz. Neka je \mathbf{x}^* nerastući poredak vektora $\mathbf{x} \in \mathbb{C}^N$ i $\alpha_j := (x_j^*)^p$. Dokazat ćemo ekvivalentnu tvrdnju

$$\left. \begin{array}{l} \alpha_1 \geq \alpha_2 \geq \dots \geq \alpha_N \geq 0 \\ \alpha_1 + \alpha_2 + \dots + \alpha_N \leq 1 \end{array} \right\} \implies \alpha_{s+1}^{q/p} + \alpha_{s+2}^{q/p} + \dots + \alpha_{s+N}^{q/p} \leq \frac{c_q^q}{s^{q/p-1}}. \quad (1.1)$$

Stoga, za $r := q/p > 1$, problem se svodi na maksimizaciju konveksne funkcije

$$f(\alpha_1, \alpha_2, \dots, \alpha_N) := \alpha_{s+1}^r + \alpha_{s+2}^r + \dots + \alpha_N^r$$

na konveksnom mnogokutu

$$\mathcal{C} := \{ (\alpha_1, \dots, \alpha_N) \in \mathbb{R}^N : \alpha_1 \geq \alpha_2 \geq \dots \geq \alpha_N \geq 0 \text{ i } \alpha_1 + \alpha_2 + \dots + \alpha_N \leq 1 \}.$$

Prema teoremu B.16 u [5] f postiže maksimum na nekom od vrhova mnogokuta \mathcal{C} , a vrhovi od \mathcal{C} su dani kao sjecišta N hiperplohi koje dobijemo tako da u (1.1) N nejednakosti pretvorimo u jednakosti. Mogućnosti su:

1. $\alpha_1 = \dots = \alpha_N \implies f(\alpha_1, \alpha_2, \dots, \alpha_N) = 0$
2. $\alpha_1 + \dots + \alpha_N = 1$ i $\alpha_1 = \dots = \alpha_k > \alpha_{k+1} = \dots = \alpha_N = 0$ za neki $1 \leq k \leq s \implies f(\alpha_1, \alpha_2, \dots, \alpha_N) = 0$

3. $\alpha_1 + \dots + \alpha_N = 1$ i $\alpha_1 = \dots = \alpha_k > \alpha_{k+1} = \dots = \alpha_N = 0$ za neki $s + 1 \leq k \leq N \implies \alpha_1 = \dots = \alpha_k = 1/k$ te $f(\alpha_1, \alpha_2, \dots, \alpha_N) = (k - s)/k^r$

Dakle, slijedi da je

$$\max_{(\alpha_1, \dots, \alpha_N) \in \mathcal{C}} f(\alpha_1, \alpha_2, \dots, \alpha_N) = \max_{s+1 \leq k \leq N} \frac{k - s}{k^r}.$$

Shvatimo sada k kao realnu varijablu i zamijetimo da $g(k) := (k - s)/k^r$ raste do kritične točke $k^* = (r/(r - 1))s$ nakon koje opada.

$$\max_{(\alpha_1, \dots, \alpha_N) \in \mathcal{C}} f(\alpha_1, \alpha_2, \dots, \alpha_N) \leq g(k^*) = \frac{1}{r} \left(1 - \frac{1}{r}\right)^{r-1} \frac{1}{s^r - 1} = c_{p,q}^g \frac{1}{s^{q/p} - 1}.$$

□

Alternativni način na koji bi mogli definirati pojam *kompresibilnosti* za vektor $\mathbf{x} \in \mathbb{C}^N$ je da zahtijevamo da je broj

$$\text{card}(\{j \in [N] : |x_j| \geq t\})$$

tj. broj njegovih značajnih ne-nul komponenti dovoljno mali. Ovaj pristup vodi na definiciju slabih ℓ_p -prostora.

Definicija 1.1.6. Za $p > 0$, slabi ℓ_p -prostor s oznakom $w\ell_p^N$ definiramo kao prostor \mathbb{C}^N s kvazinormom

$$\|\mathbf{x}\|_{p,\infty} := \inf \left\{ M \geq 0 : \text{card}(\{j \in [N] : |x_j| \geq t\}) \leq \frac{M^p}{t^p}, \forall t > 0 \right\}. \quad (1.2)$$

Da bi pokazali da je (1.2) zapravo kvazinorma, potreban nam je sljedeći rezultat.

Propozicija 1.1.7. Neka su $\mathbf{x}^1, \dots, \mathbf{x}^k \in \mathbb{C}^N$. Tada za svaki $p > 0$ vrijedi

$$\|\mathbf{x}^1 + \dots + \mathbf{x}^k\|_{p,\infty} \leq k^{\max\{1, 1/p\}} (\|\mathbf{x}^1\|_{p,\infty} + \dots + \|\mathbf{x}^k\|_{p,\infty}).$$

Dokaz. Neka je $t > 0$. Ako je $|x_j^1 + \dots + x_j^k| \geq t$ za neki $j \in [N]$, tada imamo da je $|x_j^i| \geq t/k$ za neki $i \in [k]$. Dakle, vrijedi

$$\{j \in [N] : |x_j^1 + \dots + x_j^k| \geq t\} \subseteq \bigcup_{i \in [k]} \{j \in [N] : |x_j^i| \geq t/k\}$$

pa je stoga

$$\begin{aligned} \text{card}(\{j \in [N] : |x_j^1 + \dots + k_j^k| \geq t\}) &\leq \sum_{i \in [k]} \frac{\|\mathbf{x}^i\|_{p,\infty}^p}{(t/k)^p} \\ &= \frac{k^p (\|\mathbf{x}^1\|_{p,\infty}^p + \dots + \|\mathbf{x}^k\|_{p,\infty}^p)}{t^p}. \end{aligned}$$

Prema definiciji slabe ℓ_p -kvazinorme (1.2) vektora $\mathbf{x}^1 + \dots + \mathbf{x}^k$ dobivamo

$$\|\mathbf{x}^1 + \dots + \mathbf{x}^k\|_{p,\infty} \leq k \left(\|\mathbf{x}^1\|_{p,\infty}^p + \dots + \|\mathbf{x}^k\|_{p,\infty}^p \right)^{1/p}.$$

Ako je $p \leq 1$, uspoređujući ℓ_p i ℓ_1 norme na \mathbb{R}^k slijedi

$$\left(\|\mathbf{x}^1\|_{p,\infty}^p + \dots + \|\mathbf{x}^k\|_{p,\infty}^p \right)^{1/p} \leq k^{1/p-1} \left(\|\mathbf{x}^1\|_{p,\infty} + \dots + \|\mathbf{x}^k\|_{p,\infty} \right)$$

te ako je $p \geq 1$ slijedi

$$\left(\|\mathbf{x}^1\|_{p,\infty}^p + \dots + \|\mathbf{x}^k\|_{p,\infty}^p \right)^{1/p} \leq \|\mathbf{x}^1\|_{p,\infty} + \dots + \|\mathbf{x}^k\|_{p,\infty}.$$

Tvrđnja slijedi kombiniranjem dobivenih ocjena. □

Pokažimo sada da je $\|\cdot\|_{p,\infty}$ kvazinorma. Uzmimo $\mathbf{x}, \mathbf{y} \in \mathbb{C}^N$ i neka je $\lambda \in \mathbb{C}$ proizvoljan.

1. Neka je $\|\mathbf{x}\|_{p,\infty} = 0$. Iz (1.2) slijedi $\text{card}(\{j \in [N] : |x_j| \geq t\}) = 0$ za svaki $t > 0$ pa je stoga broj ne-nul komponenti on \mathbf{x} jednak nuli, tj. $\mathbf{x} = 0$.
2. Ako je λ nula, $\|\lambda\mathbf{x}\| = |\lambda|\|\mathbf{x}\|$ vrijedi trivijalno. Za $\lambda \neq 0$, imamo $\text{card}(\{j \in [N] : |\alpha x_j| \geq t\}) = \text{card}(\{j \in [N] : |x_j| \geq t/|\alpha|\}) \leq (\alpha M)^p/t^p$ za svaki $t > 0$. Dakle, opet $\|\lambda\mathbf{x}\| = |\lambda|\|\mathbf{x}\|$.
3. $\|\mathbf{x} + \mathbf{y}\| \leq C(\|\mathbf{x}\| + \|\mathbf{y}\|)$ je sada direktna posljedica prethodne propozicije.

Sljedeća propozicija daje alternativni izraz za slabu ℓ_p -kvazinormu.

Propozicija 1.1.8. *Za $p > 0$, vrijedi*

$$\|\mathbf{x}\|_{p,\infty} = \max_{k \in [N]} k^{1/p} x_k^*$$

gdje je $\mathbf{x}^* \in \mathbb{R}^N$ nerastući poredak vektora $\mathbf{x} \in \mathbb{C}^N$.

Dokaz. Primijetimo prvo da iz (1.2) slijedi da je $\|\mathbf{x}\|_{p,\infty} = \|\mathbf{x}^*\|_{p,\infty}$, pa zapravo pokazujemo da je $\|\mathbf{x}\| := \max_{k \in [N]} k^{1/p} x_k^* = \|\mathbf{x}^*\|$. Nadalje, za $t > 0$ vrijedi da je

$\{j \in [N] : x_j^* \geq t\} = [k]$ za neki $k \in [N]$ ili je $\{j \in [N] : x_j^* \geq t\} = \emptyset$. U prvom slučaju $t \leq x_k^* \leq \|\mathbf{x}\|/k^{1/p}$ pa je $\text{card}(\{j \in [N] : x_j^* \geq t\}) = k \leq \|\mathbf{x}\|/k^{1/p}$. U drugom slučaju ista nejednakost vrijedi trivijalno. Iz definicije slabe ℓ_p -kvazinorme (1.2) sada dobivamo $\|\mathbf{x}^*\|_{p,\infty} \leq \|\mathbf{x}\|$. Pretpostavimo da je $\|\mathbf{x}^*\|_{p,\infty} < \|\mathbf{x}\|$. Tada postoji $\varepsilon > 0$ takav da je $(1 + \varepsilon)\|\mathbf{x}^*\|_{p,\infty} \leq \|\mathbf{x}\|$. Slijedi da je $(1 + \varepsilon)\|\mathbf{x}^*\| \leq k^{1/p}x_k^*$ za neki $k \in [N]$ pa stoga

$$[k] \subseteq \left\{j \in [N] : (1 + \varepsilon)\|\mathbf{x}^*\|_{p,\infty}/k^{1/p} \leq x_j^*\right\}.$$

Ponovo iz (1.2) imamo

$$k \leq \frac{\|\mathbf{x}^*\|_{p,\infty}^p}{\left((1 + \varepsilon)\|\mathbf{x}^*\|_{p,\infty}k^{1/p}\right)^p} = \frac{k}{(1 + \varepsilon)^p}.$$

Kontradikcija, dakle mora vrijediti $\|\mathbf{x}\| = \|\mathbf{x}^*\|_{p,\infty}$. □

Sada lagano možemo usporediti slabu i jaku ℓ_p normu.

Propozicija 1.1.9. *Za svaki $p > 0$ i za svaki $\mathbf{x} \in \mathbb{C}^N$,*

$$\|\mathbf{x}\|_{p,\infty} \leq \|\mathbf{x}\|_p.$$

Dokaz. Neka je $k \in [N]$,

$$\|\mathbf{x}\|_p^p = \sum_{j=1}^N (x_j^*)^p \geq \sum_{j=1}^k (x_j^*)^p \geq k(x_k^*)^p.$$

Tvrđnja slijedi potenciranjem na $1/p$, uzimajući maksimum po k i primjenom prethodne propozicije. □

Koristeći propoziciju (1.1.8) možemo dobiti verziju ocjene iz propozicije (1.1.4) sa slabom ℓ_p normom.

Propozicija 1.1.10. *Za svaki $q > p > 0$ i $\mathbf{x} \in \mathbb{C}^N$, vrijedi*

$$\sigma_s(\mathbf{x})_q \leq \frac{d_{p,q}}{s^{1/p-1/q}} \|\mathbf{x}\|_{p,\infty}$$

gdje je

$$d_{p,q} := \left(\frac{p}{q-p}\right)^{1/q}.$$

Dokaz. Bez smanjenja općenitosti možemo pretpostaviti da je $\|\mathbf{x}\|_{p,\infty} \leq 1$, pa je $x_k^* \leq 1/k^{1/p}$ za svaki $k \in [N]$. Tada vrijedi,

$$\sigma_s(\mathbf{x})_q^q = \sum_{k=s+1}^N (x_k^*)^q \leq \sum_{k=s+1}^N \frac{1}{k^{q/p}} \leq \int_s^N \frac{1}{t^{q/p}} dt = -\frac{1}{q/p-1} \frac{1}{t^{q/p-1}} \Big|_{t=s}^{t=N} \leq \frac{p}{q-p} \frac{1}{s^{q/p-1}}.$$

Potenciranjem s $1/q$ slijedi tvrdnja. \square

Prethodna propozicija daje da su vektori $\mathbf{x} \in \mathbb{C}^N$ koji su kompresibilni u smislu $\|\mathbf{x}\|_{p,\infty} \leq 1$ za mali $p > 0$, također kompresibilni u smislu da greška njihove najbolje s -rijetke aproksimacije brzo konvergira u 0 kada s teži u N . Iskažimo još jedan tehnički rezultat.

Lema 1.1.11. *Neka su $\mathbf{x}, \mathbf{y} \in \mathbb{C}^N$. Tada vrijedi,*

$$\|\mathbf{x}^* - \mathbf{y}^*\|_\infty \leq \|\mathbf{x} - \mathbf{y}\|_\infty. \quad (1.3)$$

Nadalje, za $s \in [N]$,

$$|\sigma_s(\mathbf{x})_1 - \sigma_s(\mathbf{y})_1| \leq \|\mathbf{x} - \mathbf{y}\|_1 \quad (1.4)$$

i za $k > s$,

$$(k-s)x_k^* \leq \|\mathbf{x} - \mathbf{y}\|_1 + \sigma_s(\mathbf{y})_1. \quad (1.5)$$

Dokaz. Za $j \in [N]$, skup indeksa j najvećih komponenti vektora \mathbf{x} ima ne-trivijalni presjek sa skupom od $N-j+1$ najmanjih komponenti vektora \mathbf{y} . Izaberimo indeks l iz tog presjeka. Tada vrijedi,

$$x_j^* \leq |x_l| \leq |y_l| + \|\mathbf{x} - \mathbf{y}\|_\infty \leq z_j^* + \|\mathbf{x} - \mathbf{y}\|_\infty.$$

Zamjenom uloga od \mathbf{x} i \mathbf{y} slijedi (1.3). Neka je $\mathbf{v} \in \mathbb{C}^N$ najbolja s -rijetka aproksimacija vektora \mathbf{y} . Tada

$$\sigma_s(\mathbf{x})_1 \leq \|\mathbf{x} - \mathbf{v}\|_1 \leq \|\mathbf{x} - \mathbf{y}\|_1 + \|\mathbf{y} - \mathbf{v}\|_1 = \|\mathbf{x} - \mathbf{y}\|_1 + \sigma_s(\mathbf{y})_1.$$

Ponovno, zbog simetrije slijedi (1.4). Napokon, ocjena (1.5) slijedi iz (1.4) te iz činjenice

$$(k-s)x_k^* \leq \sum_{j=s+1}^k x_j^* \leq \sum_{j \geq s+1} x_j^* = \sigma_s(\mathbf{x})_1.$$

\square

1.2 Minimalni broj mjerenja

Problem sažetog uzorkovanja sastoji se od rekonstrukcije s -rijetkog vektora $\mathbf{x} \in \mathbb{C}^N$ iz sustava

$$\mathbf{y} = \mathbf{A}\mathbf{x}.$$

Matricu $\mathbf{A} \in \mathbb{C}^{m \times N}$ nazivamo *matrica mjerenja*. Ako je $m < N$, za ovakav sustav linearnih jednadžbi kažemo da je *neodređen*. Iako iz klasične teorije linearne algebre ovakvi sustavi imaju beskonačno mnogo rješenja, pokazat će se da je dodatna pretpostavka rijetkosti vektora \mathbf{x} dovoljno za jedinstvenost rješenja. U ovom poglavlju istražiti ćemo koji je minimalni broj mjerenja, tj. m broj redaka matrice \mathbf{A} , koji garantira rekonstrukciju s -rijetkog vektora \mathbf{x} . Zapravo, postoje dva pristupa ovom problemu. Možemo zahtijevati da problem mjerenja rekonstruira sve s -rijetke vektore $\mathbf{x} \in \mathbb{C}^N$ istodobno ili možemo tražiti rekonstrukciju specifičnog, tj. predodređenog vektora $\mathbf{x} \in \mathbb{C}^N$. Taj pristup čini se neprirodan, no pokazuje se da je on važan u proučavanju problema gdje matricu \mathbf{A} biramo na slučajan način.

Pokažimo da su za danu rijetkost s , matricu $\mathbf{A} \in \mathbb{C}^{m \times N}$ i s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$, naredne tvrdnje ekvivalentne:

1. Vektor \mathbf{x} je jedinstveno s -rijetko rješenje sustava $\mathbf{A}\mathbf{z} = \mathbf{y}$ gdje je $\mathbf{y} = \mathbf{A}\mathbf{x}$, tj. $\{\mathbf{z} \in \mathbb{C}^N : \mathbf{A}\mathbf{z} = \mathbf{A}\mathbf{x}, \|\mathbf{z}\|_0 \leq s\} = \{\mathbf{x}\}$.
2. Vektor \mathbf{x} je jedinstveno rješenje problema minimizacije

$$\min_{\mathbf{z} \in \mathbb{C}^N} \|\mathbf{z}\|_0 \quad \text{uz uvjet } \mathbf{A}\mathbf{z} = \mathbf{y}. \quad (P_0)$$

Ako je $\mathbf{x} \in \mathbb{C}^N$ jedinstveno s -rijetko rješenje od $\mathbf{A}\mathbf{z} = \mathbf{y}$ takvo da je $\mathbf{y} = \mathbf{A}\mathbf{x}$, onda rješenje \mathbf{x}^\sharp od (P_0) je s -rijetko i zadovoljava $\mathbf{A}\mathbf{x} = \mathbf{y}$ pa je $\mathbf{x}^\sharp = \mathbf{x}$. Drugi smjer slijedi trivijalno.

Rekonstrukcija svih rijetkih vektora

Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ i $S \subseteq [N]$, s \mathbf{A}_S označujemo matricu formiranu od stupaca od \mathbf{A} indeksiranih sa S . Slično, s \mathbf{x}_S označujemo ili vektor iz \mathbb{C}^S koji se sastoji od komponenti vektora \mathbf{x} indeksiranih po S , tj. $(\mathbf{x}_S)_l = x_l$ za sve $l \in S$, ili vektor iz \mathbb{C}^N koji se podudara s \mathbf{x} na komponentama indeksiranim u S i jednak je nula na indeksima koji nisu u S , tj. $(\mathbf{x}_S)_l = x_l$ za $l \in S$ i $(\mathbf{x}_S)_l = 0$ za $l \notin S$. Iz konteksta će uvijek biti jasno na koju definiciju se misli.

Teorem 1.2.1. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$. Ekvivalentno je:*

- (a) Postoji samo jedan s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ koji zadovoljava $\mathbf{Ax} = \mathbf{Az}$, tj. ako je $\mathbf{Ax} = \mathbf{Az}$ i ako su \mathbf{x}, \mathbf{z} oba s -rijetki tada je $\mathbf{x} = \mathbf{z}$.
- (b) Jezgra od \mathbf{A} ne sadrži niti jedan $2s$ -rijedak vektor osim nul-vektora, tj. $\ker \mathbf{A} \cap \{\mathbf{z} \in \mathbb{C}^N : \|\mathbf{z}\|_0 \leq 2s\} = \{\mathbf{0}\}$.
- (c) Za svaki $S \subseteq [N]$ takav da je $\text{card}(S) \leq 2s$, podmatrica \mathbf{A}_S je injektivna kao preslikavanje s \mathbb{C}^S u \mathbb{C}^m .
- (d) Svaki skup od $2s$ stupaca matrice \mathbf{A} je linearno nezavisan skup.

Dokaz. (b) \implies (a). Neka su \mathbf{x} i \mathbf{z} s -rijetki vektori takvi da $\mathbf{Ax} = \mathbf{Az}$. Tada je $\mathbf{x} - \mathbf{z}$ $2s$ -rijedak i $\mathbf{A}(\mathbf{x} - \mathbf{z}) = \mathbf{0}$. Pošto $\ker \mathbf{A}$ ne sadrži $2s$ -rijetke vektore osim nul-vektora, mora vrijediti $\mathbf{x} = \mathbf{z}$.

(a) \implies (b). Obratno, pretpostavimo da za svaki s -rijetki vektor $\mathbf{x} \in \mathbb{C}^N$ vrijedi $\{\mathbf{z} \in \mathbb{C}^N : \mathbf{Az} = \mathbf{Ax}, \|\mathbf{z}\|_0 \leq s\} = \{\mathbf{x}\}$. Neka je $\mathbf{v} \in \ker \mathbf{A}$, $2s$ -rijedak. Tada \mathbf{v} možemo rastaviti kao $\mathbf{v} = \mathbf{x} - \mathbf{z}$ gdje su \mathbf{x} i \mathbf{z} s -rijetki takvi da $\text{supp}(\mathbf{x}) \cap \text{supp}(\mathbf{z}) = \emptyset$. Imamo da je $\mathbf{Ax} = \mathbf{Az}$ pa prema pretpostavci vrijedi $\mathbf{x} = \mathbf{z}$. Pošto su nosači od \mathbf{x} i \mathbf{z} disjunktne, mora vrijediti $\mathbf{x} = \mathbf{z} = \mathbf{0}$ pa je stoga i $\mathbf{v} = \mathbf{0}$.

(b) \implies (c). Pretpostavimo suprotno, $\ker \mathbf{A} \cap \{\mathbf{z} \in \mathbb{C}^N : \|\mathbf{z}\|_0 \leq 2s\} = \{\mathbf{0}\}$ i postoji $S \in [N]$ takav da je $\text{card}(S) \leq 2s$ te da \mathbf{A}_S nije injektivna. To znači da postoji vektor $\mathbf{x} \in \mathbb{C}^{\text{card}(S)} \setminus \{\mathbf{0}\}$ takav da je $\mathbf{A}_S \mathbf{x} = \mathbf{0}$. Definiramo vektor $\tilde{\mathbf{x}} \in \mathbb{C}^N$ s

$$\tilde{x}_j = \begin{cases} x_j & \text{za } j \in S \\ 0 & \text{za } j \in \bar{S} \end{cases}$$

Dakle, imamo $\mathbf{x} \neq \mathbf{0}$, $\|\mathbf{x}\|_0 \leq 2s$ i vrijedi $\mathbf{Ax} = \mathbf{0}$, tj. $\mathbf{x} \in \ker \mathbf{A}$. Kontradikcija s (b).

(c) \implies (d). Odaberimo $2s$ stupaca od \mathbf{A} . Skup indeksa tih stupaca označimo sa S . Prema (c), matrica \mathbf{A}_S je injektivna, a to znači da su njezini stupci linearno nezavisni, pa su stoga i $2s$ odabranih stupaca matrice \mathbf{A} linearno nezavisni.

(d) \implies (b). Pretpostavimo da jezgra od \mathbf{A} sadrži $2s$ -rijedak ne-nul vektor $\mathbf{x} \in \mathbb{C}^N$. Neka je S skup indeksa ne-nul elemenata vektora \mathbf{x} . To znači da je $\mathbf{A}_S \mathbf{x}_S = \mathbf{0}$, i $\mathbf{x}_S \neq \mathbf{0}$. Dakle \mathbf{A}_S nije injektivna, pa stoga i skup stupaca od \mathbf{A} indeksiranih sa S nije linearno nezavisan, što je kontradikcija s (d). □

Uočimo da ako je moguće rekonstruirati svaki s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ iz vektora mjerenja $\mathbf{y} = \mathbf{A}\mathbf{x} \in \mathbb{C}^m$, tada vrijedi (a). Prema prošlom teoremu tada vrijedi i tvrdnja (d) pa je stoga $r(\mathbf{A}) \geq 2s$. Također vrijedi da je $r(\mathbf{A}) \leq m$ pa imamo

$$m \geq 2s.$$

To znači da je potrebno barem $2s$ mjerenja da bi rekonstruirali svaki s -rijedak vektor. Pokazat ćemo da je, makar u teoriji, dovoljno točno $2s$ mjerenja.

Teorem 1.2.2. *Za svaki $N \geq 2s$, postoji matrica mjerenja $\mathbf{A} \in \mathbb{C}^{2s \times N}$ takva da se svaki s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ može rekonstruirati iz vektora mjerenja $\mathbf{y} = \mathbf{A}\mathbf{x} \in \mathbb{C}^{2s}$ kao rješenje problema minimizacije (P_0).*

Dokaz. Fiksirajmo $t_N > \dots > t_2 > t_1 > 0$ i neka je $\mathbf{A} \in \mathbb{C}^{2s \times N}$ dana s

$$\mathbf{A} = \begin{bmatrix} 1 & 1 & \dots & 1 \\ t_1 & t_2 & \dots & t_N \\ \vdots & \vdots & \dots & \vdots \\ t_1^{2s-1} & t_2^{2s-1} & \dots & t_N^{2s-1} \end{bmatrix}. \quad (1.6)$$

Nadalje, neka je $S = \{j_1 < \dots < j_{2s}\}$ skup indeksa. Matrica $\mathbf{A}_S \in \mathbb{C}^{2s \times 2s}$ je transponirana *Vandermonтова matrica*. Lako se provjeri da

$$\det(\mathbf{A}_S) = \prod_{k < l} (t_{j_l} - t_{j_k}) > 0.$$

To znači da je matrica \mathbf{A} invertibilna, pa posebno i injektivna. Tada je zadovoljena tvrdnja (c) teorema 1.2.1, pa je po istom teoremu zadovoljena i tvrdnja (a), tj. svaki s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ zadovoljava $\mathbf{A}\mathbf{z} = \mathbf{A}\mathbf{x}$. Stoga je taj vektor moguće jedinstveno rekonstruirati putem minimizacije (P_0). \square

Zapravo, mnogo matrica zadovoljava uvjet (c) iz teorema 1.2.1. Na primjer, potencije od t_1, \dots, t_N u (1.6) ne moraju biti uzastopne. Nadalje, brojevi t_1, \dots, t_N ne moraju biti pozitivni, niti realni sve dok vrijedi $\det(\mathbf{A}_S) \neq 0$. Posebno, možemo uzeti $t_l = e^{2\pi i(l-1)/N}$ za $l \in [N]$ te argumentom iz prošlog teorema vidimo da parcijalna Fourierova matrica

$$\mathbf{A} = \begin{bmatrix} 1 & 1 & 1 & \dots & 1 \\ 1 & e^{2\pi i/N} & e^{2\pi i 2/N} & \dots & e^{2\pi i(N-1)/N} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & e^{2\pi i(2s-1)/N} & e^{2\pi i(2s-1)2/N} & \dots & e^{2\pi i(2s-1)(N-1)/N} \end{bmatrix}$$

rekonstruira svaki s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ iz $\mathbf{y} = \mathbf{A}\mathbf{x} \in \mathbb{C}^{2s}$. Zapravo može se pokazati da skup $(2s) \times N$ matrica takvih da $\det(\mathbf{A}_S) = 0$ za neki $S \subseteq [N]$ i $\text{card}(S) \leq 2s$ ima Lebesgueovu mjeru nula, pa stoga gotovo sve $(2s) \times N$ matrice rekonstruiraju svaki s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ iz $\mathbf{y} = \mathbf{A}\mathbf{x} \in \mathbb{C}^{2s}$. Međutim, u praksi nije isplativo rješavati problem minimizacije (P_0) , što ćemo kasnije i pokazati.

Rekonstrukcija zadanog rijetkog vektora

Promatramo problem gdje je s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ unaprijed zadan i poznat, a matricu $\mathbf{A} \in \mathbb{C}^{m \times N}$ želimo odabrati tako da ona garantira rekonstrukciju vektora \mathbf{x} iz mjerenja $\mathbf{y} = \mathbf{A}\mathbf{x} \in \mathbb{C}^m$. Isprva, ovakav pristup izgleda neprirodan zbog činjenice da je vektor \mathbf{x} apriorno poznat. Ideja je da će uvjeti rekonstrukcije vrijediti za gotovo sve $(s+1) \times N$ matrice, što podupire činjenicu da se u praksi matrice mjerenja često odabiru na slučajajan način.

Teorem 1.2.3. *Za svaki $N \geq s+1$ i za dani s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$, postoji matrica mjerenja $\mathbf{A} \in \mathbb{C}^{(s+1) \times N}$, takva da se vektor \mathbf{x} može rekonstruirati iz mjerenja $\mathbf{y} = \mathbf{A}\mathbf{x} \in \mathbb{C}^m$ kao rješenje minimizacije (P_0) .*

Dokaz. Neka je $\mathbf{A} \in \mathbb{C}^{(s+1) \times N}$ matrica za koju se s -rijedak vektor \mathbf{x} ne može rekonstruirati iz $\mathbf{y} = \mathbf{A}\mathbf{x}$ putem minimizacije (P_0) . To znači da postoji vektor $\mathbf{z} \in \mathbb{C}^N$ različit od \mathbf{x} , takav da je $S = \text{supp}(\mathbf{z}) = \{j_1, \dots, j_s\}$, $\text{card}(S) \leq s$ (ako je $\|\mathbf{z}\|_0 < s$, u S dodamo proizvoljne elemente $j_l \in [N]$) i $\mathbf{A}\mathbf{z} = \mathbf{A}\mathbf{x}$. Ako je $\text{supp}(\mathbf{x}) \subseteq S$, tada iz $(\mathbf{A}(\mathbf{z} - \mathbf{x}))_{[s]} = 0$ slijedi da $\mathbf{A}_{[s],S}$ nije invertibilna, tj.

$$f(a_{1,1}, \dots, a_{1,N}, \dots, a_{m,1}, \dots, a_{m,N}) := \det(\mathbf{A}_{[s],S}) = 0.$$

Ako $\text{supp}(\mathbf{x}) \not\subseteq S$ tada je dimenzija prostora $V := \{\mathbf{u} \in \mathbb{C}^N : \text{supp}(\mathbf{u}) \subseteq S\} + \mathbb{C}\mathbf{x}$ jednaka $s+1$, i linearno preslikavanje $G : V \rightarrow \mathbb{C}^{s+1}$, $\mathbf{v} \mapsto \mathbf{A}\mathbf{v}$ nije invertibilno, pošto je $G(\mathbf{z} - \mathbf{x}) = 0$. Matrica linearnog preslikavanja G u bazi $(\mathbf{e}_{j_1}, \dots, \mathbf{e}_{j_s}, \mathbf{x})$ prostora V , je oblika

$$B_{\mathbf{x},S} := \begin{bmatrix} a_{1,j_1} & \cdots & a_{1,j_s} & \sum_{j \in \text{supp}(\mathbf{x})} x_j a_{1,j} \\ \vdots & \ddots & \vdots & \vdots \\ a_{s+1,j_1} & \cdots & a_{s+1,j_s} & \sum_{j \in \text{supp}(\mathbf{x})} x_j a_{s+1,j} \end{bmatrix}$$

i imamo

$$g_S(a_{1,1}, \dots, a_{1,N}, \dots, a_{m,1}, \dots, a_{m,N}) := \det(B_{\mathbf{x},S}) = 0.$$

Dakle, vrijedi

$$(a_{1,1}, \dots, a_{1,N}, \dots, a_{m,1}, \dots, a_{m,N}) \in f^{-1}(\{0\}) \cup \bigcup_{\text{card}(S)=s} g_S^{-1}(\{0\}).$$

Primijetimo da su skupovi $f^{-1}(\{0\})$ i $g_S^{-1}(\{0\})$ Lebesgueove mjere nula iz razloga što su f i g_S polinomi u varijablama $(a_{1,1}, \dots, a_{1,N}, \dots, a_{m,1}, \dots, a_{m,N})$. Dakle, elemente matrice \mathbf{A} moramo izabrati izvan skupa mjere nula, da bi osigurali rekonstrukciju vektora \mathbf{x} iz $\mathbf{y} = \mathbf{A}\mathbf{x}$. \square

1.3 NP-složenost ℓ_0 -minimizacije

Kao što smo najavili, pokazat ćemo da je u praksi neisplativo rješavati problem ℓ_0 -minimizacije u svrhu rekonstrukcije vektora \mathbf{x} iz mjerenja $\mathbf{y} = \mathbf{A}\mathbf{x}$. Prisjetimo se, problem koji rješavamo je oblika,

$$\min_{\mathbf{z} \in \mathbb{C}^N} \|\mathbf{z}\|_0 \quad \text{uz uvjet } \mathbf{A}\mathbf{z} = \mathbf{y}.$$

Pošto je minimizator najviše s -rijedak, najjednostavniji algoritam za rješavanje ovog problema je riješiti sve pravokutne sustave $\mathbf{A}_S \mathbf{u} = \mathbf{y}$ ili sve kvadratne sustave oblika $\mathbf{A}_S^* \mathbf{A}_S \mathbf{u} = \mathbf{A}_S^* \mathbf{y}$ za svaki $\mathbf{u} \in \mathbb{C}^S$ gdje S ide po svim poskupovima od $[N]$, veličine s . No ispada da je broj podskupova $\binom{N}{s}$, što za male probleme $s = N = 1000$ i $s = 10$, iznosi $\binom{1000}{10} \geq \left(\frac{1000}{10}\right)^{10} = 10^{20}$. Kada bi jedan 10×10 sustav mogli riješiti u 10^{-10} sekundi, trebalo bi nam više od 300 godina da sve riješimo. Sada ćemo pokazati zašto je zapravo općenitiji problem

$$\min_{\mathbf{z} \in \mathbb{C}^N} \|\mathbf{z}\|_0 \quad \text{uz uvjet } \|\mathbf{A}\mathbf{z} - \mathbf{y}\|_2 \leq \eta \quad (P_{0,\eta})$$

NP-težak.

Uvedimo prvo potrebne pojmove iz kompleksnosti algoritama. Za algoritam kažemo da je *polinomijalnog-vremena* ako je broj koraka do rješenja ograničen polinomom u varijabli veličine ulaza. Nadalje, uvedimo neformalne definicije klasa problema odlučivanja:

- \mathfrak{P} : Svi problemi odlučivanja za koje postoji algoritam polinomijalnog vremena koji daje rješenje.
- \mathfrak{NP} : Svi problemi odlučivanja za koje postoji algoritam polinomijalnog vremena koji provjerava točnost rješenja.

- \mathfrak{NP} -teški: Svi problemi (ne nužno problemi odlučivanja) za koje se algoritam za rješenje može u polinomijalnom vremenu transformirati u algoritam rješenja za bilo koji \mathfrak{NP} problem.
- \mathfrak{NP} -potpuni: Svi problemi koji su istovremeno \mathfrak{NP} i \mathfrak{NP} -teški.

Pitanje je li \mathfrak{P} strogo sadržano u \mathfrak{NP} do dan danas nije odgovoreno. No, vjeruje se da postoje problemi za koje ne postoji algoritam rješenja polinomijalnog vremena, ali postoji algoritam koji će provjeriti točnost rješenja u polinomijalnom vremenu. Najpoznatiji \mathfrak{NP} -potpun problem je problem putujućeg prodavača. No, iskoristit ćemo problem egzaktnog pokrivača tročlanim skupovima da bi pokazali da je problem $(P_{0,\eta})$ \mathfrak{NP} -težak.

Egzaktni pokrivač tročlanim skupovima

Za danu kolekciju $\{\mathcal{C}_i; i \in [N]\}$ tročlanih podskupova od $[m]$, postoji li egzaktni pokrivač skupa $[m]$, tj. postoji li $J \subseteq [N]$ takav da je $\cup_{j \in J} \mathcal{C}_j = [m]$, gdje je $\mathcal{C}_j \cap \mathcal{C}_k = \emptyset$ za sve međusobno različite $j, k \in J$? Poznato je da je taj problem \mathfrak{NP} -potpun (vidi [8], [6]).

