#### Towards Completely-Data-Driven Functional Estimation

#### Xiaoming Huo

School of Industrial & Systems Engineering Georgia Institute of Technology, Atlanta

Banff International Research Station Tuesday, December 13, 2011

Jointly work with Z. Yang & H. Xie & Y. Lu

# Outline

#### Background

- 2 Data Driven Method
- 3 Theoretical Consideration: Rate of Convergence
- Asymptotic Optimality of the Generalized Cross Validation
- 5 Fast Computation



- 4 周 ト - 4 日 ト - 4 日 ト

# Outline

#### Background

- 2 Data Driven Method
- 3 Theoretical Consideration: Rate of Convergence
- 4 Asymptotic Optimality of the Generalized Cross Validation
- 5 Fast Computation
- 6 Simulations

< 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 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

# Observe (X<sub>i</sub>, y<sub>i</sub>), X<sub>i</sub> ∈ ℝ<sup>d</sup>, p ≥ 1, y<sub>i</sub> ∈ ℝ, i = 1, 2, ..., n Relation

 $y_i = f(X_i) + \varepsilon_i,$ 

or

$$y_i = f(X_{i1}, X_{i2}, \ldots, X_{id}) + \varepsilon_i,$$

where  $\varepsilon_i$ 's are i.i.d. and satisfy some conditions

• Objective: estimating f

• Desideratum:  $f \in \mathscr{F}$ 

3

ヘロト 人間ト 人造ト 人造ト

• Observe  $(X_i, y_i), X_i \in \mathbb{R}^d, p \ge 1, y_i \in \mathbb{R}, i = 1, 2, \dots, n$ • Relation

$$y_i = f(X_i) + \varepsilon_i,$$

or

$$y_i = f(X_{i1}, X_{i2}, \ldots, X_{id}) + \varepsilon_i,$$

where  $\varepsilon_i$ 's are i.i.d. and satisfy some conditions

Objective: estimating f

• Desideratum:  $f \in \mathscr{F}$ 

• Observe  $(X_i, y_i), X_i \in \mathbb{R}^d, p \ge 1, y_i \in \mathbb{R}, i = 1, 2, \dots, n$ • Relation

$$y_i = f(X_i) + \varepsilon_i,$$

or

$$y_i = f(X_{i1}, X_{i2}, \ldots, X_{id}) + \varepsilon_i,$$

where  $\varepsilon_i$ 's are i.i.d. and satisfy some conditions

• Objective: estimating f

• Desideratum:  $f \in \mathscr{F}$ 

• Observe  $(X_i, y_i), X_i \in \mathbb{R}^d, p \ge 1, y_i \in \mathbb{R}, i = 1, 2, \dots, n$ • Relation

$$y_i = f(X_i) + \varepsilon_i,$$

or

$$y_i = f(X_{i1}, X_{i2}, \ldots, X_{id}) + \varepsilon_i,$$

where  $\varepsilon_i$ 's are i.i.d. and satisfy some conditions

- Objective: estimating f
- Desideratum:  $f \in \mathscr{F}$

イロト 不得 トイヨト イヨト

#### • Linear regression, $\mathscr{F} = a$ finite-dimensional linear subspace

Kernel

- Splines
- Wavelets
- ...
- $\mathcal{F}$  is a Sobolev space

$$\mathcal{F} = H^m(\Omega) = \left\{ f: D^lpha f \in L^2(\Omega), orall lpha \in \mathbb{Z}^d_+, |lpha| \leq m 
ight\}$$

where  $\Omega \in \mathbb{R}^d$  is the domain of the function, for  $\alpha \in \mathbb{Z}_+^d$ ,  $\alpha = (\alpha_1, \alpha_2, ..., \alpha_d)$  and  $|\alpha| = \sum_{i=1}^d \alpha_i$ , we define the partial derivative

$$D^{\alpha}f = \frac{\partial^{|\alpha|}f}{\partial x_1^{\alpha_1}\partial x_2^{\alpha_2}\cdots \partial x_d^{\alpha_d}}$$

