# Rank Minimization over Finite Fields: Fundamental Limits and Coding-Theoretic Interpretations

#### Vincent Tan

#### Department of Electrical and Computer Engineering, University of Wisconsin-Madison

UIUC Comm Seminar (Apr 25, 2011)



Laura Balzano



Stark C. Draper

・ 同 ト ・ ヨ ト ・ ヨ



æ

590

<ロト < 回 > < 回 > < 回 > < 回 >

#### Problem Setup and Summary of Main Results

• • • • • • • • • • • • •

#### 2 Problem Setup and Summary of Main Results

#### Converse

∃ >

• • • • • • • •

Problem Setup and Summary of Main Results

#### 3 Converse



Problem Setup and Summary of Main Results

#### 3 Converse

- Achievability for Uniform Model
- 5 Achievability for Sparse Model

< 17 ▶

Problem Setup and Summary of Main Results

#### Converse

- Achievability for Uniform Model
- 5 Achievability for Sparse Model
- 6 Coding-Theoretic Interpretations

< A

# Outline

# Motivation

2 Problem Setup and Summary of Main Results

#### 3 Converse

- 4 Achievability for Uniform Model
- 5 Achievability for Sparse Model
- 6 Coding-Theoretic Interpretations

< 6 b

Area of	Matrix Completion	Rank-Metric Codes
Study	Rank Minimization	

< 17 ▶

Area of Study	Matrix Completion Rank Minimization	Rank-Metric Codes
Applications	Collaborative Filtering Minimal Realization	Crisscross Error Correction Network Coding

< 17 ▶

Area of Study	Matrix Completion Rank Minimization	Rank-Metric Codes
Applications	Collaborative Filtering Minimal Realization	Crisscross Error Correction Network Coding
Field	Reals $\mathbb{R}$ , Complex $\mathbb{C}$	Finite Field $\mathbb{F}_q$

< 17 ▶

Area of Study	Matrix Completion Rank Minimization	Rank-Metric Codes
Applications	Collaborative Filtering Minimal Realization	Crisscross Error Correction Network Coding
Field	Reals $\mathbb{R}$ , Complex $\mathbb{C}$	Finite Field $\mathbb{F}_q$
Techniques	Functional Analysis	Algebraic coding

< 17 ▶

Area of Study	Matrix Completion Rank Minimization	Rank-Metric Codes
Applications	Collaborative Filtering Minimal Realization	Crisscross Error Correction Network Coding
Field	Reals $\mathbb{R}$ , Complex $\mathbb{C}$	Finite Field $\mathbb{F}_q$
Techniques	Functional Analysis	Algebraic coding
Decoding	Nuclear Norm Convex Optimization	Berlekamp-Massey Error Trapping

< 17 ▶

Area of Study	Matrix Completion Rank Minimization	Rank-Metric Codes
Applications	Collaborative Filtering Minimal Realization	Crisscross Error Correction Network Coding
Field	Reals $\mathbb{R}$ , Complex $\mathbb{C}$	Finite Field $\mathbb{F}_q$
Techniques	Functional Analysis	Algebraic coding
Decoding	Nuclear Norm Convex Optimization	Berlekamp-Massey Error Trapping

Can we draw analogies between the two areas of study?

Area of Study	Matrix Completion Rank Minimization	Rank-Metric Codes
Applications	Collaborative Filtering Minimal Realization	Crisscross Error Correction Network Coding
Field	Reals $\mathbb{R}$ , Complex $\mathbb{C}$	Finite Field $\mathbb{F}_q$
Techniques	Functional Analysis	Algebraic coding
Decoding	Nuclear Norm Convex Optimization	Berlekamp-Massey Error Trapping

Can we draw analogies between the two areas of study?

Rank Minimization over finite fields

Vincent Tan (UW-Madison)

Rank Minimization over Finite Fields

#### Definition

The rank distance between matrices  $\mathbf{A}, \mathbf{B} \in \mathbb{F}_a^{m \times n}$  is defined as

 $\Delta(\mathbf{A}, \mathbf{B}) := \operatorname{rank}(\mathbf{A} - \mathbf{B}).$ 

590

< ロ > < 同 > < 回 > < 回 >

#### Definition

The rank distance between matrices  $\mathbf{A}, \mathbf{B} \in \mathbb{F}_a^{m \times n}$  is defined as

 $\Delta(\mathbf{A}, \mathbf{B}) := \operatorname{rank}(\mathbf{A} - \mathbf{B}).$ 

Fact:  $\Delta(\mathbf{A}, \mathbf{B})$  is a metric

< ロ > < 同 > < 回 > < 回 >

#### Definition

The rank distance between matrices  $\mathbf{A}, \mathbf{B} \in \mathbb{F}_a^{m \times n}$  is defined as

 $\Delta(\mathbf{A}, \mathbf{B}) := \operatorname{rank}(\mathbf{A} - \mathbf{B}).$ 

Fact:  $\Delta(\mathbf{A}, \mathbf{B})$  is a metric

#### Definition

A rank-metric code is C is a non-empty subset of  $\mathbb{F}_q^{m \times n}$  endowed with the rank distance.

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

 $\bullet$  Transmit some codeword  $C \in \mathcal{C}$ 

 $\bullet$  Transmit some codeword  $C \in \mathcal{C}$ 

• Receive some received word  $\mathbf{R} \in \mathbb{F}_q^{m imes n}$ 

Image: A matrix

- $\bullet$  Transmit some codeword  $C \in \mathcal{C}$
- Receive some received word  $\mathbf{R} \in \mathbb{F}_q^{m imes n}$
- Decoding problem (under mild conditions) is

$$\hat{\mathbf{C}} = \underset{\mathbf{C} \in \mathcal{C}}{\operatorname{arg\,min}} \operatorname{rank}(\mathbf{R} - \mathbf{C})$$

• Minimum distance decoding since rank induces a metric

- Transmit some codeword  $C \in \mathcal{C}$
- Receive some received word  $\mathbf{R} \in \mathbb{F}_q^{m imes n}$
- Decoding problem (under mild conditions) is

$$\hat{\mathbf{C}} = \underset{\mathbf{C} \in \mathcal{C}}{\operatorname{arg\,min}} \operatorname{rank}(\mathbf{R} - \mathbf{C})$$

- Minimum distance decoding since rank induces a metric
- $X \equiv R C$  is known as the error matrix low-rank

- Transmit some codeword  $C \in \mathcal{C}$
- Receive some received word  $\mathbf{R} \in \mathbb{F}_q^{m imes n}$
- Decoding problem (under mild conditions) is

$$\hat{\mathbf{C}} = \underset{\mathbf{C} \in \mathcal{C}}{\operatorname{arg\,min}} \operatorname{rank}(\mathbf{R} - \mathbf{C})$$

- Minimum distance decoding since rank induces a metric
- $X \equiv R C$  is known as the error matrix low-rank
- Assume linear

- $\bullet$  Transmit some codeword  $C \in \mathcal{C}$
- Receive some received word  $\mathbf{R} \in \mathbb{F}_q^{m imes n}$
- Decoding problem (under mild conditions) is

$$\hat{\mathbf{C}} = \underset{\mathbf{C} \in \mathcal{C}}{\operatorname{arg\,min}} \operatorname{rank}(\mathbf{R} - \mathbf{C})$$

- Minimum distance decoding since rank induces a metric
- $X \equiv R C$  is known as the error matrix low-rank
- Assume linear
- Rank minimization over finite field problem

$$\hat{\mathbf{X}} = \underset{\mathbf{X} \in \text{coset}}{\operatorname{arg\,min}} \operatorname{rank}(\mathbf{X})$$

Vincent Tan (UW-Madison)