Teorem 1.3.1. *Za svaki $\eta \geq 0$, $\mathbf{A} \in \mathbb{C}^{m \times N}$ i $\mathbf{y} \in \mathbb{C}^m$, problem minimizacije $(P_{0,\eta})$ je \mathfrak{NP} -potpun.*

Dokaz. Zbog linearnosti problema $(P_{0,\eta})$, možemo uzeti da je $\eta < 1$. Pokazat ćemo da se problem egzaktnog pokrivača može u polinomijalnom vremenu reducirati na problem ℓ_0 -minimizacije. Neka je $\{\mathcal{C}_i; i \in [N]\}$ kolekcija tročlanih podskupova $[m]$. Definirajmo vektora $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_N \in \mathbb{C}^m$

$$(\mathbf{a}_i)_j = \begin{cases} 1 & \text{za } j \in \mathcal{C}_i, \\ 0 & \text{za } j \notin \mathcal{C}_i \end{cases}.$$

Definirajmo matricu $\mathbf{A} \in \mathbb{C}^{m \times N}$ i vektor $\mathbf{y} \in \mathbb{C}^m$ s

$$\mathbf{A} = [\mathbf{a}_1 \ \mathbf{a}_2 \ \cdots \ \mathbf{a}_N], \quad \mathbf{y} = [1, 1, \dots, 1]^T.$$

Pošto je $N \leq \binom{m}{3}$, to možemo napraviti u polinomijalnom vremenu. Ako $\mathbf{z} \in \mathbb{C}^N$ zadovoljava $\|\mathbf{Az} - \mathbf{y}\|_2 \leq \eta$, tada su svih m komponenti od \mathbf{Az} udaljene od 1 za najviše η , pa su te komponente različite od nula, jer smo η uzeli manji od 1. Dakle, vrijedi $\|\mathbf{Az}\|_0 = m$. Ali pošto svaki od vektora \mathbf{a}_i ima točno tri ne-nul komponente, vektor $\mathbf{Az} = \sum_{j=1}^N z_j \mathbf{a}_j$ ima najviše $3\|\mathbf{z}\|_0$ ne-nul elemenata, tj. $\|\mathbf{Az}\|_0 \leq 3\|\mathbf{z}\|_0$. Dakle, za svaki vektor $\mathbf{z} \in \mathbb{C}^N$ koji zadovoljava $\|\mathbf{Az} - \mathbf{y}\|_2 \leq \eta$ vrijedi $\|\mathbf{z}\|_0 \geq m/3$.

Neka je sada $\mathbf{x} \in \mathbb{C}^N$ rješenje ℓ_0 -minimizacije $(P_{0,\eta})$. Imamo dva slučaja za normu vektora \mathbf{x} :

1. Ako je $\|\mathbf{x}\|_0 = m/3$ tada je $\{\mathcal{C}_j; j \in \text{supp}(\mathbf{x})\}$ egzaktni pokrivač skupa $[m]$ jer inače bi neke od m komponenti od \mathbf{Ax} bile jednake nuli.
2. Ako je $\|\mathbf{x}\|_0 > m/3$ tada ne može postojati egzaktni pokrivač $\{\mathcal{C}_j; j \in J\}$ jer bi u suprotnom vektor $\mathbf{z} \in \mathbb{C}^N$ definiran tako da je $z_j = 1$ ako je $j \in J$ i $z_j = 0$ ako je $j \notin J$, zadovoljavao $\mathbf{Az} = \mathbf{y}$ i $\|\mathbf{z}\|_0 = m/3$, što je kontradikcija s minimalnosti vektora \mathbf{x} .

Dakle, rješavanjem problem ℓ_0 -minimizacije, možemo riješiti problem egzaktnog pokrivača tročlanim skupovima, pa je stoga i sam problem ℓ_0 -minimizacije \mathfrak{NP} -potpun. \square

Čini se da prethodni teorem predstavlja ozbiljnu zapreku u praktičnom rješavanju problema sažetog uzorkovanja. No primijetimo, teorem tvrdi da je algoritam koji rješava problem ℓ_0 -minimizacije, za sve moguće matrice \mathbf{A} i vektore \mathbf{y} barem klase \mathfrak{NP} . Naravno, u samoj praksi nije nužno zahtijevati rekonstrukciju za sve takve matrice i vektore. Naime, pokazat ćemo da postoje algoritmi koji uspješno rekonstruiraju \mathbf{x} iz \mathbf{y} za posebno dizajnirane matrice \mathbf{A} .

Poglavlje 2

Osnovni algoritmi sažetog uzorkovanja

Algoritmi za rješavanje problema sažetog uzorkovanja, koje ćemo predstaviti, podijeljeni su u tri kategorije: optimizacije, greedy metode i granične metode. U ovom poglavlju dat ćemo samo pregled najpopularnijih algoritama, dok ćemo formalnu analizu nekih od njih ostaviti za kasnije, nakon što razvijemo potrebne teorijske alate.

2.1 Optimizacijske metode

Općeniti problem optimizacije je oblika

$$\min_{\mathbf{x} \in \mathbb{R}^N} F_0(\mathbf{x}) \quad \text{uz uvjet } F_i(\mathbf{x}) \leq b_i, \quad i \in [n]$$

gdje $F_0 : \mathbb{R}^N \rightarrow \mathbb{R}$ zovemo *funkcija cilja*, a funkcije $F_1, \dots, F_n : \mathbb{R}^N \rightarrow \mathbb{R}$ zovu se *funkcije ograničenja*. Ako su F_0, F_1, \dots, F_n konveksne funkcije, tada ovaj problem zovemo *problem konveksne optimizacije*. Ako su te funkcije linearne, tada je to *problem linearnog programiranja* (vidi [4]). Primijetimo da je problem rekonstrukcije rijetkog vektora (P_0), zapravo problem minimizacije. No, nažalost taj problem nije konveksan i kao što smo u prethodnom poglavlju pokazali, općenito je \mathfrak{NP} -težak. Prisjetimo se da $\|\mathbf{z}\|_q^q$ konvergira k $\|\mathbf{z}\|_0$ za $q \rightarrow 0^+$, pa je prirodno (P_0) aproksimirati problemom

$$\min \|\mathbf{z}\|_q \quad \text{uz uvjet } \mathbf{Az} = \mathbf{y}. \quad (P_q)$$

Pokaže se da za $q > 1$, čak 1-rijetki vektori nisu rješenja od (P_q). Dok za $0 < q < 1$, (P_q) ponovno nije konveksan i dalje je općenito \mathfrak{NP} -težak. Za $q = 1$, problem postaje

konveksan

$$\min \|\mathbf{z}\|_1 \quad \text{uz uvjet } \mathbf{Az} = \mathbf{y}. \quad (P_1)$$

To je zapravo konveksna relaksacija problema (P_0) i zovemo ga ℓ_1 -minimizacija ili BP algoritam (eng. *basis pursuit*).

ℓ_1 -minimizacija (BP)

Ulaz: Matrica mjerenja \mathbf{A} , vektor mjerenja \mathbf{y} .

Problem:

$$\mathbf{x}^\sharp = \arg \min \|\mathbf{z}\|_1 \quad \text{uz uvjet } \mathbf{Az} = \mathbf{y} \quad (\ell_1 - \min)$$

Izlaz: vektor \mathbf{x}^\sharp

Pokažimo sada da su ℓ_1 -minimizatori rijetki vektori u realnom slučaju.

Teorem 2.1.1. *Neka je $\mathbf{A} \in \mathbb{R}^{m \times N}$ matrica mjerenja sa stupcima $\mathbf{a}_1, \dots, \mathbf{a}_N$. Ako je \mathbf{x}^\sharp minimizator od*

$$\min_{\mathbf{z} \in \mathbb{R}^N} \|\mathbf{z}\|_1 \quad \text{uz uvjet } \mathbf{Az} = \mathbf{y},$$

tada je skup $\{\mathbf{a}_j, j \in \text{supp}(\mathbf{x}^\sharp)\}$ linearno nezavisan i vrijedi

$$\|\mathbf{x}^\sharp\|_0 = \text{card}(\text{supp}(\mathbf{x}^\sharp)) \leq m.$$

Dokaz. Pretpostavimo suprotno, tj. da je skup $\{\mathbf{a}_j, j \in \text{supp}(\mathbf{x}^\sharp)\}$ linearno zavisin. Neka je $S = \text{supp}(\mathbf{x}^\sharp)$. To znači da postoji ne-nul vektor $\mathbf{v} \in \mathbb{R}^N$ s nosačem na S takav da je $\mathbf{Av} = \mathbf{0}$. Tada za svaki $t \neq 0$ imamo

$$\|\mathbf{x}^\sharp\|_1 < \|\mathbf{x}^\sharp + t\mathbf{v}\|_1 = \sum_{j \in S} |x_j^\sharp + tv_j| = \sum_{j \in S} \text{sgn}(x_j^\sharp + tv_j)(x_j^\sharp + tv_j).$$

Ako je $|t|$ dovoljno mali, tj. $|t| < \min_{j \in S} |x_j^\sharp| / \|\mathbf{v}\|_\infty$, onda vrijedi

$$\text{sgn}(x_j^\sharp + tv_j) = \text{sgn}(x_j^\sharp) \quad \text{za svaki } j \in S.$$

Dakle, za $0 < |t| < \min_{j \in S} |x_j^\sharp| / \|\mathbf{v}\|_\infty$ slijedi

$$\begin{aligned} \|\mathbf{x}^\sharp\|_1 &< \sum_{j \in S} \operatorname{sgn}(x_j^\sharp)(x_j^\sharp + tv_j) = \sum_{j \in S} \operatorname{sgn}(x_j^\sharp)(x_j^\sharp) + t \sum_{j \in S} \operatorname{sgn}(x_j^\sharp)v_j \\ &= \|\mathbf{x}^\sharp\|_1 + t \sum_{j \in S} \operatorname{sgn}(x_j^\sharp)v_j. \end{aligned}$$

No, to je kontradikcija jer $t \neq 0$ možemo odabrati dovoljno mali tako da je $t \sum_{j \in S} \operatorname{sgn}(x_j^\sharp)v_j \leq 0$. \square

U realnom slučaju, (P_1) možemo reinterpretirati kao problem linearnog programiranja, tako da uvedemo pomoćne varijable \mathbf{z}^+ , $\mathbf{z}^- \in \mathbb{R}^N$ definirane sa

$$z_j^+ = \begin{cases} z_j & \text{za } z_j > 0, \\ 0 & \text{za } z_j \leq 0 \end{cases} \quad z_j^- = \begin{cases} 0 & \text{za } z_j > 0, \\ -z_j & \text{za } z_j \leq 0 \end{cases}$$

za svaki $j \in [N]$. Tada je problem (P_1) ekvivalentan problemu

$$\min_{\mathbf{z}^+, \mathbf{z}^- \in \mathbb{R}^N} \sum_{j=1}^N (z_j^+ + z_j^-) \quad \text{uz uvjet} \quad \begin{bmatrix} \mathbf{A} & -\mathbf{A} \end{bmatrix} \begin{bmatrix} \mathbf{z}^+ \\ \mathbf{z}^- \end{bmatrix} = \mathbf{y}, \quad \begin{bmatrix} \mathbf{z}^+ \\ \mathbf{z}^- \end{bmatrix} \geq 0. \quad (P'_1)$$

Isto ne vrijedi za kompleksan slučaj. Tu činjenicu pokazat ćemo na općenitijem problemu,

$$\min \|\mathbf{z}\|_1 \quad \text{uz uvjet} \quad \|\mathbf{A}\mathbf{z} - \mathbf{y}\|_2 \leq \eta. \quad (P_{1,\eta})$$

Taj problem je zapravo pogodniji za praksu, pošto vektor $\mathbf{y} \in \mathbb{C}^m$ ne možemo izmjeriti s beskonačnom točnošću, već uz neku grešku $\mathbf{e} \in \mathbb{C}^m$ pa je stoga

$$\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{e}.$$

U praksi takvoj grešci često možemo ocijeniti ℓ_2 -normu

$$\|\mathbf{e}\|_2 \leq \eta, \quad \text{za neki } \eta > 0.$$

Za dani vektor $\mathbf{z} \in \mathbb{C}^N$, neka su $\mathbf{u}, \mathbf{v} \in \mathbb{R}^N$ njegovi realni i imaginarni dijelovi te neka je $\mathbf{c} \in \mathbb{R}^N$ takav da je $c_j \geq |z_j| = \sqrt{u_j^2 + v_j^2}$ za sve $j \in [N]$. Problem $(P_{1,\eta})$ je tada ekvivalentan problemu

$$\begin{aligned} \min_{\mathbf{c}, \mathbf{u}, \mathbf{v} \in \mathbb{R}^N} \sum_{j=1}^N c_j \quad \text{uz uvjete} \quad & \left\| \begin{bmatrix} \operatorname{Re}(\mathbf{A}) & -\operatorname{Im}(\mathbf{A}) \\ \operatorname{Im}(\mathbf{A}) & \operatorname{Re}(\mathbf{A}) \end{bmatrix} \begin{bmatrix} \mathbf{u} \\ \mathbf{v} \end{bmatrix} - \begin{bmatrix} \operatorname{Re}(\mathbf{y}) \\ \operatorname{Im}(\mathbf{y}) \end{bmatrix} \right\|_2 \leq \eta \\ & \sqrt{u_j^2 + v_j^2} \leq c_j, \quad \forall j \in [N]. \end{aligned} \quad (P'_{1,\eta})$$

Ovo je *problem konike drugog reda*. Primijetimo da za $\eta = 0$ dobivamo formulaciju problema (P_1) za kompleksni slučaj u takvom obliku.

Princip rješavanja $(P_{1,\eta})$ zove se *kvadratično ograničena ℓ_1 -minimizacija* ili *ℓ -minimizacija osjetljiva na šum* (eng. *quadratically constrained basis pursuit*).

Kvadratično ograničena ℓ_1 -minimizacija

Ulaz: Matrica mjerenja \mathbf{A} , vektor mjerenja \mathbf{y} , razina šuma η .

Problem:

$$\mathbf{x}^\# = \arg \min \|\mathbf{z}\|_1 \quad \text{uz uvjet } \|\mathbf{Az} - \mathbf{y}\|_2 \leq \eta \quad (\ell_1 - \min_\eta)$$

Izlaz: vektor $\mathbf{x}^\#$

Rješenje $\mathbf{x}^\#$ povezano je s rješenjem problema ℓ_1 -minimizacije s ugrađenim uklanjanjem šuma

$$\min_{\mathbf{z} \in \mathbb{C}^N} \lambda \|\mathbf{z}\|_1 + \|\mathbf{Az} - \mathbf{y}\|_2^2 \quad (2.1)$$

za neki $\lambda \geq 0$. Također povezano je s rješenjem *LASSO* problema (vidi [13]), za neki $\tau \geq 0$,

$$\min_{\mathbf{z} \in \mathbb{C}^N} \|\mathbf{Az} - \mathbf{y}\|_2 \quad \text{uz uvjet } \|\mathbf{z}\|_1 \leq \tau \quad (2.2)$$

To upravo tvrdi naredna propozicija.

Propozicija 2.1.2. (a) *Ako je \mathbf{x} minimizator problema (2.1) s $\lambda > 0$, onda postoji $\eta = \eta_{\mathbf{x}} \geq 0$ takav da je \mathbf{x} minimizator kvadratično ograničene ℓ_1 -minimizacije $(P_{1,\eta})$.*

(b) *Ako je \mathbf{x} jedinstveni minimizator problema $(P_{1,\eta})$ s $\eta \geq 0$, onda postoji $\tau = \tau_{\mathbf{x}} \geq 0$ takav da je \mathbf{x} minimizator *LASSO* problema (2.2).*

(c) *Ako je \mathbf{x} minimizator *LASSO* problema (2.2), onda postoji $\lambda = \lambda_{\mathbf{x}} \geq 0$ takav da je \mathbf{x} minimizator problema (2.1).*

Dokaz. (a) Neka je $\eta := \|\mathbf{Ax} - \mathbf{y}\|_2$ i $\mathbf{z} \in \mathbb{C}^N$ takav da je $\|\mathbf{Az} - \mathbf{y}\|_2 \leq \eta$. Pošto je prema pretpostavci \mathbf{x} minimizator od (2.1) slijedi

$$\lambda \|\mathbf{x}\|_1 + \|\mathbf{Ax} - \mathbf{y}\|_2^2 \leq \lambda \|\mathbf{z}\|_1 + \|\mathbf{Az} - \mathbf{y}\|_2^2 \leq \lambda \|\mathbf{z}\|_1 + \|\mathbf{Ax} - \mathbf{y}\|_2^2.$$

Dakle slijedi da je $\|\mathbf{x}\|_1 \leq \|\mathbf{y}\|_1$, pa je \mathbf{x} minimizator problema $(P_{1,\eta})$

- (b) Neka je $\eta := \|\mathbf{x}\|_1$ i neka je $\mathbf{z} \in \mathbb{C}^N \setminus \{\mathbf{x}\}$ takav da je $\|\mathbf{z}\|_1 \leq \tau$. Pošto je \mathbf{x} jedinstveni minimizator od $(P_{1,\eta})$ to znači da \mathbf{z} ne može zadovoljavati uvjet iz $(P_{1,\eta})$, pa stoga $\|\mathbf{Az} - \mathbf{y}\|_2 > \eta \geq \|\mathbf{Ax} - \mathbf{y}\|_2$. Dakle, \mathbf{x} je jedinstveni minimizator *LASSO* problema.
- (c) Za dokaz ove tvrdnje potrebni su alati konveksne analize, vidi teorem B.24 u [5].

□

2.2 Greedy metode

Upoznat ćemo se s dva iterativna greedy algoritma koji se često koriste u kontekstu sažetog uzorkovanja. Prvo algoritam koji ćemo proučiti zove se *OMP* (skraćena od eng. *orthogonal matching pursuit*).

OMP

Ulaz: Matrica mjerenja \mathbf{A} , vektor mjerenja \mathbf{y} .

Inicijalizacija: $S^0 = \emptyset$, $\mathbf{x}^0 = \mathbf{0}$

Iteracija: Zaustavi kada $n = \bar{n}$:

$$S^{n+1} = S^n \cup \{j_{n+1}\}, \quad j_{n+1} := \arg \max_{j \in [N]} |(\mathbf{A}^*(\mathbf{y} - \mathbf{Ax}^n))_j|, \quad (OMP_1)$$

$$\mathbf{x}^{n+1} = \arg \min_{\mathbf{z} \in \mathbb{C}^N} \{\|\mathbf{y} - \mathbf{Az}\|_2, \text{supp}(\mathbf{z}) \subseteq S^{n+1}\}. \quad (OMP_2)$$

Izlaz: \bar{n} -rijedak vektor $\mathbf{x}^\# = \mathbf{x}^{\bar{n}}$.

Numerički najskuplja operacija ovog algoritma je (OMP_2) . Situacija se može popraviti korištenjem *QR* dekompozicije matrice \mathbf{A}_{S_n} . Tada se mogu iskoristiti efikasni algoritmi za ažuriranje *QR* dekompozicije kada se u matricu doda novi stupac. Nadalje, za dodatna ubrzanja mogu se iskoristiti i algoritmi za brzo matrica-vektor množenje bazirani na brzom Fourierovoj transformaciji.

Indeks j_{n+1} bira se tako da se reducira ℓ_2 -norma reziduala $\mathbf{y} - \mathbf{Ax}^n$ što je više moguće. Sljedeća lema opravdava zašto je smisleno j odabrati takav da maksimizira vrijednost $|(\mathbf{A}^*(\mathbf{y} - \mathbf{Ax}^n))_j|$.

Lema 2.2.1. Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ s ℓ_2 -normaliziranim stupcima. Ako su $S \subseteq [N]$, $\mathbf{v} \in \mathbb{C}^N$ s nosačem na S , $j \in [N]$, te ako vrijedi

$$\mathbf{w} := \arg \min_{\mathbf{z} \in \mathbb{C}^N} \{\|\mathbf{y} - \mathbf{Az}\|_2, \text{supp}(\mathbf{z}) \subseteq S \cup \{j\}\},$$

tada

$$\|\mathbf{y} - \mathbf{Aw}\|_2^2 \leq \|\mathbf{y} - \mathbf{Av}\|_2^2 - |(\mathbf{A}^*(\mathbf{y} - \mathbf{Av}))_j|^2.$$

Dokaz. Pošto svaki vektor oblika $\mathbf{v} + t\mathbf{e}_j$, $t \in \mathbb{C}$, ima nosač u $S \cup \{j\}$ vrijedi,

$$\|\mathbf{y} - \mathbf{Aw}\|_2^2 \leq \min_{t \in \mathbb{C}} \|\mathbf{y} - \mathbf{A}(\mathbf{v} + t\mathbf{e}_j)\|_2^2.$$

Stavimo da je $t = \rho e^{i\theta}$, gdje je $\rho \geq 0$ i $\theta \in [0, 2\pi)$. Imamo,

$$\begin{aligned} \|\mathbf{y} - \mathbf{A}(\mathbf{v} + t\mathbf{e}_j)\|_2^2 &= \|\mathbf{y} - \mathbf{Av} - t\mathbf{Ae}_j\|_2^2 \\ &= \|\mathbf{y} - \mathbf{Av}\|_2^2 + |t|^2 \|\mathbf{Ae}_j\|_2^2 - 2\text{Re}(\bar{t}\langle \mathbf{y} - \mathbf{Av}, \mathbf{Ae}_j \rangle) \\ &= \|\mathbf{y} - \mathbf{Av}\|_2^2 + \rho^2 - 2\text{Re}(\rho e^{-i\theta} (\mathbf{A}^*(\mathbf{y} - \mathbf{Av}))_j) \\ &\geq \|\mathbf{y} - \mathbf{Av}\|_2^2 + \rho^2 - 2\rho |(\mathbf{A}^*(\mathbf{y} - \mathbf{Av}))_j|^2 \end{aligned}$$

gdje jednakost vrijedi za pogodno odabrani θ . Kao kvadratni polinom u varijabli ρ , zadnji izraz poprima minimum za $\rho = |(\mathbf{A}^*(\mathbf{y} - \mathbf{Av}))_j|$. \square

Korak (OMP_2) može se prikazati u obliku

$$\mathbf{x}_{S^{n+1}}^{n+1} = \mathbf{A}_{S^{n+1}}^\dagger \mathbf{y},$$

gdje je $\mathbf{x}_{S^{n+1}}^{n+1}$ restrikcija od \mathbf{x}^{n+1} na svoj nosač S^{n+1} i gdje je $\mathbf{A}_{S^{n+1}}^\dagger$ pseudo-inverz od $\mathbf{A}_{S^{n+1}}$ (vidi [9]). Drugim riječima to znači da je $\mathbf{z} = \mathbf{x}_{S^{n+1}}^{n+1}$ rješenje sustava $\mathbf{A}_{S^{n+1}}^* \mathbf{A}_{S^{n+1}} \mathbf{z} = \mathbf{A}_{S^{n+1}}^* \mathbf{y}$. Ta činjenica je korisna i u drugim algoritmima koji imaju korak sličan s (OMP_2).

Lema 2.2.2. Ako je $S \subseteq [N]$ i

$$\mathbf{v} := \arg \min_{\mathbf{z} \in \mathbb{C}^N} \{\|\mathbf{y} - \mathbf{Az}\|_2, \text{supp}(\mathbf{z}) \subseteq S\},$$

tada je

$$(\mathbf{A}^*(\mathbf{y} - \mathbf{Av}))_S = \mathbf{0}. \quad (2.3)$$

Dokaz. Prema definiciji vektora \mathbf{v} , vektor \mathbf{Av} je ortogonalna projekcija vektora \mathbf{y} na

prostor $\{\mathbf{Az}, \text{supp}(\mathbf{z} \subseteq S)\}$, pa je karakteriziran relacijom ortogonalnosti

$$\langle \mathbf{y} - \mathbf{Av}, \mathbf{Az} \rangle = 0 \quad \text{za sve } \mathbf{z} \in \mathbb{C}^N \text{ takve da } \text{supp}(\mathbf{z}) \subseteq S.$$

Dakle, imamo da vrijedi $\langle \mathbf{A}^*(\mathbf{y} - \mathbf{Av}), \mathbf{z} \rangle = 0$ za sve $\mathbf{z} \in \mathbb{C}^N$, $\text{supp}(\mathbf{z}) \subseteq S$, što vrijedi ako i samo ako vrijedi (2.3). \square

Prirodan uvjet zaustavljanja OMP-a je kada se postigne $\|\mathbf{y} - \mathbf{Ax}^{\bar{n}}\|_2 \leq \varepsilon$ ili $\|\mathbf{A}^*(\mathbf{y} - \mathbf{Ax}^{\bar{n}})\|_\infty \leq \varepsilon$ za neku toleranciju $\varepsilon > 0$. Ako nam je dostupna ocjena rijetkosti s rješenja \mathbf{x} , tada je razumno stati kada je $\bar{n} = s$. Sljedeći rezultat govori o uvjetima za uspješnu rekonstrukciju s -rijetkog vektora u s iteracija OMP algoritma.

Propozicija 2.2.3. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$. Svaki ne-nul vektor $\mathbf{x} \in \mathbb{C}^N$ s nosačem na skupu S , kardinaliteta s može se rekonstruirati iz $\mathbf{y} = \mathbf{Ax}$ u najviše s iteracija OMP algoritma ako i samo ako je matrica \mathbf{A}_S injektivna i*

$$\max_{j \in S} |(\mathbf{A}^* \mathbf{r})_j| > \max_{l \in \bar{S}} |(\mathbf{A}^* \mathbf{r})_l| \quad (2.4)$$

za sve ne-nul $\mathbf{r} \in \{\mathbf{Az}, \text{supp}(\mathbf{z}) \subseteq S\}$.

Dokaz. Pretpostavimo da OMP algoritam rekonstruira sve vektore s nosačem na skupu S u najviše $s = \text{card}(S)$ iteracija. Neka su \mathbf{v}, \mathbf{w} s nosačem na S , takvi da je $\mathbf{Av} = \mathbf{Aw}$. Zbog pretpostavke, \mathbf{v} i \mathbf{w} moraju biti jednaki, a to znači da je matrica \mathbf{A}_S injektivna. Nadalje, ako je $\mathbf{y} = \mathbf{Ax}$ za neki $\mathbf{x} \in \mathbb{C}^N$ sa $\text{supp}(\mathbf{x}) = S$, indeks $l \in \bar{S}$ ne može biti izabran u prvoj iteraciji, pošto indeks izabran u prvoj iteraciji ostaje uvijek u nosaču, a po pretpostavci OMP rekonstruira \mathbf{x} iz $\mathbf{y} = \mathbf{Ax}$ u točno s iteracija. Dakle za $n = 0$ iz (OMP_1) imamo da je $\max_{j \in S} |(\mathbf{A}^* \mathbf{y})_j| > |(\mathbf{A}^* \mathbf{y})_l|$ za svaki $l \in \bar{S}$, pa stoga vrijedi $\max_{j \in S} |(\mathbf{A}^* \mathbf{y})_j| > \max_{l \in \bar{S}} |(\mathbf{A}^* \mathbf{y})_l|$ za sve ne-nul $\mathbf{y} \in \{\mathbf{Az}, \text{supp}(\mathbf{z}) \subseteq S\}$.

Obratno, pretpostavimo da je $\mathbf{Ax}^1 \neq \mathbf{y}, \dots, \mathbf{Ax}^{s-1} \neq \mathbf{y}$ jer u suprotnom nemamo što dokazivati. Pokazat ćemo da $S^n \subseteq S$, $\text{card}(S^n) = n$ za $0 \leq n \leq s$. To će implicirati $S^s = S$. Nadalje, (OMP_2) daje $\mathbf{Ax}^s = \mathbf{y}$ a iz injektivnosti od \mathbf{A}_S slijedi $\mathbf{x}_s = \mathbf{x}$. Dakle, neka je $0 \leq n \leq s-1$. Ako je $S^n \subseteq S$, to povlači da je $\mathbf{r}^n := \mathbf{y} - \mathbf{Ax}^n \in \{\mathbf{Az}, \text{supp}(\mathbf{z}) \subseteq S\}$, pa prema (2.4) indeks j_{n+1} leži u S , pa $S^{n+1} = S \cup \{j_{n+1}\} \subseteq S$. Ovo induktivno pokazuje da je S^n podskup od S za svaki $0 \leq n \leq s$. Nadalje, neka je $1 \leq n \leq s-1$. Lema (2.2.2) daje $(\mathbf{A}^* \mathbf{r}^n)_{S^n} = \mathbf{0}$. Stoga, iz (OMP_1) vidimo da indeks j_{n+1} ne leži u S^n , jer bi u protivnom $\mathbf{A}^* \mathbf{r}^n = \mathbf{0}$, a po (2.4) $\mathbf{r}^n = \mathbf{0}$. Dakle, $\text{card}(S^n) = n$. \square

Slabost OMP algoritma leži u činjenici da ako krivi indeks uđe u nosač, on ostaje u nosaču u svim sljedećim iteracijama. Stoga s iteracija algoritma nije dovoljno za rekonstrukciju vektora koji je s -rijedak. Moguće rješenje je povećati broj iteracija. Naredni algoritam, CoSaMP (eng. *compressive sampling matching pursuit*

algorithm), koristi drugačiju strategiju kada nam je dostupna ocijena rijetkosti s . Uvedimo oznake $H_s(\mathbf{z})$ za najbolju s -rijetku aproksimaciju vektora $\mathbf{z} \in \mathbb{C}^N$ i $L_s(\mathbf{z})$ za nosač od $H_s(\mathbf{z})$, tj.

$$L_s(\mathbf{z}) := \text{skup indeksa } s \text{ najvećih komponenti vektora } \mathbf{z} \in \mathbb{C}^N \quad (2.5)$$

$$H_s(\mathbf{z}) := \mathbf{z}_{L_s(\mathbf{z})}. \quad (2.6)$$

Nelinearni operator H_s zovemo *hard thresholding* operator reda s . Za dani vektor $\mathbf{z} \in \mathbb{C}^N$ on čuva s apsolutno najvećih komponenti a ostale postavi na nulu. Primijetimo da to nije nužno jedinstveno definirano. Da bi zaobišli taj problem, skup indeksa $L_s(\mathbf{z})$ biramo iz svih mogućih kandidata leksikografskim poretkom.

CoSaMP

Ulaz: Matrica mjerenja \mathbf{A} , vektor mjerenja \mathbf{y} , rijetkost s

Inicijalizacija: s -rijedak vektor \mathbf{x}^0 (npr. $\mathbf{x}^0 = \mathbf{0}$).

Iteracija: Zaustavi kada $n = \bar{n}$:

$$U^{n+1} = \text{supp}(\mathbf{x}^n) \cup L_{2s}(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n)) \quad (\text{CoSaMP}_1)$$

$$\mathbf{u}^{n+1} = \arg \min_{\mathbf{z} \in \mathbb{C}^N} \{\|\mathbf{y} - \mathbf{A}\mathbf{z}\|_2, \text{supp}(\mathbf{z}) \subseteq U^{n+1}\} \quad (\text{CoSaMP}_2)$$

$$\mathbf{x}^{n+1} = H_s(\mathbf{u}^{n+1}) \quad (\text{CoSaMP}_3)$$

Izlaz: \bar{n} -rijedak vektor $\mathbf{x}^\sharp = \mathbf{x}^{\bar{n}}$.

2.3 Granične metode

Algoritmi predstavljeni u ovom poglavlju također koriste *hard thresholding* operator H_s . Prvi algoritam, BT (eng. *basic thresholding*), sastoji se od određivanja nosača s -rijetkog vektora $\mathbf{x} \in \mathbb{C}^N$, koji se rekonstruira iz $\mathbf{y} = \mathbf{A}\mathbf{x} \in \mathbb{C}^m$ te traženja vektora koji najbolje aproksimira mjerenje \mathbf{y} .

BT

Ulaz: Matrica mjerenja \mathbf{A} , vektor mjerenja \mathbf{y} , rijetkost s

Problem:

$$S^\sharp = L_s(\mathbf{A}^* \mathbf{y}), \quad (BT_1)$$

$$\mathbf{x}^\sharp = \arg \min_{\mathbf{z} \in \mathbb{C}^N} \{\|\mathbf{y} - \mathbf{A}\mathbf{z}\|_2, \text{supp}(\mathbf{z}) \subseteq S^\sharp\}. \quad (BT_2)$$

Izlaz: s -rijedak vektor \mathbf{x}^\sharp .

Dovoljni i nužni uvjeti rekonstrukcije jednostavnim BT algoritmom, slični su uvjetima iz (2.4).

Propozicija 2.3.1. *BT algoritam rekonstruira vektor $\mathbf{x} \in \mathbb{C}^N$ s nosačem na S , iz $\mathbf{y} = \mathbf{A}\mathbf{x}$ ako i samo ako*

$$\min_{j \in S} |(\mathbf{A}^* \mathbf{y})_j| > \max_{l \in \bar{S}} |(\mathbf{A}^* \mathbf{y})_l|. \quad (2.7)$$

Dokaz. Vektor \mathbf{x} može se rekonstruirati ako i samo ako je skup indeksa S^\sharp u (BT_1) jednak skupu S . To vrijedi ako i samo ako je element vektora $\mathbf{A}^* \mathbf{y}$ s indeksom iz S , veći od svakog elementa vektora $\mathbf{A}^* \mathbf{y}$ s indeksom u \bar{S} . \square

IHT (eng. *iterative hard thresholding*) algoritam rješava kvadratni sustav $\mathbf{A}^* \mathbf{A}\mathbf{z} = \mathbf{A}^* \mathbf{y}$ umjesto $\mathbf{A}\mathbf{z} = \mathbf{y}$. To možemo interpretirati kao rješavanje problema fiksne točke $\mathbf{z} = (\mathbf{I} - \mathbf{A}^* \mathbf{A})\mathbf{z} + \mathbf{A}^* \mathbf{y}$. Prirodno je gledati iteracije oblika $\mathbf{x}^{n+1} = (\mathbf{I} - \mathbf{A}^* \mathbf{A})\mathbf{x}^n + \mathbf{A}^* \mathbf{y}$. Pošto tražimo s -rijetko rješenje u svakoj iteraciji uzimamo samo s apsolutno najvećih komponenti od $(\mathbf{I} - \mathbf{A}^* \mathbf{A})\mathbf{x}^n + \mathbf{A}^* \mathbf{y}$.

IHT

Ulaz: Matrica mjerenja \mathbf{A} , vektor mjerenja \mathbf{y} , rijetkost s

Inicijalizacija: s -rijedak vektor \mathbf{x}^0 (npr. $\mathbf{x}^0 = \mathbf{0}$).

Iteracija: Zaustavi kada $n = \bar{n}$:

$$\mathbf{x}^{n+1} = H_s(\mathbf{x}^n + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n). \quad (IHT)$$

Izlaz: s -rijedak vektor $\mathbf{x}^\sharp = \mathbf{x}^{\bar{n}}$.

Primijetimo da IHT algoritam ne koristi ortogonalne projekcije, što je njegova prednost. No, ako smo spremi platiti cijenu projekcija, ima smisla gledati vektor koji ima isti nosač kao \mathbf{x}^{n+1} koji najbolje aproksimira mjerenje. Upravo je to strategija HTP (eng. *hard thresholding pursuit*) algoritma.

HTP

Ulaz: Matrica mjerenja \mathbf{A} , vektor mjerenja \mathbf{y} , rijetkost s

Inicijalizacija: s -rijedak vektor \mathbf{x}^0 (npr. $\mathbf{x}^0 = \mathbf{0}$).

Iteracija: Zaustavi kada $n = \bar{n}$:

$$S^{n+1} = L_s(\mathbf{x}^n + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n), \quad (HTP_1)$$

$$\mathbf{x}^{n+1} = \arg \min_{\mathbf{z} \in \mathbb{C}^N} \{\|\mathbf{y} - \mathbf{A}\mathbf{z}\|_2, \text{supp}(\mathbf{z}) \subseteq S^{n+1}\}. \quad (HTP_2)$$

Izlaz: s -rijedak vektor $\mathbf{x}^\sharp = \mathbf{x}^{\bar{n}}$.