< ロ > < 四 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

- Linear regression,  $\mathscr{F} = a$  finite-dimensional linear subspace
- Kernel
- Splines
- Wavelets
- ...
- $\mathcal{F}$  is a Sobolev space

$$\mathcal{F} = H^m(\Omega) = \left\{ f: D^lpha f \in L^2(\Omega), orall lpha \in \mathbb{Z}^d_+, |lpha| \leq m 
ight\}$$

where  $\Omega \in \mathbb{R}^d$  is the domain of the function, for  $\alpha \in \mathbb{Z}_+^d$ ,  $\alpha = (\alpha_1, \alpha_2, ..., \alpha_d)$  and  $|\alpha| = \sum_{i=1}^d \alpha_i$ , we define the partial derivative

$$D^{\alpha}f = \frac{\partial^{|\alpha|}f}{\partial x_1^{\alpha_1}\partial x_2^{\alpha_2}\cdots \partial x_d^{\alpha_d}}$$

ヘロト 人間ト 人間ト 人目ト

- Linear regression,  $\mathscr{F} = a$  finite-dimensional linear subspace
- Kernel
- Splines
- Wavelets
- ...
- $\mathcal F$  is a Sobolev space

$$\mathcal{F} = H^m(\Omega) = \left\{ f: D^lpha f \in L^2(\Omega), orall lpha \in \mathbb{Z}^d_+, |lpha| \leq m 
ight\}$$

where  $\Omega \in \mathbb{R}^d$  is the domain of the function, for  $\alpha \in \mathbb{Z}_+^d$ ,  $\alpha = (\alpha_1, \alpha_2, ..., \alpha_d)$  and  $|\alpha| = \sum_{i=1}^d \alpha_i$ , we define the partial derivative

$$D^{\alpha}f = \frac{\partial^{|\alpha|}f}{\partial x_1^{\alpha_1}\partial x_2^{\alpha_2}\cdots \partial x_d^{\alpha_d}}$$

- Linear regression,  $\mathscr{F} = a$  finite-dimensional linear subspace
- Kernel
- Splines
- Wavelets
- ...
- ${\mathcal F}$  is a Sobolev space

$$\mathcal{F} = H^m(\Omega) = \left\{ f: D^lpha f \in L^2(\Omega), orall lpha \in \mathbb{Z}^d_+, |lpha| \leq m 
ight\}$$

where  $\Omega \in \mathbb{R}^d$  is the domain of the function, for  $\alpha \in \mathbb{Z}_+^d$ ,  $\alpha = (\alpha_1, \alpha_2, ..., \alpha_d)$  and  $|\alpha| = \sum_{i=1}^d \alpha_i$ , we define the partial derivative

$$D^{\alpha}f = \frac{\partial^{|\alpha|}f}{\partial x_1^{\alpha_1}\partial x_2^{\alpha_2}\cdots \partial x_d^{\alpha_d}}$$

- Linear regression,  $\mathscr{F} = a$  finite-dimensional linear subspace
- Kernel
- Splines
- Wavelets
- ...
- $\mathcal{F}$  is a Sobolev space

$$\mathcal{F} = H^m(\Omega) = \left\{ f: D^lpha f \in L^2(\Omega), orall lpha \in \mathbb{Z}^d_+, |lpha| \leq m 
ight\}$$

where  $\Omega \in \mathbb{R}^d$  is the domain of the function, for  $\alpha \in \mathbb{Z}_+^d$ ,  $\alpha = (\alpha_1, \alpha_2, ..., \alpha_d)$  and  $|\alpha| = \sum_{i=1}^d \alpha_i$ , we define the partial derivative

$$D^{\alpha}f = \frac{\partial^{|\alpha|}f}{\partial x_1^{\alpha_1}\partial x_2^{\alpha_2}\cdots \partial x_d^{\alpha_d}}$$