< 17 ▶

Probabilistic crisscross error correction

< 17 ▶

Probabilistic crisscross error correction

#### Roth, IT Trans 1997



< 🗇 🕨 < 🖃 🕨

Probabilistic crisscross error correction



• Data storage applications: Data stored in arrays

⇐

Probabilistic crisscross error correction



- Data storage applications: Data stored in arrays
- Error patterns confined to two rows and three columns above

Probabilistic crisscross error correction



- Data storage applications: Data stored in arrays
- Error patterns confined to two rows and three columns above
- Low-rank errors

# Index coding with side information

Vincent Tan (UW-Madison)

Rank Minimization over Finite Fields

UIUC Comm Seminar 9 / 49

< 47 ▶

- k-receiver deterministic broadcast channel
- Birk and Kol (IT Trans 06) and Bar-Yossef et al. (FOCS 06)

- k-receiver deterministic broadcast channel
- Birk and Kol (IT Trans 06) and Bar-Yossef et al. (FOCS 06)
- Transmitter has *k* bits of information  $x^k = \{0, 1\}^k$

- k-receiver deterministic broadcast channel
- Birk and Kol (IT Trans 06) and Bar-Yossef et al. (FOCS 06)
- Transmitter has *k* bits of information  $x^k = \{0, 1\}^k$
- Wishes to transmit *x<sub>i</sub>* to receiver *i*

- k-receiver deterministic broadcast channel
- Birk and Kol (IT Trans 06) and Bar-Yossef et al. (FOCS 06)
- Transmitter has *k* bits of information  $x^k = \{0, 1\}^k$
- Wishes to transmit *x<sub>i</sub>* to receiver *i*
- Receiver *i* also has subset of other coordinates
- *k*-receiver deterministic broadcast channel
- Birk and Kol (IT Trans 06) and Bar-Yossef et al. (FOCS 06)
- Transmitter has *k* bits of information  $x^k = \{0, 1\}^k$
- Wishes to transmit *x<sub>i</sub>* to receiver *i*
- Receiver *i* also has subset of other coordinates
- Side information  $\{x_j : (i,j) \in \mathcal{G}\}$







< A



< 行い



< A



UIUC Comm Seminar 10 / 49





We say that a matrix  $\mathbf{A} \in \mathbb{F}_2^{k imes k}$  fits a graph  $\mathcal{G}$  if

$$a_{ii} = 1, \qquad a_{ij} = 0 \quad \text{if} \quad (i,j) \notin \mathcal{G}$$

We say that a matrix  $\mathbf{A} \in \mathbb{F}_2^{k imes k}$  fits a graph  $\mathcal G$  if

$$a_{ii} = 1, \qquad a_{ij} = 0 \quad \text{if} \quad (i,j) \notin \mathcal{G}$$

#### Definition

The minimum rank of a graph  $\mathcal{G}$  is defined as

 $minrk_2(\mathcal{G}) := min\{rank(\mathbf{A}) : \mathbf{A} \text{ fits } \mathcal{G}\}$ 

This is an example of a rank minimization problem over  $\mathbb{F}_2$ 

4 O N 4 🗐 N 4 E N 4

We say that a matrix  $\mathbf{A} \in \mathbb{F}_2^{k imes k}$  fits a graph  $\mathcal G$  if

$$a_{ii} = 1, \qquad a_{ij} = 0 \quad \text{if} \quad (i,j) \notin \mathcal{G}$$

#### Definition

The minimum rank of a graph  $\mathcal{G}$  is defined as

 $minrk_2(\mathcal{G}) := min\{rank(\mathbf{A}) : \mathbf{A} \text{ fits } \mathcal{G}\}$ 

This is an example of a rank minimization problem over  $\mathbb{F}_2$ 

#### Theorem (Bar-Yossef et al. 06)

The optimal length of a linear index code for graph  $\mathcal{G}$  equals  $\operatorname{minrk}_2(\mathcal{G})$ .

< ロ > < 同 > < 回 > < 回 >

• Very popular and well-studied problem

< 17 ▶

- Very popular and well-studied problem
- Given a subset of entries from a low-rank matrix  $\mathbf{X} \in \mathbb{R}^{m imes n}$

nac

- Very popular and well-studied problem
- Given a subset of entries from a low-rank matrix  $\mathbf{X} \in \mathbb{R}^{m imes n}$



Green = Missing entry

• Goal: Recover the matrix X

- Very popular and well-studied problem
- Given a subset of entries from a low-rank matrix  $\mathbf{X} \in \mathbb{R}^{m imes n}$



Green = Missing entry

- Goal: Recover the matrix X
- The nuclear norm heuristic has enjoyed tremendous successes

•  $\mathbf{X} \in \mathbb{R}^{m \times n}$  a low-rank matrix

- $\mathbf{X} \in \mathbb{R}^{m \times n}$  a low-rank matrix
- Given *k* linear measurements:

$$y_1 = \langle \mathbf{H}_1, \mathbf{X} \rangle = \operatorname{Trace}(\mathbf{H}_1 \mathbf{X}^T)$$
  
$$\vdots$$
  
$$y_k = \langle \mathbf{H}_k, \mathbf{X} \rangle = \operatorname{Trace}(\mathbf{H}_k \mathbf{X}^T)$$

**H** 16

- $\mathbf{X} \in \mathbb{R}^{m \times n}$  a low-rank matrix
- Given *k* linear measurements:

$$y_1 = \langle \mathbf{H}_1, \mathbf{X} \rangle = \operatorname{Trace}(\mathbf{H}_1 \mathbf{X}^T)$$
  
$$\vdots$$
  
$$y_k = \langle \mathbf{H}_k, \mathbf{X} \rangle = \operatorname{Trace}(\mathbf{H}_k \mathbf{X}^T)$$

• A generalization of matrix completion

- $\mathbf{X} \in \mathbb{R}^{m \times n}$  a low-rank matrix
- Given *k* linear measurements:

$$y_1 = \langle \mathbf{H}_1, \mathbf{X} \rangle = \operatorname{Trace}(\mathbf{H}_1 \mathbf{X}^T)$$
  
$$\vdots$$
  
$$y_k = \langle \mathbf{H}_k, \mathbf{X} \rangle = \operatorname{Trace}(\mathbf{H}_k \mathbf{X}^T)$$

- A generalization of matrix completion
- Goal: Recover the matrix X

- $\mathbf{X} \in \mathbb{R}^{m \times n}$  a low-rank matrix
- Given *k* linear measurements:

$$y_1 = \langle \mathbf{H}_1, \mathbf{X} \rangle = \operatorname{Trace}(\mathbf{H}_1 \mathbf{X}^T)$$
  
$$\vdots$$
  
$$y_k = \langle \mathbf{H}_k, \mathbf{X} \rangle = \operatorname{Trace}(\mathbf{H}_k \mathbf{X}^T)$$

- A generalization of matrix completion
- Goal: Recover the matrix X
- The nuclear norm heuristic has also enjoyed tremendous successes

- $\mathbf{X} \in \mathbb{R}^{m \times n}$  a low-rank matrix
- Given *k* linear measurements:

$$y_1 = \langle \mathbf{H}_1, \mathbf{X} \rangle = \operatorname{Trace}(\mathbf{H}_1 \mathbf{X}^T)$$
  
$$\vdots$$
  
$$y_k = \langle \mathbf{H}_k, \mathbf{X} \rangle = \operatorname{Trace}(\mathbf{H}_k \mathbf{X}^T)$$

- A generalization of matrix completion
- Goal: Recover the matrix X
- The nuclear norm heuristic has also enjoyed tremendous successes
- Wide applicability in for e.g., collaborative filtering, minimal realization of LTI system etc.

