

## 6. Další algoritmy pro rekonstrukci řídkých vektorů ( "sparse recovery" )

-1-

- Doplňd: optimalizační metody... globální optima lišace konvexních problémů: např.:  $\min_{z \in \mathbb{R}^N} \|z\|_1, \text{ s.t. } Az=y$

### 7.1. Greedy algoritmy (= "bládní algoritmy")

- Orthogonal matching pursuit (OMP)

Pro vstup  $A \in \mathbb{R}^{m \times N}, y \in \mathbb{R}^m$

- Inicializace  $S^0 = \emptyset, x^0 = 0$

$$S^{m+1} = S^m \cup \{j_{m+1}\}, j_{m+1} = \arg \max_{j \in \{1, \dots, N\}} |(A^*(y - Ax^m))_j|$$

$$x^{m+1} = \arg \min_{\substack{z \in \mathbb{C}^N \\ (\text{repp. } \mathbb{R}^N)}} \{ \|y - Az\|_2, \text{ supp}(z) \subset S^{m+1} \}$$

...opakuje se pro  $m \leq m_0$  ... výsledek  $x^\# = x^{m_0}$ .

- Iterativní algoritmus, který postupně rozšiřuje uzení ( $S^d$ ) a hledá nejmenší "chybu" uzení  $Az, \text{ supp}(z) \subset S^d$  a  $y$ .

- Proč rozšiřujeme potenciálně možná právi o  $j_{m+1}$ ?

Lemma: Necht  $A \in \mathbb{C}^{m \times N}$  je matice s  $\ell_2$ -norm. sloupci. Pro daní

$S \subset \{1, \dots, N\}$ ,  $j \in \{1, \dots, N\}$  a  $v \in \mathbb{C}^N$  s  $\text{supp}(v) \subset S$  a

$$w := \underset{z \in \mathbb{C}^N}{\text{argmin}} \{ \|y - Az\|_2, \text{supp}(z) \subset S \cup \{j\} \}$$

platí

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

Důkaz: Uvažujme vektor typu  $v + te_j$  s  $t \in \mathbb{C}$  ... má násič na  $S \cup \{j\}$

a platí

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

Volíme  $t = \rho e^{i\theta}$ ,  $\rho \geq 0$ ,  $\theta \in [0, 2\pi)$ :

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

kde pro vhodné  $\theta$  platí rovnost ...

Minimalizace přesp:  $\rho = |(A^*(y - Av))_j| \Rightarrow$

$$\min_{t \in \mathbb{C}} \|y - A(v + te_j)\|_2^2 = \|y - Av\|_2^2 - |(A^*(y - Av))_j|^2. \quad \blacksquare$$

Lemma: Pro danou množinu  $S \subset \{1, \dots, N\}$  a

$$v := \underset{z \in \mathbb{C}^N}{\text{argmin}} \{ \|y - Az\|_2 : \text{supp}(z) \subset S \}$$

platí  $(A^*(y - Av))_S = 0$ .

Důkaz:  $Av$  je ortogonální projekce  $y$  na  $\{Az : \text{supp}(z) \subset S\}$  ...

je tedy charakterizován  $\langle y - Av, Az \rangle = 0$  pro  $\forall z \in \mathbb{C}^N$  s  $\text{supp}(z) \subset S$

... tedy  $\langle A^*(y - Av), z \rangle = 0$  pro  $\forall z \in \mathbb{C}^N$  s  $\text{supp}(z) \subset S$  ... Tedy  $(A^*(y - Av))_S = 0. \quad \blacksquare$

# Compressive sampling matching pursuit (CoSaMP)

• Pro  $A, y, s \in \mathbb{R}^1, -N$  :  $x^0 = 0$

•  $U^{m+1} = \text{supp}(x^m) \cup L_{2s}(A^*(y - Ax^m))$

$L_s(z)$  ... maximální index s nejv. převážně  $z \in \mathbb{C}^N$  v abs. hodnotě

•  $u^{m+1} = \arg \min_{z \in \mathbb{C}^N} \|y - Az\|_2 : \text{supp}(z) \subset U^{m+1}$

•  $x^{m+1} = H_s(u^{m+1})$  ...  $H_s(z) = \mathcal{R}_{L_s(z)}$  ... a rozhodne' na s nejv. největších koef.

... opakujeme

Věty: • Pro  $A \in \mathbb{C}^{m \times N}$ ,  $y = Ax + e$ , kde  $x$  je  $s$ -sparse,  $x^m$  a OMP

• Pokud  $\delta_{3s} < 1/6$ , pak  $\|y - Ax^m\|_2 \leq C \|e\|_2$ ,  $\bar{m} = 12s$ .

• Pro  $\delta_{4s} < 0.478$  a  $x^m$  a (CoSaMP) platí

$$\|x^m - x_s\|_2 \leq \rho^m \|x^0 - x_s\|_2 + \tilde{c} \|Ax_s + e\|_2, \text{ kde } 0 < \rho < 1 \text{ a } \tilde{c} > 0$$

na'vím na  $\delta_{4s}$ .

... spec.  $x$   $s$ -sparse,  $x^0 = 0$

$$\|x^m - x\|_2 \leq \rho^m \|x\|_2 + \tilde{c} \underbrace{\|y\|_2}_{\|y\|_2} + \tilde{c} \|Ax + e\|_2.$$

• Iterative Hard Thresholding :  $x_{m+1} = H_s(x^m + A^*(y - Ax^m))$  ... opakovat

Věta: Pro  $\delta_{3s} < 1/2$  a  $s$ -řídke'  $x \in \mathbb{C}^N$  konverguje  $x^m$  a (IHT) k  $x$ .