- Linear regression,  $\mathscr{F} = a$  finite-dimensional linear subspace
- Kernel
- Splines
- Wavelets
- ...
- $\bullet \ \mathcal{F}$  is a Sobolev space

$$\mathcal{F} = H^m(\Omega) = \left\{ f: D^lpha f \in L^2(\Omega), orall lpha \in \mathbb{Z}^d_+, |lpha| \leq m 
ight\}$$

where  $\Omega \in \mathbb{R}^d$  is the domain of the function, for  $\alpha \in \mathbb{Z}_+^d$ ,  $\alpha = (\alpha_1, \alpha_2, ..., \alpha_d)$  and  $|\alpha| = \sum_{i=1}^d \alpha_i$ , we define the partial derivative

$$D^{\alpha}f = \frac{\partial^{|\alpha|}f}{\partial x_1^{\alpha_1}\partial x_2^{\alpha_2}\cdots \partial x_d^{\alpha_d}}$$

(本語) (本語) (本語)

 $\min_{f\in\mathscr{F}}G(f)+\lambda\cdot R(f)$ 

#### where

- G(f): goodness of fit, e.g.,  $G(f) = \sum_{i=1}^{n} [y_i f(X_i)]^2$
- R(f): regularity of f, e.g.,  $R(f) = \int_{\Omega} \sum_{i,j=1}^{p} \left( \frac{\partial^2 f}{\partial x_i \partial x_j} \right)^2$
- $\Omega$ : domain of f, e.g.,  $\Omega = \mathcal{R}^d$

$$\min_{f\in\mathscr{F}}G(f)+\lambda\cdot R(f)$$

where

- G(f): goodness of fit, e.g.,  $G(f) = \sum_{i=1}^{n} [y_i f(X_i)]^2$
- R(f): regularity of f, e.g.,  $R(f) = \int_{\Omega} \sum_{i,j=1}^{p} \left( \frac{\partial^2 f}{\partial x_i \partial x_j} \right)^2$
- $\Omega$ : domain of f, e.g.,  $\Omega = \mathcal{R}^d$

$$\min_{f\in\mathscr{F}}G(f)+\lambda\cdot R(f)$$

where

- G(f): goodness of fit, e.g.,  $G(f) = \sum_{i=1}^{n} [y_i f(X_i)]^2$
- R(f): regularity of f, e.g.,  $R(f) = \int_{\Omega} \sum_{i,j=1}^{p} \left( \frac{\partial^2 f}{\partial x_i \partial x_j} \right)^2$

•  $\Omega$ : domain of f, e.g.,  $\Omega = \mathcal{R}^a$ 

$$\min_{f\in\mathscr{F}}G(f)+\lambda\cdot R(f)$$

where

- G(f): goodness of fit, e.g.,  $G(f) = \sum_{i=1}^{n} [y_i f(X_i)]^2$
- R(f): regularity of f, e.g.,  $R(f) = \int_{\Omega} \sum_{i,j=1}^{p} \left( \frac{\partial^2 f}{\partial x_i \partial x_j} \right)^2$
- $\Omega$ : domain of f, e.g.,  $\Omega = \mathcal{R}^d$

イロト 不得下 イヨト イヨト 二日

# More on the Existing Approach

• Define a regularity functional. Recall

$$R(f) = \int_{\Omega} \|\mathbf{H}f\|_F^2$$

• Essence: Need to show that solving problem

$$\min_{\substack{f \in \mathscr{F}} \\ \mathsf{subject to} \quad f(X_i) = y'_i } R(f)$$

ends up with a quadratic form:

$$R(f) = \mathbf{f}^T \mathbf{M} \mathbf{f}$$

where  $\mathbf{f} = (f(X_1), f(X_2), \dots, f(X_n))^T$ 

 If Ω is irregular, determining analytically the gram matrix M can be very difficult.

# More on the Existing Approach

• Define a regularity functional. Recall

$$R(f) = \int_{\Omega} \|\mathbf{H}f\|_F^2$$

• Essence: Need to show that solving problem

$$\min_{\substack{f \in \mathscr{F}}} R(f)$$
  
subject to  $f(X_i) = y'_i$ 

ends up with a quadratic form:

$$R(f) = \mathbf{f}^T \mathbf{M} \mathbf{f}$$

where 
$$\mathbf{f} = (f(X_1), f(X_2), ..., f(X_n))^T$$

• If  $\Omega$  is irregular, determining analytically the gram matrix **M** can be very difficult.

xiaoming@isye.gatech.edu (Georgia Tech)