Vincent Tan (UW-Madison)

Rank Minimization over Finite Fields

#### Motivation

#### Problem Setup and Summary of Main Results

#### 3 Converse

- 4 Achievability for Uniform Model
- 5 Achievability for Sparse Model
- 6 Coding-Theoretic Interpretations

**E 6 4** 

• Assume that the sensing matrices  $H_1, \ldots, H_k$  are random.

- Assume that the sensing matrices  $H_1, \ldots, H_k$  are random.
- Assume for simplicity that **X** is square  $(n \times n)$

- Assume that the sensing matrices  $H_1, \ldots, H_k$  are random.
- Assume for simplicity that **X** is square  $(n \times n)$
- X has rank  $\leq r \leq n$

- Assume that the sensing matrices  $H_1, \ldots, H_k$  are random.
- Assume for simplicity that **X** is square  $(n \times n)$
- X has rank  $\leq r \leq n$



- Assume that the sensing matrices  $H_1, \ldots, H_k$  are random.
- Assume for simplicity that **X** is square  $(n \times n)$
- X has rank  $\leq r \leq n$



• Arithmetic is performed in the field  $\mathbb{F}_q$ 

- Assume that the sensing matrices  $H_1, \ldots, H_k$  are random.
- Assume for simplicity that **X** is square  $(n \times n)$
- X has rank  $\leq r \leq n$



- Arithmetic is performed in the field  $\mathbb{F}_q$
- Each measurement  $y_a, a = 1, \ldots, k$  belongs to  $\mathbb{F}_q$

• Problem Statement: Given  $(y^k, \mathbf{H}^k)$  and the measurement model, estimate **X**.

- Problem Statement: Given  $(y^k, \mathbf{H}^k)$  and the measurement model, estimate **X**.
- Find necessary and sufficient conditions on *k* and sensing model such that recovery is reliable, i.e.,

$$\mathbb{P}(\mathcal{E}_n) \to 0$$

- Converse without assuming linear model
  - Lower bound on number of measurements k

∃ >

< 67 ▶

- Converse without assuming linear model
  - Lower bound on number of measurements k
- Achievability under uniform sampling model
  - Sufficient condition that matches lower bound
  - Reliability function for the particular decoder

- Converse without assuming linear model
  - Lower bound on number of measurements k
- Achievability under uniform sampling model
  - Sufficient condition that matches lower bound
  - Reliability function for the particular decoder
- Achievability under sparse sampling model
  - Sufficient condition that matches lower bound

- Converse without assuming linear model
  - Lower bound on number of measurements k
- Achievability under uniform sampling model
  - Sufficient condition that matches lower bound
  - Reliability function for the particular decoder
- Achievability under sparse sampling model
  - Sufficient condition that matches lower bound
- Coding-theoretic interpretations: Geometric insights

# Main Results

- k: Num. of linear measurements
- n: Dim. of matrix X
- r: Max. rank of matrix X
- $\gamma = \frac{r}{n}$ : Rank-dimension ratio

∃ ► < ∃</p>

< 17 ▶
- k: Num. of linear measurements
- n: Dim. of matrix X
- r: Max. rank of matrix X
- $\gamma = \frac{r}{n}$ : Rank-dimension ratio

$$2\gamma (1 - \gamma/2) n^2$$
$$= 2rn - r^2$$

∃ ► 4 Ξ

< 17 ▶

- k: Num. of linear measurements
- n: Dim. of matrix X
- r: Max. rank of matrix X
- $\gamma = \frac{r}{n}$ : Rank-dimension ratio

$$2\gamma (1 - \gamma/2) n^2$$
$$= 2rn - r^2$$

Result	Statement	Consequence
--------	-----------	-------------

∃ ► < ∃</p>

< 4 ₽ >

- k: Num. of linear measurements
- n: Dim. of matrix X
- r: Max. rank of matrix X
- $\gamma = \frac{r}{n}$ : Rank-dimension ratio

$$2\gamma (1 - \gamma/2) n^2$$
$$= 2rn - r^2$$

Result	Statement	Consequence
Converse	$k < (2 - \varepsilon)\gamma(1 - \gamma/2)n^2$	$\mathbb{P}(\mathcal{E}) \rightarrow 0$

∃ ► 4 Ξ

< 17 ▶

- k: Num. of linear measurements
- n: Dim. of matrix X
- r: Max. rank of matrix X
- $\gamma = \frac{r}{n}$ : Rank-dimension ratio

$$2\gamma (1 - \gamma/2) n^2$$
$$= 2rn - r^2$$

Result	Statement	Consequence
Converse	$k < (2 - \varepsilon)\gamma(1 - \gamma/2)n^2$	$\mathbb{P}(\mathcal{E}_n)  ightarrow 0$
		$\mathbb{P}(\mathcal{E}_n) \to 0$
Achievability (Uniform)	$k > (2 + \varepsilon)\gamma(1 - \gamma/2)n^2$	$\mathbb{P}(\mathcal{E}_n) \approx q^{-n^2 E(R)}$

∃ ► 4 Ξ

< 17 ▶

- k: Num. of linear measurements
- n: Dim. of matrix X
- r: Max. rank of matrix X
- $\gamma = \frac{r}{n}$ : Rank-dimension ratio

$$2\gamma (1 - \gamma/2) n^2$$
$$= 2rn - r^2$$

Result	Statement	Consequence
Converse	$k < (2 - \varepsilon)\gamma(1 - \gamma/2)n^2$	$\mathbb{P}(\mathcal{E}_n)  ightarrow 0$
		$\mathbb{P}(\mathcal{E}_n)  o 0$
Achievability (Uniform)	$k > (2+\varepsilon)\gamma(1-\gamma/2)n^2$	$\mathbb{P}(\mathcal{E}_n) \approx q^{-n^2 E(R)}$
Achievability (Sparse)	$k > (2 + \varepsilon)\gamma(1 - \gamma/2)n^2$	$\mathbb{P}(\mathcal{E}_n)  o 0$

(4) (5) (4) (5)

< 4 ₽ >

- k: Num. of linear measurements
- n: Dim. of matrix X
- r: Max. rank of matrix X
- $\gamma = \frac{r}{n}$ : Rank-dimension ratio

$$2\gamma (1 - \gamma/2) n^2$$
$$= 2rn - r^2$$

Result	Statement	Consequence
Converse	$k < (2 - \varepsilon)\gamma(1 - \gamma/2)n^2$	$\mathbb{P}(\mathcal{E}_n) \not\rightarrow 0$
		$\mathbb{P}(\mathcal{E}_n)  o 0$
Achievability (Uniform)	$k > (2 + \varepsilon)\gamma(1 - \gamma/2)n^2$	$\mathbb{P}(\mathcal{E}_n) \approx q^{-n^2 E(R)}$
Achievability (Sparse)	$k > (2 + \varepsilon)\gamma(1 - \gamma/2)n^2$	$\mathbb{P}(\mathcal{E}_n)  o 0$
Achievability (Noisy)	$k \gtrsim (3+\varepsilon)(\gamma+\sigma)n^2$	$\mathbb{P}(\mathcal{E}_n) \to 0$
	(q assumed large)	

< 17 ▶

# Motivation

Problem Setup and Summary of Main Results

#### Converse

- 4 Achievability for Uniform Model
- 5 Achievability for Sparse Model
- 6 Coding-Theoretic Interpretations

3 1 4 3

< 🗐 🕨

Given *k* measurements  $y_a \in \mathbb{F}_q$  and sensing matrices  $\mathbf{H}_a \in \mathbb{F}_q^{n \times n}$ , we want a necessary condition for reliable recovery of **X**.

Given *k* measurements  $y_a \in \mathbb{F}_q$  and sensing matrices  $\mathbf{H}_a \in \mathbb{F}_q^{n \times n}$ , we want a necessary condition for reliable recovery of **X**.