Poglavlje 3

ℓ_1 -minimizacija

Prisjetimo se, problem sažetog uzorkovanja sastoji se od rekonstrukcije s -rijetkog vektora $\mathbf{x} \in \mathbb{C}^N$ iz mjerenja $\mathbf{y} = \mathbf{A}\mathbf{x} \in \mathbb{C}^m$, gdje je $m < N$. Prirodno se nameće problem ℓ_0 -minimizacije,

$$\min_{\mathbf{z} \in \mathbb{C}^N} \|\mathbf{z}\|_0 \quad \text{uz uvjet } \mathbf{A}\mathbf{z} = \mathbf{y}. \quad (P_0)$$

U poglavlju (1) vidjeli smo da je taj problem općenito \mathfrak{NP} -težak. U poglavlju (2) pokazali smo nekoliko učinkovitih strategija za rješavanje problema sažetog uzorkovanja. U ovom poglavlju fokusirat ćemo se na strategiju ℓ_1 -minimizacije

$$\min_{\mathbf{z} \in \mathbb{C}^N} \|\mathbf{z}\|_1 \quad \text{uz uvjet } \mathbf{A}\mathbf{z} = \mathbf{y}. \quad (P_1)$$

Proučit ćemo uvjete na matricu \mathbf{A} koji osiguravaju egzaktnu ili aproksimativnu rekonstrukciju vektora \mathbf{x} .

3.1 Svojstvo nul-prostora

Argumenti u ovom potpoglavlju vrijede u kontekstu realnih i u kontekstu kompleksnih prostora. Stoga ćemo rezultate prvo iznijeti za polje \mathbb{K} , koje može biti \mathbb{R} ili \mathbb{C} . Nakon toga uspostaviti ćemo ekvivalenciju realnog i kompleksnog svojstva nul-prostora.

Definicija 3.1.1. Za matricu $\mathbf{A} \in \mathbb{K}^{m \times N}$ kažemo da zadovoljava svojstvo nul-prostora za skup $S \subseteq [N]$ ako vrijedi

$$\|\mathbf{v}_S\|_1 < \|\mathbf{v}_{\bar{S}}\|_1 \quad \text{za svaki } \mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}. \quad (3.1)$$

Nadalje, kažemo da \mathbf{A} zadovoljava svojstvo nul-prostora reda s ako zadovoljava gornju nejednakost za svaki $S \subseteq [N]$ takav da je $\text{card}(S) \leq s$.

Primijetimo da za vektor $\mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}$ svojstvo nul-prostora vrijedi za svaki $S \subseteq [N]$ takav da je $\text{card}(S) \leq s$, čim vrijedi za skup indeksa s apsolutno najvećih komponenti vektora \mathbf{v} .

Postoje dvije dodatne formulacije svojstva nul-prostora. Prvu dobijemo tako da gornjoj nejednakosti dodamo $\|\mathbf{v}_S\|_1$ s obje strane. Tada imamo

$$2\|\mathbf{v}_S\|_1 < \|\mathbf{v}\|_1 \quad \text{za svaki } \mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}. \quad (3.2)$$

Drugu dobijemo tako da u skup S stavimo s apsolutno najvećih komponenti vektora \mathbf{v} i ovaj put nejednakosti dodamo $\|\mathbf{v}_{\bar{S}}\|_1$ s obje strane. Tada imamo

$$\|\mathbf{v}\|_1 < 2\sigma_s(\mathbf{v})_1 \quad \text{za sve } \mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}. \quad (3.3)$$

Prisjetimo se definicije (1.1.2) ℓ_p -greške najbolje s -rijetke aproksimacije vektora $\mathbf{x} \in \mathbb{K}^N$,

$$\sigma_s(\mathbf{x})_p = \inf_{\|\mathbf{z}\|_0 \leq s} \|\mathbf{x} - \mathbf{z}\|_p.$$

Sljedeći teorem govori o vezi svojstva nul-prostora i egzaktne rekonstrukcije rijetkog vektora putem ℓ_1 -minimizacije.

Teorem 3.1.2. *Za $\mathbf{A} \in \mathbb{K}^{m \times N}$, svaki vektor $\mathbf{x} \in \mathbb{K}^N$ s nosačem na S je jedinstveno rješenje od (P_1) s $\mathbf{y} = \mathbf{A}\mathbf{x}$ ako i samo ako \mathbf{A} zadovoljava svojstvo nul-prostora za skup S .*

Dokaz. Neka je skup indeksa S fiksiran. Pretpostavimo da je svaki vektor $\mathbf{x} \in \mathbb{K}^N$ s nosačem na S jedinstveni minimizator od $\|\mathbf{z}\|_1$ takav da je $\mathbf{A}\mathbf{z} = \mathbf{A}\mathbf{x}$. Stoga za svaki $\mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}$, vektor \mathbf{v}_S je jedinstveni minimizator od $\|\mathbf{z}\|_1$ takav da je $\mathbf{A}\mathbf{z} = \mathbf{A}\mathbf{v}_S$. Međutim, imamo $\mathbf{A}(-\mathbf{v}_{\bar{S}}) = \mathbf{A}\mathbf{v}_S$ i $-\mathbf{v}_{\bar{S}} \neq \mathbf{v}_S$ jer je $\mathbf{v} \neq \mathbf{0}$ i $\mathbf{0} = \mathbf{A}\mathbf{v} = \mathbf{A}(\mathbf{v}_S + \mathbf{v}_{\bar{S}})$. Dakle, mora vrijediti $\|\mathbf{v}_S\|_1 < \|\mathbf{v}_{\bar{S}}\|_1$.

Obratno, pretpostavimo da \mathbf{A} zadovoljava svojstvo nul-prostora za skup S . Tada za vektor $\mathbf{x} \in \mathbb{K}^N$ s nosačem na S i za $\mathbf{z} \in \mathbb{K}^N$, $\mathbf{z} \neq \mathbf{x}$ takve da je $\mathbf{A}\mathbf{z} = \mathbf{A}\mathbf{x}$, označimo vektor $\mathbf{v} := \mathbf{x} - \mathbf{z} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}$. Imamo,

$$\|\mathbf{x}\|_1 \leq \|\mathbf{x} - \mathbf{z}_S\|_1 + \|\mathbf{z}_S\|_1 = \|\mathbf{v}_S\|_1 + \|\mathbf{z}_S\|_1 < \|\mathbf{v}_{\bar{S}}\|_1 + \|\mathbf{z}_S\|_1 = \|-\mathbf{z}_{\bar{S}}\|_1 + \|\mathbf{z}_S\|_1 = \|\mathbf{z}\|_1.$$

Dakle, vektor \mathbf{x} je minimizator od (P_1) . \square

Variranjem skupa S , sljedeći rezultat slijedi direktno iz prethodnog teorema.

Teorem 3.1.3. *Za matricu $\mathbf{A} \in \mathbb{K}^{m \times N}$, svaki s -rijedak vektor $\mathbf{x} \in \mathbb{K}^N$ je jedinstveno rješenje problema (P_1) uz $\mathbf{y} = \mathbf{A}\mathbf{x}$ ako i samo ako \mathbf{A} zadovoljava svojstvo nul-prostora reda s .*

Primijetimo da prethodni teorem tvrdi da za svaki $\mathbf{y} = \mathbf{Ax}$, gdje je \mathbf{x} s -rijedak, ℓ_1 -minimizacija (P_1) zapravo rješava problem ℓ_0 -minimizacije (P_0) kada vrijedi svojstvo nul-prostora reda s . Zaista, pretpostavimo da se svaki s -rijedak vektor \mathbf{x} može rekonstruirati ℓ_1 -minimizacijom iz $\mathbf{y} = \mathbf{Ax}$. Neka je \mathbf{z} minimizator ℓ_0 problema (P_0) s $\mathbf{y} = \mathbf{Ax}$, tada je $\|\mathbf{z}\|_0 \leq \|\mathbf{x}\|_0$ pa je \mathbf{z} također s -rijedak. No, po prethodnom teoremu, svaki s -rijedak vektor je jedinstveni ℓ_1 -minimizator pa slijedi da je $\mathbf{x} = \mathbf{z}$.

Za algoritam rekonstrukcije poželjno je da zadrži mogućnost rekonstrukcije ako su neka od mjerenja reskaliraju, permutiraju ili dodaju nova. ℓ_1 -minimizacija ima takvo svojstvo. Formalno, gore opisane promjene zapravo predstavljaju zamjenu matrice \mathbf{A} matricama $\hat{\mathbf{A}}$ i $\tilde{\mathbf{A}}$

$$\begin{aligned}\hat{\mathbf{A}} &:= \mathbf{GA}, \quad \text{gdje je } \mathbf{G} \text{ neka invertibilna } m \times m \text{ matrica,} \\ \tilde{\mathbf{A}} &:= \begin{bmatrix} \mathbf{A} \\ \mathbf{B} \end{bmatrix}, \quad \text{gdje je } \mathbf{B} \text{ neka } m' \times N \text{ matrica.}\end{aligned}$$

Primijetimo da je $\ker \hat{\mathbf{A}} = \ker \mathbf{A}$ i $\ker \tilde{\mathbf{A}} \subseteq \ker \mathbf{A}$, pa svojstvo nul-prostora vrijedi i za matrice $\hat{\mathbf{A}}$ i $\tilde{\mathbf{A}}$.

Za kraj proučit ćemo utjecaj polja \mathbb{K} . Razlika između $\ker_{\mathbb{R}} \mathbf{A}$ i $\ker_{\mathbb{C}} \mathbf{A} = \ker_{\mathbb{R}} \mathbf{A} + i \ker_{\mathbb{R}} \mathbf{A}$ vodi u slučaju da je $\mathbb{K} = \mathbb{R}$ na realno svojstvo nul-prostora,

$$\sum_{j \in S} |v_j| < \sum_{l \in \bar{S}} |v_l| \quad \text{za svaki } \mathbf{v} \in \ker_{\mathbb{R}} \mathbf{A}, \mathbf{v} \neq \mathbf{0}, \quad (3.4)$$

a u slučaju da je $\mathbb{K} = \mathbb{C}$, na kompleksno svojstvo nul-prostora,

$$\sum_{j \in S} \sqrt{v_j^2 + w_j^2} < \sum_{l \in \bar{S}} \sqrt{v_l^2 + w_l^2} \quad \text{za svaki } \mathbf{v}, \mathbf{w} \in \ker_{\mathbb{R}} \mathbf{A}, (\mathbf{v}, \mathbf{w}) \neq (\mathbf{0}, \mathbf{0}). \quad (3.5)$$

Zapravo, pokazat ćemo da su svojstva nul-prostora međusobno ekvivalentna u realnom i kompleksnom slučaju. Zato možemo reći da realna matrica mjerenja egzaktno rekonstruira sve rijetke vektore ℓ_1 -minimizacijom.

Teorem 3.1.4. *Neka je $\mathbf{A} \in \mathbb{R}^{m \times N}$. Tada je realno svojstvo nul-prostora (3.4) za skup S ekvivalentno je kompleksnom svojstvu nul-prostora (3.5) za isti skup S .*

Dokaz. Primijetimo (3.4) slijedi direktno iz (3.5) za $\mathbf{w} = \mathbf{0}$. Uzmimo sada $\mathbf{v}, \mathbf{w} \in \ker_{\mathbb{R}} \mathbf{A}$, takvi da je $(\mathbf{v}, \mathbf{w}) \neq (\mathbf{0}, \mathbf{0})$. Ako su \mathbf{v} i \mathbf{w} linearno zavisni. tj. $\mathbf{v} = \alpha \mathbf{w}$ za

neki $\alpha \in \mathbb{R} \setminus \{0\}$ onda je

$$\begin{aligned} \sum_{j \in S} \sqrt{v_j^2 + w_j^2} &= \sum_{j \in S} \sqrt{(1 + \alpha^2)w_j^2} = \sqrt{1 + \alpha^2} \sum_{j \in S} \sqrt{w_j^2} \\ &< \sqrt{1 + \alpha^2} \sum_{j \in \bar{S}} \sqrt{w_j^2} = \sum_{j \in \bar{S}} \sqrt{(1 + \alpha^2)w_j^2} = \sum_{j \in \bar{S}} \sqrt{v_j^2 + w_j^2}. \end{aligned}$$

Pretpostavimo sada da su \mathbf{v} i \mathbf{w} linearno nezavisni i definirajmo $\mathbf{u} := \cos \theta \mathbf{v} + \sin \theta \mathbf{w} \in \ker_{\mathbb{R}} \mathbf{A} \setminus \{0\}$. Tada za svaki $\theta \in \mathbb{R}$ vrijedi

$$\sum_{j \in S} |\cos \theta v_j + \sin \theta w_j| < \sum_{l \in \bar{S}} |\cos \theta v_l + \sin \theta w_l|. \quad (3.6)$$

Za svaki $k \in [N]$, neka je $\theta_k \in [-\pi, \pi]$ takav da

$$v_k = \sqrt{v_k^2 + w_k^2} \cos \theta_k, \quad w_k = \sqrt{v_k^2 + w_k^2} \sin \theta_k.$$

Iz (3.6) slijedi

$$\sum_{j \in S} \sqrt{v_j^2 + w_j^2} |\cos(\theta - \theta_j)| < \sum_{l \in \bar{S}} \sqrt{v_l^2 + w_l^2} |\cos(\theta - \theta_l)|.$$

Integriranjem po $\theta \in [-\pi, \pi]$ dobijemo

$$\sum_{j \in S} \sqrt{v_j^2 + w_j^2} \int_{-\pi}^{\pi} |\cos(\theta - \theta_j)| d\theta < \sum_{l \in \bar{S}} \sqrt{v_l^2 + w_l^2} \int_{-\pi}^{\pi} |\cos(\theta - \theta_l)| d\theta.$$

No lako se provjeri da je

$$\int_{-\pi}^{\pi} |\cos(\theta - \theta')| d\theta = 4$$

tj. da je taj integral pozitivan i neovisan o $\theta' \in [-\pi, \pi]$. □

Nekonveksna minimizacija

Prisjetimo se, ℓ_0 -norma vektora $\mathbf{z} \in \mathbb{C}^N$ aproksimirana je q -tom potencijom svoje ℓ_q -kvazinorme,

$$\|\mathbf{z}\|_q^q := \sum_{j=1}^N |x_j|^q \xrightarrow{q \rightarrow 0} \sum_{j=1}^N \mathbf{1}_{\{z_j \neq 0\}} = \|\mathbf{z}\|_0.$$

To sugerira da ℓ_0 -minimizaciju (P_0) zamijenimo s

$$\min_{\mathbf{z} \in \mathbb{C}^N} \|\mathbf{z}\|_q \quad \text{uz uvjet } \mathbf{Az} = \mathbf{y}. \quad (P_q)$$

Za $0 < q < 1$ taj je problem nekonveksan i \mathfrak{NP} -težak. No, želimo teoretski potvrditi ideju da (P_q) dobro aproksimira (P_0) za male q . Sljedeći teorem daje analogon svojstva nul-prostora za $0 < q < 1$. Dokaz je također analogan dokazu teorema 3.1.3 te se koristi činjenica da ℓ_q -kvazinorma zadovoljava nejednakost trokuta.

Teorem 3.1.5. *Za matricu $\mathbf{A} \in \mathbb{C}^{m \times N}$ i $0 < q < 1$, svaki s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ je jedinstveno rješenje problema (P_q) uz $\mathbf{y} = \mathbf{Ax}$ ako i samo ako*

$$\|\mathbf{v}_S\|_q < \|\mathbf{v}_{\bar{S}}\|_q \quad \text{za svaki } \mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}.$$

Sada možemo dokazati da rekonstrukcija ℓ_q -minimizacijom implicira rekonstrukciju ℓ_p -minimizacijom za $0 < p < q < 1$.

Teorem 3.1.6. *Za matricu $\mathbf{A} \in \mathbb{C}^{m \times N}$ i $0 < p < q < 1$, ako je svaki s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ jedinstveno rješenje problema (P_q) uz $\mathbf{y} = \mathbf{Ax}$ onda je \mathbf{x} također i rješenje problema (P_p) za $\mathbf{y} = \mathbf{Ax}$.*

Dokaz. Prema teoremu 3.1.5 dovoljno je pokazati da vrijedi

$$\sum_{j \in S} |v_j|^p < \sum_{l \in \bar{S}} |v_l|^p, \quad (3.7)$$

ako je $\mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}$, S skup indeksa od s apsolutno najvećih komponenti od \mathbf{v} i ako ista nejednakost vrijedi za q . Dakle, pretpostavimo da (3.7) vrijedi za q . Tada je nužno $\mathbf{v}_{\bar{S}} \neq \mathbf{0}$ pošto je S skup indeksa od s apsolutno najvećih komponenti ne-nul vektora \mathbf{v} . Stoga (3.7) možemo napisati u obliku

$$\sum_{j \in S} \frac{1}{\sum_{l \in \bar{S}} (|v_l|/|v_j|)^p} < 1. \quad (3.8)$$

Primijetimo da $|v_l|/|v_j| \leq 1$ za $l \in \bar{S}$ i $j \in S$. Stoga je lijeva strana (3.8) nepadajuća funkcija u varijabli $0 < p \leq 1$. Zato njezina vrijednost u p ne prelazi njezinu vrijednost u q , koja je manja od 1 po pretpostavci. \square

3.2 Stabilnost

Signali u praksi gotovo nikad nisu idealno rijetki. U najboljem slučaju blizu su rijetkim vektorima. Stoga želimo da metode sažetog uzorkovanja rekonstruiraju vektor

$\mathbf{x} \in \mathbb{C}^N$ s greškom koja je kontrolirana udaljenosti vektora \mathbf{x} do s -rijetkih vektora. Za algoritme koji imaju to svojstvo kažemo da su *stabilni* s obzirom na defekte rijetkosti. Pokazat ćemo da je ℓ_1 -minimizacija (P_1) stabilna pod jačim svojstvom nul-prostora.

Definicija 3.2.1. *Matrica $\mathbf{A} \in \mathbb{C}^{m \times N}$ zadovoljava stabilno svojstvo nul-prostora s konstantom $0 < \rho < 1$ za skup $S \subseteq [N]$ ako*

$$\|\mathbf{v}_S\|_1 \leq \rho \|\mathbf{v}_{\bar{S}}\|_1 \quad \text{za svaki } \mathbf{v} \in \ker \mathbf{A}.$$

Nadalje, kažemo da \mathbf{A} zadovoljava stabilno svojstvo nul-prostora reda s sa konstantom $0 < \rho < 1$ ako zadovoljava zadovoljava gornju nejednakost za svaki $S \subseteq [N]$ takav da $\text{card}(S) = s$.

Teorem 3.2.2. *Ako matrica $\mathbf{A} \in \mathbb{C}^{m \times N}$ zadovoljava stabilno svojstvo nul-prostora reda s sa konstantom $0 < \rho < 1$, tada za svaki $\mathbf{x} \in \mathbb{C}^N$, rješenje \mathbf{x}^\sharp problema (P_1) s $\mathbf{y} = \mathbf{A}\mathbf{x}$ aproksimira vektor \mathbf{x} s ℓ_1 -greškom*

$$\|\mathbf{x} - \mathbf{x}^\sharp\|_1 \leq \frac{2(1 + \rho)}{(1 - \rho)} \sigma_s(\mathbf{x})_1. \quad (3.9)$$

Sada više nemamo jedinstvenost ℓ_1 -minimizatora. Prethodni teorem biti će direktna posljedica jače tvrdnje,

Teorem 3.2.3. *Ako matrica $\mathbf{A} \in \mathbb{C}^{m \times N}$ zadovoljava stabilno svojstvo nul-prostora s konstantom $0 < \rho < 1$ za skup S ako i samo ako*

$$\|\mathbf{z} - \mathbf{x}\|_1 \leq \frac{1 + \rho}{1 - \rho} (\|\mathbf{z}\|_1 - \|\mathbf{x}\|_1 + 2\|\mathbf{x}_{\bar{S}}\|_1) \quad (3.10)$$

za sve vektore $\mathbf{x}, \mathbf{z} \in \mathbb{C}^N$ takve da je $\mathbf{A}\mathbf{z} = \mathbf{A}\mathbf{x}$.

Pokažimo kako teorem 3.2.2 slijedi iz 3.2.3: Neka je S skup s apsolutno najvećih komponenti vektora \mathbf{x} , tako da $\|\mathbf{x}_{\bar{S}}\|_1 = \sigma_s(\mathbf{x})_1$. Ako je \mathbf{x}^\sharp minimizator problema (P_1) , tada vrijedi $\|\mathbf{x}^\sharp\|_1 \leq \|\mathbf{x}\|_1$ i $\mathbf{A}\mathbf{x}^\sharp = \mathbf{A}\mathbf{x}$. Dakle, desnu strana u (3.10) za $\mathbf{z} = \mathbf{x}^\sharp$ možemo ocijeniti desnom stranom (3.9).

Prije dokaza teorema 3.2.3 pokažimo još jedan koristan rezultat.

Lema 3.2.4. *Za $S \subseteq [N]$ i vektore $\mathbf{x}, \mathbf{z} \in \mathbb{C}^N$ vrijedi,*

$$\|(\mathbf{x} - \mathbf{z})_{\bar{S}}\|_1 \leq \|\mathbf{z}\|_1 - \|\mathbf{x}\|_1 + \|(\mathbf{x} - \mathbf{z})_S\|_1 + 2\|\mathbf{x}_{\bar{S}}\|_1.$$

Dokaz. Imamo,

$$\begin{aligned} \|\mathbf{x}\|_1 &= \|\mathbf{x}_{\bar{S}}\|_1 + \|\mathbf{x}_S\|_1 \leq \|\mathbf{x}_{\bar{S}}\|_1 + \|(\mathbf{x} - \mathbf{z})_S\|_1 + \|\mathbf{z}_S\|_1 \\ \|(\mathbf{x} - \mathbf{z})_{\bar{S}}\|_1 &\leq \|\mathbf{x}_{\bar{S}}\|_1 + \|\mathbf{z}_{\bar{S}}\|_1. \end{aligned}$$

Sumiranjem ove dvije nejednakosti, slijedi

$$\|\mathbf{x}\|_1 + \|(\mathbf{x} - \mathbf{z})_{\bar{S}}\|_1 \leq 2\|\mathbf{x}_{\bar{S}}\|_1 + \|(\mathbf{x} - \mathbf{z})_S\|_1 + \|\mathbf{z}\|_1.$$

□

Dokaz (Teorem 3.2.3). Pretpostavimo da matrica \mathbf{A} zadovoljava (3.10) za sve vektore $\mathbf{x}, \mathbf{z} \in \mathbb{C}^N$ uz $\mathbf{Az} = \mathbf{Ax}$. Za dani vektor $\mathbf{v} \in \ker \mathbf{A}$, pošto je $\mathbf{Av}_{\bar{S}} = \mathbf{A}(-\mathbf{v}_S)$ možemo primjeniti (3.10) s $\mathbf{x} = -\mathbf{v}_S$ i $\mathbf{z} = \mathbf{v}_{\bar{S}}$. Slijedi,

$$\|\mathbf{v}\|_1 \leq \frac{1 + \rho}{1 - \rho} (\|\mathbf{v}_{\bar{S}}\|_1 - \|\mathbf{v}_S\|_1).$$

To možemo zapisati kao

$$(1 - \rho)(\|\mathbf{v}_S\|_1 + \|\mathbf{v}_{\bar{S}}\|_1) \leq (1 + \rho)(\|\mathbf{v}_{\bar{S}}\|_1 + \|\mathbf{v}_S\|_1).$$

Jednostavnom manipulacijom slijedi

$$\|\mathbf{v}_S\|_1 \leq \rho\|\mathbf{v}_{\bar{S}}\|_1.$$

Obratno, neka matrica \mathbf{A} zadovoljava stabilno svojstvo nul-prostora s konstantom $0 < \rho < 1$ za skup S . Neka su $\mathbf{x}, \mathbf{z} \in \mathbb{C}^N$ takvi da je $\mathbf{Az} = \mathbf{Ax}$, pošto je $\mathbf{v} := \mathbf{z} - \mathbf{x} \in \ker \mathbf{A}$, stabilno svojstvo nul-prostora daje

$$\|\mathbf{v}_S\|_1 \leq \rho\|\mathbf{v}_{\bar{S}}\|_1. \quad (3.11)$$

Nadalje, iz leme 3.2.4 slijedi

$$\|\mathbf{v}_{\bar{S}}\|_1 \leq \|\mathbf{z}\|_1 - \|\mathbf{x}\|_1 + \|\mathbf{v}_S\|_1 + 2\|\mathbf{x}_{\bar{S}}\|_1. \quad (3.12)$$

Substituiramo (3.11) u (3.12),

$$\|\mathbf{v}_{\bar{S}}\|_1 \leq \|\mathbf{z}\|_1 - \|\mathbf{x}\|_1 + \rho\|\mathbf{v}_{\bar{S}}\|_1 + 2\|\mathbf{x}_{\bar{S}}\|_1.$$

Pošto je $\rho < 1$,

$$\|\mathbf{v}_{\bar{S}}\|_1 \leq \frac{1}{1 - \rho} (\|\mathbf{z}\|_1 - \|\mathbf{x}\|_1 + 2\|\mathbf{x}_{\bar{S}}\|_1).$$

Ponovno iskoristimo (3.11),

$$\|\mathbf{v}\|_1 = \|\mathbf{v}_{\bar{S}}\|_1 + \|\mathbf{v}_S\|_1 \leq (1 + \rho)\|\mathbf{v}_{\bar{S}}\|_1 \leq \frac{1 + \rho}{1 - \rho} (\|\mathbf{z}\|_1 - \|\mathbf{x}\|_1 + 2\|\mathbf{x}_{\bar{S}}\|_1).$$

□

3.3 Robusnost

Jasno je da u realnosti signal nikad ne možemo mjeriti s beskonačnom točnošću. U našem kontekstu to znači da je vektor mjerenja $\mathbf{y} \in \mathbb{C}^m$ aproksimacija vektora $\mathbf{Ax} \in \mathbb{C}^m$, tj. formalno

$$\|\mathbf{Ax} - \mathbf{y}\| \leq \eta$$

za neki $\eta \geq 0$ i neku normu na \mathbb{C}^m . Od metode rekonstrukcije tražimo da udaljenost rekonstruiranog vektora \mathbf{x}^\sharp i originalnog vektora \mathbf{x} bude kontrolirana preciznošću mjerenja η . Ako metoda zadovoljava to svojstvo kažemo da je *robustna* ili *otporna* na greške mjerenja. Pokazat ćemo da je BP algoritam (ℓ_1 -minimizacija) robustna ako (P_1) zamjenimo konveksnim problemom

$$\min_{\mathbf{z} \in \mathbb{C}^N} \|\mathbf{z}\|_1 \quad \text{uz uvjet } \|\mathbf{Az} - \mathbf{y}\| \leq \eta \quad (P_{1,\eta})$$

te ako vrijedi sljedeća jača varijanta svojstva nul-prostora.

Definicija 3.3.1. Za matricu $\mathbf{A} \in \mathbb{C}^{m \times N}$ kažemo da zadovoljava *robustno svojstvo nul-prostora* s konstantama $0 < \rho < 1$ i $\tau > 0$ za skup $S \subseteq [N]$ ako

$$\|\mathbf{v}_S\|_1 \leq \rho \|\mathbf{v}_{\bar{S}}\|_1 + \tau \|\mathbf{Av}\| \quad \text{za sve } \mathbf{v} \in \mathbb{C}^N. \quad (3.13)$$

Nadalje, kažemo da \mathbf{A} zadovoljava *robustno svojstvo nul-prostora* s konstantama $0 < \rho < 1$ i $\tau > 0$ reda s ako zadovoljava gornje svojstvo za svaki $S \subseteq [N]$ takav da $\text{card}(S) \leq s$.

Primijetimo da definicija ne traži da je $\mathbf{v} \in \ker \mathbf{A}$. Kada bi to vrijedilo propao bi član $\|\mathbf{Av}\|$ i time bi dobili stabilno svojstvo nul-prostora.

Teorem 3.3.2. Neka matrica $\mathbf{A} \in \mathbb{C}^{m \times N}$ zadovoljava *robustno svojstvo nul-prostora* reda s sa konstantama $0 < \rho < 1$ i $\tau > 0$. Tada za svaki vektor $\mathbf{x} \in \mathbb{C}^N$, rješenje problema $(P_{1,\eta})$ za $\mathbf{y} = \mathbf{Ax} + \mathbf{e}$ i $\|\mathbf{e}\| \leq \eta$ aproksimira vektor \mathbf{x} s greškom

$$\|\mathbf{x} - \mathbf{x}^\sharp\|_1 \leq \frac{2(1+\rho)}{(1-\rho)} \sigma_s(\mathbf{x})_1 + \frac{4\tau}{1-\rho} \eta$$

Dokazat ćemo jaču tvrdnju,

Teorem 3.3.3. Matrica $\mathbf{A} \in \mathbb{C}^{m \times N}$ zadovoljava *robustno svojstvo nul-prostora* s konstantama $0 < \rho < 1$ i $\tau > 0$ za skup S ako i samo ako

$$\|\mathbf{z} - \mathbf{x}\|_1 \leq \frac{1+\rho}{1-\rho} (\|\mathbf{z}\|_1 - \|\mathbf{x}\|_1 + 2\|\mathbf{x}_{\bar{S}}\|_1) + \frac{2\tau}{1-\rho} \|\mathbf{A}(\mathbf{z} - \mathbf{x})\| \quad (3.14)$$

za sve vektore $\mathbf{x}, \mathbf{z} \in \mathbb{C}^N$.

Dokaz. Pretpostavimo da \mathbf{A} zadovoljava (3.14). Za $\mathbf{v} \in \mathbb{C}^N$, uzmimo $\mathbf{x} = -\mathbf{v}_S$ i $\mathbf{z} = \mathbf{v}_{\bar{S}}$. Slijedi,

$$\|\mathbf{v}\|_1 \leq \frac{1+\rho}{1-\rho}(\|\mathbf{v}_{\bar{S}}\|_1 - \|\mathbf{v}_S\|_1) + \frac{2\tau}{1-\rho}\|\mathbf{A}\mathbf{v}\|.$$

Preslagivanjem članova dobivamo

$$(1-\rho)(\|\mathbf{v}_S\|_1 + \|\mathbf{v}_{\bar{S}}\|_1) \leq (1+\rho)(\|\mathbf{v}_{\bar{S}}\|_1 - \|\mathbf{v}_S\|_1) + 2\tau\|\mathbf{A}\mathbf{v}\|$$

tj. imamo

$$\|\mathbf{v}_S\|_1 \leq \rho\|\mathbf{v}_{\bar{S}}\|_1 + \tau\|\mathbf{A}\mathbf{v}\|.$$

Obratno, neka \mathbf{A} zadovoljava robusno svojstva nul-prostora s konstantama $0 < \rho < 1$ i $\tau > 0$ za skup S . Za $\mathbf{x}, \mathbf{z} \in \mathbb{C}^N$, neka je $\mathbf{v} := \mathbf{z} - \mathbf{x}$. Iz robusnog svojstvo nul-prostora i leme 3.2.4 slijedi

$$\begin{aligned} \|\mathbf{v}_S\|_1 &\leq \rho\|\mathbf{v}_{\bar{S}}\|_1 + \tau\|\mathbf{A}\mathbf{v}\|, \\ \|\mathbf{v}_{\bar{S}}\|_1 &\leq \|\mathbf{z}\|_1 - \|\mathbf{x}\|_1 + \|\mathbf{v}_S\|_1 + 2\|\mathbf{x}_{\bar{S}}\|_1. \end{aligned}$$

Kombiniranjem te dvije nejednakosti imamo,

$$\|\mathbf{v}_{\bar{S}}\|_1 \leq \frac{1}{1-\rho}(\|\mathbf{z}\|_1 - \|\mathbf{x}\|_1 + 2\|\mathbf{x}_{\bar{S}}\|_1 + \tau\|\mathbf{A}\mathbf{v}\|).$$

Ponovno iskoristimo robusno svojstvo nul-prostora

$$\begin{aligned} \|\mathbf{v}\|_1 &= \|\mathbf{v}_{\bar{S}}\|_1 + \|\mathbf{v}_S\|_1 \leq (1+\rho)\|\mathbf{v}_{\bar{S}}\|_1 + \tau\|\mathbf{A}\mathbf{v}\| \\ &\leq \frac{1+\rho}{1-\rho}(\|\mathbf{z}\|_1 - \|\mathbf{x}\|_1 + 2\|\mathbf{x}_{\bar{S}}\|_1) + \frac{2\tau}{1-\rho}\|\mathbf{A}\mathbf{v}\|. \end{aligned}$$

□

Sada ćemo poboljšati prethodni rezultat robusnosti, tj. dat ćemo ℓ_p ocjenu greške za $p \geq 1$. Za to potrebna nam je još jedna varijantna svojstva nul-prostora,

Definicija 3.3.4. Za $q \geq 1$, matrica $\mathbf{A} \in \mathbb{C}^{m \times N}$ zadovoljava ℓ_q -robusno svojstvo nul-prostora reda s sa konstantama $0 < \rho < 1$ i $\tau > 0$, ako za svaki $S \subseteq [N]$, takav da $\text{card}(S) \leq s$,

$$\|\mathbf{v}_S\|_q \leq \frac{\rho}{s^{1-1/q}}\|\mathbf{v}_{\bar{S}}\|_1 + \tau\|\mathbf{A}\mathbf{v}\| \quad \text{za svaki } \mathbf{v} \in \mathbb{C}^N.$$

Iz $\|\mathbf{v}_S\|_p \leq s^{1/p-1/q} \|\mathbf{v}_S\|_q$ za $1 \leq p \leq q$, ℓ_1 -robusno svojstvo nul-prostora implicira

$$\|\mathbf{v}_S\|_p \leq \frac{\rho}{s^{1-1/p}} \|\mathbf{v}_{\bar{S}}\|_1 + \tau s^{1/p-1/q} \|\mathbf{A}\mathbf{v}\| \quad \text{za sve } \mathbf{v} \in \mathbb{C}^N.$$

Stoga, za $1 \leq p \leq q$, ℓ_q -robusno svojstvo nul-prostora implicira ℓ_p -robusno svojstvo nul-prostora s jednakim konstantama, do na promjenu norme. Sljedeći teorem daje robusnost kvadratično ograničene ℓ_1 -minimizacije.

Teorem 3.3.5. *Neka matrica $\mathbf{A} \in \mathbb{C}^{m \times N}$ zadovoljava ℓ_2 -robusno svojstvo nul-prostora reda s sa konstantama $0 < \rho < 1$ i $\tau > 0$. Tada za svaki $\mathbf{x} \in \mathbb{C}^N$, rješenje $\mathbf{x}^\#$ problema $(P_{1,\eta})$ aproksimira \mathbf{x} s ℓ_p -greškom*

$$\|\mathbf{x} - \mathbf{x}^\#\|_p \leq \frac{C}{s^{1-1/p}} \sigma_s(\mathbf{x})_1 + D s^{1/p-1/2} \eta, \quad 1 \leq p \leq 2, \quad (3.15)$$

za neke konstante $C, D > 0$ koje ovise samo o ρ i τ .

Ovaj teorem je direktna posljedica narednog općenitijeg teorema za $q = 2$ i $\mathbf{z} = \mathbf{x}^\#$.

Teorem 3.3.6. *Neka je $1 \leq p \leq q$ i neka matrica $\mathbf{A} \in \mathbb{C}^{m \times N}$ zadovoljava ℓ_q -robusno svojstvo nul-prostora reda s sa konstantama $0 < \rho < 1$ i $\tau > 0$. Tada za svaki $\mathbf{x}, \mathbf{z} \in \mathbb{C}^N$,*

$$\|\mathbf{z} - \mathbf{x}\|_p \leq \frac{C}{s^{1-1/p}} (\|\mathbf{z}\|_1 - \|\mathbf{x}\|_1 + 2\sigma_s(\mathbf{x})_1) + D s^{1/p-1/q} \|\mathbf{A}(\mathbf{z} - \mathbf{x})\|,$$

gdje su $C := (1 + \rho)^2 / (1 - \rho)$ i $D := (3 + \rho)\tau / (1 - \rho)$.