Birs 7 / 38

# More on the Existing Approach

Define a regularity functional. Recall

$$R(f) = \int_{\Omega} \|\mathbf{H}f\|_F^2$$

• Essence: Need to show that solving problem

$$\min_{\substack{f\in\mathscr{F}}\\ ext{subject to}} R(f)$$

ends up with a quadratic form:

$$R(f) = \mathbf{f}^T \mathbf{M} \mathbf{f}$$

where  $\mathbf{f} = (f(X_1), f(X_2), \dots, f(X_n))^T$ 

• If  $\Omega$  is irregular, determining analytically the gram matrix **M** can be very difficult. ・ロト ・ 日 ・ ・ 日 ・ ・ 日 ・

#### Example of Irregular Domain



Birs 8 / 38

20

15

10

0 10

< 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 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

#### Background

- 2 Data Driven Method
  - 3 Theoretical Consideration: Rate of Convergence
  - 4 Asymptotic Optimality of the Generalized Cross Validation
  - 5 Fast Computation
  - 6 Simulations

< 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 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

#### Unbiased Estimation in a Neighborhood

• An unbiased alternative:

$$\min_{f \in \mathcal{F}} \sum_{i=1}^{n} [y_i - f(X_i)]^2 + \lambda \sum_{i=1}^{n} \|\mathcal{H}f(X_i)\|_F^2.$$

• Let  $\mathbf{V}_i, 1 \le i \le k$ , denote the k nearest neighbors of  $\mathbf{V}_0$ . Let  $\bar{\mathbf{V}} = \frac{1}{k+1} \sum_{i=0}^{k} \mathbf{V}_i$ , i.e.,  $\bar{\mathbf{V}}$  is the average. Taylor expansion:

$$f(\mathbf{V}_i) \approx f(\bar{\mathbf{V}}) + (\mathbf{V}_i - \bar{\mathbf{V}})^T \mathcal{J}f(\bar{\mathbf{V}}) + \frac{1}{2}(\mathbf{V}_i - \bar{\mathbf{V}})^T \mathcal{H}f(\bar{\mathbf{V}})(\mathbf{V}_i - \bar{\mathbf{V}}),$$
  
$$i = 0, 1, \cdots, n,$$

where  $f(\bar{\mathbf{V}})$  is the functional value,  $\mathcal{J}f(\bar{\mathbf{V}})$  is the Jacobian, and  $\mathcal{H}f(\bar{\mathbf{V}})$  is the hessian matrix. Note we have  $\mathcal{J}f(\bar{\mathbf{V}}) \in \mathbb{R}^d$  and  $\mathcal{H}f(\bar{\mathbf{V}}) \in \mathbb{R}^{d \times d}$ .

Birs

・ロト ・聞ト ・ヨト ・ヨト

# Unbiased Estimation in a Neighborhood

• An unbiased alternative:

$$\min_{f \in \mathcal{F}} \sum_{i=1}^{n} [y_i - f(X_i)]^2 + \lambda \sum_{i=1}^{n} \|\mathcal{H}f(X_i)\|_F^2.$$

• Let  $\mathbf{V}_i, 1 \le i \le k$ , denote the k nearest neighbors of  $\mathbf{V}_0$ . Let  $\bar{\mathbf{V}} = \frac{1}{k+1} \sum_{i=0}^{k} \mathbf{V}_i$ , i.e.,  $\bar{\mathbf{V}}$  is the average. Taylor expansion:

$$f(\mathbf{V}_i) \approx f(\bar{\mathbf{V}}) + (\mathbf{V}_i - \bar{\mathbf{V}})^T \mathcal{J}f(\bar{\mathbf{V}}) + \frac{1}{2}(\mathbf{V}_i - \bar{\mathbf{V}})^T \mathcal{H}f(\bar{\mathbf{V}})(\mathbf{V}_i - \bar{\mathbf{V}}),$$
  
$$i = 0, 1, \cdots, n,$$

where  $f(\bar{\mathbf{V}})$  is the functional value,  $\mathcal{J}f(\bar{\mathbf{V}})$  is the Jacobian, and  $\mathcal{H}f(\bar{\mathbf{V}})$  is the hessian matrix. Note we have  $\mathcal{J}f(\bar{\mathbf{V}}) \in \mathbb{R}^d$  and  $\mathcal{H}f(\bar{\mathbf{V}}) \in \mathbb{R}^{d \times d}$ .