#### Proposition (Converse)

Assume

• **X** drawn uniformly at random from all matrices in  $\mathbb{F}_{a}^{n \times n}$  of rank  $\leq r$ 

э

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

Given *k* measurements  $y_a \in \mathbb{F}_q$  and sensing matrices  $\mathbf{H}_a \in \mathbb{F}_q^{n \times n}$ , we want a necessary condition for reliable recovery of **X**.

#### Proposition (Converse)

Assume

- **X** drawn uniformly at random from all matrices in  $\mathbb{F}_q^{n \times n}$  of rank  $\leq r$
- Sensing matrices H<sub>a</sub> independent of X

э

Given *k* measurements  $y_a \in \mathbb{F}_q$  and sensing matrices  $\mathbf{H}_a \in \mathbb{F}_q^{n \times n}$ , we want a necessary condition for reliable recovery of **X**.

#### Proposition (Converse)

Assume

- X drawn uniformly at random from all matrices in  $\mathbb{F}_q^{n \times n}$  of rank  $\leq r$
- Sensing matrices **H**<sub>a</sub> independent of **X**
- $r/n \rightarrow \gamma$  (constant)

э.

Given *k* measurements  $y_a \in \mathbb{F}_q$  and sensing matrices  $\mathbf{H}_a \in \mathbb{F}_q^{n \times n}$ , we want a necessary condition for reliable recovery of **X**.

#### Proposition (Converse)

Assume

- X drawn uniformly at random from all matrices in  $\mathbb{F}_q^{n \times n}$  of rank  $\leq r$
- Sensing matrices H<sub>a</sub> independent of X
- $r/n \rightarrow \gamma$  (constant)

If the number of measurements satisfies

$$k < (2 - \varepsilon) \gamma \left( 1 - \frac{\gamma}{2} \right) n^2$$

then  $\mathbb{P}(\hat{\mathbf{X}} \neq \mathbf{X}) \geq \varepsilon/2$  for all *n* sufficiently large.

э

Ramifications:

• We need at least

$$k \ge 2\gamma \left(1 - \frac{\gamma}{2}\right) n^2$$

measurements for successful recovery

Ramifications:

• We need at least

$$k \ge 2\gamma \left(1 - \frac{\gamma}{2}\right) n^2$$

measurements for successful recovery

• Need as many measurements as there are degrees of freedom

Ramifications:

We need at least

$$k \ge 2\gamma \left(1 - \frac{\gamma}{2}\right) n^2$$

measurements for successful recovery

- Need as many measurements as there are degrees of freedom
- Fano's inequality and counting

## Motivation

2 Problem Setup and Summary of Main Results

#### B) Converse

- 4 Achievability for Uniform Model
- 5 Achievability for Sparse Model
- 6 Coding-Theoretic Interpretations

THE 1 1

< 🗐 🕨

Now we assume that X is non-random

< 4 ₽ >

- Now we assume that X is non-random
- $\operatorname{rank}(\mathbf{X}) \leq r = \gamma n$

< 17 ▶

- Now we assume that X is non-random
- $rank(\mathbf{X}) \leq r = \gamma n$



- Now we assume that X is non-random
- $\operatorname{rank}(\mathbf{X}) \leq r = \gamma n$



Each entry of each sensing matrix H<sub>a</sub> is i.i.d. and has a uniform distribution in F<sub>q</sub>:

$$\mathbb{P}([\mathbf{H}_a]_{i,j} = h) = \frac{1}{q}, \qquad \forall h \in \mathbb{F}_q$$

minimize 
$$\operatorname{rank}(\tilde{\mathbf{X}})$$
  
subject to  $\langle \mathbf{H}_a, \tilde{\mathbf{X}} \rangle = y_a, \quad a = 1, \dots, k$ 

< 17 ▶

minimize 
$$\operatorname{rank}(\tilde{\mathbf{X}})$$
  
subject to  $\langle \mathbf{H}_a, \tilde{\mathbf{X}} \rangle = y_a, \quad a = 1, \dots, k$ 

#### • NP-hard, combinatorial

minimize 
$$\operatorname{rank}(\tilde{\mathbf{X}})$$
  
subject to  $\langle \mathbf{H}_a, \tilde{\mathbf{X}} \rangle = y_a, \quad a = 1, \dots, k$ 

- NP-hard, combinatorial
- $\bullet\,$  Denote the set of optimizers as  ${\cal S}\,$

minimize 
$$\operatorname{rank}(\tilde{\mathbf{X}})$$
  
subject to  $\langle \mathbf{H}_a, \tilde{\mathbf{X}} \rangle = y_a, \quad a = 1, \dots, k$ 

- NP-hard, combinatorial
- Denote the set of optimizers as S
- Define the error event:

$$\mathcal{E}_n := \{|\mathcal{S}| > 1\} \cup (\{|\mathcal{S}| = 1\} \cap \{\mathbf{X}^* \neq \mathbf{X}\})$$

minimize 
$$\operatorname{rank}(\tilde{\mathbf{X}})$$
  
subject to  $\langle \mathbf{H}_a, \tilde{\mathbf{X}} \rangle = y_a, \quad a = 1, \dots, k$ 

- NP-hard, combinatorial
- $\bullet\,$  Denote the set of optimizers as  ${\cal S}\,$
- Define the error event:

$$\mathcal{E}_n := \{|\mathcal{S}| > 1\} \cup (\{|\mathcal{S}| = 1\} \cap \{\mathbf{X}^* \neq \mathbf{X}\})$$

• We want the solution to be unique and correct

Assume

• Sensing matrices H<sub>a</sub> drawn uniformly

Assume

- Sensing matrices H<sub>a</sub> drawn uniformly
- Min-rank decoder is used

・ 同 ト ・ ヨ ト ・ ヨ

Assume

- Sensing matrices H<sub>a</sub> drawn uniformly
- Min-rank decoder is used
- $r/n \rightarrow \gamma$  (constant)

< ロ > < 同 > < 回 > < 回 >

Assume

- Sensing matrices H<sub>a</sub> drawn uniformly
- Min-rank decoder is used
- $r/n \rightarrow \gamma$  (constant)

If the number of measurements satisfies

$$k > (2 + \varepsilon)\gamma \left(1 - \frac{\gamma}{2}\right)n^2$$

then  $\mathbb{P}(\mathcal{E}_n) \to 0$ .

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

By the union bound, the error probability can be bounded as

$$\mathbb{P}(\mathcal{E}_n) \leq \sum_{\mathbf{Z} \neq \mathbf{X}: \operatorname{rank}(\mathbf{Z}) \leq \operatorname{rank}(\mathbf{X})} \mathbb{P}(\langle \mathbf{Z}, \mathbf{H}_a \rangle = \langle \mathbf{X}, \mathbf{H}_a \rangle, \forall a = 1, \dots, k)$$

→ 3 → 4 3

< 17 ▶

By the union bound, the error probability can be bounded as

$$\mathbb{P}(\mathcal{E}_n) \leq \sum_{\mathbf{Z} \neq \mathbf{X}: \operatorname{rank}(\mathbf{Z}) \leq \operatorname{rank}(\mathbf{X})} \mathbb{P}(\langle \mathbf{Z}, \mathbf{H}_a \rangle = \langle \mathbf{X}, \mathbf{H}_a \rangle, \forall a = 1, \dots, k)$$

At the same time, by uniformity and independence,

$$\mathbb{P}(\langle \mathbf{Z}, \mathbf{H}_a \rangle = \langle \mathbf{X}, \mathbf{H}_a \rangle, \forall a = 1, \dots, k) = q^{-k}$$