Dokaz. Iskoristimo prvo da ℓ_q -robusno svojstvo nul-prostora implicira ℓ_1 -robusno i ℓ_p -robusno svojstvo nul-prostora, tj.

$$\|\mathbf{v}_S\|_1 \leq \rho \|\mathbf{v}_{\bar{S}}\|_1 + \tau s^{1-1/q} \|\mathbf{A}\mathbf{v}\|, \quad (3.16)$$

$$\|\mathbf{v}_S\|_p \leq \frac{\rho}{s^{1-1/p}} \|\mathbf{v}_{\bar{S}}\|_1 + \tau s^{1/p-1/q} \|\mathbf{A}\mathbf{v}\|, \quad (3.17)$$

za svaki $\mathbf{v} \in \mathbb{C}^N$ i za sve $S \subseteq [N]$, takve da je $\text{card}(S) \leq s$. Uvažavajući (3.17) i primjenom teorema 3.3.3 sa skupom S koji je jednak skupu s apsolutno najvećih komponenti vektora \mathbf{x} , imamo

$$\|\mathbf{z} - \mathbf{x}\|_1 \leq \frac{1 + \rho}{1 - \rho} (\|\mathbf{z}\|_1 - \|\mathbf{x}\|_1 + 2\sigma_s(\mathbf{x})_1) + \frac{2\tau}{1 - \rho} s^{1-1/q} \|\mathbf{A}(\mathbf{z} - \mathbf{x})\|. \quad (3.18)$$

Nadalje, odabirom skupa S kao skupa s apsolutno najvećih komponenti vektora $\mathbf{z} - \mathbf{x}$, iz teorema 1.1.5 slijedi

$$\|\mathbf{z} - \mathbf{x}\|_p \leq \|(\mathbf{z} - \mathbf{x})_{\bar{S}}\|_p + \|(\mathbf{z} - \mathbf{x})_S\|_p \leq \frac{1}{s^{1-1/p}} \|\mathbf{z} - \mathbf{x}\|_1 + \|(\mathbf{z} - \mathbf{x})_S\|_p.$$

Iz (3.17) imamo,

$$\begin{aligned} \|\mathbf{z} - \mathbf{x}\|_p &\leq \frac{1}{s^{1-1/p}} \|\mathbf{z} - \mathbf{x}\|_1 + \frac{2}{s^{1-1/p}} \|(\mathbf{z} - \mathbf{x})_{\bar{S}}\|_1 + \tau s^{1/p-1/q} \|\mathbf{A}(\mathbf{z} - \mathbf{x})\| \\ &\leq \frac{1 + \rho}{s^{1-1/p}} \|\mathbf{z} - \mathbf{x}\|_1 + \tau s^{1/p-1/q} \|\mathbf{A}(\mathbf{z} - \mathbf{x})\|. \end{aligned} \quad (3.19)$$

Preostaje (3.18) ubaciti u (3.19). \square

3.4 Rekonstrukcija predodređenog vektora

Ukoliko želimo rekonstruirati predodređeni rijetki vektor \mathbf{x} umjesto svih rijetkih vektora \mathbf{z} s nosačem u nekom skupu S , potrebno nam je finije svojstvo rekonstrukcije od svojstva nul-prostora. Naglasimo da se će ovdje biti sitna razlika između realnog i kompleksnog slučaja, što je posljedica definicije predznaka broja z ,

$$\text{sgn}(z) := \begin{cases} \frac{z}{|z|} & \text{ako } z \neq 0, \\ 0 & \text{ako } z = 0 \end{cases}$$

i činjenice da je u realnom slučaju to diskretna vrijednost, dok u kompleksnom nije. Za vektor $\mathbf{x} \in \mathbb{C}^N$, $\text{sgn}(\mathbf{x}) \in \mathbb{C}^N$ definiramo kao vektor s komponentama $\text{sgn}(x_j)$, $j \in [N]$.

Teorem 3.4.1. *Za danu matricu $\mathbf{A} \in \mathbb{C}^{m \times N}$, vektor $\mathbf{x} \in \mathbb{C}^N$ s nosačem S je jedinstveni minimizator od $\|\mathbf{z}\|_1$ uz uvjet $\mathbf{A}\mathbf{z} = \mathbf{A}\mathbf{x}$ ako je jedna od narednih, ekvivalentnih tvrdnji zadovoljena:*

$$(a) \quad \left| \sum_{j \in S} \overline{\text{sgn}(x_j)} v_j \right| < \|\mathbf{v}_{\bar{S}}\| \text{ za sve } \mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\},$$

(b) \mathbf{A}_S je injektivna i postoji vektor $\mathbf{h} \in \mathbb{C}^m$ takav da

$$(\mathbf{A}^*\mathbf{h})_j = \text{sgn}(x_j), \quad j \in S, \quad |(\mathbf{A}^*\mathbf{h})_l| < 1, \quad l \in \bar{S}.$$

Dokaz. Dokažimo prvo da (a) implicira da je \mathbf{x} jedinstveni minimizator od $\|\mathbf{z}\|_1$ takav da $\mathbf{Az} = \mathbf{Ax}$. Za $\mathbf{z} \neq \mathbf{x}$ takav da $\mathbf{Az} = \mathbf{Ax}$ uzmimo $\mathbf{v} := \mathbf{x} - \mathbf{z} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}$

$$\begin{aligned} \|\mathbf{z}\|_1 &= \|\mathbf{z}_S\|_1 + \|\mathbf{z}_{\bar{S}}\|_1 = \|(\mathbf{x} - \mathbf{v})_S\|_1 + \|\mathbf{v}_{\bar{S}}\|_1 \\ &> |\langle \mathbf{x} - \mathbf{z}, \text{sgn}(\mathbf{x})_S \rangle| + |\langle \mathbf{v}, \text{sgn}(\mathbf{x})_S \rangle| \geq |\langle \mathbf{x}, \text{sgn}(\mathbf{x})_S \rangle| = \|\mathbf{x}\|_1. \end{aligned}$$

Pokažimo sada (b) \implies (a). Koristeći činjenicu da $\mathbf{Av}_S = -\mathbf{Av}_{\bar{S}}$ za $\mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}$ slijedi

$$\begin{aligned} \left| \sum_{j \in S} \overline{\text{sgn}(x_j)} v_j \right| &= |\langle \mathbf{v}_S, \mathbf{A}^*\mathbf{h} \rangle| = |\langle \mathbf{Av}_S, \mathbf{h} \rangle| = |\langle \mathbf{Av}_{\bar{S}}, \mathbf{h} \rangle| \\ &= |\langle \mathbf{v}_{\bar{S}}, \mathbf{A}^*\mathbf{h} \rangle| \leq \max_{l \in \bar{S}} |(\mathbf{A}^*\mathbf{h})_l| \|\mathbf{v}_{\bar{S}}\|_1 < \|\mathbf{v}_{\bar{S}}\|_1. \end{aligned}$$

Striktne nejednakosti vrijedi jer $\|\mathbf{v}_{\bar{S}}\|_1 > 0$. U suprotnom bi ne-nul vektor $\mathbf{v} \in \ker \mathbf{A}$ imao nosač u S , što je kontradikcija s injektivnosti od \mathbf{A}_S .

Preostaje pokazati (a) \implies (b). Primijetimo da (a) povlači $\|\mathbf{v}_{\bar{S}}\|_1 > 0$ za sve $\mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}$. Pokažimo da je \mathbf{A}_S injektivna. Pretpostavimo $\mathbf{A}_S \mathbf{v}_S = \mathbf{0}$ za neki $\mathbf{v}_S \neq \mathbf{0}$. Nadopunimo \mathbf{v}_S do vektora $\mathbf{v} \in \mathbb{C}^N$ tako da stavimo $\mathbf{v}_{\bar{S}} = \mathbf{0}$. Tada je $\mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}$, što je kontradikcija s $\|\mathbf{v}_{\bar{S}}\|_1 > 0$ za svaki $\mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}$. Nadalje, primijetimo da je funkcija $\mathbf{v} \mapsto |\langle \mathbf{v}, \text{sgn}(\mathbf{x})_S \rangle| / \|\mathbf{v}_{\bar{S}}\|_1$ neprekidna i da poprima vrijednosti manje od jedan na jediničnoj kugli u $\ker \mathbf{A}$, koja je kompaktna skup. Dakle, maksimum η zadovoljava $\eta < 1$ i vrijedi

$$|\langle \mathbf{v}, \text{sgn}(\mathbf{x})_S \rangle| \leq \mu \|\mathbf{v}_{\bar{S}}\|_1 \quad \text{za sve } \mathbf{v} \in \ker \mathbf{A}.$$

Za $\eta < \nu < 1$ definiramo konveksni skup \mathcal{C} i afini skup \mathcal{D} ,

$$\begin{aligned} \mathcal{C} &:= \{\mathbf{z} \in \mathbb{C}^N : \|\mathbf{z}_S\|_1 + \nu \|\mathbf{z}_{\bar{S}}\|_1 \leq \|\mathbf{x}\|_1\}, \\ \mathcal{D} &:= \{\mathbf{z} \in \mathbb{C}^N : \mathbf{Az} = \mathbf{Ax}\}. \end{aligned}$$

Pokažimo da je $\mathcal{C} \cap \mathcal{D} = \{\mathbf{x}\}$. Uzmimo $\mathbf{x} \in \mathcal{C} \cap \mathcal{D}$. Za $\mathbf{z} \in \ker \mathbf{A} \setminus \{\mathbf{0}, \mathbf{x}\}$ kontradikcija slijedi iz

$$\begin{aligned} \|\mathbf{x}\|_1 &\geq \|\mathbf{z}_S\|_1 + \nu \|\mathbf{z}_{\bar{S}}\|_1 = \|(\mathbf{x} - \mathbf{z})_S\|_1 + \nu \|\mathbf{v}_{\bar{S}}\|_1 \\ &> \|(\mathbf{x} - \mathbf{v})_S\|_1 + \mu \|\mathbf{v}_{\bar{S}}\|_1 \geq |\langle \mathbf{x} - \mathbf{v}, \text{sgn}(\mathbf{x})_S \rangle| + |\langle \mathbf{v}, \text{sgn}(\mathbf{x})_S \rangle| \\ &\geq |\langle \mathbf{x}, \text{sgn}(\mathbf{x})_S \rangle| = \|\mathbf{x}\|_1. \end{aligned}$$

Dakle, prema teoremu o separaciji konveksnih skupova hiperplohami (vidi teorem B.4 u [5]), postoji vektor $\mathbf{w} \in \mathbb{C}^N$ takav da

$$\mathcal{C} \subseteq \{\mathbf{z} \in \mathbb{C}^N : \operatorname{Re}\langle \mathbf{z}, \mathbf{w} \rangle \leq \|\mathbf{x}\|_1\}, \quad (3.20)$$

$$\mathcal{D} \subseteq \{\mathbf{z} \in \mathbb{C}^N : \operatorname{Re}\langle \mathbf{z}, \mathbf{w} \rangle = \|\mathbf{x}\|_1\}. \quad (3.21)$$

Iz (3.20) slijedi

$$\begin{aligned} \|\mathbf{x}\|_1 &\geq \max_{\|\mathbf{z}_S + \nu \mathbf{z}_{\bar{S}}\|_1 \leq \|\mathbf{x}\|_1} \operatorname{Re}\langle \mathbf{z}, \mathbf{x} \rangle \\ &= \max_{\|\mathbf{z}_S + \nu \mathbf{z}_{\bar{S}}\|_1 \leq \|\mathbf{x}\|_1} \operatorname{Re}\left(\sum_{j \in S} z_j \bar{w}_j + \sum_{j \in \bar{S}} \nu z_j \bar{w}_j / \nu\right) \\ &= \max_{\|\mathbf{z}_S + \nu \mathbf{z}_{\bar{S}}\|_1 \leq \|\mathbf{x}\|_1} \operatorname{Re}\langle \mathbf{z}_S + \nu \mathbf{z}_{\bar{S}}, \mathbf{w}_{\bar{S}} + (1/\nu) \mathbf{w}_S \rangle \\ &= \|\mathbf{x}\|_1 \|\mathbf{w}_S + (1/\nu) \mathbf{w}_{\bar{S}}\|_\infty = \|\mathbf{x}\|_1 \max\{\|\mathbf{w}_S\|_\infty, (1/\nu) \|\mathbf{w}_{\bar{S}}\|_\infty\}. \end{aligned}$$

U slučaju $\mathbf{x} = \mathbf{0}$, dovoljno je uzeti vektor $\mathbf{h} = \mathbf{0}$, stoga neka je $\mathbf{x} \neq \mathbf{0}$. Gornja nejednakost daje $\|\mathbf{w}_S\|_\infty \leq 1$ i $\|\mathbf{w}_{\bar{S}}\|_\infty \leq \nu < 1$. Iz (3.21) slijedi $\operatorname{Re}\langle \mathbf{x}, \mathbf{w} \rangle = \|\mathbf{x}\|_1$, tj. $w_j = \operatorname{sgn}(x_j)$ za sve $j \in S$, te $\operatorname{Re}\langle \mathbf{v}, \mathbf{w} \rangle = 0$ za sve $\mathbf{v} \in \ker \mathbf{A}$, tj. $\mathbf{w} \in (\ker \mathbf{A})^\perp$. Pošto je $(\ker \mathbf{A})^\perp = \operatorname{im} \mathbf{A}^*$, imamo $\mathbf{w} = \mathbf{A}^* \mathbf{h}$ za neki $\mathbf{h} \in \mathbb{C}^m$. \square

U realnom slučaju obratna tvrdnja također vrijedi, dok općenito to nije istina. Dat ćemo još jednu karakterizaciju egzaktne rekonstrukcije ℓ_1 -minimizacijom u realnom slučaju. Za vektor $\mathbf{x} \in \mathbb{R}^N$, *konveksni konus* definiramo kao

$$T(\mathbf{x}) = \operatorname{cone}\{\mathbf{z} - \mathbf{x} : \mathbf{z} \in \mathbb{R}^N, \|\mathbf{z}\|_1 \leq \|\mathbf{x}\|_1\} \quad (3.22)$$

gdje $\operatorname{cone}(\cdot)$ predstavlja konusnu ljusku: za $S = \{x_1, x_2, \dots, x_n\}$

$$\operatorname{cone}(S) = \left\{ \sum_{i=1}^n \alpha_i x_i : \alpha_i \geq 0, i \in [n] \right\}.$$

Teorem 3.4.2. *Za matricu $\mathbf{A} \in \mathbb{R}^{m \times N}$, vektor $\mathbf{x} \in \mathbb{R}^N$ je jedinstveni minimizator od $\|\mathbf{z}\|_1$ takav da $\mathbf{A}\mathbf{z} = \mathbf{A}\mathbf{x}$ ako i samo ako $\ker \mathbf{A} \cap T(\mathbf{x}) = \{\mathbf{0}\}$.*

Dokaz. Pretpostavimo da je $\ker \mathbf{A} \cap T(\mathbf{x}) = \{\mathbf{0}\}$. Neka je \mathbf{x}^\sharp ℓ_1 -minimizator. Imamo, $\|\mathbf{x}^\sharp\|_1 \leq \|\mathbf{x}\|_1$ i $\mathbf{A}\mathbf{x}^\sharp = \mathbf{A}\mathbf{x}$, pa je $\mathbf{v} := \mathbf{x}^\sharp - \mathbf{x} \in T(\mathbf{x}) \cap \ker \mathbf{A} = \{\mathbf{0}\}$. Stoga je $\mathbf{x}^\sharp = \mathbf{x}$. Dakle, \mathbf{x} je jedinstveni ℓ_1 -minimizator.

Obratno, neka je \mathbf{x} jedinstveni ℓ_1 -minimizator. Vektor $\mathbf{v} \in T(\mathbf{x}) \setminus \{\mathbf{0}\}$ možemo zapisati kao $\mathbf{v} = \sum t_j (\mathbf{z}_j - \mathbf{x})$ gdje je $t_j \geq 0$ i $\|\mathbf{z}_j\|_1 \leq \|\mathbf{x}\|_1$. Da je $\mathbf{v} \in \ker \mathbf{A}$, vrijedilo bi $\mathbf{A}(\sum t'_j \mathbf{z}_j) = \mathbf{A}\mathbf{x}$ i $\|\sum t'_j \mathbf{z}_j\|_1 \leq \sum t'_j \|\mathbf{z}_j\|_1 \leq \|\mathbf{x}\|_1$. Zbog jedinstvenosti, to bi značilo

da $\sum t'_j \mathbf{z}_j = \mathbf{x}$ pa bi $\mathbf{v} = \mathbf{0}$, što je kontradikcija. Dakle, vrijedi $(T(\mathbf{x}) \setminus \{\mathbf{0}\}) \cap \ker \mathbf{A} = \emptyset$. \square

Ovaj rezultat možemo proširiti i na robusnu rekonstrukciju.

Teorem 3.4.3. *Za $\mathbf{A} \in \mathbb{R}^{m \times N}$, neka je $\mathbf{x} \in \mathbb{R}^N$ i $\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{e} \in \mathbb{R}^m$ i $\|\mathbf{e}\|_2 \leq \eta$. Ako je*

$$\inf_{\mathbf{v} \in T(\mathbf{x}), \|\mathbf{v}\|_2=1} \|\mathbf{A}\mathbf{v}\|_2 \geq \tau$$

za neki $\tau > 0$, tada minimizator \mathbf{x}^\sharp od $\|\mathbf{z}\|_1$ takav da $\|\mathbf{A}\mathbf{z} - \mathbf{y}\|_2 \leq \eta$ zadovoljava

$$\|\mathbf{x} - \mathbf{x}^\sharp\|_2 \leq \frac{2\eta}{\tau}. \quad (3.23)$$

Dokaz. Iz $\|\mathbf{x}^\sharp\|_1 \leq \|\mathbf{x}\|_1$ slijedi da je $\mathbf{v} := (\mathbf{x}^\sharp - \mathbf{x})/\|\mathbf{x}^\sharp - \mathbf{x}\|_2 \in T(\mathbf{x})$ pa možemo pretpostaviti da je $\mathbf{x}^\sharp - \mathbf{x} \neq \mathbf{0}$. Pošto je $\|\mathbf{v}\|_2 = 1$ imamo da je $\|\mathbf{A}\mathbf{v}\|_2 \geq \tau$, tj. $\|\mathbf{A}(\mathbf{x}^\sharp - \mathbf{x})\|_2 \geq \tau\|\mathbf{x}^\sharp - \mathbf{x}\|_2$. Nadalje, vrijedi

$$\|\mathbf{A}(\mathbf{x}^\sharp - \mathbf{x})\|_2 \leq \|\mathbf{A}\mathbf{x}^\sharp - \mathbf{y}\|_2 + \|\mathbf{A}\mathbf{x} - \mathbf{y}\|_2 \leq 2\eta.$$

Tvrđnja slijedi kombiniranjem prethodne dvije nejednakosti. \square

Poglavlje 4

Koherencija

Kao što smo vidjeli, uspješnost rekonstrukcije rijetkog vektora u kontekstu sažetog uzorkovanja ovisi o određenim kvalitetama matrice mjerenja. Jedna od takvih mjera kvalitete je koherencija. Neformalno, što je koherencija matrice mjerenja manja, to je rekonstrukcija uspješnija.

4.1 Definicija i svojstva

U cijelom poglavlju podrazumijevamo da su stupci matrice mjerenja ℓ_2 -normalizirani.

Definicija 4.1.1. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ matrica s ℓ_2 -normaliziranim stupcima $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_N$, tj. $\|\mathbf{a}_i\|_2 = 1$ za sve $i \in [N]$. Koherenciju $\mu = \mu(\mathbf{A})$ matrice \mathbf{A} definiramo kao*

$$\mu := \max_{1 \leq i \neq j \leq N} |\langle \mathbf{a}_i, \mathbf{a}_j \rangle|. \quad (4.1)$$

Nadalje, uvodimo općenitiji pojam ℓ_1 -koherencije. Gornja definicija je poseban slučaj za $s = 1$.

Definicija 4.1.2. *Neka je matrica $\mathbf{A} \in \mathbb{C}^{m \times N}$ s ℓ_2 -normaliziranim stupcima $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_N$. Za $s \in [N - 1]$, funkcija ℓ_1 -koherencije μ_1 matrice \mathbf{A} je definirana kao*

$$\mu_1(s) := \max_{i \in [N]} \max \left\{ \sum_{j \in S} |\langle \mathbf{a}_i, \mathbf{a}_j \rangle|, S \subseteq [N], \text{card}(S) = s, i \notin S \right\}.$$

Jasno je da za $1 \leq s \leq N - 1$ vrijedi

$$\mu \leq \mu_1(s) \leq s\mu \quad (4.2)$$

i općenitije za $1 \leq s, t \leq N - 1$ takve da je $s + t \leq N - 1$

$$\max\{\mu_1(s), \mu_1(t)\} \leq \mu_1(s + t) \leq \mu_1(s) + \mu_1(t). \quad (4.3)$$

Primijetimo da je ℓ_1 -koherencija pa stoga i koherencija invarijanta na množenje s lijeva unitarnom matricom \mathbf{U} . Zaista, stupci od $\mathbf{U}\mathbf{A}$ su ℓ_2 -normalizirani vektori $\mathbf{U}\mathbf{a}_1, \dots, \mathbf{U}\mathbf{a}_N$ te zadovoljavaju $\langle \mathbf{U}\mathbf{a}_i, \mathbf{U}\mathbf{a}_j \rangle = \langle \mathbf{a}_i, \mathbf{a}_j \rangle$. Nadalje, zbog Cauchy-Schwarzove nejednakosti vrijedi

$$\mu \leq 1.$$

Neka je na matrica $\mathbf{A} \in \mathbb{C}^{m \times N}$ takva da $m \geq N$. Tada je $\mu = 0$ ako i samo ako stupci matrice \mathbf{A} formiraju ortonormirani sustav. U slučaju da je matrica kvadratna, $\mu = 0$ ako i samo ako je \mathbf{A} unitarna. U nastavku ćemo proučavati samo matrice kojima je $m < N$. U tom slučaju vrijednost koherencije je odozdo ograničena, što ćemo kasnije i pokazati.

Teorem 4.1.3. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ matrica s ℓ_2 -normaliziranim stupcima i neka je $s \in [N]$. Za sve s -rijetke vektore $\mathbf{x} \in \mathbb{C}^N$ vrijedi,*

$$(1 - \mu_1(s - 1)) \|\mathbf{x}\|_2^2 \leq \|\mathbf{A}\mathbf{x}\|_2^2 \leq (1 + \mu_1(s - 1)) \|\mathbf{x}\|_2^2$$

ili ekvivalentno, za svaki skup $S \subseteq [N]$ takav da $\text{card}(S) \leq s$, svojstvene vrijednosti matrice $\mathbf{A}_S^* \mathbf{A}_S$ leže u segmentu $[1 - \mu_1(s - 1), 1 + \mu_1(s - 1)]$. Posebno, ako je $\mu_1(s - 1) < 1$ tada je $\mathbf{A}_S^* \mathbf{A}_S$ invertibilna.

Dokaz. Neka je $S \subseteq [N]$. Pošto je matrica $\mathbf{A}_S^* \mathbf{A}_S$ pozitivno semidefinitna, svojstveni vektori koji odgovaraju realnim pozitivnim svojstvenim vrijednostima čine ortonormiranu bazu. Označimo s λ_{\min} najmanju i s λ_{\max} najveću svojstvenu vrijednost. Pošto je $\mathbf{A}\mathbf{x} = \mathbf{A}_S \mathbf{x}_S$ za svaki $\mathbf{x} \in \mathbb{C}^N$ sa nosačem na skupu S , slijedi da je maksimum od

$$\|\mathbf{A}\mathbf{x}\|_2^2 = \langle \mathbf{A}_S \mathbf{x}_S, \mathbf{A}_S \mathbf{x}_S \rangle = \langle \mathbf{A}_S^* \mathbf{A}_S \mathbf{x}_S, \mathbf{x}_S \rangle$$

po skupu $\{\mathbf{x} \in \mathbb{C}^N, \text{supp}(\mathbf{x}) \subseteq S, \|\mathbf{x}\|_2 = 1\}$, jednak λ_{\max} i minimum jednak λ_{\min} . Ovo pokazuje ekvivalenciju dvije tvrdnje u teoremu. Nadalje, pošto imamo da je $\|\mathbf{a}_j\|_2 = 1$ za sve $j \in [N]$, svi dijagonalni elementi matrice $\mathbf{A}_S^* \mathbf{A}_S$ jednaki su jedan. Prema Gershgorinom teoremu (vidi [7], A.11 [5]), svojstvene vrijednosti od $\mathbf{A}_S^* \mathbf{A}_S$ sadržane su u uniji diskova s centrom u 1 radijusa

$$r_j := \sum_{l \in S, l \neq j} |(\mathbf{A}_S^* \mathbf{A}_S)_{j,l}| = \sum_{l \in S, l \neq j} |\langle \mathbf{a}_l, \mathbf{a}_j \rangle| \leq \mu_1(s - 1), \quad j \in S.$$

Pošto su svojstvene vrijednosti realne, moraju ležati u segmentu $[1 - \mu_1(s - 1), 1 + \mu_1(s - 1)]$. \square

Korolar 4.1.4. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ s ℓ_2 -normaliziranim stupcima i neka je $s \geq 1$. Ako*

$$\mu_1(s) + \mu_1(s - 1) < 1,$$

onda je, za svaki $S \subseteq [N]$ takav da $\text{card}(S) \leq 2s$, matrica $\mathbf{A}_S^ \mathbf{A}_S$ invertibilna i matrica \mathbf{A}_S injektivna. Posebno, isti zaključak vrijedi ako je*

$$\mu < \frac{1}{2s - 1}.$$

Dokaz. Iz (4.3), $\mu_1(s) + \mu_1(s - 1) < 1$ povlači $\mu_1(2s - 1) < 1$. Prema prethodnom teoremu, za $S \subseteq [N]$ takav da $\text{card}(S) = 2s$, najmanja svojstvena vrijednost matrice $\mathbf{A}_S^* \mathbf{A}_S$ zadovoljava $\lambda_{\min} \geq 1 - \mu_1(2s - 1) > 0$. Dakle, $\mathbf{A}_S^* \mathbf{A}_S$ je invertibilna. Ako je $\mathbf{A}_S \mathbf{z} = \mathbf{0}$ tada je i $\mathbf{A}_S^* \mathbf{A}_S \mathbf{z} = \mathbf{0}$ ali to implicira $\mathbf{z} = \mathbf{0}$. Dakle, \mathbf{A}_S je injektivna. Isti zaključak slijedi iz $\mu_1(s) + \mu_1(s - 1) \leq (2s - 1)\mu < 1$ ako je $\mu < 1/(2s - 1)$. \square

4.2 Matrice male koherencije

Sada ćemo proučiti ocjene odozdo na koherenciju i na ℓ_1 -koherenciju matrice $\mathbf{A} \in \mathbb{K}^{m \times N}$ takve da je $m < N$ i gdje je $\mathbb{K} = \mathbb{R}$ ili $\mathbb{K} = \mathbb{C}$.

Definicija 4.2.1. *Za sustav ℓ_2 -normaliziranih vektora $(\mathbf{a}_1, \dots, \mathbf{a}_N)$ iz \mathbb{K}^m kažemo da je ekviangularan ako postoji konstanta $c \leq 0$ takva da*

$$|\langle \mathbf{a}_i, \mathbf{a}_j \rangle| = c \quad \text{za sve } i, j \in [N], i \neq j.$$

Definicija 4.2.2. *Sustav vektora $(\mathbf{a}_1, \dots, \mathbf{a}_N)$ iz \mathbb{K}^m zovemo napeti bazni okvir ako postoji konstanta $\lambda > 0$ takva da vrijedi jedan od ekvivalentnih uvjeta:*

$$(a) \quad \|\mathbf{x}\|_2^2 = \lambda \sum_{j=1}^N |\langle \mathbf{x}, \mathbf{a}_j \rangle|^2 \quad \text{za sve } \mathbf{x} \in \mathbb{K}^m,$$

$$(b) \quad \mathbf{x} = \lambda \sum_{j=1}^N \langle \mathbf{x}, \mathbf{a}_j \rangle \mathbf{a}_j \quad \text{za sve } \mathbf{x} \in \mathbb{K}^m,$$

$$(c) \quad \mathbf{A} \mathbf{A}^* = (1/\lambda) \mathbf{I}_m, \quad \text{gdje je } \mathbf{A} \text{ matrica sa stupcima } \mathbf{a}_1, \dots, \mathbf{a}_N.$$

Sustav ℓ_2 -normaliziranih vektora zove se ekviangularni napeti bazni okvir ako je ujedno ekviangularni sustav vektora i napeti bazni okvir. Takvi sustavi vektora postižu takozvanu *Welchovu ocjenu*.

Teorem 4.2.3. *Koherencija matrice $\mathbf{A} \in \mathbb{K}^{m \times N}$ s ℓ_2 -normaliziranim stupcima zadovoljava*

$$\mu \geq \sqrt{\frac{N-m}{m(N-1)}}. \quad (4.4)$$

Jednakost vrijedi ako i samo ako stupci $\mathbf{a}_1, \dots, \mathbf{a}_N$ matrice \mathbf{A} čine ekviangularni napeti bazni okvir.

Dokaz. $\mathbf{G} := \mathbf{A}^* \mathbf{A} \in \mathbb{K}^{N \times N}$ zovemo *Gramova matrica* sustava vektora $(\mathbf{a}_1, \dots, \mathbf{a}_N)$. Elementi od \mathbf{G} su obika

$$G_{i,j} = \overline{\langle \mathbf{a}_i, \mathbf{a}_j \rangle} = \langle \mathbf{a}_j, \mathbf{a}_i \rangle, \quad i, j \in [N].$$

Nadalje, definirajmo matricu $\mathbf{H} := \mathbf{A} \mathbf{A}^* \in \mathbb{K}^{m \times m}$. Pošto su stupci od \mathbf{A} ℓ_2 -normalizirani, imamo

$$\text{tr}(\mathbf{G}) = \sum_{i=1}^N \|\mathbf{a}_i\|_2^2 = N. \quad (4.5)$$

Pošto skalarni produkt

$$\langle \mathbf{U}, \mathbf{V} \rangle_F := \text{tr}(\mathbf{U} \mathbf{V}^*) = \sum_{i,j=1}^n U_{i,j} \overline{V_{i,j}}$$

inducira *Froebeniusovu normu* $\|\cdot\|_F$ na $\mathbb{K}^{n \times n}$ (vidi A.16 [5]), Cauchy-Schwarzova nejednakost daje

$$\text{tr}(\mathbf{H}) = \langle \mathbf{H}, \mathbf{I}_m \rangle_F \leq \|\mathbf{H}\|_F \|\mathbf{I}_m\|_F = \sqrt{m} \sqrt{\text{tr}(\mathbf{H} \mathbf{H}^*)}. \quad (4.6)$$

Nadalje,

$$\begin{aligned} \text{tr}(\mathbf{H} \mathbf{H}^*) &= \text{tr}(\mathbf{A} \mathbf{A}^* \mathbf{A} \mathbf{A}^*) = \text{tr}(\mathbf{A}^* \mathbf{A} \mathbf{A}^* \mathbf{A}) = \text{tr}(\mathbf{G} \mathbf{G}^*) = \sum_{i,j=1}^N |\langle \mathbf{a}_i, \mathbf{a}_j \rangle|^2 \\ &= \sum_{i=1}^N \|\mathbf{a}_i\|_2^2 + \sum_{i,j=1, i \neq j}^N |\langle \mathbf{a}_i, \mathbf{a}_j \rangle|^2 = N + \sum_{i,j=1, i \neq j}^N |\langle \mathbf{a}_i, \mathbf{a}_j \rangle|^2. \end{aligned} \quad (4.7)$$

Iz činjenice da $\text{tr}(\mathbf{G}) = \text{tr}(\mathbf{H})$, te kombiniranjem (4.5), (4.6) i (4.7) imamo

$$N^2 \leq m \left(N + \sum_{i,j=1, i \neq j}^N |\langle \mathbf{a}_i, \mathbf{a}_j \rangle|^2 \right). \quad (4.8)$$

Napokon, uvažimo da

$$|\langle \mathbf{a}_i, \mathbf{a}_j \rangle| \leq \mu \quad \text{za sve } i, j \in [N], i \neq j, \quad (4.9)$$

pa slijedi

$$N^2 \leq m(N + (N^2 - N)\mu^2),$$

od kuda lako slijedi ocjena iz tvrdnje teorema. Nadalje, u (4.4) nastupa jednakost ako vrijede jednakosti u (4.6) i (4.9). Jednakost u (4.6) daje $\mathbf{H} = \lambda \mathbf{I}_m$ za neku nenegativnu konstantu λ , tj. sustav $(\mathbf{a}_1, \dots, \mathbf{a}_N)$ je napeti bazni okvir. Iz jednakost u (4.9) slijedi da je taj sustav ekviangularan. \square

Welchovu ocjenu možemo proširiti i na funkciju ℓ_1 -koherencije.

Teorem 4.2.4. *Funkcija ℓ_1 -koherencije matrice $\mathbf{A} \in \mathbb{K}^{m \times N}$ s ℓ_2 -normaliziranim stupcima zadovoljava*

$$\mu_1(s) \geq s \sqrt{\frac{N-m}{m(N-1)}} \quad \text{za } s < \sqrt{N-1}. \quad (4.10)$$

Jednakost se postiže ako i samo stupci matrice \mathbf{A} formiraju ekviangularni napeti bazni okvir.

Za dokaz biti će nam potrebna sljedeća lema,

Lema 4.2.5. *Za $k < \sqrt{n}$, ako konačni niz brojeva $(\alpha_1, \alpha_2, \dots, \alpha_n)$ zadovoljava*

$$\alpha_1 \geq \alpha_2 \geq \dots \geq \alpha_n \geq 0 \quad \text{i} \quad \alpha_1^2, \alpha_2^2, \dots, \alpha_n^2 \geq \frac{n}{k^2}$$

tada

$$\alpha_1 + \alpha_2 + \dots + \alpha_n \geq 1,$$

gdje se jednakost postiže ako i samo ako $\alpha_1 = \dots = \alpha_n = 1/k$.

Ideja dokaza je analogna dokazu teorema 1.1.5, tj. problem se svodi na maksimizaciju konveksne funkcije (vidi lema 5.9 u [5]).

Dokaz (Teorem 4.2.4). Iz (4.8) imamo

$$\sum_{i,j=1, i \neq j}^N |\langle \mathbf{a}_i, \mathbf{a}_j \rangle|^2 \geq \frac{N^2}{m} - N = \frac{N(N-m)}{m},$$

odakle slijedi

$$\max_{i \in [N]} \sum_{j=1, j \neq i}^N |\langle \mathbf{a}_i, \mathbf{a}_j \rangle|^2 \geq \frac{1}{N} \sum_{i,j=1, i \neq j}^N |\langle \mathbf{a}_i, \mathbf{a}_j \rangle|^2 \geq \frac{N-m}{m}.$$

Neka je $i^* \in [N]$ indeks za koji se postiže maksimum. Sortirajmo niz $(|\langle \mathbf{a}_{i^*}, \mathbf{a}_j \rangle|)_{j=1}^N$ kao $\beta_1 \geq \beta_2 \geq \dots \geq \beta_{N-1} \geq 0$, tako da

$$\beta_1^2 + \beta_2^2 + \dots + \beta_{N-1}^2 \geq \frac{N-m}{m}.$$

Primjenom prethodne leme s $n = N - 1$, $k = s$, i $\alpha_l := (\sqrt{m(N-1)/(N-m)}/s)\beta_l$ dobivamo $\alpha_1 + \dots + \alpha_s \geq 1$. Dakle,

$$\mu_1(s) \geq \beta_1 + \beta_2 + \dots + \beta_s \geq s \sqrt{\frac{N-m}{m(N-1)}}.$$

Pretpostavimo sada da u (4.10) vrijedi jednakost, pa su sve nejednakosti zapravo jednakosti. Jednakost u (4.8) implicira da su stupci matrice \mathbf{A} napeti bazni okvir. Jednakost u prethodnoj lemi implicira da $|\langle \mathbf{a}_{i^*}, \mathbf{a}_j \rangle| = \sqrt{(N-m)/(m(N-1))}$ za sve $j \in [N]$, takve da je $j \neq i^*$. Pošto indeks j možemo proizvoljno odabrati iz $[N] \setminus \{i^*\}$, slijedi da je sustav stupaca matrice \mathbf{A} ekviangularan. Obrat lako slijedi iz teorema 4.2.3 i (4.2). \square

U kontekstu sažetog uzorkovanja zanimaju nas $m \times N$ matrice gdje je N puno veći od m . No, pokazat ćemo da u tom slučaju ne možemo postići Welchovu ocjenu.

Teorem 4.2.6. *Kardinalitet N ekviangularnog sustava $(\mathbf{a}_1, \dots, \mathbf{a}_N)$ ℓ_2 -normaliziranih vektora u \mathbb{K}^m zadovoljava*

$$N \leq \begin{cases} \frac{m(m+1)}{2} & \text{za } \mathbb{K} = \mathbb{R}, \\ m^2 & \text{za } \mathbb{K} = \mathbb{C}. \end{cases}$$

Ako vrijedi jednakost onda je sustav $(\mathbf{a}_1, \dots, \mathbf{a}_N)$ također i napeti bazni okvir.