Birs

#### Derivation

• Rewrite as a linear system:

$$\mathbf{f}^* \approx \mathbf{1}_{k+1} \cdot \mathbf{c} + \mathbf{V} \cdot \mathbf{J} + \frac{1}{2} \mathbf{C} \cdot \mathbf{H},$$

A partial implementation of QR-decomposition

$$\begin{bmatrix} \mathbf{1}_{k+1} & \mathsf{V} & \frac{1}{2}\mathsf{C} \end{bmatrix} = \begin{bmatrix} \mathsf{Q}_1 & \mathsf{Q}_2 \end{bmatrix} \begin{bmatrix} \mathsf{R}_{11} & \mathsf{R}_{12} \\ \mathbf{0} & \mathsf{I}_{(d^2+d)/2} \end{bmatrix},$$

where columns of  $\mathbf{Q}_1 \in \mathbb{R}^{(k+1) \times (d+1)}$  are orthonormal  $(\mathbf{Q}_1^T \mathbf{Q}_1 = \mathbf{I}_{d+1})$ , and columns of  $\mathbf{Q}_2 \in \mathbb{R}^{(k+1) \times \frac{d^2+d}{2}}$  are orthogonal to the columns of  $\mathbf{Q}_1$  (i.e.,  $\mathbf{Q}_2^T \mathbf{Q}_1 = \mathbf{0}$ ).

ヘロト 人間 ト 人 ヨ ト 人 ヨ トー

• Rewrite as a linear system:

$$\mathbf{f}^* \approx \mathbf{1}_{k+1} \cdot \mathbf{c} + \mathbf{V} \cdot \mathbf{J} + \frac{1}{2} \mathbf{C} \cdot \mathbf{H},$$

• A partial implementation of QR-decomposition

$$\begin{bmatrix} \mathbf{1}_{k+1} & \mathbf{V} & \frac{1}{2}\mathbf{C} \end{bmatrix} = \begin{bmatrix} \mathbf{Q}_1 & \mathbf{Q}_2 \end{bmatrix} \begin{bmatrix} \mathbf{R}_{11} & \mathbf{R}_{12} \\ \mathbf{0} & \mathbf{I}_{(d^2+d)/2} \end{bmatrix},$$

where columns of  $\mathbf{Q}_1 \in \mathbb{R}^{(k+1)\times(d+1)}$  are orthonormal  $(\mathbf{Q}_1^T \mathbf{Q}_1 = \mathbf{I}_{d+1})$ , and columns of  $\mathbf{Q}_2 \in \mathbb{R}^{(k+1)\times \frac{d^2+d}{2}}$  are orthogonal to the columns of  $\mathbf{Q}_1$  (i.e.,  $\mathbf{Q}_2^T \mathbf{Q}_1 = \mathbf{0}$ ).

Birs

イロト 不得 トイヨト イヨト

#### More on Derivation

• we have

$$\mathbf{Q}_2^T \mathbf{f}^* = \begin{pmatrix} \mathbf{0} & \mathbf{Q}_2^T \mathbf{Q}_2 \end{pmatrix} \begin{bmatrix} \mathbf{R}_{11} & \mathbf{R}_{12} \\ \mathbf{0} & \mathbf{I}_{(p^2+p)/2} \end{bmatrix} \begin{bmatrix} c \\ \mathbf{J} \\ \mathbf{H} \end{bmatrix} = \mathbf{Q}_2^T \mathbf{Q}_2 \mathbf{H}.$$

• least-squares estimator of H

 $\hat{\mathbf{H}} = (\mathbf{Q}_2^{\mathsf{T}} \mathbf{Q}_2)^+ \mathbf{Q}_2^{\mathsf{T}} \mathbf{f}^*,$ 

where  $(\cdot)^+$  denotes a pseudo-inverse of a matrix.