< ロ > < 同 > < 回 > < 回 >

By the union bound, the error probability can be bounded as

$$\mathbb{P}(\mathcal{E}_n) \leq \sum_{\mathbf{Z} \neq \mathbf{X}: \operatorname{rank}(\mathbf{Z}) \leq \operatorname{rank}(\mathbf{X})} \mathbb{P}(\langle \mathbf{Z}, \mathbf{H}_a \rangle = \langle \mathbf{X}, \mathbf{H}_a \rangle, \forall a = 1, \dots, k)$$

At the same time, by uniformity and independence,

$$\mathbb{P}(\langle \mathbf{Z}, \mathbf{H}_a \rangle = \langle \mathbf{X}, \mathbf{H}_a \rangle, \forall a = 1, \dots, k) = q^{-k}$$

That the number of matrices of rank  $\leq r$  is bounded above as

$$4q^{2\gamma(1-\gamma/2)n^2}$$

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

• Recall the lower bound:

$$k \ge 2\gamma \left(1 - \frac{\gamma}{2}\right) n^2$$

• Recall the lower bound:

$$k \ge 2\gamma \left(1 - \frac{\gamma}{2}\right) n^2$$

• Thus, min-rank decoder matches the lower bound

• Recall the lower bound:

$$k \ge 2\gamma \left(1 - \frac{\gamma}{2}\right) n^2$$

- Thus, min-rank decoder matches the lower bound
- Optimal measurement complexity

• Recall the lower bound:

$$k \ge 2\gamma \left(1 - \frac{\gamma}{2}\right) n^2$$

- Thus, min-rank decoder matches the lower bound
- Optimal measurement complexity
- Can we provide a precise rate of convergence of  $\mathbb{P}(\mathcal{E}_n)$ ?
# Remarks for the sufficient condition

• Recall the lower bound:

$$k \ge 2\gamma \left(1 - \frac{\gamma}{2}\right) n^2$$

- Thus, min-rank decoder matches the lower bound
- Optimal measurement complexity
- Can we provide a precise rate of convergence of  $\mathbb{P}(\mathcal{E}_n)$ ?
- Reliability Function?

The rate of a sequence of linear measurement models is defined as

$$R := \lim_{n \to \infty} \frac{n^2 - k}{n^2} = \lim_{n \to \infty} 1 - \frac{k}{n^2}, \qquad k = \#$$
 measurements

4 A N

nac

The rate of a sequence of linear measurement models is defined as

$$R := \lim_{n \to \infty} \frac{n^2 - k}{n^2} = \lim_{n \to \infty} 1 - \frac{k}{n^2}, \qquad k = \#$$
 measurements

Analogy to coding: The rate of the code

$$\mathcal{C} = \{\mathbf{C} : \langle \mathbf{C}, \mathbf{H}_a \rangle = 0, a = 1, \dots, k\}$$

is lower bounded by  $1 - k/n^2$ .

The reliability function of the min-rank decoder is defined as

$$E(R) := \lim_{n \to \infty} -\frac{1}{n^2} \log_q \mathbb{P}(\mathcal{E}_n)$$

The reliability function of the min-rank decoder is defined as

$$E(R) := \lim_{n \to \infty} -\frac{1}{n^2} \log_q \mathbb{P}(\mathcal{E}_n)$$

Roughly speaking,

$$\mathbb{P}(\mathcal{E}_n) \approx q^{-n^2 E(R)}$$

The reliability function of the min-rank decoder is defined as

$$E(R) := \lim_{n \to \infty} -\frac{1}{n^2} \log_q \mathbb{P}(\mathcal{E}_n)$$

Roughly speaking,

$$\mathbb{P}(\mathcal{E}_n) \approx q^{-n^2 E(R)}$$

Reliability function also known as error exponent

. . . . . . .

A D M A A A M M

nac

# The Reliability Function

• Our achievability proof gives a lower bound on E(R)

# The Reliability Function

- Our achievability proof gives a lower bound on E(R)
- Upper bound is more tricky. But...

- Our achievability proof gives a lower bound on E(R)
- Upper bound is more tricky. But...

Assume

• Sensing matrices H<sub>a</sub> drawn uniformly

• □ ▶ • # # ▶ • = ▶ •

- Our achievability proof gives a lower bound on E(R)
- Upper bound is more tricky. But...

Assume

- Sensing matrices H<sub>a</sub> drawn uniformly
- Min-rank decoder is used

∃ ▶ ∢

A D M A A A M M

- Our achievability proof gives a lower bound on E(R)
- Upper bound is more tricky. But...

Assume

- Sensing matrices H<sub>a</sub> drawn uniformly
- Min-rank decoder is used
- $r/n \rightarrow \gamma$  (constant)

- Our achievability proof gives a lower bound on E(R)
- Upper bound is more tricky. But...

Assume

- Sensing matrices H<sub>a</sub> drawn uniformly
- Min-rank decoder is used
- $r/n \rightarrow \gamma$  (constant)

Then,

$$E(R) = \left| (1-R) - 2\gamma \left( 1 - \frac{\gamma}{2} \right) \right|^+$$

Note  $|x|^+ := \max\{x, 0\}$ .

200

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

$$E(R) \approx \left| \frac{k}{n^2} - 2\gamma \left( 1 - \frac{\gamma}{2} \right) \right|^+$$

æ

<ロト < 回 > < 回 > < 回 > < 回 >

$$E(R) \approx \left| \frac{k}{n^2} - 2\gamma \left( 1 - \frac{\gamma}{2} \right) \right|^+$$

• The more the ratio  $\frac{k}{n^2}$  exceeds  $2\gamma \left(1 - \frac{\gamma}{2}\right)$ 

æ

イロト イポト イヨト イヨト

$$E(R) \approx \left| \frac{k}{n^2} - 2\gamma \left( 1 - \frac{\gamma}{2} \right) \right|^+$$

- The more the ratio  $\frac{k}{n^2}$  exceeds  $2\gamma \left(1 \frac{\gamma}{2}\right)$
- The larger E(R)

3

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

$$E(R) \approx \left| \frac{k}{n^2} - 2\gamma \left( 1 - \frac{\gamma}{2} \right) \right|^+$$

- The more the ratio  $\frac{k}{n^2}$  exceeds  $2\gamma \left(1 \frac{\gamma}{2}\right)$
- The larger E(R)
- The faster  $\mathbb{P}(\mathcal{E}_n)$  decays

э

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

$$E(R) \approx \left| \frac{k}{n^2} - 2\gamma \left( 1 - \frac{\gamma}{2} \right) \right|^+$$

- The more the ratio  $\frac{k}{n^2}$  exceeds  $2\gamma \left(1 \frac{\gamma}{2}\right)$
- The larger E(R)
- The faster  $\mathbb{P}(\mathcal{E}_n)$  decays
- Linear relationship

★ 3 > ★ 3

• 
$$E(R) \approx \left|\frac{k}{n^2} - 2\gamma \left(1 - \frac{\gamma}{2}\right)\right|^+$$

• Proof of upper bound on *E*(*R*) is interesting

• 
$$E(R) \approx \left|\frac{k}{n^2} - 2\gamma \left(1 - \frac{\gamma}{2}\right)\right|^+$$

- Proof of upper bound on *E*(*R*) is interesting
- It utilizes de Caen's lower bound: Let  $\mathcal{B}_1, \ldots, \mathcal{B}_M$  be events:

$$\mathbb{P}\left(\bigcup_{m=1}^{M} \mathcal{B}_{m}\right) \geq \sum_{m=1}^{M} \frac{\mathbb{P}(\mathcal{B}_{m})^{2}}{\sum_{m'=1}^{M} \mathbb{P}(\mathcal{B}_{m} \cap \mathcal{B}_{m'})}.$$

• 
$$E(R) \approx \left|\frac{k}{n^2} - 2\gamma \left(1 - \frac{\gamma}{2}\right)\right|^+$$