Za dokaz teorema potrebna nam je sljedeća tvrdnja, koja se lagano provjeri.

Lema 4.2.7. *Neka je $z \in \mathbb{C}$, matrica*

$$\begin{bmatrix} 1 & z & z & \cdots & z \\ z & 1 & z & \cdots & z \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ z & \cdots & z & 1 & z \\ z & \cdots & z & z & 1 \end{bmatrix}$$

ima jednostruku svojstvenu vrijednost $1 + (n - 1)z$ te svojstvenu vrijednost $1 - z$ algebarske kratnosti $n - 1$.

Dokaz (Teorem 4.2.6). Ideja je razmatranja s prostora \mathbb{K}^m prebaciti na potprostor \mathcal{S}_m operatora na \mathbb{K}^m . U slučaju $\mathbb{K} = \mathbb{R}$, \mathcal{S}_m je prostor simetričnih operatora na \mathbb{R}^m , a u slučaju $\mathbb{K} = \mathbb{C}$, \mathcal{S}_m je cijeli prostor operatora na \mathbb{C}^m . Ti su prostori opremljeni Froebeniusovim skalarnim produktom

$$\langle \mathbf{P}, \mathbf{Q} \rangle_F = \text{tr}(\mathbf{P}\mathbf{Q}^*) \quad (4.11)$$

za $\mathbf{P}, \mathbf{Q} \in \mathcal{S}_m$. Označimo s $\mathbf{P}_1, \dots, \mathbf{P}_N \in \mathcal{S}_m$ ortogonalne projektore na potprostore razapete sa $\{\mathbf{a}_i\}$ za $i = 1, 2, \dots, N$, definirane s

$$\mathbf{P}_i(\mathbf{v}) = \langle \mathbf{v}, \mathbf{a}_i \rangle \mathbf{a}_i$$

za $\mathbf{v} \in \mathbb{K}^m$. Nadalje, neka je $c := |\langle \mathbf{a}_i, \mathbf{a}_j \rangle|$ za $i \neq j$ te neka je $(\mathbf{e}_1, \dots, \mathbf{e}_N)$ kanonska baza za \mathbb{K}^m . Koristeći činjenicu da je $\mathbf{P}_i^2 = \mathbf{P}_i = \mathbf{P}_i^*$, za $i, j \in [N]$, $i \neq j$ računamo

$$\begin{aligned} \langle \mathbf{P}_i, \mathbf{P}_i \rangle_F &= \text{tr}(\mathbf{P}_i \mathbf{P}_i^*) = \text{tr}(\mathbf{P}_i) = \sum_{k=1}^m \langle \mathbf{P}_i(\mathbf{e}_k), \mathbf{e}_k \rangle_F = \sum_{k=1}^m \langle \mathbf{e}_k, \mathbf{a}_i \rangle \langle \mathbf{a}_i, \mathbf{e}_k \rangle \\ &= \sum_{k=1}^m |\langle \mathbf{a}_i, \mathbf{e}_k \rangle|^2 = \|\mathbf{a}_i\|_2^2 = 1, \\ \langle \mathbf{P}_i, \mathbf{P}_j \rangle_F &= \text{tr}(\mathbf{P}_i \mathbf{P}_j^*) = \text{tr}(\mathbf{P}_i \mathbf{P}_j) = \sum_{k=1}^m \langle \mathbf{P}_i \mathbf{P}_j(\mathbf{e}_k), \mathbf{e}_k \rangle = \sum_{k=1}^m \langle \mathbf{P}_j(\mathbf{e}_k), \mathbf{P}_i(\mathbf{e}_k) \rangle \\ &= \sum_{k=1}^m \langle \mathbf{e}_k, \mathbf{a}_j \rangle \overline{\langle \mathbf{e}_k, \mathbf{a}_i \rangle} \langle \mathbf{a}_j, \mathbf{a}_i \rangle = \overline{\langle \mathbf{a}_i, \mathbf{a}_j \rangle} \left\langle \sum_{k=1}^m \langle \mathbf{a}_i, \mathbf{e}_k \rangle \mathbf{e}_k, \mathbf{a}_j \right\rangle \\ &= \overline{\langle \mathbf{a}_i, \mathbf{a}_j \rangle} \langle \mathbf{a}_i, \mathbf{a}_j \rangle = |\langle \mathbf{a}_i, \mathbf{a}_j \rangle|^2 = c^2. \end{aligned}$$

Dakle, Gramova matrica sustava $(\mathbf{P}_1, \dots, \mathbf{P}_N)$ je $N \times N$ matrica oblika

$$\begin{bmatrix} 1 & c^2 & c^2 & \dots & c^2 \\ c^2 & 1 & c^2 & \dots & c^2 \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ c^2 & \dots & c^2 & 1 & c^2 \\ c^2 & \dots & c^2 & c^2 & 1 \end{bmatrix}$$

Iz činjenice $0 \leq c^2 < 1$ i leme 4.2.7 slijedi da je ova Gramova matrica invertibilna, što znači da je sustav $(\mathbf{P}_1, \dots, \mathbf{P}_N)$ linearno nezavisan. Taj sustav leži u prostoru \mathcal{S}_m koji je dimenzije $m(m+1)/2$ za $\mathbb{K} = \mathbb{R}$ te dimenzije m^2 za $\mathbb{K} = \mathbb{C}$. Stoga vrijedi,

$$N \leq \frac{m(m+1)}{2} \quad \text{za } \mathbb{K} = \mathbb{R}, \quad N \leq m^2 \quad \text{za } \mathbb{K} = \mathbb{C}.$$

Pretpostavimo sada da vrijedi jednakost. Tada je sustav $(\mathbf{I}_m, \mathbf{P}_1, \dots, \mathbf{P}_N)$ linearno zavisano, pa je stoga

$$\begin{vmatrix} 1 & b & b & \dots & b \\ b & 1 & b & \dots & b \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ b & \dots & b & 1 & b \\ b & \dots & b & b & 1 \end{vmatrix} = 0, \quad \text{gdje je } b := \frac{mc^2 - 1}{m - 1}.$$

Pošto je $1 - b = m(1 - c^2)/(m - 1) \neq 0$, lema 4.2.7 implicira da je $1 + (N - 1)b = 0$. Slijedi,

$$c^2 = \frac{N - m}{m(N - 1)}.$$

Dakle, pokazali smo da ℓ_2 -normalizirani sustav $(\mathbf{a}_1, \dots, \mathbf{a}_N)$ postiže Welchovu ocjenu a teorem 4.2.3 implicira da je taj sustav ekviangularan napeti okvir. \square

Zanimljivo je da u kontekstu prostora \mathbb{C}^m postoje sustavi od m^2 ekviangularnih vektora za sve m , dok u \mathbb{R}^m sustavi od $m(m+1)/2$ ekviangularnih vektora ne postoje za sve m . Poznato je da postoje u slučajevima gdje je m jednak 2, 3, 7 i 23. Pitanje ostalih slučajeva je i dalje otvoreno.

Teorem 4.2.8. *Za $m \geq 3$, ako postoji ekviangularni sustav od $m(m+1)/2$ vektora u \mathbb{R}^m , tada je $m+2$ nužno kvadrat nekog neparnog prirodnog broja.*

Dokaz. Neka je $(\mathbf{a}_1, \dots, \mathbf{a}_N)$ sustav od $N = m(m+1)/2$ ekviangularnih ℓ_2 -normaliziranih vektora. Prema teoremu 4.2.6 taj je sustav napeti bazni okvir, pa stoga matrica \mathbf{A} sa stupcima $\mathbf{a}_1, \dots, \mathbf{a}_N$ zadovoljava $\mathbf{A}\mathbf{A}^* = \lambda\mathbf{I}_m$ za neki $\lambda > 0$. Matrica $\mathbf{G} := \mathbf{A}^*\mathbf{A}$ ima iste ne-nul svojstvene vrijednosti kao i $\mathbf{A}\mathbf{A}^*$, tj. svojstvenu vrijednost λ algebarske kratnosti m i svojstvenu vrijednost nula kratnosti $N - m$. Nadalje, pošto je \mathbf{G} Gramova matrica sustava $(\mathbf{a}_1, \dots, \mathbf{a}_N)$, njezini dijagonalni elementi jednaki su jedinici, dok su svi vandijagonalni elementi jednaki po apsolutnoj vrijednosti nekom broju c . Dakle, matrica $\mathbf{B} := (\mathbf{G} - \mathbf{I}_N)/c$ je oblika

$$\begin{bmatrix} 0 & b_{1,2} & b_{1,3} & \cdots & b_{1,N} \\ b_{2,1} & 0 & b_{2,2} & \cdots & b_{2,N} \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ b_{N-1,1} & \cdots & b_{N-1,N-2} & 0 & b_{N-1,N} \\ b_{N,1} & \cdots & b_{N,N-2} & b_{N,N-1} & 0 \end{bmatrix} = 0, \quad \text{gdje je } b_{i,j} := \pm 1,$$

i ima $-1/c$ kao svojstvenu vrijednost kratnosti $N - m$. Stoga je njezin karakteristični polinom $p_{\mathbf{B}}(x) := \sum_{k=0}^N \beta_k (-x)^k$, $\beta_N = 1$, s cjelobrojnim koeficijentima β_k i poništava se za $-1/c$. Uvažavajući da je

$$c = \sqrt{\frac{N-m}{m(N-1)}} = \sqrt{\frac{(m+1)/2 - 1}{m(m+1)/2 - 1}} = \sqrt{\frac{m-1}{m^2 + m - 2}} = \frac{1}{\sqrt{m+2}}$$

imamo $p_{\mathbf{B}}(-\sqrt{m+2}) = 0$, tj.

$$\left(\sum_{0 \leq k \leq N/2} b_{2k} (m+2)^k \right) + \sqrt{m+2} \left(\sum_{0 \leq k \leq (N-1)/2} b_{2k+1} (m+2)^k \right) = 0.$$

Označimo gornje cjelobrojne sume sa Σ_1 i Σ_2 . Dakle, imamo $\Sigma_1^2 = (m+2)\Sigma_2^2$, što implicira da je $(m+2)$ kvadrat. Preostaje pokazati da je $n := \sqrt{m+2}$ neparan. Definiramo $N \times N$ matricu \mathbf{J}_N kojoj su svi elementi jednaki jedinici. Dimenzija njezine jezgre je $N - 1$ pa je stoga u presjeku s $N - m$ dimenzionalnim svojstvenim potprostorom od \mathbf{B} koji odgovara svojstvenoj vrijednosti $-1/c = -n$, pošto $N - 1 + N - m > N$ za $m \geq 3$, tj. $N = m(m+1)/2 > m+1$. Matrica $\mathbf{C} := (\mathbf{B} - \mathbf{I}_n + \mathbf{J}_N)/2$ ima $-(n+1)/2$ kao svojstvenu vrijednost. Dijagonalni elementi su joj nula, a vandijagonalni jednaki su ili nuli ili jedinici. Stoga je $p_{\mathbf{C}}(x) := \sum_{k=0}^N \gamma_k (-x)^k$, $\gamma_N = 1$ s cjelobrojnim koeficijentima i $p_{\mathbf{C}}(x)$ poništava se za $x = -(n+1)/2$. Tu zadnju činjenicu možemo zapisati u obliku

$$(n+1)^N = - \sum_{k=0}^{N-1} 2^{N-k} \gamma_k (n+1)^k.$$

Slijedi da je $(n+1)^N$ paran pa je stoga i $n+1$. Konačno imamo da je $n = \sqrt{m+2}$ neparan. \square

Naredni teorem daje eksplicitnu konstrukciju $m \times m^2$ kompleksnih matrica s koherencijom $1/\sqrt{m}$, što je ujedno i limes Welchove ocjene kada N ide u beskonačnost.

Teorem 4.2.9. *Za svaki prosti broj $m \geq 5$, postoji eksplicitna $m \times m^2$ kompleksna matrica s koherencijom $\mu = 1/\sqrt{m}$.*

Dokaz. Neka je $\mathbb{Z}/m\mathbb{Z} =: \mathbb{Z}_m$. Za $k, l \in \mathbb{Z}_m$ uvodimo operator translacije \mathbf{T}_k i operator modulacije \mathbf{M}_l definirane sa

$$(\mathbf{T}_k \mathbf{z})_j = z_{j-k}, \quad (\mathbf{M}_l \mathbf{z})_j = e^{2\pi i l j / m} z_j$$

za $\mathbf{z} \in \mathbb{C}^{\mathbb{Z}_m}$ i $j \in \mathbb{Z}_m$. Ti operatori su izometrije prostora $\ell_2(\mathbb{Z}_m)$. Uvedimo takozvani Alltop ℓ_2 -normalizirani vektor $\mathbf{x} \in \mathbb{C}^{\mathbb{Z}_m}$ definiran s

$$x_j := \frac{1}{\sqrt{m}} e^{2\pi i j^3 / m}, \quad j \in \mathbb{Z}_m.$$

Eksplicitna $m \times m^2$ matrica iz tvrdnje teorema dana je kao matrica sa stupcima $\mathbf{M}_l \mathbf{T}_k \mathbf{x}$ za $k, l \in \mathbb{Z}_m$, tj. matrica oblika

$$\begin{bmatrix} \mathbf{M}_1 \mathbf{T}_1 \mathbf{x} & \cdots & \mathbf{M}_1 \mathbf{T}_m \mathbf{x} & \mathbf{M}_2 \mathbf{T}_1 \mathbf{x} & \cdots & \mathbf{M}_m \mathbf{T}_m \mathbf{x} \end{bmatrix}$$

Računamo skalarni produkt dva stupca indeksirana sa (k, l) i (k', l')

$$\begin{aligned} \langle \mathbf{M}_l \mathbf{T}_k \mathbf{x}, \mathbf{M}_{l'} \mathbf{T}_{k'} \mathbf{x} \rangle &= \sum_{j \in \mathbb{Z}_m} (\mathbf{M}_l \mathbf{T}_k \mathbf{x})_j \overline{(\mathbf{M}_{l'} \mathbf{T}_{k'} \mathbf{x})_j} \\ &= \sum_{j \in \mathbb{Z}_m} e^{2\pi i l j / m} x_{j-k} e^{-2\pi i l' j / m} \overline{x_{j-k'}} \\ &= \frac{1}{m} \sum_{j \in \mathbb{Z}_m} e^{2\pi i (l-l') j / m} e^{2\pi i ((j-k)^3 - (j-k')^3) / m}. \end{aligned}$$

Označimo $a := l - l'$ i $b := k - k'$, $(a, b) \neq (0, 0)$ i promijenimo indeks sumacije za $h = j - k'$

$$\begin{aligned} |\langle \mathbf{M}_l \mathbf{T}_k \mathbf{x}, \mathbf{M}_{l'} \mathbf{T}_{k'} \mathbf{x} \rangle| &= \frac{1}{m} \left| e^{2\pi i a k' / m} \sum_{h \in \mathbb{Z}_m} e^{2\pi i a h / m} e^{2\pi i ((h-b)^3 - h^3) / m} \right| \\ &= \frac{1}{m} \left| \sum_{h \in \mathbb{Z}_m} e^{2\pi i a h / m} e^{2\pi i (-3bh^2 + 3b^2 h - b^3) / m} \right| \\ &= \frac{1}{m} \left| \sum_{h \in \mathbb{Z}_m} e^{2\pi i (-3bh^2 + (a+3b^2)h) / m} \right| \end{aligned}$$

Neka je $c := -3b$ i $d := a + 3b^2$,

$$\begin{aligned}
|\langle \mathbf{M}_l \mathbf{T}_{k\mathbf{x}}, \mathbf{M}_{l'} \mathbf{T}_{k'\mathbf{x}} \rangle|^2 &= \frac{1}{m^2} \sum_{h \in \mathbb{Z}_m} e^{2\pi i(ch^2+dh)/m} \sum_{h' \in \mathbb{Z}_m} e^{-2\pi i(ch'^2+dh')/m} \\
&= \frac{1}{m^2} \sum_{h, h'} e^{2\pi i(h-h')(c(h+h')+d)/m} \\
&= \frac{1}{m^2} \sum_{h', h'' \in \mathbb{Z}_m} e^{2\pi ih''(c(h''+2h')+d)/m} \\
&= \frac{1}{m^2} \sum_{h'' \in \mathbb{Z}_m} e^{2\pi ih''(ch''+d)/m} \left(\sum_{h' \in \mathbb{Z}_m} e^{4\pi ich''h'/m} \right).
\end{aligned}$$

Primijetimo, za svaki $h'' \in \mathbb{Z}_m$ imamo

$$\sum_{h' \in \mathbb{Z}_m} e^{4\pi ich''h'/m} = \begin{cases} m & \text{ako } 2ch'' = 0 \pmod{m}, \\ 0 & \text{ako } 2ch'' \neq 0 \pmod{m}. \end{cases}$$

Pogledajmo dva slučaja:

1. $c = 0 \pmod{m}$:

Pošto je $c = -3b$ i $3 \neq 0 \pmod{m}$, imamo $b = 0$, pa stoga $d = a + 3b^2 \neq 0 \pmod{m}$ i

$$|\langle \mathbf{M}_l \mathbf{T}_{k\mathbf{x}}, \mathbf{M}_{l'} \mathbf{T}_{k'\mathbf{x}} \rangle|^2 = \frac{1}{m} \sum_{h'' \in \mathbb{Z}_m} e^{2\pi idh''/m} = 0.$$

2. $c \neq 0 \pmod{m}$:

Pošto $2 \neq 0 \pmod{m}$, jednakost $2ch'' = 0$ vrijedi samo kada je $h'' = 0 \pmod{m}$, pa stoga

$$|\langle \mathbf{M}_l \mathbf{T}_{k\mathbf{x}}, \mathbf{M}_{l'} \mathbf{T}_{k'\mathbf{x}} \rangle|^2 = \frac{1}{m}.$$

Dakle, koherencija matrice je $1/\sqrt{m}$. □

4.3 Analiza OMP algoritma

Pokazat ćemo da mala koherencija osigurava rekonstrukciju rijetkih vektora OMP algoritmom.

Teorem 4.3.1. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ matrica s ℓ_2 -normaliziranim stupcima. Ako je*

$$\mu_1(s) + \mu_1(s-1) < 1, \quad (4.12)$$

onda se svaki s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ može rekonstruirati iz vektora mjerenja $\mathbf{y} = \mathbf{A}\mathbf{x}$ u najviše s iteracija OMP algoritma.

Dokaz. Neka su $\mathbf{a}_1, \dots, \mathbf{a}_N$ ℓ_2 -normalizirani stupci matrice \mathbf{A} . Prema propoziciji 2.2.3 dovoljno je dokazati da je za svaki $S \subseteq [N]$ takav da $\text{card}(S) = s$ matrica \mathbf{A}_S injektivna te da vrijedi

$$\max_{j \in S} |\langle \mathbf{r}, \mathbf{a}_j \rangle| > \max_{l \in \bar{S}} |\langle \mathbf{r}, \mathbf{a}_l \rangle| \quad (4.13)$$

za sve ne-nul vektore $\mathbf{r} \in \{\mathbf{A}\mathbf{z}, \text{supp}(\mathbf{z}) \subseteq S\}$. Neka je $\mathbf{r} := \sum_{i \in S} r_i \mathbf{a}_i$ i neka je $k \in S$ takav da $|r_k| = \max_{i \in S} |r_i| > 0$. Za $l \in \bar{S}$ imamo,

$$\begin{aligned} |\langle \mathbf{r}, \mathbf{a}_l \rangle| &= \left| \sum_{i \in S} r_i \langle \mathbf{a}_i, \mathbf{a}_l \rangle \right| \leq \sum_{i \in S} |r_i| |\langle \mathbf{a}_i, \mathbf{a}_l \rangle| \leq |r_k| \mu_1(s) \\ |\langle \mathbf{r}, \mathbf{a}_k \rangle| &= \left| \sum_{i \in S} r_i \langle \mathbf{a}_i, \mathbf{a}_k \rangle \right| \geq |r_k| |\langle \mathbf{a}_k, \mathbf{a}_k \rangle| - \sum_{i \in S, i \neq k} |r_i| |\langle \mathbf{a}_i, \mathbf{a}_k \rangle| \\ &\geq |r_k| - |r_k| \mu_1(s-1). \end{aligned}$$

Dakle, (4.13) vrijedi jer (4.12) implicira $1 - \mu_1(s-1) > \mu_1(s)$. Injektivnost od \mathbf{A}_S slijedi iz korolara 4.1.4. \square

4.4 Analiza ℓ_1 -minimizacije

Pokazat ćemo da mala koherencija matrice mjerenja također garantira i rekonstrukciju vektora ℓ_1 -minimizacijom (BT algoritmom).

Teorem 4.4.1. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ s ℓ_2 -normaliziranim stupcima. Ako je*

$$\mu_1(s) + \mu_1(s-1) < 1, \quad (4.14)$$

onda se svaki s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ može rekonstruirati iz vektora mjerenja $\mathbf{y} = \mathbf{A}\mathbf{x}$ putem ℓ_1 -minimizacije.

Dokaz. Prema teoremu 3.1.3 dovoljno i nužno je dokazati da matrica \mathbf{A} zadovoljava svojstvo nul-prostora te da vrijedi

$$\|\mathbf{v}_S\|_1 < \|\mathbf{v}_{\bar{S}}\|_1 \quad (4.15)$$

za svaki ne-nul vektor $\mathbf{v} \in \ker \mathbf{A}$ i za svaki skup indeksa $S \subseteq [N]$ takav da $\text{card}(S) = s$. Neka su $\mathbf{a}_1, \dots, \mathbf{a}_N$ stupci od \mathbf{A} . Uvjet $\mathbf{v} \in \ker \mathbf{A}$ interpretiramo kao $\sum_{j=1}^N v_j \mathbf{a}_j = \mathbf{0}$. Dakle, imamo

$$v_i = v_i \langle \mathbf{a}_i, \mathbf{a}_i \rangle = - \sum_{j=1, j \neq i}^N v_j \langle \mathbf{a}_j, \mathbf{a}_i \rangle = - \sum_{l \in \bar{S}} v_l \langle \mathbf{a}_l, \mathbf{a}_i \rangle - \sum_{j \in S, j \neq i} v_j \langle \mathbf{a}_j, \mathbf{a}_i \rangle.$$

Slijedi,

$$|v_i| \leq \sum_{l \in \bar{S}} |v_l| |\langle \mathbf{a}_l, \mathbf{a}_i \rangle| + \sum_{j \in S, j \neq i} |v_j| |\langle \mathbf{a}_j, \mathbf{a}_i \rangle|.$$

Sumiranjem po $i \in S$ i zamjenom poretka sumacije imamo

$$\begin{aligned} \|\mathbf{v}_S\|_1 &= \sum_{l \in \bar{S}} |v_l| \sum_{i \in S} |\langle \mathbf{a}_l, \mathbf{a}_i \rangle| + \sum_{j \in S} |v_j| \sum_{i \in S, i \neq j} |\langle \mathbf{a}_j, \mathbf{a}_i \rangle| \\ &\leq \sum_{l \in \bar{S}} |v_l| \mu_1(s) + \sum_{j \in S} |v_j| \mu_1(s-1) = \mu_1(s) \|\mathbf{v}_{\bar{S}}\|_1 + \mu_1(s-1) \|\mathbf{v}_S\|_1. \end{aligned}$$

Od tuda lako slijedi tvrdnja. □

Prema teoremu 4.2.9 možemo odabrati matricu $\mathbf{A} \in \mathbb{C}^{m \times N}$ s koherencijom $\mu \leq c/\sqrt{m}$. Vidimo da je uvjet $(2s-1)\mu < 1$, koji garantira rekonstrukciju OMP algoritmom i ℓ_1 -minimizacijom, zadovoljen ako

$$m \geq Cs^2. \quad (4.16)$$

Dakle imamo ocjenu na minimalni broj mjerenja za specifičnu matricu \mathbf{A} i rijetkost s . No, primijetimo da ova ocjena nije praktična za s razumne veličine pošto ono ulazi u ocjenu s kvadratom. Uvjerimo se da nije moguće poboljšati ovu ocjenu u kontekstu teorema 4.3.1 i 4.4.1. Pretpostavimo da vrijedi dovoljan uvjet $\mu_1(s) + \mu_1(s-1) < 1$ s $m \leq (2s-1)^2/2$ i $s < \sqrt{N-1}$ na primjer. Nadalje za $N \geq m$ iz teorema 4.2.4 slijedi

$$1 > \mu_1(s) + \mu_1(s-1) \geq (2s-1) \sqrt{\frac{N-m}{m(N-1)}} \geq \sqrt{\frac{2(N-m)}{N-1}} \geq \sqrt{\frac{N}{N-1}}.$$

što je kontradikcija.

4.5 Analiza graničnih metoda

Uz slične uvjete kao u prethodna dva teorema čak i BT algoritam garantira rekonstrukciju.

Teorem 4.5.1. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ s ℓ_2 -normaliziranim stupcima i neka je $\mathbf{x} \in \mathbb{C}^N$ s nosačem S , $\text{card}(S) = s$. Ako je*

$$\mu_1(s) + \mu_1(s-1) < \frac{\min_{i \in S} |x_i|}{\max_{i \in S} |x_i|}, \quad (4.17)$$

onda se vektor \mathbf{x} može rekonstruirati iz vektora mjerenja $\mathbf{y} = \mathbf{A}\mathbf{x}$ putem BT algoritma.

Dokaz. Neka su $\mathbf{a}_1, \dots, \mathbf{a}_N$ ℓ_2 -normalizirani stupci matrice \mathbf{A} . Prema propoziciji 2.3.1 dovoljno je dokazati da za svaki $j \in S$ i $l \in \bar{S}$,

$$|\langle \mathbf{A}\mathbf{x}, \mathbf{a}_j \rangle| > |\langle \mathbf{A}\mathbf{x}, \mathbf{a}_l \rangle|. \quad (4.18)$$

Primijetimo,

$$\begin{aligned} |\langle \mathbf{A}\mathbf{x}, \mathbf{a}_l \rangle| &= \left| \sum_{i \in S} x_i \langle \mathbf{a}_i, \mathbf{a}_l \rangle \right| \leq \sum_{i \in S} |x_i| |\langle \mathbf{a}_i, \mathbf{a}_l \rangle| \leq \mu_1(s) \max_{i \in S} |x_i|, \\ |\langle \mathbf{A}\mathbf{x}, \mathbf{a}_j \rangle| &= \left| \sum_{i \in S} x_i \langle \mathbf{a}_i, \mathbf{a}_j \rangle \right| \geq |x_j| - \sum_{i \in S, i \neq j} |x_i| |\langle \mathbf{a}_i, \mathbf{a}_j \rangle| \\ &\geq \min_{i \in S} |x_i| - \mu_1(s-1) \max_{i \in S} |x_i|. \end{aligned}$$

Iz (4.17) slijedi

$$|\langle \mathbf{A}\mathbf{x}, \mathbf{a}_j \rangle| - |\langle \mathbf{A}\mathbf{x}, \mathbf{a}_l \rangle| \geq \min_{i \in S} |x_i| - (\mu_1(s) - \mu_1(s-1)) \max_{i \in S} |x_i| > 0.$$

□

Uz iste uvjete, analogno se pokaže da IHT algoritam garantira rekonstrukciju. Sada ćemo pokazati da HTP algoritam uz određene uvjete, isto kao u OMP u s iteracija rekonstruira s -rijedak vektor.

Teorem 4.5.2. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ s ℓ_2 -normaliziranim stupcima. Ako je*

$$2\mu_1(s) + \mu_1(s-1) < 1,$$

tada se svaki s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ može rekonstruirati iz vektora mjerenja $\mathbf{y} = \mathbf{A}\mathbf{x}$ u najviše s iteracija HTP algoritma.

Dokaz. Neka su j_1, j_2, \dots, j_N takvi da

$$|x_{j_1}| \geq |x_{j_2}| \geq \dots \geq |x_{j_s}| > |x_{j_{s+1}}| = \dots = |x_{j_N}| = 0.$$

Pokazat ćemo da je za $0 \leq n \leq s-1$, skup $\{j_1, \dots, j_{n+1}\}$ sadržan u S^{n+1} iz (HTP_1) , koji je definiran kao skup s apsolutno najvećih komponenti od

$$\mathbf{z}^{n+1} := \mathbf{x}^n + \mathbf{A}^* \mathbf{A}(\mathbf{x} - \mathbf{x}^n). \quad (4.19)$$

To će implicirati $S^s = S = \text{supp}(\mathbf{x})$ pa prema (HTP_2) $\mathbf{x}^s = \mathbf{x}$. Primijetimo dovoljno je dokazati

$$\min_{1 \leq k \leq n+1} |z_{j_k}^{n+1}| > \max_{l \in \bar{S}} |z_l^{n+1}|. \quad (4.20)$$

Dokazujemo indukcijom. Vrijedi

$$z_j^{n+1} = x_j^n + \sum_{i=1}^N (x_i - x_i^n) \langle \mathbf{a}_i, \mathbf{a}_j \rangle = x_j + \sum_{i \neq j} (x_i - x_i^n) \langle \mathbf{a}_i, \mathbf{a}_j \rangle.$$

Stoga,

$$|z_j^{n+1} - x_j| \leq \sum_{i \in S^n, i \neq j} |x_i - x_i^n| |\langle \mathbf{a}_i, \mathbf{a}_j \rangle| + \sum_{i \in S \setminus S^n, i \neq j} |x_i| |\langle \mathbf{a}_i, \mathbf{a}_j \rangle|. \quad (4.21)$$

Za $1 \leq k \leq n+1$ i $l \in \bar{S}$ imamo

$$|z_{j_k}^{n+1}| \geq |x_{j_k}| - \mu_1(s) \|(\mathbf{x} - \mathbf{x}^n)_{S^n}\|_\infty - \mu_1(s) \|\mathbf{x}_{S \setminus S^n}\|_\infty \quad (4.22)$$

$$|z_l^{n+1}| \leq \mu_1(s) \|(\mathbf{x} - \mathbf{x}^n)_{S^n}\|_\infty + \mu_1(s) \|\mathbf{x}_{S \setminus S^n}\|_\infty. \quad (4.23)$$

Posebno, za $n=0$ je $\|(\mathbf{x} - \mathbf{x}^n)_{S^n}\|_\infty = 0$ pa iz (4.22), (4.23) i činjenice da $2\mu_1(s) < 1$ slijedi

$$|z_{j_1}^1| \geq (1 - \mu_1(s)) \|\mathbf{x}\|_\infty > \mu_1(s) \|\mathbf{x}\|_\infty \geq |z_l^1| \quad \text{za sve } l \in \bar{S}.$$

Dakle, tvrdnja (4.20) vrijedi za $n=0$. Pretpostavimo da tvrdnja vrijedi za $n-1$ pri čemu je $n \geq 1$. To implicira $\{j_1, \dots, j_n\} \subseteq S^n$. Iz (HTP_2) i leme 2.2.2 slijedi

$$(\mathbf{A}^* \mathbf{A}(\mathbf{x} - \mathbf{x}^n))_{S^n} = 0.$$

Stoga za svaki $j \in S^n$, definicija (4.19) implicira $z_j^{n+1} = x_j^n$, te iz (4.21) slijedi

$$|x_j^n - x_j| \leq \mu_1(s-1) \|(\mathbf{x} - \mathbf{x}^n)_{S^n}\|_\infty + \mu_1(s-1) \|\mathbf{x}_{S \setminus S^n}\|_\infty.$$

Uzimajući maksimum po $j \in S^n$ dobivamo

$$\|(\mathbf{x} - \mathbf{x}^n)_{S^n}\|_\infty \leq \frac{\mu_1(s-1)}{1 - \mu_1(s-1)} \|\mathbf{x}_{S \setminus S^n}\|_\infty.$$

Dobiveno vratimo nazad u (4.22) i (4.23),

$$\begin{aligned} |z_{j_k}^{n+1}| &\geq \left(1 - \frac{\mu_1(s)}{1 - \mu_1(s-1)}\right) |x_{j_{n+1}}|, \\ |z_l^{n+1}| &\leq \frac{\mu_1(s)}{1 - \mu_1(s-1)} |x_{j_{n+1}}|, \end{aligned}$$

za $1 \leq k \leq n+1$ i $l \in \bar{S}$. Pošto je $\mu_1(s)/(1 - \mu_1(s-1)) < 1/2$, (4.20) vrijedi i za n . Po principu matematičke indukcije slijedi tvrdnja. \square

Poglavlje 5

Svojstvo restriktivne izometričnosti

U prošlom poglavlju vidjeli smo da je pojam koherencije vrlo koristan kao mjera kvalitete matrice mjerenja. Pomoću njega lako smo postavili i dokazali uvjete koji garantiraju rekonstrukciju rijetkih vektora raznim algoritmima. No, ocjena na koherenciju iz teorema (4.2.3) ograničava analizu algoritama na male vrijednosti rijetkosti s . U ovom poglavlju uvest ćemo novu mjeru kvalitete matrice, *svojstvo restriktivne izometričnosti* (eng. *restricted isometry property*) koje se ponekad zove i *princip uniformne neodređenosti* (eng. *uniform uncertainty principle*).

5.1 Definicija i osnovna svojstva

Za razliku od koherencije koja uzima u obzir parove stupaca matrice, svojstvo restriktivne izometričnosti uzima u obzir sve s -torke stupaca matrice pa je stoga prikladnija mjera kvalitete.

Definicija 5.1.1. s -ta konstanta restriktivne izometričnosti $\delta_s = \delta_s(\mathbf{A})$ matrice $\mathbf{A} \in \mathbb{C}^{m \times N}$ je najmanji $\delta \geq 0$ takva da

$$(1 - \delta)\|\mathbf{x}\|_2^2 \leq \|\mathbf{A}\mathbf{x}\|_2^2 \leq (1 + \delta)\|\mathbf{x}\|_2^2 \quad (5.1)$$

za sve s -rijetke vektore $\mathbf{x} \in \mathbb{C}^N$. Ili ekvivalentno

$$\delta_s = \max_{S \subseteq [N], \text{card}(S) \leq s} \|\mathbf{A}_S^* \mathbf{A}_S - \mathbf{I}\|_2. \quad (5.2)$$

Neformalno, kažemo da matrica \mathbf{A} zadovoljava svojstvo restriktivne izometričnosti ako je δ_s dovoljno mali za s dovoljno velik (kasnije ćemo točno precizirati).

Uvjerimo se da su (5.1) i (5.2) ekvivalente tvrdnje. Iz (5.1) direktno slijedi

$$\left| \|\mathbf{A}_S \mathbf{x}\|_2^2 - \|\mathbf{x}\|_2^2 \right| \leq \delta \|\mathbf{x}\|_2^2 \quad \text{za sve } S \subseteq [N], \text{ card}(S) \leq s, \text{ i za sve } \mathbf{x} \in \mathbb{C}^s.$$

Primijetimo, za svaki $\mathbf{x} \in \mathbb{C}^s$

$$\|\mathbf{A}_S \mathbf{x}\|_2^2 - \|\mathbf{x}\|_2^2 = \langle \mathbf{A}_S \mathbf{x}, \mathbf{A}_S \mathbf{x} \rangle - \langle \mathbf{x}, \mathbf{x} \rangle = \langle (\mathbf{A}_S^* \mathbf{A}_S - \mathbf{I}) \mathbf{x}, \mathbf{x} \rangle.$$

Pošto je $\mathbf{A}_S^* \mathbf{A}_S - \mathbf{I}$ hermitska, imamo

$$\max_{\mathbf{x} \in \mathbb{C}^s \setminus \{0\}} \frac{\langle (\mathbf{A}_S^* \mathbf{A}_S - \mathbf{I}) \mathbf{x}, \mathbf{x} \rangle}{\|\mathbf{x}\|_2^2} = \|\mathbf{A}_S^* \mathbf{A}_S - \mathbf{I}\|_2.$$

Dakle, (5.1) je ekvivalentno s

$$\max_{S \subseteq [N], \text{card}(S) \leq s} \|\mathbf{A}_S^* \mathbf{A}_S - \mathbf{I}\|_2 \leq \delta.$$

Moguće je usporediti konstantu restriktivne izometričnosti s koherencijom μ .