• Frobenius norm of the hessian matrix at a point:

$$\begin{aligned} \|\hat{\mathcal{H}}f(X_i)\|_F^2 &= \|\hat{\mathbf{H}}\|_2^2 &= \hat{\mathbf{H}}^T \hat{\mathbf{H}} \\ &= (\mathbf{f}^*)^T \mathbf{Q}_2 (\mathbf{Q}_2^T \mathbf{Q}_2)^+ (\mathbf{Q}_2^T \mathbf{Q}_2)^+ \mathbf{Q}_2^T \mathbf{f}^* \end{aligned}$$

Birs 12 / 38

イロト イヨト イヨト イヨト

#### More on Derivation

we have

$$\mathbf{Q}_2^T \mathbf{f}^* = \begin{pmatrix} \mathbf{0} & \mathbf{Q}_2^T \mathbf{Q}_2 \end{pmatrix} \begin{bmatrix} \mathbf{R}_{11} & \mathbf{R}_{12} \\ \mathbf{0} & \mathbf{I}_{(p^2+p)/2} \end{bmatrix} \begin{bmatrix} c \\ \mathbf{J} \\ \mathbf{H} \end{bmatrix} = \mathbf{Q}_2^T \mathbf{Q}_2 \mathbf{H}.$$

least-squares estimator of H

$$\hat{\mathbf{H}} = (\mathbf{Q}_2^T \mathbf{Q}_2)^+ \mathbf{Q}_2^T \mathbf{f}^*,$$

where  $(\cdot)^+$  denotes a pseudo-inverse of a matrix.

$$\begin{aligned} \|\hat{\mathcal{H}}f(X_i)\|_F^2 &= \|\hat{\mathbf{H}}\|_2^2 = \hat{\mathbf{H}}^T \hat{\mathbf{H}} \\ &= (\mathbf{f}^*)^T \mathbf{Q}_2 (\mathbf{Q}_2^T \mathbf{Q}_2)^+ (\mathbf{Q}_2^T \mathbf{Q}_2)^+ \mathbf{Q}_2^T \mathbf{f}^* \end{aligned}$$

・ロト ・聞ト ・ヨト ・ヨト

# More on Derivation

• we have

$$\mathbf{Q}_2^T \mathbf{f}^* = \begin{pmatrix} \mathbf{0} & \mathbf{Q}_2^T \mathbf{Q}_2 \end{pmatrix} \begin{bmatrix} \mathbf{R}_{11} & \mathbf{R}_{12} \\ \mathbf{0} & \mathbf{I}_{(p^2+p)/2} \end{bmatrix} \begin{bmatrix} c \\ \mathbf{J} \\ \mathbf{H} \end{bmatrix} = \mathbf{Q}_2^T \mathbf{Q}_2 \mathbf{H}.$$

 $\bullet$  least-squares estimator of  ${\bf H}$ 

$$\hat{\mathbf{H}} = (\mathbf{Q}_2^{\mathsf{T}} \mathbf{Q}_2)^+ \mathbf{Q}_2^{\mathsf{T}} \mathbf{f}^*,$$

where  $(\cdot)^+$  denotes a pseudo-inverse of a matrix.

• Frobenius norm of the hessian matrix at a point:

$$\begin{aligned} \|\hat{\mathcal{H}}f(X_i)\|_F^2 &= \|\hat{\mathbf{H}}\|_2^2 = \hat{\mathbf{H}}^T \hat{\mathbf{H}} \\ &= (\mathbf{f}^*)^T \mathbf{Q}_2 (\mathbf{Q}_2^T \mathbf{Q}_2)^+ (\mathbf{Q}_2^T \mathbf{Q}_2)^+ \mathbf{Q}_2^T \mathbf{f}^*. \end{aligned}$$

< 回 > < 三 > < 三 >

#### A Quadratic Form

Denote

 $\mathbf{K}_i = \mathbf{Q}_2 (\mathbf{Q}_2^T \mathbf{Q}_2)^+ (\mathbf{Q}_2^T \mathbf{Q}_2)^+ \mathbf{Q}_2^T.$ 