- Proof of upper bound on *E*(*R*) is interesting
- It utilizes de Caen's lower bound: Let  $\mathcal{B}_1, \ldots, \mathcal{B}_M$  be events:

$$\mathbb{P}\left(\bigcup_{m=1}^{M} \mathcal{B}_{m}\right) \geq \sum_{m=1}^{M} \frac{\mathbb{P}(\mathcal{B}_{m})^{2}}{\sum_{m'=1}^{M} \mathbb{P}(\mathcal{B}_{m} \cap \mathcal{B}_{m'})}.$$

• Pairwise independence of error events

• 
$$E(R) \approx \left|\frac{k}{n^2} - 2\gamma \left(1 - \frac{\gamma}{2}\right)\right|^+$$

- Proof of upper bound on *E*(*R*) is interesting
- It utilizes de Caen's lower bound: Let  $\mathcal{B}_1, \ldots, \mathcal{B}_M$  be events:

$$\mathbb{P}\left(\bigcup_{m=1}^{M} \mathcal{B}_{m}\right) \geq \sum_{m=1}^{M} \frac{\mathbb{P}(\mathcal{B}_{m})^{2}}{\sum_{m'=1}^{M} \mathbb{P}(\mathcal{B}_{m} \cap \mathcal{B}_{m'})}.$$

- Pairwise independence of error events
- Analogy: Linear codes achieve capacity for symmetric DMCs

• 
$$E(R) \approx \left|\frac{k}{n^2} - 2\gamma \left(1 - \frac{\gamma}{2}\right)\right|^+$$

- Proof of upper bound on *E*(*R*) is interesting
- It utilizes de Caen's lower bound: Let  $\mathcal{B}_1, \ldots, \mathcal{B}_M$  be events:

$$\mathbb{P}\left(\bigcup_{m=1}^{M} \mathcal{B}_{m}\right) \geq \sum_{m=1}^{M} \frac{\mathbb{P}(\mathcal{B}_{m})^{2}}{\sum_{m'=1}^{M} \mathbb{P}(\mathcal{B}_{m} \cap \mathcal{B}_{m'})}.$$

- Pairwise independence of error events
- Analogy: Linear codes achieve capacity for symmetric DMCs
- de Caen's inequality allows us to exploit pairwise independence to make statements about error exponents

• 
$$E(R) \approx \left|\frac{k}{n^2} - 2\gamma \left(1 - \frac{\gamma}{2}\right)\right|^+$$

- Proof of upper bound on *E*(*R*) is interesting
- It utilizes de Caen's lower bound: Let  $\mathcal{B}_1, \ldots, \mathcal{B}_M$  be events:

$$\mathbb{P}\left(\bigcup_{m=1}^{M} \mathcal{B}_{m}\right) \geq \sum_{m=1}^{M} \frac{\mathbb{P}(\mathcal{B}_{m})^{2}}{\sum_{m'=1}^{M} \mathbb{P}(\mathcal{B}_{m} \cap \mathcal{B}_{m'})}.$$

- Pairwise independence of error events
- Analogy: Linear codes achieve capacity for symmetric DMCs
- de Caen's inequality allows us to exploit pairwise independence to make statements about error exponents
- Union bound in achievability is tight!

• All the preceding analyses can be extended to the noisy case:

$$y_a = \langle \mathbf{H}_a, \mathbf{X} \rangle + w_a$$

• All the preceding analyses can be extended to the noisy case:

$$y_a = \langle \mathbf{H}_a, \mathbf{X} \rangle + w_a$$

• Noise  $w_a$  can be random or deterministic but assume  $\|\mathbf{w}\|_0 = \sigma n^2$ 

• All the preceding analyses can be extended to the noisy case:

 $y_a = \langle \mathbf{H}_a, \mathbf{X} \rangle + w_a$ 

• Noise  $w_a$  can be random or deterministic but assume  $\|\mathbf{w}\|_0 = \sigma n^2$ 

$$\begin{array}{ll} \text{minimize} & \operatorname{rank}(\tilde{\mathbf{X}}) + \lambda \|\tilde{\mathbf{w}}\|_{0} \\ \text{subject to} & \langle \mathbf{H}_{a}, \tilde{\mathbf{X}} \rangle + \tilde{w}_{a} = y_{a}, \quad a = 1, \dots, k \end{array}$$

• All the preceding analyses can be extended to the noisy case:

$$y_a = \langle \mathbf{H}_a, \mathbf{X} \rangle + w_a$$

• Noise  $w_a$  can be random or deterministic but assume  $\|\mathbf{w}\|_0 = \sigma n^2$ 

$$\begin{array}{ll} \text{minimize} & \operatorname{rank}(\tilde{\mathbf{X}}) + \lambda \|\tilde{\mathbf{w}}\|_{0} \\ \text{subject to} & \langle \mathbf{H}_{a}, \tilde{\mathbf{X}} \rangle + \tilde{w}_{a} = y_{a}, \quad a = 1, \dots, k \end{array}$$

• Choose  $\lambda = 1/n$ 

590

< 回 > < 三 > < 三 >

• All the preceding analyses can be extended to the noisy case:

$$y_a = \langle \mathbf{H}_a, \mathbf{X} \rangle + w_a$$

• Noise  $w_a$  can be random or deterministic but assume  $\|\mathbf{w}\|_0 = \sigma n^2$ 

$$\begin{array}{ll} \text{minimize} & \operatorname{rank}(\tilde{\mathbf{X}}) + \lambda \|\tilde{\mathbf{w}}\|_{0} \\ \text{subject to} & \langle \mathbf{H}_{a}, \tilde{\mathbf{X}} \rangle + \tilde{w}_{a} = y_{a}, \quad a = 1, \dots, k \end{array}$$

• Choose  $\lambda = 1/n$ 

If

$$k \gtrsim (3+\varepsilon)(\gamma+\sigma)n^2,$$

 $\mathbb{P}(\mathcal{E}_n) \to 0$ . See preprint

# Motivation

2 Problem Setup and Summary of Main Results

#### 3 Converse

- 4 Achievability for Uniform Model
- 5 Achievability for Sparse Model
- 6 Coding-Theoretic Interpretations

The 14 at 14

• Assume as usual that X is non-random

< 17 ▶

→ Ξ →

• Assume as usual that X is non-random

• 
$$\operatorname{rank}(\mathbf{X}) \leq r = \gamma n$$

→ Ξ →

< 17 ▶

- Assume as usual that X is non-random
- $\operatorname{rank}(\mathbf{X}) \leq r = \gamma n$
- Sensing matrices are sparse



< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

- Assume as usual that X is non-random
- $\operatorname{rank}(\mathbf{X}) \leq r = \gamma n$
- Sensing matrices are sparse



• Arithmetic still performed in  $\mathbb{F}_q$ 

Each entry of each sensing matrix H<sub>a</sub> is i.i.d. and has a δ-sparse distribution in F<sub>q</sub>:



Each entry of each sensing matrix H<sub>a</sub> is i.i.d. and has a δ-sparse distribution in F<sub>q</sub>:



• Fewer adds and multiplies since  $\mathbf{H}_a$  sparse  $\Rightarrow$  Encoding cheaper

Each entry of each sensing matrix H<sub>a</sub> is i.i.d. and has a δ-sparse distribution in F<sub>q</sub>:



- Fewer adds and multiplies since **H**<sub>a</sub> sparse ⇒ Encoding cheaper
- May help in decoding via message-passing algorithms
# Sparse sensing model

Each entry of each sensing matrix H<sub>a</sub> is i.i.d. and has a δ-sparse distribution in F<sub>q</sub>:



- Fewer adds and multiplies since **H**<sub>a</sub> sparse ⇒ Encoding cheaper
- May help in decoding via message-passing algorithms
- How fast can  $\delta$ , the sparsity factor, decay with *n* for reliable recovery?