Propozicija 5.1.2. *Neka je \mathbf{A} s ℓ_2 -normaliziranim stupcima $\mathbf{a}_1, \dots, \mathbf{a}_N$. Tada za svaki $j \in [N]$ vrijedi*

$$\delta_1 = 0, \quad \delta_2 = \mu \quad \delta_s \leq \mu_1(s-1) \leq (s-1)\mu, \quad s \geq 2.$$

Dokaz. Pošto su stupci od \mathbf{A} ℓ_2 -normalizirani, vrijedi $\|\mathbf{A} \mathbf{e}_j\|_2^2 = \|\mathbf{e}_j\|_2^2$ za sve $j \in [N]$. Dakle, $\delta_1 = 0$. Neka su $\mathbf{a}_1, \dots, \mathbf{a}_N$ stupci od \mathbf{A} . Imamo,

$$\delta_2 = \max_{1 \leq i \neq j \leq N} \|\mathbf{A}_{\{i,j\}}^* \mathbf{A}_{\{i,j\}} - \mathbf{I}\|_2, \quad \mathbf{A}_{\{i,j\}}^* \mathbf{A}_{\{i,j\}} = \begin{bmatrix} 1 & \langle \mathbf{a}_j, \mathbf{a}_i \rangle \\ \langle \mathbf{a}_j, \mathbf{a}_i \rangle & 1 \end{bmatrix}. \quad (5.3)$$

Svojstvene vrijednosti od $\mathbf{A}_{\{i,j\}}^* \mathbf{A}_{\{i,j\}} - \mathbf{I}$ su $|\langle \mathbf{a}_i, \mathbf{a}_j \rangle|$ i $-|\langle \mathbf{a}_i, \mathbf{a}_j \rangle|$. Stoga je njezina operatorska norma jednaka $|\langle \mathbf{a}_i, \mathbf{a}_j \rangle|$. Uzimajući maksimum po $1 \leq i \neq j \leq N$ dobivamo $\delta_2 = \mu$. Nejednakost $\delta_s \leq \mu_1(s-1) \leq (s-1)\mu$ posljedica je teorema 4.1.3. \square

U prošlom poglavlju pokazali smo egzistenciju $m \times m^2$ matrica s koherencijom $1/\sqrt{m}$ što direktno implicira egzistenciju matrica istih dimenzije s konstantom restriktivne izometričnosti $\delta_s < 1$ za $s \leq \sqrt{m}$.

Propozicija 5.1.3. *Neka su $\mathbf{u}, \mathbf{v} \in \mathbb{C}^N$ takvi da $\|\mathbf{u}\|_0 \leq s$ i $\|\mathbf{v}\|_0 \leq t$. Ako je $\text{supp}(\mathbf{u}) \cap \text{supp}(\mathbf{v}) = \emptyset$ tada*

$$|\langle \mathbf{A} \mathbf{u}, \mathbf{A} \mathbf{v} \rangle| \leq \delta_{s+t} \|\mathbf{u}\|_2 \|\mathbf{v}\|_2. \quad (5.4)$$

Dokaz. Neka je $S := \text{supp}(\mathbf{u}) \cup \text{supp}(\mathbf{v})$. Pošto su nosači od \mathbf{v} i \mathbf{u} disjunktni, imamo $\langle \mathbf{u}_S, \mathbf{v}_S \rangle = 0$. Slijedi,

$$\begin{aligned} |\langle \mathbf{A}\mathbf{u}, \mathbf{A}\mathbf{v} \rangle| &= |\langle \mathbf{A}_S \mathbf{u}_S, \mathbf{A}_S \mathbf{v}_S \rangle - \langle \mathbf{u}_S, \mathbf{v}_S \rangle| = |\langle (\mathbf{A}_S^* \mathbf{A}_S - \mathbf{I}) \mathbf{u}_S, \mathbf{v}_S \rangle| \\ &\leq \|(\mathbf{A}_S^* \mathbf{A}_S - \mathbf{I}) \mathbf{u}_S\|_2 \|\mathbf{v}_S\|_2 \leq \|\mathbf{A}_S^* \mathbf{A}_S - \mathbf{I}\|_2 \|\mathbf{u}_S\|_2 \|\mathbf{v}_S\|_2. \end{aligned}$$

Tvrđnja slijedi iz (5.2), $\|\mathbf{u}_S\|_2 = \|\mathbf{u}\|_2$ i $\|\mathbf{v}_S\|_2 = \|\mathbf{v}\|_2$. \square

Definicija 5.1.4. (s, t) -ograničena konstanta ortogonalnosti $\theta_{s,t} = \theta_{s,t}(\mathbf{A})$ matrice $\mathbf{A} \in \mathbb{C}^{m \times N}$ je najmanji $\theta \geq 0$ takva da

$$|\langle \mathbf{A}\mathbf{u}, \mathbf{A}\mathbf{v} \rangle| \leq \theta \|\mathbf{u}\|_2 \|\mathbf{v}\|_2 \quad (5.5)$$

za sve s -rijetke vektore $\mathbf{u} \in \mathbb{C}^N$ i t -rijetke vektore $\mathbf{v} \in \mathbb{C}^N$ s disjunktnim nosačem ili ekvivalentno,

$$\theta_{s,t} = \max \left\{ \|\mathbf{A}_T^* \mathbf{A}_S\|_2, S \cap T = \emptyset, \text{card}(S) \leq s, \text{card}(T) \leq t \right\}. \quad (5.6)$$

Propozicija 5.1.5. Vrijedi

$$\theta_{s,t} \leq \delta_{s+t} \leq \frac{1}{s+t} (s\delta_s + t\delta_t + 2\sqrt{st}\theta_{s,t}).$$

Posebno, za $t = s$ imamo

$$\theta_{s,s} \leq \delta_{2s} \quad i \quad \delta_{2s} \leq \delta_s + \theta_{s,s}.$$

Dokaz. Prva nejednakost slijedi direktno iz propozicije 5.1.3. Pokažimo i drugu nejednakost. Neka je $\mathbf{x} \in \mathbb{C}^N$ $(s+t)$ -rijedak vektor takav da $\|\mathbf{x}\|_2 = 1$. Moramo pokazati da

$$\left| \|\mathbf{A}\mathbf{x}\|_2^2 - \|\mathbf{x}\|_2^2 \right| \leq \frac{1}{s+t} (s\delta_s + t\delta_t + s\sqrt{st}\theta_{s,t}).$$

Neka su $\mathbf{u}, \mathbf{v} \in \mathbb{C}^N$ takvi da $\mathbf{u} + \mathbf{v} = \mathbf{x}$, gdje je \mathbf{u} s -rijedak, \mathbf{v} t -rijedak te imaju disjunktnu nosače. Vrijedi,

$$\|\mathbf{A}\mathbf{x}\|_2^2 = \langle \mathbf{A}(\mathbf{u} + \mathbf{v}), \mathbf{A}(\mathbf{u} + \mathbf{v}) \rangle = \|\mathbf{A}\mathbf{u}\|_2^2 + \|\mathbf{A}\mathbf{v}\|_2^2 + 2\text{Re}\langle \mathbf{A}\mathbf{u}, \mathbf{A}\mathbf{v} \rangle.$$

Uvrstimo $\|\mathbf{x}\|_2^2 = \|\mathbf{u}\|_2^2 + \|\mathbf{v}\|_2^2$,

$$\begin{aligned} \left| \|\mathbf{A}\mathbf{x}\|_2^2 - \|\mathbf{x}\|_2^2 \right| &\leq \left| \|\mathbf{A}\mathbf{u}\|_2^2 - \|\mathbf{u}\|_2^2 \right| + \left| \|\mathbf{A}\mathbf{v}\|_2^2 - \|\mathbf{v}\|_2^2 \right| + 2|\langle \mathbf{A}\mathbf{u}, \mathbf{A}\mathbf{v} \rangle| \\ &\leq \delta_s \|\mathbf{u}\|_2^2 + \delta_t \|\mathbf{v}\|_2^2 + 2\theta \|\mathbf{u}\|_2^2 \|\mathbf{v}\|_2^2 =: f(\|\mathbf{u}\|_2^2), \end{aligned}$$

gdje je za $\alpha \in [0, 1]$

$$f(\alpha) := \delta_s \alpha + \delta_t (1 - \alpha) + 2\theta_{s,t} \sqrt{\alpha(1 - \alpha)}. \quad (5.7)$$

Lako se pokaže da postoji $\alpha^* \in [0, 1]$ tako da je f nepadajuća na $[0, \alpha^*]$ i nerastuća na $[\alpha^*, 1]$. Ovisno o poziciji od α^* s obzirom na $s/(s+t)$ funkcija f je ili nepadajuća na $[0, s/(s+t)]$ ili nerastuća na $[s/(s+t), 1]$. Dobrim odabirom vektora \mathbf{u} , uvijek možemo pretpostaviti da je $\|\mathbf{u}\|_2^2$ u jednom od ta dva intervala. Zaista, ako se \mathbf{u} sastoji od s apsolutno najmanjih komponenti od \mathbf{x} a \mathbf{v} od t apsolutno najvećih komponenti od \mathbf{x} onda imamo

$$\frac{\|\mathbf{u}\|_2^2}{s} \leq \frac{\|\mathbf{v}\|_2^2}{t} = \frac{1 - \|\mathbf{u}\|_2^2}{t}, \quad \text{tako da } \|\mathbf{u}\|_2^2 \leq \frac{s}{s+t}.$$

U slučaju da je \mathbf{u} sačinjen od s apsolutno najvećih komponenti od \mathbf{x} , tada bi vrijedilo $\|\mathbf{u}\|_2^2 \geq s/(s+t)$. Dakle,

$$\left| \|\mathbf{Ax}\|_2^2 - \|\mathbf{x}\|_2^2 \right| \leq f\left(\frac{s}{s+t}\right) = \delta_s \frac{s}{s+t} + \delta_t \frac{t}{s+t} + 2\theta_{s,t} \frac{\sqrt{st}}{s+t}.$$

□

Kao kod koherencije, zanima nas koja je donja granica za s -tu konstantu restriktivne izometričnosti matrice $\mathbf{A} \in \mathbb{C}^{m \times N}$.

Teorem 5.1.6. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ i $2 \leq s \leq N$. Tada je*

$$m \geq c \frac{s}{\delta_s^2}, \quad (5.8)$$

za $N \geq Cm$ i $\delta_s \leq \delta_*$, gdje konstante c, C i δ_* ovise samo o sebi međusobno. Na primjer, možemo uzeti $c = 1/162$, $C = 30$ i $\delta_* = 2/3$.

Dokaz. Primijetimo da tvrdnja ne vrijedi za $s = 1$ jer je $\delta_1 = 0$ ako svi stupci od \mathbf{A} imaju ℓ_2 -normu jednaku jedan. Neka je $t := \lfloor s/2 \rfloor \geq 1$ i rastavimo \mathbf{A} na blokove tipa $m \times t$, osim možda zadnjeg koji može imati manje stupaca,

$$\mathbf{A} = [\mathbf{A}_1 \quad \mathbf{A}_2 \quad \dots \quad \mathbf{A}_n], \quad N \leq nt.$$

Iz (5.2) i (5.6) za $i, j \in [n]$, $i \neq j$ imamo

$$\|\mathbf{A}_i^* \mathbf{A}_i - \mathbf{I}\|_2 \leq \delta_t \leq \delta_s, \quad \|\mathbf{A}_i^* \mathbf{A}_j\|_2 \leq \theta_{t,t} \leq \delta_{2t} \leq \delta_s,$$

pa svojstvene vrijednosti od $\mathbf{A}_i^* \mathbf{A}_i$ i singularne vrijednosti od $\mathbf{A}_i^* \mathbf{A}_j$ zadovoljavaju

$$1 - \delta_s \leq \lambda_k(\mathbf{A}_i^* \mathbf{A}_i) \leq 1 + \delta_s, \quad \sigma_k(\mathbf{A}_i^* \mathbf{A}_j) \leq \delta_s.$$

Uvedimo oznake za matrice

$$\mathbf{H} := \mathbf{A}\mathbf{A}^* \in \mathbb{C}^{m \times m}, \quad \mathbf{G} := \mathbf{A}^* \mathbf{A} = [\mathbf{A}_i^* \mathbf{A}_j]_{1 \leq i, j \leq n} \in \mathbb{C}^{N \times N}.$$

Imamo

$$\operatorname{tr}(\mathbf{H}) = \operatorname{tr}(\mathbf{G}) = \sum_{i=1}^n \operatorname{tr}(\mathbf{A}_i^* \mathbf{A}_i) = \sum_{i=1}^n \sum_{k=1}^t \lambda_k(\mathbf{A}_i^* \mathbf{A}_i) \geq nt(1 - \delta_s). \quad (5.9)$$

Nadalje,

$$\operatorname{tr}(\mathbf{H})^2 = \langle \mathbf{I}_m, \mathbf{H} \rangle_F^2 \leq \|\mathbf{I}_m\|_F^2 \|\mathbf{H}\|_F^2 = m \operatorname{tr}(\mathbf{H}^* \mathbf{H}).$$

Zbog svojstva cikličnosti traga vrijedi,

$$\begin{aligned} \operatorname{tr}(\mathbf{H}^* \mathbf{H}) &= \operatorname{tr}(\mathbf{A}\mathbf{A}^* \mathbf{A}\mathbf{A}^*) = \operatorname{tr}(\mathbf{A}^* \mathbf{A}\mathbf{A}^* \mathbf{A}) = \operatorname{tr}(\mathbf{G}\mathbf{G}^*) \\ &= \sum_{i=1}^n \operatorname{tr} \left(\sum_{j=1}^m \mathbf{A}_i^* \mathbf{A}_j \mathbf{A}_j^* \mathbf{A}_i \right) \\ &= \sum_{1 \leq i \neq j \leq n} \sum_{k=1}^t \sigma_k(\mathbf{A}_i^* \mathbf{A}_j)^2 + \sum_{i=1}^n \sum_{k=1}^t \lambda_k(\mathbf{A}_i^* \mathbf{A}_i)^2 \\ &\leq n(n-1)t\delta_s^2 + nt(1 + \delta_s)^2. \end{aligned}$$

Dobivamo ocjenu

$$\operatorname{tr}(\mathbf{H})^2 \leq mnt \left((n-1)\delta_s^2 + (1 + \delta_s)^2 \right). \quad (5.10)$$

Kombiniranjem (5.9) i (5.10) imamo

$$m \geq \frac{nt(1 - \delta_s)^2}{(n-1)\delta_s^2 + (1 + \delta_s)^2}.$$

Pretpostavimo da je $(n-1)\delta_s^2 < (1 + \delta_s)^2/5$. Za $\delta_s \leq 2/3$ slijedi

$$m > \frac{nt(1 - \delta_s)^2}{6(1 + \delta_s)^2/5} \geq \frac{5(1 - \delta_s)^2}{6(1 + \delta_s)^2} N \geq \frac{1}{30} N,$$

što je kontradikcija. Dakle, mora vrijediti $(n-1)\delta_s^2 \geq (1 + \delta_s)^2/5$, što uz $\delta_s \leq 2/3$ i

$s \leq 3t$ implicira

$$m \geq \frac{nt(1 - \delta_s)^2}{6(n-1)\delta_s^2} \geq \frac{1}{54} \frac{t}{\delta_s^2} \geq \frac{1}{162} \frac{s}{\delta_s^2}.$$

□

Usporedimo ocjene dobivene do sada. Imamo ocjenu odozdo

$$\delta_s \geq \sqrt{cs/m}. \quad (5.11)$$

Za $\mathbf{A} \in \mathbb{C}^{m \times N}$ s optimalnom koherencijom $\mu \leq c/\sqrt{m}$, propozicija 5.1.2 implicira

$$\delta_s \leq (s-1)\mu \leq cs/\sqrt{m}. \quad (5.12)$$

Primijetimo da je razmak između (5.11) i (5.12) značajan. Iz (5.12) imamo

$$m \geq c's^2 \quad (5.13)$$

što dozvoljava da δ_s bude malen. Ako je to zadovoljeno iz (5.11) imamo da je $m \geq c's$. Nije poznato je li takav uvjet dovoljan. Pokaže se da određene slučajne matrice $\mathbf{A} \in \mathbb{R}^{m \times N}$ zadovoljavaju $\delta_s \leq \delta$ s velikom vjerojatnošću za neki $\delta > 0$ ako je

$$m \geq C\delta^{-2}s \ln(eN/S). \quad (5.14)$$

Konstrukcija determinističkih matrica u polinomijalnom vremenu koje zadovoljavaju $\delta_s \leq \delta$ u kontekstu (5.14) do danas otvoren je problem. Glavna zapreka je što gotovo sve aproksimacije δ_s kombiniraju ocjenu koherencije i tvrdnju oblika propozicije 5.1.2. To vodi na ocjene oblika (5.12) i kvadratnu ovisnost ocjene u varijabli s . Iznimka su radovi [1] i [3]. Bourgain et al. u [1] daje eksplicitnu konstrukciju determinističkih matrica $\mathbf{A} \in \mathbb{C}^{m \times N}$ s malim δ_s za $m \geq Cs^{2-\varepsilon}$ i $s^{2-\varepsilon} \leq N \leq s^{2+\varepsilon}$ za neki $\varepsilon > 0$. Napredak je ostvaren putem novih estimacija za produkt skupova koji su suma dvaju skupa i za eksponencijalnu sumu produkta skupova s posebnom aditivnom strukturom. U [3] nadograđuje se ideja iz [1] korištenjem algebarske geometrije. Nadalje u [14] pokazano je da izračun δ_s \mathfrak{NB} -težak problem. Intuitivno to je jasno. Naime, svojstvo restriktivne izometričnosti uzima u obzir sve moguće s -torke stupaca matrice \mathbf{A} .

5.2 Analiza ℓ_1 -minimizacije

Pokazat ćemo da ℓ_1 -minimizacija uspješno rekonstruira sve s -rijetke vektore za dovoljno male konstante restriktivne izometričnosti, točnije za $\delta_{2s} < 1/3$.

Teorem 5.2.1. *Neka $2s$ -ta konstanta restriktivne izometričnosti matrice $\mathbf{A} \in \mathbb{C}^{m \times N}$ zadovoljava*

$$\delta_{2s} < \frac{1}{3}. \quad (5.15)$$

Tada je svaki s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ jedinstveno rješenje problema

$$\min_{\mathbf{z} \in \mathbb{C}^N} \|\mathbf{z}\|_1 \quad \text{uz uvjet } \mathbf{Az} = \mathbf{Ax}.$$

Za dokaz potreban je sljedeći argument.

Lema 5.2.2. *Neka je $q > p > 0$. Ako $\mathbf{u} \in \mathbb{C}^s$ i $\mathbf{v} \in \mathbb{C}^t$ zadovoljavaju*

$$\max_{i \in [s]} |u_i| \leq \min_{j \in [t]} |v_j|, \quad (5.16)$$

onda,

$$\|\mathbf{u}\|_q \leq \frac{s^{1/q}}{t^{1/p}} \|\mathbf{v}\|_p.$$

Posebno za $p = 1$, $q = 2$ i $t = s$,

$$\|\mathbf{u}\|_2 \leq \frac{1}{\sqrt{s}} \|\mathbf{v}\|_1.$$

Dokaz. Primijetimo da je

$$\frac{\|\mathbf{u}\|_q}{s^{1/q}} = \left[\frac{1}{s} \sum_{i=1}^s |u_i|^q \right]^{1/q} \leq \max_{i \in [s]} |u_i|,$$

$$\frac{\|\mathbf{v}\|_p}{t^{1/p}} = \left[\frac{1}{t} \sum_{j=1}^t |v_j|^p \right]^{1/p} \geq \min_{j \in [t]} |v_j|.$$

Sada iskoristimo (5.16) i slijedi tvrdnja. \square

Dokaz (Teorem 5.2.1). Prema teoremu 3.1.3 dovoljno je pokazati da vrijedi svojstvo

nul-prostora reda s , tj.

$$\|\mathbf{v}_S\|_1 \leq \frac{1}{2} \|\mathbf{v}\|_1$$

za sve $\mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}$ i za sve $S \subseteq [N]$, $\text{card}(S) = s$. To će slijediti iz općenitije tvrdnje

$$\|\mathbf{v}_S\|_2 \leq \frac{\rho}{2\sqrt{s}} \|\mathbf{v}\|_1$$

za sve $\mathbf{v} \in \ker \mathbf{A} \setminus \{\mathbf{0}\}$ i za sve $S \subseteq [N]$, $\text{card}(S) = s$, gdje

$$\rho := \frac{2\delta_{2s}}{1 - \delta_{2s}}$$

zadovoljava $\rho < 1$ za $\delta_{2s} < 1/3$. Primijetimo da je dovoljno promatrati skup $S =: S_0$, koji sadrži indekse s apsolutno najvećih komponenti vektora $\mathbf{v} \in \ker \mathbf{A}$. Nadalje, \bar{S}_0 particioniramo na $\bar{S}_0 = S_1 \cup S_2 \cup \dots$, tako da

$$\begin{aligned} S_1 &: \text{skup indeksa } s \text{ apsolutno najvećih komponenti vektora } \mathbf{v} \text{ u } \bar{S}_0 \\ S_2 &: \text{skup indeksa } s \text{ apsolutno najvećih komponenti vektora } \mathbf{v} \text{ u } \overline{S_0 \cup S_1} \\ &\vdots \end{aligned}$$

Pošto je $\mathbf{v} \in \ker \mathbf{A}$, imamo $\mathbf{A}(\mathbf{v}_{S_0}) = \mathbf{A}(-\mathbf{v}_{S_1} - \mathbf{v}_{S_2} - \dots)$ pa stoga

$$\begin{aligned} \|\mathbf{v}_{S_0}\|_2^2 &\leq \frac{1}{1 - \delta_{2s}} \|\mathbf{A}(\mathbf{v}_{S_0})\|_2^2 = \frac{1}{1 - \delta_{2s}} \langle \mathbf{A}(\mathbf{v}_{S_0}), \mathbf{A}(-\mathbf{v}_{S_1}) + \mathbf{A}(-\mathbf{v}_{S_2}) + \dots \rangle \\ &= \frac{1}{1 - \delta_{2s}} \sum_{k \geq 1} \langle \mathbf{A}(\mathbf{v}_{S_0}), \mathbf{A}(-\mathbf{v}_{S_k}) \rangle \end{aligned} \quad (5.17)$$

Prema propoziciji 5.1.3 također vrijedi

$$\langle \mathbf{A}(\mathbf{v}_{S_0}), \mathbf{A}(-\mathbf{v}_{S_k}) \rangle \leq \delta_{2s} \|\mathbf{v}_{S_0}\|_2 \|\mathbf{v}_{S_k}\|_2. \quad (5.18)$$

Uvrstimo (5.18) u (5.17) te podijelimo s $\|\mathbf{v}_{S_0}\| > 0$,

$$\|\mathbf{v}_{S_0}\|_2 \leq \frac{\delta_{2s}}{1 - \delta_{2s}} \sum_{k \geq 1} \|\mathbf{v}_{S_k}\|_2 = \frac{\rho}{2} \sum_{k \geq 1} \|\mathbf{v}_{S_k}\|_2.$$

Za $k \geq 1$, s apsolutno najvećih komponenti od \mathbf{v}_{S_k} nisu veće od s apsolutnih kompo-

nenti od $\mathbf{v}_{S_{k-1}}$. Stoga lema 5.2.2 daje

$$\|\mathbf{v}_{S_k}\|_2 \leq \frac{1}{\sqrt{s}} \|\mathbf{v}_{S_{k-1}}\|_1.$$

Napokon,

$$\|\mathbf{v}_{S_0}\|_2 \leq \frac{\rho}{2\sqrt{s}} \sum_{k \geq 1} \|\mathbf{v}_{S_{k-1}}\|_1 \leq \frac{\rho}{2\sqrt{s}} \|\mathbf{v}\|_1.$$

□

U prethodni teorem moguće je ukomponirati stabilnost i robusnost te dodatno oslabiti uvjet, tj. dovoljno je tražiti da $\delta_{2s} < \frac{4}{\sqrt{41}} \approx 0.6246$. No, svojstvo restriktivne izometričnosti nosi i neke probleme kod ℓ_1 -minimizacije. Naime, pokazali smo da je ℓ_1 -minimizacija invarijanta na reskalanje, preslagivanje te dodavanje novih mjerenja. Međutim, takve transformacije mogu pokvariti konstantu restriktivne izometričnosti. Preciznije, preslagivanje mjerenja odgovora zamjeni matrice $\mathbf{A} \in \mathbb{C}^{m \times N}$ matricom \mathbf{PA} , gdje je $\mathbf{P} \in \mathbb{C}^{m \times m}$ matrica permutacije, i takva transformacija ne mijenja δ_s . Dodavanje mjerenja odgovara dodavanju retka matrici \mathbf{A} , što može rezultirati povećanjem od δ_s . Zaista, neka je $\delta_s(\mathbf{A}) < 1$ i uzmimo $\delta > \delta_s(\mathbf{A})$. Neka je $\tilde{\mathbf{A}}$ matrica \mathbf{A} kojoj smo dodali redak $[0 \cdots 0 \sqrt{1 + \delta}]$. Sada za $\mathbf{x} := [0 \cdots 0 1]^T$ vidimo da je $\|\mathbf{Ax}\|_2^2 \geq 1 + \delta$. To implicira da je $\delta_1(\mathbf{A}) \geq \delta$ pa stoga i $\delta_s(\tilde{\mathbf{A}}) > \delta_s(\mathbf{A})$. Skaliranje dijagonalnom matricom te skaliranje konstantom također mogu povećati δ_s .

5.3 Analiza graničnih metoda

Pokazat ćemo da IHT i HTP algoritmi uspješno rekonstruiraju rijetke vektore za matrice mjerenja s malim konstantama restriktivne izometričnosti.

Teorem 5.3.1. *Neka je matrica $\mathbf{A} \in \mathbb{C}^{m \times N}$ takva da*

$$\delta_{3s} < \frac{1}{2}. \tag{5.19}$$

Tada za svaki s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$, niz (\mathbf{x}^n) definiran s (IHT) za $\mathbf{y} = \mathbf{Ax}$ konvergira prema \mathbf{x} .

Za dokaz potrebna nam je sljedeća lema,

Lema 5.3.2. Za $\mathbf{u}, \mathbf{v} \in \mathbb{C}^N$ i skup indeksa $S \subseteq [N]$ vrijedi,

$$|\langle \mathbf{u}, (\mathbf{I} - \mathbf{A}^* \mathbf{A}) \mathbf{v} \rangle| \leq \delta_t \|\mathbf{u}\|_2 \|\mathbf{v}\|_2 \quad \text{za } \text{card}(\text{supp}(\mathbf{u}) \cup \text{supp}(\mathbf{v})) \leq t,$$

$$\|((\mathbf{I} - \mathbf{A}^* \mathbf{A}) \mathbf{v})_S\|_2 \leq \delta_t \|\mathbf{v}\|_2 \quad \text{za } \text{card}(S \cup \text{supp}(\mathbf{v})) \leq t.$$

Dokaz. Neka je $T := \text{supp}(\mathbf{u}) \cup \text{supp}(\mathbf{v})$. Imamo,

$$\begin{aligned} |\langle \mathbf{u}, (\mathbf{I} - \mathbf{A}^* \mathbf{A}) \mathbf{v} \rangle| &= |\langle \mathbf{u}, \mathbf{v} \rangle - \langle \mathbf{A} \mathbf{u}, \mathbf{A} \mathbf{v} \rangle| = |\langle \mathbf{u}_T, \mathbf{v}_T \rangle - \langle \mathbf{A}_T \mathbf{u}_T, \mathbf{A}_T \mathbf{v}_T \rangle| \\ &= |\langle \mathbf{u}_T, (\mathbf{I} - \mathbf{A}_T^* \mathbf{A}_T) \mathbf{v}_T \rangle| \leq \|\mathbf{u}_T\|_2 \|(\mathbf{I} - \mathbf{A}_T^* \mathbf{A}_T) \mathbf{v}_T\|_2 \\ &\leq \|\mathbf{u}_T\|_2 \|\mathbf{I} - \mathbf{A}_T^* \mathbf{A}_T\|_2 \|\mathbf{v}_T\|_2 \leq \delta_t \|\mathbf{u}\|_2 \|\mathbf{v}\|_2. \end{aligned}$$

Druga nejednakost slijedi iz prve i činjenice

$$\|((\mathbf{I} - \mathbf{A}^* \mathbf{A}) \mathbf{v})_S\|_2^2 = \langle ((\mathbf{I} - \mathbf{A}^* \mathbf{A}) \mathbf{v})_S, (\mathbf{I} - \mathbf{A}^* \mathbf{A}) \mathbf{v} \rangle \leq \delta_t \|((\mathbf{I} - \mathbf{A}^* \mathbf{A}) \mathbf{v})_S\|_2 \|\mathbf{v}\|_2.$$

□

Dokaz (Teorem 5.3.1). Primijetimo da je dovoljno pronaći konstantu $0 \leq \rho < 1$ takvu da

$$\|\mathbf{x}^{n+1} - \mathbf{x}\|_2 \leq \rho \|\mathbf{x}^n - \mathbf{x}\|_2, \quad n \geq 0 \quad (5.20)$$

odakle induktivno imamo

$$\|\mathbf{x}^n - \mathbf{x}\|_2 \leq \rho^n \|\mathbf{x}^0 - \mathbf{x}\|_2 \xrightarrow{n \rightarrow \infty} 0.$$

Prema samoj definiciji, vektor \mathbf{x}^{n+1} je bolja ili barem jednako dobra aproksimacija vektora

$$\mathbf{u}^n := \mathbf{x}^n + \mathbf{A}^*(\mathbf{y} - \mathbf{A} \mathbf{x}^n) = \mathbf{x}^n + \mathbf{A}^* \mathbf{A}(\mathbf{x} - \mathbf{x}^n)$$

od s -rijetkog vektora \mathbf{x} . Dakle,

$$\|\mathbf{u}^n - \mathbf{x}^{n+1}\|_2^2 \leq \|\mathbf{u}^n - \mathbf{x}\|_2^2.$$

Uvrstimo $\|\mathbf{u}^n - \mathbf{x}^{n+1}\|_2^2 = \|(\mathbf{u}^n - \mathbf{x}) - (\mathbf{x}^{n+1} - \mathbf{x})\|_2^2$ te sređivanjem dobivamo

$$\|\mathbf{x}^{n+1} - \mathbf{x}\|_2^2 \leq 2\text{Re}\langle \mathbf{u}^n - \mathbf{x}, \mathbf{x}^{n+1} - \mathbf{x} \rangle. \quad (5.21)$$

Lema 5.3.2 daje

$$\begin{aligned} \text{Re}\langle \mathbf{u}^n - \mathbf{x}, \mathbf{x}^{n+1} - \mathbf{x} \rangle &= \text{Re}\langle (\mathbf{I} - \mathbf{A}^* \mathbf{A})(\mathbf{x}^n - \mathbf{x}), \mathbf{x}^{n+1} - \mathbf{x} \rangle \\ &\leq \delta_{3s} \|\mathbf{x}^n - \mathbf{x}\|_2 \|\mathbf{x}^{n+1} - \mathbf{x}\|_2. \end{aligned} \quad (5.22)$$

Ako je $\|\mathbf{x}^{n+1} - \mathbf{x}\|_2 > 0$, iz (5.21) i (5.22) slijedi

$$\|\mathbf{x}^{n+1} - \mathbf{x}\|_2 \leq 2\delta_{3s}\|\mathbf{x}^n - \mathbf{x}\|_2$$

Stoga, tražena nejednakost vrijedi za $\rho = 2\delta_{3s} < 1$. \square

Ponovno je moguće dobiti robusnost i stabilnost te se ocjena može oslabiti. To je tvrdnja sljedećeg teorema koji vrijedi i za IHT, i za HTP algoritam.

Teorem 5.3.3. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ takva da*

$$\delta_{3s} < \frac{1}{\sqrt{3}} \approx 0.5773. \quad (5.23)$$

Tada, za svaki $\mathbf{x} \in \mathbb{C}^N$, $\mathbf{e} \in \mathbb{C}^m$ i $S \subseteq [N]$, $\text{card}(S) = s$, niz (\mathbf{x}^n) definiran s (IHT) ili s (HTP₁), (HTP₂) za $\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{e}$ zadovoljava

$$\|\mathbf{x}^n - \mathbf{x}_S\|_2 \leq \rho^n \|\mathbf{x}^0 - \mathbf{x}_S\|_2 + \tau \|\mathbf{A}\mathbf{x}_{\bar{S}} + \mathbf{e}\|_2, \quad (5.24)$$

za svaki $n \geq 0$, gdje je $\rho = \sqrt{3} < 1$, $\tau \leq 2.18/(1-\rho)$ za (IHT), $\rho = \sqrt{2\delta_{3s}^2/(1-\delta_{2s}^2)} < 1$, $\tau \leq 5.15/(1-\rho)$ za (HTP₁), (HTP₂).

U dokazu koristimo sljedeću tvrdnju,

Lema 5.3.4. *Za $\mathbf{e} \in \mathbb{C}^m$ i $S \in [N]$, $\text{card}(S) \leq s$ vrijedi*

$$\|(\mathbf{A}^*\mathbf{e})_S\|_2^2 \leq \sqrt{1 + \delta_s} \|\mathbf{e}\|_2.$$

Dokaz. Vrijedi,

$$\begin{aligned} \|(\mathbf{A}^*\mathbf{e})_S\|_2^2 &= \langle \mathbf{A}^*\mathbf{e}, (\mathbf{A}^*\mathbf{e})_S \rangle = \langle \mathbf{e}, \mathbf{A}((\mathbf{A}^*\mathbf{e})_S) \rangle \leq \|\mathbf{e}\|_2 \|\mathbf{A}((\mathbf{A}^*\mathbf{e})_S)\|_2 \\ &\leq \|\mathbf{e}\|_2 \sqrt{1 + \delta_s} \|(\mathbf{A}^*\mathbf{e})_S\|_2. \end{aligned}$$

\square

Dokaz (Teorem 5.3.3). Neka je $\mathbf{x} \in \mathbb{C}^N$, $\mathbf{e} \in \mathbb{C}^m$, $S \subseteq [N]$ takav da je $\text{card}(S) = s$. Ako pokažemo da za svaki $n \geq 0$ vrijedi

$$\|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2 \leq \rho \|\mathbf{x}^n - \mathbf{x}_S\|_2 + (1 - \rho)\tau \|\mathbf{A}\mathbf{x}_{\bar{S}} + \mathbf{e}\|_2 \quad (5.25)$$

tada (5.24) slijedi indukcijom. Neka je $S^{n+1} := \text{supp}(\mathbf{x}^{n+1})$ skup indeksa s apsolutno najvećih vrijednosti od $\mathbf{x}^n + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n)$. Stoga,

$$\|(\mathbf{x}^n + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_S\|_2^2 \leq \|(\mathbf{x}^n + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S^{n+1}}\|_2^2$$

Nadalje, maknemo doprinos od $S \cap S^{n+1}$

$$\|(\mathbf{x}^n + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S \setminus S^{n+1}}\|_2^2 \leq \|(\mathbf{x}^n + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S^{n+1} \setminus S}\|_2^2.$$

Desnu stranu možemo zapisati kao

$$\|(\mathbf{x}^n + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S^{n+1} \setminus S}\|_2^2 = \|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S^{n+1} \setminus S}\|_2^2.$$

Lijeva strana zadovoljava,

$$\begin{aligned} \|(\mathbf{x}^n + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S \setminus S^{n+1}}\|_2 &= \|(\mathbf{x}_S - \mathbf{x}^{n+1} + \mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S \setminus S^{n+1}}\|_2 \\ &\geq \|(\mathbf{x}_S - \mathbf{x}^{n+1})_{S \setminus S^{n+1}}\|_2 \\ &\quad - \|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S \setminus S^{n+1}}\|_2. \end{aligned}$$

Sa $S \Delta S^{n+1} = (S \setminus S^{n+1}) \cup (S^{n+1} \setminus S)$ označimo simetričnu razliku skupa S i S^{n+1} . Slijedi

$$\begin{aligned} \|(\mathbf{x}_S - \mathbf{x}^{n+1})_{S \setminus S^{n+1}}\|_2 &\leq \|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S \setminus S^{n+1}}\|_2 \\ &\quad + \|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S^{n+1} \setminus S}\|_2 \\ &\leq \sqrt{2} \|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S \Delta S^{n+1}}\|_2. \end{aligned} \quad (5.26)$$

Koncentrirajmo se na IHT algoritam prvo. Tada imamo,

$$\mathbf{x}^{n+1} = (\mathbf{x}^n + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S^{n+1}}.$$

Slijedi

$$\begin{aligned} \|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2^2 &= \|(\mathbf{x}^{n+1} - \mathbf{x}_S)_{S^{n+1}}\|_2^2 + \|(\mathbf{x}^{n+1} - \mathbf{x}_S)_{\overline{S^{n+1}}}\|_2^2 \\ &= \|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S^{n+1}}\|_2^2 + \|(\mathbf{x}^{n+1} - \mathbf{x}_S)_{S \setminus S^{n+1}}\|_2^2. \end{aligned}$$

Nadalje, iz (5.26) imamo

$$\begin{aligned} \|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2^2 &\leq \|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S^{n+1}}\|_2^2 \\ &\quad + 2\|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S \Delta S^{n+1}}\|_2^2 \\ &\leq 3\|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S \cup S^{n+1}}\|_2^2. \end{aligned}$$

Neka je $\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{e} = \mathbf{A}\mathbf{x}_S + \mathbf{e}'$ gdje je $\mathbf{e}' := \mathbf{A}\mathbf{x}_{\bar{S}} + \mathbf{e}$. Iz lema 5.3.2 i 5.3.4 slijedi

$$\begin{aligned} \|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2 &\leq \sqrt{3} \|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S \cup S^{n+1}}\|_2 \\ &\leq \sqrt{3} \left[\|(\mathbf{I} - \mathbf{A}^* \mathbf{A})(\mathbf{x}^n - \mathbf{x}_S)_{S \cup S^{n+1}}\|_2 + \|(\mathbf{A}^* \mathbf{e}')_{S \cup S^{n+1}}\|_2 \right] \\ &\leq \left[\delta_{3s} \|\mathbf{x}^n - \mathbf{x}_S\|_2 + \sqrt{1 + \delta_{2s}} \|\mathbf{e}'\|_2 \right]. \end{aligned}$$

To je nejednakost za IHT koja se traži u (5.25). Odavde lako vidimo da je $\rho = \sqrt{3}\delta_{3s} < 1$ za $\delta_{3s} < 1/\sqrt{3}$ i da $(1 - \rho)\tau = \sqrt{3}\sqrt{1 + \delta_{2s}} \leq \sqrt{3 + \sqrt{3}} \leq 2.18$.