#### Problem becomes more challenging

∃ → 4

< 17 ▶

- Problem becomes more challenging
- X is not sensed "as much"

- Problem becomes more challenging
- X is not sensed "as much"
- Measurements *y*<sup>*k*</sup> do not contain as much information about **X**

- Problem becomes more challenging
- X is not sensed "as much"
- Measurements *y*<sup>*k*</sup> do not contain as much information about **X**
- The equality

$$\mathbb{P}(\langle \mathbf{Z}, \mathbf{H}_a \rangle = \langle \mathbf{X}, \mathbf{H}_a \rangle, \forall a = 1, \dots, k) = q^{-k}$$

no longer holds

- Problem becomes more challenging
- X is not sensed "as much"
- Measurements *y*<sup>*k*</sup> do not contain as much information about **X**
- The equality

$$\mathbb{P}(\langle \mathbf{Z}, \mathbf{H}_a \rangle = \langle \mathbf{X}, \mathbf{H}_a \rangle, \forall a = 1, \dots, k) = q^{-k}$$

no longer holds

Nevertheless....

### Theorem (Achievability under sparse model)

Assume

• Sensing matrices  $\mathbf{H}_a$  drawn according to  $\delta$ -sparse distribution

## Theorem (Achievability under sparse model)

Assume

- Sensing matrices  $\mathbf{H}_a$  drawn according to  $\delta$ -sparse distribution
- Min-rank decoder is used

## Theorem (Achievability under sparse model)

Assume

- Sensing matrices  $\mathbf{H}_a$  drawn according to  $\delta$ -sparse distribution
- Min-rank decoder is used
- $r/n \rightarrow \gamma$  (constant)

## Theorem (Achievability under sparse model)

Assume

- Sensing matrices  $\mathbf{H}_a$  drawn according to  $\delta$ -sparse distribution
- Min-rank decoder is used
- $r/n \rightarrow \gamma$  (constant)

If the sparsity factor satisfies

$$\delta \in \Omega\left(\frac{\log n}{n}\right)$$

## Theorem (Achievability under sparse model)

Assume

- Sensing matrices  $\mathbf{H}_a$  drawn according to  $\delta$ -sparse distribution
- Min-rank decoder is used
- $r/n \rightarrow \gamma$  (constant)

If the sparsity factor satisfies

$$\delta \in \Omega\left(\frac{\log n}{n}\right)$$

and the number of measurements satisfies

$$k > (2 + \varepsilon)\gamma \left(1 - \frac{\gamma}{2}\right)n^2$$

then  $\mathbb{P}(\mathcal{E}_n) \to 0$ .

## Remarks on achievability under sparse model

• No loss in measurement complexity

nac

## Remarks on achievability under sparse model

- No loss in measurement complexity
- Average number of entries in  $\mathbf{H}_a$  is  $\Omega(n \log n)$

- No loss in measurement complexity
- Average number of entries in  $\mathbf{H}_a$  is  $\Omega(n \log n)$
- Number of measurements matches uniform model and information-theoretic (Fano's) lower bound

- No loss in measurement complexity
- Average number of entries in  $\mathbf{H}_a$  is  $\Omega(n \log n)$
- Number of measurements matches uniform model and information-theoretic (Fano's) lower bound
- Roughly speaking, if

$$\delta \in \Omega\left(\frac{\log n}{n}\right)$$

probability of error events still "look like" the uniform model

크

$$\mathbb{P}(\mathcal{E}_n) \leq \sum_{\substack{\mathbf{Z} \neq \mathbf{X}: \operatorname{rank}(\mathbf{Z}) \leq \operatorname{rank}(\mathbf{X}) \\ \|\mathbf{Z} - \mathbf{X}\|_0 \leq \beta n^2}} \mathbb{P}(\langle \mathbf{Z}, \mathbf{H}_a \rangle = \langle \mathbf{X}, \mathbf{H}_a \rangle, \forall a = 1, \dots, k)$$

크

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

$$\mathbb{P}(\mathcal{E}_n) \leq \sum_{\substack{\mathbf{Z} \neq \mathbf{X}: \operatorname{rank}(\mathbf{Z}) \leq \operatorname{rank}(\mathbf{X}) \\ \|\mathbf{Z} - \mathbf{X}\|_0 \leq \beta n^2}} \mathbb{P}(\langle \mathbf{Z}, \mathbf{H}_a \rangle = \langle \mathbf{X}, \mathbf{H}_a \rangle, \forall a = 1, \dots, k)$$

+ 
$$\sum_{\substack{\mathbf{Z}\neq\mathbf{X}:\mathrm{rank}(\mathbf{Z})\leq\mathrm{rank}(\mathbf{X})\\\|\mathbf{Z}-\mathbf{X}\|_0>\beta n^2}} \mathbb{P}(\langle\mathbf{Z},\mathbf{H}_a\rangle=\langle\mathbf{X},\mathbf{H}_a\rangle,\forall a=1,\ldots,k)$$

크

$$\mathbb{P}(\mathcal{E}_n) \leq \sum_{\substack{\mathbf{Z} \neq \mathbf{X}: \operatorname{rank}(\mathbf{Z}) \leq \operatorname{rank}(\mathbf{X}) \\ \|\mathbf{Z} - \mathbf{X}\|_0 \leq \beta n^2}} \mathbb{P}(\langle \mathbf{Z}, \mathbf{H}_a \rangle = \langle \mathbf{X}, \mathbf{H}_a \rangle, \forall a = 1, \dots, k)$$

+ 
$$\sum_{\substack{\mathbf{Z}\neq\mathbf{X}:\mathrm{rank}(\mathbf{Z})\leq\mathrm{rank}(\mathbf{X})\\ \|\mathbf{Z}-\mathbf{X}\|_0>\beta n^2}} \mathbb{P}(\langle \mathbf{Z},\mathbf{H}_a\rangle=\langle \mathbf{X},\mathbf{H}_a\rangle,\forall a=1,\ldots,k)$$

- First term
  - Few terms
  - Low Hamming weight can afford loose bound on probability

3

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

$$\mathbb{P}(\mathcal{E}_n) \leq \sum_{\substack{\mathbf{Z} \neq \mathbf{X}: \operatorname{rank}(\mathbf{Z}) \leq \operatorname{rank}(\mathbf{X}) \\ \|\mathbf{Z} - \mathbf{X}\|_0 \leq \beta n^2}} \mathbb{P}(\langle \mathbf{Z}, \mathbf{H}_a \rangle = \langle \mathbf{X}, \mathbf{H}_a \rangle, \forall a = 1, \dots, k)$$

+ 
$$\sum_{\substack{\mathbf{Z}\neq\mathbf{X}:\mathrm{rank}(\mathbf{Z})\leq\mathrm{rank}(\mathbf{X})\\\|\mathbf{Z}-\mathbf{X}\|_0>\beta n^2}} \mathbb{P}(\langle\mathbf{Z},\mathbf{H}_a\rangle=\langle\mathbf{X},\mathbf{H}_a\rangle,\forall a=1,\ldots,k)$$

- First term
  - Few terms
  - Low Hamming weight can afford loose bound on probability
- Second term
  - Many terms
  - Tight bound on probability (circular convolution of  $\delta$ -sparse pmf)

40/49

## Motivation

2 Problem Setup and Summary of Main Results

## 3 Converse

- 4 Achievability for Uniform Model
- 5 Achievability for Sparse Model
- 6 Coding-Theoretic Interpretations

The 14 at 14

• Recall that a rank-metric code C is a non-empty subset of  $\mathbb{F}_q^{m \times n}$  endowed with the rank distance