Prijeđimo sada na HTP algoritam. Tada imamo

$$\mathbf{x}^{n+1} = \arg \min \left\{ \|\mathbf{y} - \mathbf{A}\mathbf{z}\|_2, \text{supp}(\mathbf{z}) \subseteq S^{n+1} \right\}.$$

Najbolja ℓ_2 aproksimacija $\mathbf{A}\mathbf{x}^{n+1}$ vektora $\mathbf{y} \in \{\mathbf{A}\mathbf{z}, \text{supp}(\mathbf{z}) \subseteq S^{n+1}\}$ karakterizirana je s

$$\langle \mathbf{y} - \mathbf{A}\mathbf{x}^{n+1}, \mathbf{A}\mathbf{z} \rangle = 0$$

za \mathbf{z} takav da $\text{supp}(\mathbf{z}) \subseteq S^{n+1}$. To znači da je $\langle \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^{n+1}), \mathbf{z} \rangle = 0$ kada je $\text{supp}(\mathbf{z}) \subseteq S^{n+1}$, tj. možemo zaključiti

$$(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^{n+1}))_{S^{n+1}} = \mathbf{0}.$$

Iz toga i (5.26) slijedi

$$\begin{aligned} \|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2^2 &= \|(x^{n+1} - \mathbf{x}_S)_{S^{n+1}}\|_2^2 + \|(\mathbf{x}^{n+1} - \mathbf{x}_S)_{S \setminus S^{n+1}}\|_2^2 \\ &\leq \|(\mathbf{x}^{n+1} - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^{n+1}))_{S^{n+1}}\|_2^2 \\ &\quad + 2\|(\mathbf{x}^{n+1} - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^{n+1}))_{S \Delta S^{n+1}}\|_2^2 \\ &\leq \left[\|(\mathbf{I} - \mathbf{A}^*\mathbf{A})(\mathbf{x}^{n+1} - \mathbf{x}_S)_{S^{n+1}}\|_2 + \|(\mathbf{A}^*\mathbf{e}')_{S^{n+1}}\|_2 \right]^2 \\ &\quad + 2\left[\|(\mathbf{I} - \mathbf{A}^*\mathbf{A})(\mathbf{x}^n - \mathbf{x}_S)_{S \Delta S^{n+1}}\|_2 + \|(\mathbf{A}^*\mathbf{e}')_{S \Delta S^{n+1}}\|_2 \right]^2. \end{aligned}$$

Sada primjenimo leme 5.3.2 i 5.3.4,

$$\begin{aligned} \|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2^2 &\leq [\delta_{2s}\|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2 + \sqrt{1 + \delta_s}\|\mathbf{e}'\|_2]^2 \\ &\quad + 2[\delta_{3s}\|\mathbf{x}^n - \mathbf{x}_S\|_2 + \sqrt{1 + \delta_{2s}}\|\mathbf{e}'\|_2]^2. \end{aligned}$$

Nakon preslagivanja imamo

$$\begin{aligned} &2[\delta_{3s}\|\mathbf{x}^n - \mathbf{x}_S\|_2 + \sqrt{1 + \delta_{2s}}\|\mathbf{e}'\|_2]^2 \\ &\geq (1 - \delta_{2s}^2) \left(\|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2 + \frac{\sqrt{1 + \delta_s}}{1 + \delta_{2s}}\|\mathbf{e}'\|_2 \right) \left(\|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2 - \frac{\sqrt{1 + \delta_s}}{1 - \delta_{2s}}\|\mathbf{e}'\|_2 \right). \end{aligned}$$

Možemo pretpostaviti da je $\|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2 \geq \sqrt{1 + \delta_{2s}}\|\mathbf{e}'\|_2/(1 - \delta_{2s})$. U suprotnom (5.25) odmah vrijedi za $(1 - \rho)\tau$ dan u nastavku. Dakle, drugi izraz u drugoj zagradi

je pozitivan. Vrijedi

$$2[\delta_{3s}\|\mathbf{x}^n - \mathbf{x}_S\|_2 + \sqrt{1 + \delta_{2s}}\|\mathbf{e}'\|_2]^2 \geq (1 - \delta_{2s}^2)\left(\|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2 - \frac{\sqrt{1 + \delta_s}}{1 - \delta_{2s}}\|\mathbf{e}'\|_2\right)^2.$$

Od tuda slijedi

$$\|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2 \leq \frac{\sqrt{2}\delta_{3s}}{\sqrt{1 - \delta_{2s}^2}}\|\mathbf{x}^n - \mathbf{x}_S\|_2 + \left(\frac{\sqrt{2}}{\sqrt{1 - \delta_{2s}^2}} + \frac{\sqrt{1 + \delta_s}}{1 - \delta_{2s}}\right)\|\mathbf{e}'\|_2.$$

To je jednakost oblika (5.25). Primijetimo da je $\rho := \sqrt{2}\delta_{3s}/\sqrt{1 - \delta_{2s}^2} \leq \sqrt{2}\delta_{3s}/\sqrt{1 - \delta_{3s}^2} < 1$ za $\delta_{3s} < 1/\sqrt{3}$ i da je $(1 - \rho)\tau = \sqrt{2}/\sqrt{1 - \delta_{2s}^2} + \sqrt{1 + \delta_s}/(1 - \delta_{2s}) \leq 5.15$. \square

Uzimanjem limesa kada $n \rightarrow \infty$ u (5.24) imamo da $\|\mathbf{x}^\sharp - \mathbf{x}_S\|_2 \leq \tau\|\mathbf{Ax}_{\bar{s}} + \mathbf{e}\|_2$ ako je $\mathbf{x}^\sharp \in \mathbb{C}^N$ neko gomilište niza (\mathbf{x}^n) . To gomilište sigurno postoji zbog ograničenosti od $\|\mathbf{x}^n\|$. Dakle, $\|\mathbf{x} - \mathbf{x}^\sharp\| \leq \|\mathbf{x}_{\bar{s}}\|_2 + \|\mathbf{x}_S - \mathbf{x}^\sharp\|_2$ zbog nejednakosti trokuta, pa odabirom S kao skupa indeksa s apsolutno najvećih komponenti vektora \mathbf{x} dobijemo

$$\|\mathbf{x} - \mathbf{x}^\sharp\|_2 \leq \sigma_s(\mathbf{x})_2 + \tau\|\mathbf{Ax}_{\bar{s}} + \mathbf{e}\|_2. \quad (5.27)$$

Naredni teorem daje ocjene aproksimacija.

Teorem 5.3.5. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ takva da $\delta_{3s} < 1/\sqrt{3}$. Tada za svaki $\mathbf{x} \in \mathbb{C}^N$ i $\mathbf{e} \in \mathbb{C}^m$, niz (\mathbf{x}^n) definiran s (IHT) ili s (HTP₁), (HTP₂) s $\mathbf{y} = \mathbf{Ax} + \mathbf{e}$, $\mathbf{x}^0 = \mathbf{0}$ i $2s$ umjesto s , za svaki $n \geq 0$ zadovoljava*

$$\begin{aligned} \|\mathbf{x} - \mathbf{x}^n\|_1 &\leq C\sigma_s(\mathbf{x})_1 + D\sqrt{s}\|\mathbf{e}\|_2 + 2\rho^n\sqrt{s}\|\mathbf{x}\|_2, \\ \|\mathbf{x} - \mathbf{x}^n\|_2 &\leq \frac{C}{\sqrt{s}}\sigma_s(\mathbf{x})_1 + D\|\mathbf{e}\|_2 + 2\rho^n\|\mathbf{x}\|_2, \end{aligned}$$

gdje konstante $C, D > 0$ i $0 < \rho < 1$ ovise samo o δ_{6s} . Posebno, ako je $\mathbf{x}^\sharp \in \mathbb{C}^N$ gomilište niza (\mathbf{x}^n) , onda

$$\begin{aligned} \|\mathbf{x} - \mathbf{x}^\sharp\|_1 &\leq C\sigma_s(\mathbf{x})_1 + D\sqrt{s}\|\mathbf{e}\|_2, \\ \|\mathbf{x} - \mathbf{x}^\sharp\|_2 &\leq \frac{C}{\sqrt{s}}\sigma_s(\mathbf{x})_1 + D\|\mathbf{e}\|_2. \end{aligned}$$

Za dokaz potrebna nam je lema.

Lema 5.3.6. Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ takva da $\delta_s < 1$. Za $\kappa, \tau > 0, \xi \geq 0$ i $\mathbf{e} \in \mathbb{C}^m$, pretpostavimo da vektori $\mathbf{x}, \mathbf{x}' \in \mathbb{C}^N$ zadovoljavaju $\|\mathbf{x}'\|_0 \leq \kappa s$ i

$$\|\mathbf{x}_T - \mathbf{x}'\|_2 \leq \tau \|\mathbf{A}\mathbf{x}_{\bar{T}} + \mathbf{e}\|_2 + \xi$$

gdje je T skup indeksa od $2s$ apsolutno najvećih komponenti od \mathbf{x} . Tada za $1 \leq p \leq 2$ vrijedi

$$\|\mathbf{x} - \mathbf{x}'\|_p \leq \frac{1 + c_\kappa \tau}{s^{1-1/p}} \sigma_s(\mathbf{x})_1 + d_\kappa \tau s^{1/p-1/2} \|\mathbf{e}\|_2 + d_\kappa s^{1/p-1/2} \xi, \quad (5.28)$$

gdje konstante c_κ, d_κ ovise samo o κ .

Dokaz. Iz činjenice da je vektor $\mathbf{x}_T - \mathbf{x}'$ $(2 + \kappa)s$ -rijedak slijedi

$$\begin{aligned} \|\mathbf{x} - \mathbf{x}'\|_p &\leq \|\mathbf{x}_{\bar{T}}\|_p + \|\mathbf{x}_T - \mathbf{x}'\|_p \leq \|\mathbf{x}_{\bar{T}}\|_p + ((2 + \kappa)s)^{1/p-1/2} \|\mathbf{x}_T - \mathbf{x}'\|_2 \\ &\leq \|\mathbf{x}_{\bar{T}}\|_p + \sqrt{2 + \kappa} s^{1/p-1/2} (\tau \|\mathbf{A}\mathbf{x}_{\bar{T}} + \mathbf{e}\|_2 + \xi). \end{aligned} \quad (5.29)$$

Neka je $S \subseteq T$ skup indeksa s najvećih komponenti vektora \mathbf{x} . Prema propoziciji 1.1.4

$$\|\mathbf{x}_{\bar{T}}\|_p = \sigma_s(\mathbf{x}_{\bar{S}})_p \leq \frac{1}{s^{1-1/p}} \|\mathbf{x}_{\bar{S}}\|_1 = \frac{1}{s^{1-1/p}} \sigma_s(\mathbf{x})_1. \quad (5.30)$$

Particionirajmo \bar{T} kao $\bar{T} = S_2 \cup S_3 \cup \dots$, gdje je

S_2 : skup indeksa s apsolutno najvećih komponenti od \mathbf{x} u \bar{T} ,

S_3 : skup indeksa s apsolutno najvećih komponenti od \mathbf{x} u $\overline{\bar{T} \cup S_2}$,

\vdots

Dakle,

$$\begin{aligned} \|\mathbf{A}\mathbf{x}_{\bar{T}} + \mathbf{e}\|_2 &\leq \sum_{k \geq 2} \|\mathbf{A}\mathbf{x}_{S_k}\|_2 + \|\mathbf{e}\|_2 \leq \sum_{k \geq 2} \sqrt{1 + \delta_s} \|\mathbf{x}_{S_k}\|_2 + \|\mathbf{e}\|_2 \\ &\leq \sqrt{2} \sum_{k \geq 2} \|\mathbf{x}_{S_k}\|_2 + \|\mathbf{e}\|_2. \end{aligned}$$

Iz leme 5.2.2 imamo

$$\sum_{k \geq 2} \|\mathbf{x}_{S_k}\|_2 \leq \frac{1}{s^{1/2}} \|\mathbf{x}_{\bar{S}}\|_1 = \frac{1}{s^{1/2}} \sigma_s(\mathbf{x})_1.$$

Stoga,

$$\|\mathbf{A}\mathbf{x}_{\bar{T}} + \mathbf{e}\|_2 \leq \frac{\sqrt{2}}{s^{1/2}}\sigma_s(\mathbf{x})_1 + \|\mathbf{e}\|_2. \quad (5.31)$$

Kombiniranjem (5.29), (5.30) i (5.31) dobivamo (5.28) s $c_\kappa = \sqrt{4 + 2\kappa}$ i $d_\kappa = \sqrt{2 + \kappa}$. \square

Dokaz (Teorem 5.3.5). Za dani $\mathbf{x} \in \mathbb{C}^N$ i $\mathbf{e} \in \mathbb{C}^m$, teorem 5.3.3 implicira da postoje $0 < \rho < 1$ i $\tau > 0$ koji ovise samo o δ_{6s} , takvi da za svaki $n \geq 0$ vrijedi

$$\|\mathbf{x}_T - \mathbf{x}^n\|_2 \leq \tau\|\mathbf{A}\mathbf{x}_{\bar{T}} + \mathbf{e}\|_2 + \rho^n\|\mathbf{x}_T\|_2,$$

gdje je T skup indeksa $2s$ apsolutno najvećih komponenti od \mathbf{x} . Prema lemi 5.3.6 s $\mathbf{x}' = \mathbf{x}^n$ i $\xi = \rho^n\|\mathbf{x}_T\|_2$ imamo da za svaki $1 \leq p \leq 2$ vrijedi,

$$\|\mathbf{x} - \mathbf{x}^n\|_p \leq \frac{C}{s^{1-1/p}}\sigma_s(\mathbf{x})_1 + Ds^{1/p-1/2}\|\mathbf{e}\|_2 + 2\rho^n s^{1/p-1/2}\|\mathbf{x}\|_2,$$

gdje $C, D > 0$ ovise samo o τ , pa stoga samo o δ_{6s} . Tražene ocjene su poseban slučaj za $p = 1$ i $p = 2$. \square

5.4 Analiza greedy algoritama

U ovom dijelu rada pokazat ćemo uz koje uvjete OMP i CoSaMP algoritmi uspješno rekonstruiraju rijetke vektore. No, kod ove klase algoritama nisu dovoljni uvjeti restriktivne izometričnosti. Uzmimo na primjer $1 < \eta < \sqrt{s}$ i definiramo $(s + 1) \times (s + 1)$ matricu

$$\mathbf{A} := \left[\begin{array}{c|c} \mathbf{I} & \begin{array}{c} \frac{\eta}{s} \\ \vdots \\ \frac{\eta}{s} \end{array} \\ \hline 0 \dots 0 & \sqrt{\frac{s-\eta^2}{s}} \end{array} \right] \quad (5.32)$$

Lako slijedi

$$\mathbf{A}^* \mathbf{A} - \mathbf{I} = \left[\begin{array}{c|c} \mathbf{0} & \begin{array}{c} \frac{\eta}{s} \\ \vdots \\ \frac{\eta}{s} \end{array} \\ \hline \frac{\eta}{s} \dots \frac{\eta}{s} & 0 \end{array} \right]$$

Što pokazuje da su svojstvene vrijednosti te matrice $-\eta/\sqrt{s}$, η/\sqrt{s} i 0 kratnosti $s-1$. Stoga

$$\delta_{s+1} = \|\mathbf{A}^* \mathbf{A} - \mathbf{I}\|_2 = \frac{\eta}{\sqrt{s}}.$$

Međutim, s -rijedak vektor $\mathbf{x} = [1, \dots, 1, 0]^T$ se ne može rekonstruirati iz $\mathbf{y} = \mathbf{A}\mathbf{x}$ u s iteracija, pošto se u prvoj iteraciji odabere krivi indeks $s+1$. Taj problem možemo zaobići većim brojem iteracija ili modifikacijom algoritma tako da odbacuje krive indekse, što zapravo CoSaMP radi.

OMP algoritam

Zapravo, proučavat ćemo malo generalniji algoritam koji započinje skupom S^0 i za koji je

$$\mathbf{x}^0 := \arg \min\{\|\mathbf{y} - \mathbf{A}\mathbf{z}\|, \text{supp}(\mathbf{z}) \subseteq S^0\}, \quad (5.33)$$

a čije iteracije su oblika,

$$S^{n+1} = S^n \cup L_1(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n)), \quad (OMP'_1)$$

$$\mathbf{x}^{n+1} = \arg \min\{\|\mathbf{y} - \mathbf{A}\mathbf{z}\|, \text{supp}(\mathbf{z}) \subseteq S^{n+1}\}. \quad (OMP'_2)$$

Standarni OMP algoritam odgovara odabiru $S^0 = \emptyset$ i $\mathbf{x}^0 = \mathbf{0}$. Sljedeća propozicija ključan je alat za analizu OMP algoritma, dokaz ćemo dati kasnije.

Propozicija 5.4.1. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$, i neka je $\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{e}$ za neki s -rijedak $\mathbf{x} \in \mathbb{C}^N$ takav da $S = \text{supp}(\mathbf{x})$ te $\mathbf{e} \in \mathbb{C}^m$. Nadalje, neka je (\mathbf{x}^n) niz definiran s (OMP'_1), (OMP'_2). Sa s^0 označimo kardinalitet skupa S^0 i neka je $s' = \text{card}(S \setminus S^0)$. Ako je $\delta_{s+s^0+12s'} < \frac{1}{6}$, tada postoji konstanta $C > 0$ koja ovisi samo o $\delta_{s+s^0+12s'}$ takva da*

$$\|\mathbf{y} - \mathbf{A}\mathbf{x}^{\bar{n}}\|_2 \leq C\|\mathbf{e}\|_2, \quad \bar{n} = 12s'.$$

Primijetimo da za $\mathbf{e} = \mathbf{0}$ i $S^0 = \emptyset$, prethodna propozicija implicira egzaktnu rekonstrukciju putem (OMP'_1) i (OMP'_2) u $12s$ iteracija.

Teorem 5.4.2. *Pretpostavimo da je $\mathbf{A} \in \mathbb{C}^{m \times N}$ takva da je*

$$\delta_{13s} < \frac{1}{6}.$$

Tada postoji konstanta $C > 0$ koja ovisi samo o δ_{13s} takva da za sve $\mathbf{x} \in \mathbb{C}^N$ i $\mathbf{e} \in \mathbb{C}^m$, niz (\mathbf{x}^n) definiran s (OMP'_1) , (OMP'_2) za $\mathbf{y} = \mathbf{Ax}$ zadovoljava

$$\|\mathbf{y} - \mathbf{Ax}^{12s}\|_2 \leq C\|\mathbf{Ax}_{\bar{S}} + \mathbf{e}\|_2$$

za svaki $S \subseteq [N]$, $\text{card}(S) = s$. Nadalje, ako je $\delta_{26s} < 1/6$, tada postoje konstante $C, D > 0$ koje ovise samo o δ_{26s} takve da za svaki $\mathbf{x} \in \mathbb{C}^N$ i $\mathbf{e} \in \mathbb{C}^m$, niz (\mathbf{x}^n) zadovoljava

$$\|\mathbf{x} - \mathbf{x}^{24s}\|_p \leq \frac{C}{s^{1-1/p}} \sigma_s(\mathbf{x})_1 + Ds^{1/p-1/2} \|\mathbf{e}\|_2$$

za $1 \leq p \leq 2$.

Dokaz. Uzmimo $S \subseteq [N]$ takav da $\text{card}(S) = s$. Vektor \mathbf{y} možemo zapisati kao $\mathbf{y} = \mathbf{Ax}_S + \mathbf{e}'$ gdje je $\mathbf{e}' := \mathbf{Ax}_{\bar{S}} + \mathbf{e}$. Primjenimo propoziciju 5.4.1 za $S^0 = \emptyset$,

$$\|\mathbf{y} - \mathbf{Ax}^{12s}\|_2 \leq C\|\mathbf{e}'\|_2 = C\|\mathbf{Ax}_{\bar{S}} + \mathbf{e}\|_2$$

za neku konstantu $C > 0$ koja ovisi samo o $\delta_{12s} < 1/6$. Iz

$$\begin{aligned} \|\mathbf{y} - \mathbf{Ax}^{24s}\|_2 &= \|\mathbf{A}(\mathbf{x}_T - \mathbf{x}^{24s}) + \mathbf{Ax}_{\bar{T}} + \mathbf{e}\|_2 \\ &\geq \|\mathbf{A}(\mathbf{x}_T - \mathbf{x}^{24s})\|_2 - \|\mathbf{Ax}_{\bar{T}} + \mathbf{e}\|_2 \\ &\geq \sqrt{1 - \delta_{2s}} \|\mathbf{x}^{24s} - \mathbf{x}_T\|_2 - \|\mathbf{Ax}_{\bar{T}} + \mathbf{e}\|_2, \end{aligned}$$

slijedi

$$\|\mathbf{x}^{24s} - \mathbf{x}_T\|_2 \leq \frac{C' + 1}{\sqrt{1 - \delta_{26s}}} \|\mathbf{Ax}_{\bar{T}} + \mathbf{e}\|_2.$$

Lema 5.3.6 s $\xi = 0$ daje tvrdnju. □

Za dokaz propozicije 5.4.1 trebat će nam sljedeća lema.

Lema 5.4.3. *Neka je (\mathbf{x}^n) niz definiran s (OMP'_1) , (OMP'_2) uz $\mathbf{y} = \mathbf{Ax} + \mathbf{e}$ za neki s -rijedak vektor $\mathbf{x} \in \mathbb{C}^N$ i za neki $\mathbf{e} \in \mathbb{C}^m$. Tada, za $n \geq 0$, $T \subseteq [N]$ koji nije sadržan u S^n i $\mathbf{z} \in \mathbb{C}^N$ s nosačem na T ,*

$$\begin{aligned} &\|\mathbf{y} - \mathbf{Ax}^{n+1}\|_2^2 \\ &\leq \|\mathbf{y} - \mathbf{Ax}^n\|_2^2 - \frac{\|\mathbf{A}(\mathbf{z} - \mathbf{x}^n)\|_2^2}{\|\mathbf{z}_{T \setminus S^n}\|_1^2} \max\{0, \|\mathbf{y} - \mathbf{Ax}^n\|_2^2 - \|\mathbf{y} - \mathbf{Az}\|_2^2\} \\ &\leq \|\mathbf{y} - \mathbf{Ax}^n\|_2^2 - \frac{1 - \delta}{\text{card}(T \setminus S^n)} \max\{0, \|\mathbf{y} - \mathbf{Ax}^n\|_2^2 - \|\mathbf{y} - \mathbf{Az}\|_2^2\}, \end{aligned}$$

gdje je $\delta := \delta_{\text{card}(T \cup S^n)}$.

Dokaz. Druga nejednost slijedi iz prve koristeći

$$\begin{aligned} \|\mathbf{A}(\mathbf{x}^n - \mathbf{z})\|_2^2 &\geq (1 - \delta)\|\mathbf{x}^n - \mathbf{z}\|_2^2 \geq (1 - \delta)\|(\mathbf{x}^n - \mathbf{x})_{T \setminus S^n}\|_2^2, \\ \|\mathbf{z}_{T \setminus S^n}\|_1^2 &\leq \text{card}(T \setminus S^n)\|\mathbf{z}_{T \setminus S^n}\|_2^2 = \text{card}(T \setminus S^n)\|(\mathbf{x}^n - \mathbf{z})_{T \setminus S^n}\|_2^2. \end{aligned}$$

Iz leme 2.2.1 vidimo da se ℓ_2 -norma reziduala smanjuje za barem $|(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{j^{n+1}}|^2$, gdje smo j^{n+1} izabrali kao indeks najveće komponente vektora $\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n)$. Stoga prva nejednakost slijedi iz

$$|(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{j^{n+1}}|^2 \geq \frac{\|\mathbf{A}(\mathbf{z} - \mathbf{x}^n)\|_2^2}{\|\mathbf{z}_{T \setminus S^n}\|_1^2} (\|\mathbf{y} - \mathbf{A}\mathbf{x}^n\|_2^2 - \|\mathbf{y} - \mathbf{A}\mathbf{z}\|_2^2) \quad (5.34)$$

za $\|\mathbf{y} - \mathbf{A}\mathbf{x}^n\|_2^2 \geq \|\mathbf{y} - \mathbf{A}\mathbf{z}\|_2^2$. Iz leme 2.2.2 imamo da je $(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S^n} = \mathbf{0}$, stoga

$$\begin{aligned} &\text{Re}\langle \mathbf{A}(\mathbf{z} - \mathbf{x}^n), \mathbf{y} - \mathbf{A}\mathbf{x}^n \rangle \\ &= \text{Re}\langle \mathbf{z} - \mathbf{x}^n, \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n) \rangle = \text{Re}\langle \mathbf{z} - \mathbf{x}^n, (\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S^n} \rangle \\ &= \text{Re}\langle (\mathbf{z} - \mathbf{x}^n)_{T \setminus S^n}, (\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{T \setminus S^n} \rangle \\ &\leq \|(\mathbf{z} - \mathbf{x}^n)_{T \setminus S^n}\|_1 \|\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n)\|_{\text{inf ty}} \\ &= \|\mathbf{z}_{T \setminus S^n}\|_1 |(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{j^{n+1}}|. \end{aligned} \quad (5.35)$$

Nadalje,

$$\begin{aligned} &2\text{Re}\langle \mathbf{A}(\mathbf{z} - \mathbf{x}^n), \mathbf{y} - \mathbf{A}\mathbf{x}^n \rangle \\ &= \|\mathbf{A}(\mathbf{z} - \mathbf{x}^n)\|_2^2 + \|\mathbf{y} - \mathbf{A}\mathbf{x}^n\|_2^2 - \|\mathbf{A}(\mathbf{z} - \mathbf{x}^n) - (\mathbf{y} - \mathbf{A}\mathbf{x}^n)\|_2^2 \\ &= \|\mathbf{A}(\mathbf{z} - \mathbf{x}^n)\|_2^2 + (\|\mathbf{y} - \mathbf{A}\mathbf{x}^n\|_2^2 - \|\mathbf{y} - \mathbf{A}\mathbf{z}\|_2^2) \\ &\geq \|\mathbf{A}(\mathbf{z} - \mathbf{x}^n)\|_2 \sqrt{\|\mathbf{y} - \mathbf{A}\mathbf{x}^n\|_2^2 - \|\mathbf{y} - \mathbf{A}\mathbf{z}\|_2^2}, \end{aligned} \quad (5.36)$$

gdje zadnja nejednakost slijedi iz aritmetičko geometrijske nejednakosti. Kvadriramo (5.35), (5.36) te kombiniranjem dobivamo

$$\|\mathbf{A}(\mathbf{z} - \mathbf{x}^n)\|_2^2 (\|\mathbf{y} - \mathbf{A}\mathbf{x}^n\|_2^2 - \|\mathbf{y} - \mathbf{A}\mathbf{z}\|_2^2) \leq \|\mathbf{z}_{T \setminus S^n}\|_1^2 |(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{j^{n+1}}|^2.$$

□

Dokaz (Propozicija 5.4.1). Tvrdnju dokazujemo indukcijom po $\text{card}(S \setminus S^0)$. Ako je

taj broj nula, tj. $S \subseteq S^0$ onda prema definicija od \mathbf{x}^0 imamo

$$\|\mathbf{y} - \mathbf{A}\mathbf{x}^0\|_2 \leq \|\mathbf{y} - \mathbf{A}\mathbf{x}\|_2 = \|\mathbf{e}\|_2,$$

pa tvrdnja vrijedi za $C = 1$. Pretpostavimo da tvrdnja vrijedi za sve S i S^0 takve da je $\text{card}(S \setminus S^0) \leq s' - 1$, $s' \geq 1$. Želimo pokazati da tvrdnja vrijedi za $s' = \text{card}(S \setminus S^0)$. Neka je $T^0 = \emptyset$ i

$$T^l = \{\text{indeksi } 2^{l-1} \text{ apsolutno najvećih komponenti vektora } \mathbf{x}_{\overline{S^0}}\}.$$

Primijetimo da su ti skupovi podskupovi od $S \setminus S^0$. Nadalje, definirajmo

$$\tilde{\mathbf{x}}^l := \mathbf{x}_{\overline{S^0 \cup T^l}}, \quad l \geq 0.$$

Primijetimo da posljednji T^l , tj. $T^{\lceil \log_2(s') \rceil + 1}$ jednak cjelom skupu $S \setminus S^0$, pa stoga $\tilde{\mathbf{x}}^l = \mathbf{0}$. Neka je $\mu > 0$ konstanta, koju ćemo kasnije odabrati. Pošto je $\|\tilde{\mathbf{x}}^{l-1}\|_2^2 \geq \mu \|\tilde{\mathbf{x}}^l\|_2^2 = 0$ za zadnji indeks, možemo izabrati $1 \leq L \leq \lceil \log_2(s') \rceil + 1$ takav da

$$\|\tilde{\mathbf{x}}^{L-1}\|_2^2 \geq \mu \|\tilde{\mathbf{x}}^L\|_2^2.$$

To implicira (moguće prazan) niz nejednakosti

$$\|\tilde{\mathbf{x}}^0\|_2^2 < \mu \|\tilde{\mathbf{x}}^1\|_2^2, \dots, \|\tilde{\mathbf{x}}^{L-2}\|_2^2 < \mu \|\tilde{\mathbf{x}}^{L-1}\|_2^2.$$

Za svaki $l \in [L]$, primijenimo lemu 5.4.3 na vektor $\mathbf{z} = \mathbf{x} - \tilde{\mathbf{x}}^l$, koji ima nosač $S^0 \cup T^l$. Uzimajući u obzir da $(S^0 \cup T^l) \cup S^n \subseteq S \cup S^n$ i da $(S^0 \cup T^l) \setminus S^n \subseteq (S^0 \cup T^l) \setminus S^0 = T^l$, te oduzimajući $\|\mathbf{y} - \mathbf{A}\mathbf{z}\|_2^2 = \|\mathbf{A}\tilde{\mathbf{x}}^l + \mathbf{e}\|_2^2$ dobivamo

$$\begin{aligned} & \max\{0, \|\mathbf{y} - \mathbf{A}\mathbf{x}^{n+1}\|_2^2 - \|\mathbf{A}\tilde{\mathbf{x}}^l + \mathbf{e}\|_2^2\} \\ & \leq \left(1 - \frac{1 - \delta_{s+n}}{\text{card}(T^l)}\right) \max\{0, \|\mathbf{y} - \mathbf{A}\mathbf{x}^n\|_2^2 - \|\mathbf{A}\tilde{\mathbf{x}}^l + \mathbf{e}\|_2^2\} \\ & \leq \exp\left(-\frac{1 - \delta_{s+n}}{\text{card}(T^l)}\right) \max\{0, \|\mathbf{y} - \mathbf{A}\mathbf{x}^n\|_2^2 - \|\mathbf{A}\tilde{\mathbf{x}}^l + \mathbf{e}\|_2^2\}. \end{aligned}$$

Za svaki $K \geq 0$ i za $n, k \geq 0$ takve da je $n + k \leq K$, imamo

$$\begin{aligned} & \max\{0, \|\mathbf{y} - \mathbf{A}\mathbf{x}^{n+k}\|_2^2 - \|\mathbf{A}\tilde{\mathbf{x}}^l + \mathbf{e}\|_2^2\} \\ & \leq \exp\left(-\frac{k(1 - \delta_{s+K})}{\text{card}(T^l)}\right) \max\{0, \|\mathbf{y} - \mathbf{A}\mathbf{x}^n\|_2^2 - \|\mathbf{A}\tilde{\mathbf{x}}^l + \mathbf{e}\|_2^2\}. \end{aligned}$$

Separirajući slučajeve u maksimumu na desnoj strani lako vidimo

$$\|\mathbf{y} - \mathbf{Ax}^{n+k}\|_2^2 \leq \exp\left(-\frac{k(1-\delta_{s+K})}{\text{card}(T^l)}\right) \|\mathbf{y} - \mathbf{Ax}^n\|_2^2 + \|\mathbf{Ax}^l + \mathbf{e}\|_2^2.$$

Za $\kappa \geq 0$, koji ćemo kasnije odabrati, uzastopnom primjenom prethodne nejednakosti za

$$\kappa_1 := \kappa \text{card}(T^1), \dots, \kappa_L := \kappa \text{card}(T^L), K := k_1 + \dots + k_L, \nu := \exp(\kappa(1-\delta_{s+K}))$$

slijedi

$$\begin{aligned} \|\mathbf{y} - \mathbf{Ax}^{k_1}\|_2^2 &\leq \frac{1}{\nu} \|\mathbf{y} - \mathbf{Ax}^0\|_2^2 + \|\mathbf{Ax}^1 + \mathbf{e}\|_2^2, \\ \|\mathbf{y} - \mathbf{Ax}^{k_1+k_2}\|_2^2 &\leq \frac{1}{\nu} \|\mathbf{y} - \mathbf{Ax}^{k_1}\|_2^2 + \|\mathbf{Ax}^2 + \mathbf{e}\|_2^2, \\ &\vdots \\ \|\mathbf{y} - \mathbf{Ax}^{k_1+\dots+k_L}\|_2^2 &\leq \frac{1}{\nu} \|\mathbf{y} - \mathbf{Ax}^{k_1+\dots+k_{L-1}}\|_2^2 + \|\mathbf{Ax}^L + \mathbf{e}\|_2^2. \end{aligned}$$

Kombiniranjem tih nejednakosti dobivamo

$$\|\mathbf{y} - \mathbf{Ax}^K\|_2^2 \leq \frac{\|\mathbf{y} - \mathbf{Ax}^0\|_2^2}{\nu^L} + \frac{\|\mathbf{Ax}^1 + \mathbf{e}\|_2^2}{\nu^{L-1}} + \dots + \frac{\|\mathbf{Ax}^{L-1} + \mathbf{e}\|_2^2}{\nu} + \|\mathbf{Ax}^L + \mathbf{e}\|_2^2.$$

Uvažimo da $\mathbf{x} - \tilde{\mathbf{x}}^0$ ima nosač u $S^0 \cup T^0 = S^0$, definicija (5.33) implicira da je $\|\mathbf{y} - \mathbf{Ax}^0\|_2^2 \leq \|\mathbf{y} - \mathbf{A}(\mathbf{x} - \tilde{\mathbf{x}}^0)\|_2^2 = \|\mathbf{Ax}^0 + \mathbf{e}\|_2^2$. Stoga,

$$\|\mathbf{y} - \mathbf{Ax}^K\|_2^2 \leq \sum_{l=0}^L \frac{\|\mathbf{Ax}^l + \mathbf{e}\|_2^2}{\nu^{L-l}} \leq \sum_{l=0}^L \frac{2(\|\mathbf{Ax}^l\|_2^2 - \|\mathbf{e}\|_2^2)}{\nu^{L-l}}$$

Primijetimo da za $l \leq L-1$ i za $l = L$ vrijedi

$$\|\mathbf{Ax}^l\|_2^2 \leq (1 + \delta_s) \|\tilde{\mathbf{x}}^l\|_2^2 \leq (1 + \delta_s) \mu^{L-1-l} \|\tilde{\mathbf{x}}^{L-1}\|_2^2.$$

Zbog toga, imamo

$$\begin{aligned} \|\mathbf{y} - \mathbf{Ax}^K\|_2^2 &\leq \frac{2(1 + \delta_s) \|\tilde{\mathbf{x}}^{L-1}\|_2^2}{\mu} \sum_{l=0}^L \left(\frac{\mu}{\nu}\right)^{L-l} + 2\|\mathbf{e}\|_2^2 \sum_{l=0}^L \frac{1}{\nu^{L-l}} \\ &\leq \frac{2(1 + \delta_s) \|\tilde{\mathbf{x}}^{L-1}\|_2^2}{\mu(1 - \mu/\nu)} + \frac{2\|\mathbf{e}\|_2^2}{1 - \nu}. \end{aligned}$$

Uzmimo $\mu/\nu/2$ tako da $\mu(1 - \mu/\nu)$ poprima maksimum $\nu/4$. Za $\alpha := \sqrt{8(1 + \delta_s)/\nu}$ i $\beta := \sqrt{2/(1 - \nu)}$,

$$\|\mathbf{y} - \mathbf{A}\mathbf{x}^K\|_2 \leq \alpha\|\tilde{\mathbf{x}}^{L-1}\|_2 + \beta\|\mathbf{e}\|_2. \quad (5.37)$$

Nadalje, za $\gamma := \sqrt{1 - \delta_{s+s^0+K}}$ imamo

$$\begin{aligned} \|\mathbf{y} - \mathbf{A}\mathbf{x}^K\|_2 &= \|\mathbf{A}(\mathbf{x} - \mathbf{x}^K) + \mathbf{e}\|_2 \geq \|\mathbf{A}(\mathbf{x} - \mathbf{x}^K)\|_2 - \|\mathbf{e}\|_2 \\ &\geq \gamma\|\mathbf{x} - \mathbf{x}^K\|_2 - \|\mathbf{e}\|_2 \geq \gamma\|\mathbf{x}_{\overline{S^K}}\|_2 - \|\mathbf{e}\|_2. \end{aligned}$$

Zaključujemo

$$\|\mathbf{x}_{\overline{S^K}}\|_2 \leq \frac{\alpha}{\gamma}\|\tilde{\mathbf{x}}^{L-1}\|_2 + \frac{\beta + 1}{\gamma}\|\mathbf{e}\|_2. \quad (5.38)$$

Odaberimo sada $\kappa = 3$ tako da vrijedi

$$\frac{\alpha}{\gamma} = \sqrt{\frac{8(1 + \delta_s)}{(1 - \delta_{s+s^0+K}) \exp(\kappa(1 - \delta_{s+K}))}} \leq 0.92 < 1,$$

pošto $\delta_s \leq \delta_{s+K} \leq \delta_{s+s^0+K} \leq \delta_{s+s^0+12s'} < 1/6$. Tu smo iskoristili činjenicu da je $L \leq \lceil \log_2(s') \rceil + 1$ da bi dobili

$$K = \kappa(1 + \dots + 2^{L-2} + \text{card}(T^L)) < \kappa(2^{L-1} + s') \leq 3\kappa s' = 9s'.$$

Stoga u slučaju da $((\beta + 1)/\gamma)\|\mathbf{e}\|_2 < (1 - \alpha/\gamma)\|\tilde{\mathbf{x}}^{L-1}\|_2$, iz (5.38) slijedi

$$\|\mathbf{x}_{\overline{S^K}}\|_2 < \|\tilde{\mathbf{x}}^{L-1}\|_2 \quad \text{tj.} \quad \|(\mathbf{x}_{\overline{S^0}})_{S \setminus S^K}\|_2 < \|(\mathbf{x}_{\overline{S^0}})_{(S \setminus S^0)^{L-1}}\|_2.$$

Pošto T^{L-1} sadrži indekse 2^{L-2} apsolutno najvećih komponenti od $\mathbf{x}_{\overline{S^0}}$, imamo

$$\text{card}(S \setminus S^K) < \text{card}((S \setminus S^0) \setminus T^{L-1}) = s' - 2^{L-2}.$$

Primijetimo da izvršavanje algoritma nakon K iteracija odgovara započinjanju algoritma gdje S^0 zamjenimo sa S^K . Imamo da je $K \leq \kappa(1 + \dots + 2^{L-2} + 2^{L-1}) < 3 \cdot 2^L$, pa vrijedi

$$s + \text{card}(S^K) + 12\text{card}(S \setminus S^K) \leq s + s^0 + K + 12(s' - 2^{L-2}) \leq s + s^0 + 12s'$$

a od tuda slijedi $\text{card}(S \setminus S^K) < s'$. Sada primjenimo pretpostavku indukcije

$$\|\mathbf{y} - \mathbf{A}\mathbf{x}^{K+n}\|_2 \leq C\|\mathbf{e}\|_2, \quad \text{za } n = 12 \text{ card}(S \setminus S^K).$$

Dakle, broj potrebnih iteracija zadovoljava $K + n \leq 12s'$.