- Recall that a rank-metric code C is a non-empty subset of  $\mathbb{F}_q^{m \times n}$  endowed with the rank distance
- The minimum rank distance decoding problem

 $\min_{C \in \mathcal{C}} \ \text{rank}(R-C)$ 

is in one-to-one correspondence to the rank minimization problem

- Recall that a rank-metric code C is a non-empty subset of  $\mathbb{F}_q^{m \times n}$  endowed with the rank distance
- The minimum rank distance decoding problem

 $\min_{C \in \mathcal{C}} \ \text{rank}(R-C)$ 

is in one-to-one correspondence to the rank minimization problem

minimize rank( $\mathbf{X}$ ) subject to  $\langle \mathbf{H}_a, \mathbf{X} \rangle = y_a, \quad a = 1, \dots, k$ 

with the identification  $\mathbf{X} \equiv \mathbf{R} - \mathbf{C}$  and

- Recall that a rank-metric code C is a non-empty subset of  $\mathbb{F}_q^{m \times n}$  endowed with the rank distance
- The minimum rank distance decoding problem

 $\min_{C \in \mathcal{C}} \ \text{rank}(R-C)$ 

is in one-to-one correspondence to the rank minimization problem

minimize rank(**X**)  
subject to 
$$\langle \mathbf{H}_a, \mathbf{X} \rangle = y_a, \quad a = 1, \dots, k$$

with the identification  $\mathbf{X} \equiv \mathbf{R} - \mathbf{C}$  and

$$\mathcal{C} := \{ \mathbf{C} : \langle \mathbf{C}, \mathbf{H}_a \rangle = 0, a = 1, \dots, k \}$$

#### Definition

The minimum rank distance of a rank-metric code C is

$$d(\mathcal{C}) := \min_{\mathbf{C}_1, \mathbf{C}_2 \in \mathcal{C}: \mathbf{C}_1 \neq \mathbf{C}_2} \operatorname{rank}(\mathbf{C}_1 - \mathbf{C}_2)$$

#### Definition

The minimum rank distance of a rank-metric code C is

$$d(\mathcal{C}) := \min_{\mathbf{C}_1, \mathbf{C}_2 \in \mathcal{C}: \mathbf{C}_1 \neq \mathbf{C}_2} \operatorname{rank}(\mathbf{C}_1 - \mathbf{C}_2)$$

If the code is linear (as it is)

$$d(\mathcal{C}) := \min_{\mathbf{C} \in \mathcal{C}: \mathbf{C} \neq \mathbf{0}} \operatorname{rank}(\mathbf{C})$$

How does d(C) behave for the random linear rank-metric code under the uniform and sparse models?

## Minimum rank distance

The rate of the code is defined as

$$R = 1 - \frac{k}{n^2}$$

→ Ξ →

The rate of the code is defined as

$$R = 1 - \frac{k}{n^2}$$

## Proposition (Concentration of minimum rank distance)

For the uniform model, with probability approaching 1 as  $n \to \infty$ , the relative minimum distance satisfies

$$\frac{d(\mathcal{C})}{n} \in (1 - \sqrt{R} - \varepsilon, 1 - \sqrt{R} + \varepsilon)$$

## Minimum rank distance: Interpretation

• The rate-dependent function

$$\gamma_{\rm GV}(R) := 1 - \sqrt{R}$$

can be regarded as the "Gilbert-Varshamov distance" of the random rank-metric code

## Minimum rank distance: Interpretation

• The rate-dependent function

$$\gamma_{\rm GV}(R) := 1 - \sqrt{R}$$

can be regarded as the "Gilbert-Varshamov distance" of the random rank-metric code

• Barg and Forney (2002) derived similar properties for the binary Hamming case

## Minimum rank distance: Interpretation

• The rate-dependent function

$$\gamma_{\rm GV}(R) := 1 - \sqrt{R}$$

can be regarded as the "Gilbert-Varshamov distance" of the random rank-metric code

 Barg and Forney (2002) derived similar properties for the binary Hamming case

Uniform rank-metric code has minimum distance

$$n\gamma_{\rm GV}({\it R})=n(1-\sqrt{\it R})$$

with high probability for n large



# Ramification in terms of measurement complexity for uniform model

For successful recovery of X on average,

relative minimum distance  $\geq$  rank-dimension ratio

# Ramification in terms of measurement complexity for uniform model

For successful recovery of X on average,

relative minimum distance  $\geq$  rank-dimension ratio

Achievability result may be derived by setting  $R = 1 - \frac{k}{n^2}$  and considering

$$\gamma_{\mathsf{GV}}(\mathbf{R}) = 1 - \sqrt{\mathbf{R}} - \varepsilon \ge \gamma = \frac{r}{n}$$

For successful recovery of X on average,

relative minimum distance  $\geq$  rank-dimension ratio

Achievability result may be derived by setting  $R = 1 - \frac{k}{n^2}$  and considering

$$\gamma_{\mathsf{GV}}(\mathbf{R}) = 1 - \sqrt{\mathbf{R}} - \varepsilon \ge \gamma = \frac{r}{n}$$

which is equivalent to

$$k \ge (2 + \varepsilon')\gamma\left(1 - \frac{\gamma}{2}\right)n^2$$

## Minimum distances for the sparse model

#### Proposition (Concentration of minimum rank distance)

For the

$$\delta = \Omega\left(\frac{\log n}{n}\right)$$

sparse model, with probability approaching 1 as  $n \to \infty$ , the relative minimum distance satisfies

$$\frac{d(\mathcal{C})}{n} \ge 1 - \sqrt{R} - \varepsilon$$
## Minimum distances for the sparse model

## Proposition (Concentration of minimum rank distance)

For the

$$\delta = \Omega\left(\frac{\log n}{n}\right)$$

sparse model, with probability approaching 1 as  $n \to \infty$ , the relative minimum distance satisfies

$$\frac{d(\mathcal{C})}{n} \ge 1 - \sqrt{R} - \varepsilon$$

 The minimum distance properties of the uniform and sparse models are identical

## Minimum distances for the sparse model

## Proposition (Concentration of minimum rank distance)

For the

$$\delta = \Omega\left(\frac{\log n}{n}\right)$$

sparse model, with probability approaching 1 as  $n \to \infty$ , the relative minimum distance satisfies

$$\frac{d(\mathcal{C})}{n} \ge 1 - \sqrt{R} - \varepsilon$$

- The minimum distance properties of the uniform and sparse models are identical
- So are their measurement complexities!

$$k > (2 + \varepsilon)\gamma \left(1 - \frac{\gamma}{2}\right)n^2$$

 Derived necessary and sufficient conditions for rank minimization over finite fields

3 1 4 3

4 A N

- Derived necessary and sufficient conditions for rank minimization over finite fields
- Derived minimum distance properties of rank-metric codes

- Derived necessary and sufficient conditions for rank minimization over finite fields
- Derived minimum distance properties of rank-metric codes
- Drawn analogies between number of measurements and minimum distance properties

- Derived necessary and sufficient conditions for rank minimization over finite fields
- Derived minimum distance properties of rank-metric codes
- Drawn analogies between number of measurements and minimum distance properties
- Reduced complexity of the min-rank decoder vis-à-vis exhaustive search

• Can the sparsity level of

$$\Omega\left(\frac{\log n}{n}\right)$$

be improved (reduced) further?

**H** 16

• Can the sparsity level of

$$\Omega\left(\frac{\log n}{n}\right)$$

be improved (reduced) further?

• Tradeoff between sparsity and number of measurements?

• Can the sparsity level of

$$\Omega\left(\frac{\log n}{n}\right)$$

be improved (reduced) further?

• Tradeoff between sparsity and number of measurements?

Check out the preprint: http://arxiv.org/abs/1104.4302