U slučaju da je $((\beta + 1)/\gamma)\|\mathbf{e}\|_2 \geq (1 - \alpha/\gamma)\|\tilde{\mathbf{x}}^{L-1}\|_2$, (5.37) daje

$$\|\mathbf{y} - \mathbf{A}\mathbf{x}^K\|_2 \leq \frac{\alpha(\beta + 1)}{\gamma - \alpha}\|\mathbf{e}\|_2 + \beta\|\mathbf{e}\|_2 =: C\|\mathbf{e}\|_2,$$

gdje konstanta $C \geq 1$ ovisi samo o $\delta_{s+s^0+12s'}$. Pokazali smo da tvrdnja vrijedi za $s' = \text{card}(S \setminus S^0)$. \square

CoSaMP algoritam

Prisjetimo se, CoSaMP započinje s -rijetkim vektorom $\mathbf{x}^0 \in \mathbb{C}^N$ (uglavnom $\mathbf{x}^0 = \mathbf{0}$) i generira niz (\mathbf{x}^n) induktivno definiran sa

$$U^{n+1} = \text{supp}(\mathbf{x}^n) \cup L_{2s}(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n)), \quad (\text{CoSaMP}_1)$$

$$\mathbf{u}^{n+1} = \arg \min\{\|\mathbf{y} - \mathbf{A}\mathbf{z}\|_2, \text{supp}(\mathbf{z}) \subseteq U^{n+1}\}, \quad (\text{CoSaMP}_2)$$

$$\mathbf{x}^{n+1} = H_s(\mathbf{u}^{n+1}). \quad (\text{CoSaMP}_3)$$

Teorem 5.4.4. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ takva da*

$$\delta_{4s} < \frac{\sqrt{\sqrt{11/3} - 1}}{2} \approx 0.4782. \quad (5.39)$$

Tada, za $\mathbf{x} \in \mathbb{C}^N$, $\mathbf{e} \in \mathbb{C}^m$ i $S \subseteq [N]$, $\text{card}(S) = s$, niz (\mathbf{x}^n) definiran s (CoSaMP_1) , (CoSaMP_2) , (CoSaMP_3) za $\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{e}$ zadovoljava

$$\|\mathbf{x}^n - \mathbf{x}_S\|_2 \leq \rho^n \|\mathbf{x}^0 - \mathbf{x}_S\|_2 + \tau \|\mathbf{A}\mathbf{x}_{\bar{S}} + \mathbf{e}\|_2, \quad (5.40)$$

gdje $0 < \rho < 1$ i $\tau > 0$ ovisi samo o δ_{4s} .

Primijetimo da (5.40) implicira ograničenost niza (\mathbf{x}^n) pa stoga imamo egzistenciju gomilišta.

Teorem 5.4.5. *Neka je $\mathbf{A} \in \mathbb{C}^{m \times N}$ takva da*

$$\delta_{8s} < 0.4782.$$

Tada za $\mathbf{x} \in \mathbb{C}^N$ i $\mathbf{e} \in \mathbb{C}^m$, niz (\mathbf{x}^n) definiran s (CoSaMP_1) , (CoSaMP_2) , (CoSaMP_3)

za $\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{e}$, $\mathbf{x}^0 = \mathbf{0}$ i 2s umjesto s, vrijedi

$$\begin{aligned}\|\mathbf{x} - \mathbf{x}^n\|_1 &\leq C\sigma_s(\mathbf{x})_1 + D\sqrt{s}\|\mathbf{e}\|_2 + 2\rho^n\sqrt{s}\|\mathbf{x}\|_2, \\ \|\mathbf{x} - \mathbf{x}^n\|_2 &\leq \frac{C}{\sqrt{s}}\sigma_s(\mathbf{x})_2 + D\|\mathbf{e}\|_2 + 2\rho^n\|\mathbf{x}\|_2,\end{aligned}$$

za svaki $n \leq 0$, gdje konstante $C, D > 0$ i $0 < \rho < 1$ ovisе samo o δ_{8s} . Posebno, ako je $\mathbf{x}^\sharp \in \mathbb{C}^N$ gomilište niza (\mathbf{x}^n) , onda

$$\begin{aligned}\|\mathbf{x} - \mathbf{x}^\sharp\|_1 &\leq C\sigma_s(\mathbf{x})_1 + D\sqrt{s}\|\mathbf{e}\|_2, \\ \|\mathbf{x} - \mathbf{x}^\sharp\|_2 &\leq \frac{C}{\sqrt{s}}\sigma_s(\mathbf{x})_1 + D\|\mathbf{e}\|_2.\end{aligned}$$

Teorem 5.4.5 slijedi iz teorema 5.4.4 koristeći lemu 5.3.6 na isti način kao što teorem 5.3.5 slijedi iz teorema 5.3.3. Stoga ćemo pokazati samo teorem 5.4.4.

Dokaz (Teorem 5.4.4). Kao u dokazu teorema (5.3.3) za $n \geq 0$ želimo pokazati

$$\|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2 \leq \rho\|\mathbf{x}^n - \mathbf{x}_S\|_2 + (1 - \rho)\tau\|\mathbf{A}\mathbf{x}_{\bar{s}} + \mathbf{e}\|_2 \quad (5.41)$$

za $0 < \rho < 1$ i $\tau > 0$ koje ćemo kasnije odrediti. Tvrdnja (5.40) tada slijedi induktivnim argumentom. Da bi pokazali nejednakost (5.41) proučit ćemo svaki korak CoSaMP algoritma. Zbog jednostavnosti zanemarit ćemo član s $\mathbf{A}\mathbf{x}_{\bar{s}} + \mathbf{e}$. (*CoSaMP*₁) daje ocjenu za $\|(\mathbf{x}_S - \mathbf{u}^{n+1})_{\overline{U^{n+1}}}\|_2$ u terminima $\|\mathbf{x}^n - \mathbf{x}_S\|_2$, (*CoSaMP*₂) daje ocjenu za $\|(\mathbf{x}_S - \mathbf{u}^{n+1})_{U^{n+1}}\|_2$ u terminima $\|(\mathbf{x}_S - \mathbf{u}^{n+1})_{\overline{U^{n+1}}}\|_2$ i (*CoSaMP*₃) daje ocjenu za $\|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2$ u terminima $\|(\mathbf{x}_S - \mathbf{u}^{n+1})_{U^{n+1}}\|_2$ i $\|(\mathbf{x}_S - \mathbf{u}^{n+1})_{\overline{U^{n+1}}}\|_2$. Kombiniranjem dobivenih ocjena, izvest ćemo ocjenu za $\|\mathbf{x}^{n+1} - \mathbf{x}_S\|_2$ u terminima $\|\mathbf{x}^n - \mathbf{x}_S\|_2$.

Započnimo s (*CoSaMP*₃). Primijetimo da je \mathbf{x}^{n+1} bolja (ili barem jednako dobra) aproksimacija vektora \mathbf{u}^{n+1} od $\mathbf{x}_{S \cap U^{n+1}}$. Označimo $S^{n+1} = \text{supp}(\mathbf{x}^{n+1})$, $S^{n+1} \subseteq U^{n+1}$. Vrijedi,

$$\begin{aligned}\|(\mathbf{x}_S - \mathbf{x}^{n+1})_{U^{n+1}}\|_2 &= \|\mathbf{x}_{S \cap U^{n+1}} - \mathbf{x}^{n+1}\|_2 \\ &\leq \|\mathbf{u}^{n+1} - \mathbf{x}^{n+1}\|_2 + \|\mathbf{u}^{n+1} - \mathbf{x}_{S \cap U^{n+1}}\|_2 \\ &\leq 2\|\mathbf{u}^{n+1} - \mathbf{x}_{S \cap U^{n+1}}\|_2 = 2\|(\mathbf{x}_S - \mathbf{u}^{n+1})_{U^{n+1}}\|_2.\end{aligned}$$

Nadalje, iz $(\mathbf{x}^{n+1})_{\overline{U^{n+1}}} = \mathbf{0}$ i $(\mathbf{u}^{n+1})_{\overline{U^{n+1}}} = \mathbf{0}$ slijedi

$$\begin{aligned}\|\mathbf{x}_S - \mathbf{x}^{n+1}\|_2^2 &= \|(\mathbf{x}_S - \mathbf{x}^{n+1})_{\overline{U^{n+1}}}\|_2^2 + \|(\mathbf{x}_S - \mathbf{x}^{n+1})_{U^{n+1}}\|_2^2 \\ &\leq \|(\mathbf{x}_S - \mathbf{u}^{n+1})_{\overline{U^{n+1}}}\|_2^2 + 4\|(\mathbf{x}_S - \mathbf{u}^{n+1})_{U^{n+1}}\|_2^2.\end{aligned} \quad (5.42)$$

Iz (*CoSaMP*₂) imamo da je vektor $\mathbf{A}\mathbf{u}^{n+1}$ karakteriziran s

$$\langle \mathbf{y} - \mathbf{A}\mathbf{u}^{n+1}, \mathbf{A}\mathbf{z} \rangle = 0 \quad \text{za } \text{supp}(\mathbf{z}) \subseteq U^{n+1}.$$

To je ekvivalentno s $\langle \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{u}^{n+1}), \mathbf{z} \rangle = 0$, tj. $(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{u}^{n+1}))_{U^{n+1}} = \mathbf{0}$, za $\text{supp}(\mathbf{z}) \subseteq U^{n+1}$. Pošto je $\mathbf{y} = \mathbf{A}\mathbf{x}_S + \mathbf{e}'$ gdje je $\mathbf{e}' := \mathbf{A}\mathbf{x}_{\bar{S}} + \mathbf{e}$, imamo

$$(\mathbf{A}^* \mathbf{A}(\mathbf{x}_S - \mathbf{u}^{n+1}))_{U^{n+1}} = -(\mathbf{A}^* \mathbf{e}')_{U^{n+1}}.$$

Slijedi,

$$\begin{aligned} \|(\mathbf{x}_S - \mathbf{u}^{n+1})_{U^{n+1}}\|_2 &\leq \|((\mathbf{I} - \mathbf{A}^* \mathbf{A})(\mathbf{x}_S - \mathbf{u}^{n+1}))_{U^{n+1}}\|_2 + \|(\mathbf{A}^* \mathbf{e}')_{U^{n+1}}\|_2 \\ &\leq \delta_{4s} \|\mathbf{x}_S - \mathbf{u}^{n+1}\|_2 + \|(\mathbf{A}^* \mathbf{e}')_{U^{n+1}}\|_2, \end{aligned}$$

gdje je zadnja nejednakost posljedica leme 5.3.2.

Možemo pretpostaviti da je $\|(\mathbf{x}_S - \mathbf{u}^{n+1})_{U^{n+1}}\|_2 > \|(\mathbf{A}^* \mathbf{e}')_{U^{n+1}}\|_2 / (1 - \delta_{4s})$ jer u suprotnom (5.43) iz nastavka slijedi direktno. Dakle, iz $\|(\mathbf{x}_S - \mathbf{u}^{n+1})_{U^{n+1}}\|_2 > \|(\mathbf{A}^* \mathbf{e}')_{U^{n+1}}\|_2$ slijedi

$$\begin{aligned} [\|(\mathbf{x}_S - \mathbf{u}^{n+1})_{U^{n+1}}\|_2 - \|(\mathbf{A}^* \mathbf{e}')_{U^{n+1}}\|_2] \\ \leq \delta_{4s}^2 \|(\mathbf{x}_S - \mathbf{u}^{n+1})_{U^{n+1}}\|_2^2 + \delta_{4s}^2 \|(\mathbf{x}_S - \mathbf{u}^{n+1})_{\bar{U}^{n+1}}\|_2^2. \end{aligned}$$

Iskoristimo $a^2 - b^2 = (a + b)(a - b)$

$$\begin{aligned} \delta_{4s}^2 \|(\mathbf{x}_S - \mathbf{u}^{n+1})_{\bar{U}^{n+1}}\|_2^2 &\geq (1 - \delta_{4s}^2) \\ &\cdot \left(\|(\mathbf{x}_S - \mathbf{u}^{n+1})_{U^{n+1}}\|_2 - \frac{1}{1 + \delta_{4s}} \|(\mathbf{A}^* \mathbf{e}')_{U^{n+1}}\|_2 \right) \\ &\cdot \left(\|(\mathbf{x}_S - \mathbf{u}^{n+1})_{U^{n+1}}\|_2 - \frac{1}{1 - \delta_{4s}} \|(\mathbf{A}^* \mathbf{e}')_{U^{n+1}}\|_2 \right). \end{aligned}$$

Srednji član na desnoj strani možemo ograničiti odozgo predzadnjim članom da bi dobili

$$\frac{\delta_{4s}^2}{1 - \delta_{4s}^2} \|(\mathbf{x}_S - \mathbf{u}^{n+1})_{\bar{U}^{n+1}}\|_2^2 \geq \left(\|(\mathbf{x}_S - \mathbf{u}^{n+1})_{U^{n+1}}\|_2 - \frac{1}{1 - \delta_{4s}} \|(\mathbf{A}^* \mathbf{e}')_{U^{n+1}}\|_2 \right)^2.$$

Uzimanjem korijena i preslagivanjem imamo

$$\begin{aligned} \|(\mathbf{x}_S - \mathbf{u}^{n+1})_{U^{n+1}}\|_2^2 &\leq \frac{\delta_{4s}}{\sqrt{1 - \delta_{4s}}} \|(\mathbf{x}_S - \mathbf{u}^{n+1})_{\overline{U^{n+1}}}\|_2 \\ &\quad + \frac{1}{1 - \delta_{4s}} \|(\mathbf{A}^* \mathbf{e}')_{U^{n+1}}\|_2. \end{aligned} \quad (5.43)$$

Nadalje, kao posljedica od $(CoSaMP_1)$, ako S^n označuje nosač od \mathbf{x}^n i ako je T^{n+1} skup indeksa $2s$ apsolutno najvećih komponenti od $\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n)$, imamo

$$\|(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{S \cup S^n}\|_2^2 \leq \|(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{T^{n+1}}\|_2^2.$$

Eliminiramo doprinos od $(S \cup S^n) \cap T^{n+1}$,

$$\|(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{(S \cup S^n) \setminus T^{n+1}}\|_2 \leq \|(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{T^{n+1} \setminus (S \cup S^n)}\|_2.$$

Desnu stranu možemo zapisati kao

$$\|(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{T^{n+1} \setminus (S \cup S^n)}\|_2 = \|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{T^{n+1} \setminus (S \cup S^n)}\|_2.$$

Za lijevu stranu imamo,

$$\begin{aligned} \|(\mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{(S \cup S^n) \setminus T^{n+1}}\|_2 &\geq \|(\mathbf{x}_S - \mathbf{x}^n)_{\overline{T^{n+1}}}\|_2 \\ &\quad - \|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{(S \cup S^n) \setminus T^{n+1}}\|_2. \end{aligned}$$

Dakle,

$$\begin{aligned} \|(\mathbf{x}_S - \mathbf{x}^n)_{\overline{T^{n+1}}}\|_2 &\leq \|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{(S \cup S^n) \setminus T^{n+1}}\|_2 \\ &\quad + \|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{T^{n+1} \setminus (S \cup S^n)}\|_2 \\ &\leq \sqrt{2} \|(\mathbf{x}^n - \mathbf{x}_S + \mathbf{A}^*(\mathbf{y} - \mathbf{A}\mathbf{x}^n))_{T^{n+1} \Delta (S \cup S^n)}\|_2 \\ &\leq \sqrt{2} \|((\mathbf{I} - \mathbf{A}^* \mathbf{A})(\mathbf{x}^n - \mathbf{x}_S))_{T^{n+1} \Delta (S \cup S^n)}\|_2 \\ &\quad + \sqrt{2} \|(\mathbf{A}^* \mathbf{e}')_{(S \cup S^n) \Delta T^{n+1}}\|_2, \end{aligned}$$

gdje je $\mathbf{y} = \mathbf{A}\mathbf{x}_S + \mathbf{e}'$. Pošto prema $(CoSaMP_1)$ $T^{n+1} \subseteq U^{n+1}$ i $S^n \subseteq U^{n+1}$ prema $(CoSaMP_2)$, lijeva strana gornje nejednakosti može se ocijeniti kao

$$\|(\mathbf{x}_S - \mathbf{x}^n)_{\overline{T^{n+1}}}\|_2 \geq \|(\mathbf{x}_S - \mathbf{x}^n)_{\overline{U^{n+1}}}\|_2 = \|(\mathbf{x}_S)_{\overline{U^{n+1}}}\|_2 = \|(\mathbf{x}_S - \mathbf{u}^{n+1})_{\overline{U^{n+1}}}\|_2.$$

Desnu stranu možemo ocijeniti odozgo koristeći lemu 5.3.2,

$$\begin{aligned} \|(\mathbf{x}_S - \mathbf{u}^{n+1})_{\overline{U^{n+1}}}\|_2 &\leq \sqrt{2}\delta_{4s}\|\mathbf{x}^n - \mathbf{x}_S\|_2 \\ &\quad + \sqrt{2}\|(\mathbf{A}^* \mathbf{e}')_{(S \cup S^n) \Delta T^{n+1}}\|_2. \end{aligned} \quad (5.44)$$

Kombiniranjem (5.42), (5.43) i nejednakosti $a^2 + (b + c)^2 \leq (\sqrt{a^2 + b^2} + c)^2$ imamo

$$\begin{aligned} \|\mathbf{x}_S - \mathbf{x}^{n+1}\|_2^2 &\leq \|(\mathbf{x}_S - \mathbf{u}^{n+1})_{\overline{U^{n+1}}}\|_2^2 \\ &\quad + \left(\frac{\delta_{4s}}{\sqrt{1 - \delta_{4s}^2}} \|(\mathbf{x}_S - \mathbf{u}^{n+1})_{\overline{U^{n+1}}}\|_2 + \frac{1}{1 - \delta_{4s}} \|(\mathbf{A}^* \mathbf{e}')_{U^{n+1}}\|_2 \right)^2 \\ &\leq \left(\frac{1 + 3\delta_{4s}^2}{\sqrt{1 - \delta_{4s}^2}} \|(\mathbf{x}_S - \mathbf{u}^{n+1})_{\overline{U^{n+1}}}\|_2 + \frac{2}{1 - \delta_{4s}} \|(\mathbf{A}^* \mathbf{e}')_{U^{n+1}}\|_2 \right)^2. \end{aligned}$$

Uvažimo sada (5.44)

$$\begin{aligned} \|\mathbf{x}_S - \mathbf{x}^{n+1}\|_2 &\leq \sqrt{\frac{2\delta_{4s}^2(1 + 3\delta_{4s}^2)}{1 - \delta_{4s}^2}} \|\mathbf{x}^n - \mathbf{x}_S\|_2 \\ &\quad + \sqrt{\frac{2(1 + 3\delta_{4s}^2)}{1 - \delta_{4s}^2}} \|(\mathbf{A}^* \mathbf{e}')_{(S \cup S^n) \Delta T^{n+1}}\|_2 + \frac{2}{1 - \delta_{4s}} \|(\mathbf{A}^* \mathbf{e}')_{U^{n+1}}\|_2. \end{aligned}$$

Prema lemi 5.3.4 nejednakost (5.41) vrijedi za

$$\rho = \sqrt{\frac{2\delta_{4s}^2(1 + 3\delta_{4s}^2)}{1 - \delta_{4s}^2}}, \quad (1 - \rho)\tau = \sqrt{\frac{2(1 + 3\delta_{4s}^2)}{1 - \delta_{4s}^2}} + \frac{2\sqrt{1 + \delta_{4s}}}{1 - \delta_{4s}}. \quad (5.45)$$

Konstanta ρ je manja od 1 ako i samo je $6\delta_{4s}^4 + 3\delta_{4s}^2 - 1 < 0$. To se dogodi onda kada je $\delta_{4s}^2 < (\sqrt{11/3} - 1)/4$.

□

Bibliografija

- [1] J. Bourgain, S. J. Dilworth, K. Ford, S. Konyagin i D. Kutzarova, *Explicit constructions of RIP matrices and related problems*, arXiv e-prints (2010), arXiv:1008.4535.
- [2] E. Candes i T. Tao, *Near Optimal Signal Recovery From Random Projections: Universal Encoding Strategies?*, arXiv Mathematics e-prints (2004), math/0410542.
- [3] H. Chen, *Explicit RIP Matrices in Compressed Sensing from Algebraic Geometry*, CoRR **abs/1505.07490** (2015), <http://arxiv.org/abs/1505.07490>.
- [4] E.K.P. Chong i S.H. Zak, *An Introduction to Optimization*, Wiley Series in Discrete Mathematics and Optimization, Wiley, 2013, ISBN 9781118515150, <https://books.google.hr/books?id=id5s0iKXHP8C>.
- [5] S. Foucart i H Rauhut, *A Mathematical Introduction to Compressive Sensing*, 2013, ISBN 9780817649487 0817649484.
- [6] M. R. Garey i D. S. Johnson, *Computers and Intractability: A Guide to the Theory of NP-Completeness (Series of Books in the Mathematical Sciences)*, first edition., W. H. Freeman, 1979, ISBN 0716710455, <http://www.amazon.com/Computers-Intractability-NP-Completeness-Mathematical-Sciences/dp/0716710455>.
- [7] S. Gerschgorin, *Über die Abgrenzung der Eigenwerte einer Matrix*, Izvestija Akademii Nauk SSSR, Serija Matematika **7** (1931), br. 3, 749–754.
- [8] R. M. Karp, *Reducibility Among Combinatorial Problems.*, Complexity of Computer Computations (Raymond E. Miller i James W. Thatcher, ur.), The IBM Research Symposia Series, Plenum Press, New York, 1972, str. 85–103, ISBN 0-306-30707-3, <http://dblp.uni-trier.de/db/conf/coco/cocc1972.html#Karp72>.

- [9] R. Penrose, *A generalized inverse for matrices*, Mathematical Proceedings of the Cambridge Philosophical Society **51** (1955), br. 3, 406–413.
- [10] M. Rani, S. B. Dhok i R. B. Deshmukh, *A Systematic Review of Compressive Sensing: Concepts, Implementations and Applications*, IEEE Access **6** (2018), 4875–4894, ISSN 2169-3536.
- [11] C. E. Shannon, *Communication in the Presence of Noise*, Proc. Institute of Radio Engineers **37** (1949), br. 1, 10–21.
- [12] T. Tao, *Terence Tao Blog*, <https://terrytao.wordpress.com/2007/04/13/compressed-sensing-and-single-pixel-cameras/>.
- [13] R. Tibshirani, *Regression Shrinkage and Selection via the Lasso*, Journal of the Royal Statistical Society (Series B) **58** (1996), 267–288.
- [14] A. M. Tillmann i M. E. Pfetsch, *The Computational Complexity of the Restricted Isometry Property, the Nullspace Property, and Related Concepts in Compressed Sensing*, arXiv e-prints (2012), arXiv:1205.2081.
- [15] K. Vijay Mishra i Y. C. Eldar, *Sub-Nyquist Radar: Principles and Prototypes*, arXiv e-prints (2018), arXiv:1803.01819.

Sažetak

U ovom radu upozнали smo se s matematičkim temeljima teorije sažetog uzorkovanja. Rješavali smo problem rekonstrukcije vektora $\mathbf{x} \in \mathbb{C}^N$ iz vektora mjerenja $\mathbf{y} = \mathbf{A}\mathbf{x}$ gdje je $\mathbf{A} \in \mathbb{C}^{m \times N}$. U slučaju da je $N = m$ za rekonstrukciju je dovoljno riješiti kvadratni sustav linearnih jednadžbi. Ako je $m < N$, klasična teorija linearne algebre kaže da ovakvi sustavi mogu imati beskonačno rješenja. No, uz dodatni uvjet rijetkosti vektora \mathbf{x} pokazali smo da je rekonstrukcija moguća i štoviše postoje efikasni algoritmi za rješenje. Prvo poglavlje započinje uvodom u osnovne pojmove teorije rijetkih vektora. Dali smo definiciju rijetkih vektora, izveli smo ocjene za ℓ_p -grešku najbolju s -rijetke aproksimacije vektora \mathbf{x} i dali dva načina kako se mogu definirati kompresibilni vektori. To je od praktične koristi pošto u primjeni rijetko rukujemo pravim rijetkim vektorima, već su to uglavnom kompresibilni vektori. Zatim smo istražili koji je minimalni broj mjerenja m potrebnih za rekonstrukciju, te pokazujemo kako ℓ_0 -minimizacija (P_0) daje rješenje problema sažetog uzorkovanja. Nažalost minimizacija ℓ_0 -norme je nekonveksan, a uz to i NP-težak problem, što smo pokazali tako da smo poznati NP-težak problem pokrivača tročlanim skupovima reducirali na (P_0). U drugom poglavlju dajemo pregled ostalih, efikasnih algoritama za rekonstrukciju. Ti algoritmi mogu se u grubo podijeliti na optimizacijske, greedy i granične metode. Kod optimizacijskih algoritama najvažniji je BP (eng. *basis pursuit*) algoritam ili ℓ_1 -minimizacija. Njega zapravo možemo shvatiti kao konveksnu relaksaciju problema (P_0). Nadalje, opisujemo OMP i CoSaMP greedy algoritme, te BT, IHT, HTP granične metode. Treće poglavlje posvećeno je ℓ_1 -minimizaciji. Upoznajemo se sa svojstvom nul-prostora matrice \mathbf{A} te pokazujemo kako je ono dovoljan i nužan uvjet za uspješnu rekonstrukciju vektora \mathbf{x} ℓ_1 -minimizacijom. Nadalje, uvodimo pojmove stabilnosti i robusnosti rekonstrukcijske metode. Neformalno, ta dva svojstva govore da se rekonstrukcijska metoda dobro ponaša s obzirom na defekte rijetkosti i na greške mjerenja. Uz ojačano svojstvo nul-prostora pokazujemo da je ℓ_1 -minimizacija stabilna i robusna. U četvrtom poglavlju uvodimo koherenciju, koju možemo shvatiti kao mjeru kvalitete matrice rekonstrukcije. Slijede rezultati i ocjene vezane uz koherenciju te dajemo eksplicitnu konstrukciju određenih matrica male koherencije. Zatim analiziramo uz koje uvjete na koherenciju algoritmi iz drugog poglavlja postižu

egzaktanu rekonstrukciju. U petom poglavlju dajemo novu mjeru kvalitete matrice \mathbf{A} , svojstvo restriktivne izometričnosti. Ona rješava nedostatke koherencije, tj. omogućuje analizu algoritama za velike vrijednosti rijetkosti s . Isto kao kod koherencije provodimo analizu algoritama i pokazujemo uz koje uvjete ti algoritmi postižu stabilnu i robusnu rekonstrukciju. Valja napomenuti da ovaj rad nije iscrpni pregled teorije sažetog uzorkovanja. Naime, pokazuje se da je konstrukcija eksplicitnih matrica s dovoljno malim konstantama restriktivne izometričnosti težak problem, koji nije riješen. Veliki napredak napravili su Terence Tao i Emmanuel Candes u [2], gdje su pokazali da slučajne Gaussove matrice zadovoljavaju svojstvo restriktivne izometričnosti s velikom vjerojatnošću. To je otvorilo put stohastičkoj teoriji i slučajnim matricama u teoriju sažetog uzorkovanja.

Summary

In this thesis we cover the mathematical foundations of the theory of compressive sensing. The problem in focus is the reconstruction of the vector $\mathbf{x} \in \mathbb{C}^N$ from the measurement vector $\mathbf{y} = \mathbf{A}\mathbf{x}$, where $\mathbf{A} \in \mathbb{C}^{m \times N}$. Given that $N = m$, it is enough to solve a square system of linear equations. If $m < N$, the classical theory of linear algebra tells us that such systems can have a infinite number of solutions. However, if we assume that the vector \mathbf{x} is sparse, we are able to show that the reconstruction is not only possible, but efficient reconstruction algorithms exist. First chapter gives an introduction to the theory of sparse vectors. We define the notion of sparsity, derive the ℓ_p bound for the best s -term sparse approximation of a vector \mathbf{x} and give two ways of defining compressible vectors. Which is of practical use because compressible vectors are much more common than perfectly sparse vectors in real world applications. Next, we investigate the minimal number m of measurements necessary for a perfect reconstruction and we see how the ℓ_0 -minimization (P_0) naturally arises as a reconstruction strategy. Unfortunately, ℓ_0 -minimization is non-convex and additionally a NP-hard problem. We show this fact by reducing the well known NP-hard problem of covering by 3-sets to the problem of ℓ_0 -minimization. In the second chapter we give a summary of efficient reconstruction algorithms, which can be divided into three categories: optimization methods, greedy methods and threshold-based methods. In the optimization methods category the most important is the basis pursuit algorithm or ℓ_1 -minimization. We can think of it as a convex relaxation of the (P_0) problem. Furthermore, we give a description of the OMP and CoSaMP greedy algorithms, and BT, IHT, HTP thresholding-based methods. The third chapter is dedicated to the ℓ_1 -minimization. We study the null-space property of the matrix \mathbf{A} and show how it ensures a successful reconstruction via the ℓ_1 -minimization. We introduce the definition of stability and robustness of a reconstruction method and prove how with a stronger version of the null-space property, ℓ_1 -minimization is both stable and robust. In chapter number four, we give the definition of coherence, which can be thought of as a reconstruction matrix \mathbf{A} quality. We derive some bounds and give an explicit construction of matrices with small coherence. Next, we analyse the conditions for coherence under which the reconstruction algorithms give a successful

reconstruction. In the fifth chapter we introduce the notion of restricted isometry property, which is in fact a new quality measure for the matrix \mathbf{A} , and this enables us to study the reconstruction algorithms for large values of sparsity s . Same as with the coherence, we analyse the reconstruction algorithms with regard to the restricted isometry property. We should note that this thesis is not covering the whole theory of compressive sensing as it turns out that the explicit construction of matrices with a small restricted isometry constant is a hard problem which still hasn't been resolved. A big step forward has been made by Terence Tao and Emmanuel Candes in [2], where they have shown that random Gauss matrices satisfy the restricted isometry property with a high probability and introduced stochastics into the theory of compressive sensing.

Životopis

Rođen sam 25.08.1993 u Puli. Pohađao sam osnovnu školu Kaštanjer, a zatim prva dva razreda Gimnazije Pula, prirodoslovno-matematički smjer. Kao HMC stipendist, zadnja dva razreda srednje škole završavam u Cheltenham College-u u Velikoj Britaniji gdje stječem A-levels kvalifikacije. Godine 2012. upisujem prediplomski sveučilišni studij Matematike na Prirodoslovno-matematičkom fakultetu Sveučilišta u Zagrebu. Na istom fakultetu, 2016. godine upisujem diplomski studij Primjenjene matematike. Od 2016.-2019. godine radim kao student inženjer za ugrađene sustave u firmi Ericsson Nikola Tesla, a od 2019. godine zapošljavam se kao razvojni inženjer u firmi AG04. Slobodno vrijeme provodim baveći se biciklizmom, slobodnim penjanjem, planinarenjem te trčanjem planinskih ultra maratona.