• We have  $\sum_{i=1}^{n} \|\hat{\mathcal{H}}f(X_{i})\|_{F}^{2} = \sum_{i=1}^{n} (\mathbf{f}^{T} \mathbf{S}_{i}^{T} \mathbf{K}_{i} \mathbf{S}_{i} \mathbf{f}).$ • Let  $\mathbf{M} = (\mathbf{S}_{1}^{T}, \cdots, \mathbf{S}_{n}^{T}) \operatorname{diag} \{\mathbf{K}_{1}, \mathbf{K}_{2}, \cdots, \mathbf{K}_{n}\} \begin{pmatrix} \mathbf{S}_{1} \\ \vdots \\ \mathbf{S}_{n} \end{pmatrix}$ , we have

$$\sum_{i=1}^{n} \|\hat{\mathcal{H}}f(X_i)\|_F^2 = \mathbf{f}^T \mathbf{M} \mathbf{f}, \tag{1}$$

(日) (圖) (E) (E) (E)

which is a quadratic function of f.

Birs 13 / 38

#### A Quadratic Form

Denote

$$\mathbf{K}_i = \mathbf{Q}_2 (\mathbf{Q}_2^T \mathbf{Q}_2)^+ (\mathbf{Q}_2^T \mathbf{Q}_2)^+ \mathbf{Q}_2^T.$$

• We have  $\sum_{i=1}^{n} \|\hat{\mathcal{H}}f(X_{i})\|_{F}^{2} = \sum_{i=1}^{n} (\mathbf{f}^{T}\mathbf{S}_{i}^{T}\mathbf{K}_{i}\mathbf{S}_{i}\mathbf{f}).$ 

• Let  $\mathbf{M} = (\mathbf{S}_1^T, \cdots, \mathbf{S}_n^T)$ diag $\{\mathbf{K}_1, \mathbf{K}_2, \cdots, \mathbf{K}_n\}$   $\begin{pmatrix} \mathbf{S}_1 \\ \vdots \\ \mathbf{S}_n \end{pmatrix}$ , we have

$$\sum_{i=1}^{n} \|\hat{\mathcal{H}}f(X_i)\|_F^2 = \mathbf{f}^T \mathbf{M} \mathbf{f},\tag{1}$$

(日) (圖) (E) (E) (E)

which is a quadratic function of **f**.

# A Quadratic Form

Denote

$$\mathbf{K}_i = \mathbf{Q}_2 (\mathbf{Q}_2^T \mathbf{Q}_2)^+ (\mathbf{Q}_2^T \mathbf{Q}_2)^+ \mathbf{Q}_2^T.$$

• We have  $\sum_{i=1}^{n} \|\hat{\mathcal{H}}f(X_{i})\|_{F}^{2} = \sum_{i=1}^{n} (\mathbf{f}^{T} \mathbf{S}_{i}^{T} \mathbf{K}_{i} \mathbf{S}_{i} \mathbf{f}).$   $(\mathbf{S}_{1})$ 

• Let 
$$\mathbf{M} = (\mathbf{S}_1^T, \cdots, \mathbf{S}_n^T) \text{diag} \{\mathbf{K}_1, \mathbf{K}_2, \cdots, \mathbf{K}_n\} \begin{pmatrix} \vdots \\ \mathbf{S}_n \end{pmatrix}$$
, we have

$$\sum_{i=1}^{n} \|\hat{\mathcal{H}}f(X_i)\|_F^2 = \mathbf{f}^T \mathbf{M} \mathbf{f},\tag{1}$$

▲日 ▶ ▲圖 ▶ ▲ 国 ▶ ▲ 国 ▶ →

which is a quadratic function of  $\boldsymbol{f}.$ 

#### Problem becomes

$$\min_{\mathbf{f}} \|\mathbf{Y} - \mathbf{f}\|_2^2 + \lambda \mathbf{f}^T \mathbf{M} \mathbf{f},$$

• Close form solution:

$$\hat{\mathbf{f}} = (\mathbf{I}_n + \lambda \cdot \mathbf{M})^{-1} \cdot \mathbf{Y}.$$

 J. Chen and X. Huo (2009). A Hessian regularized nonlinear time series model. *Journal of Computational and Graphical Statistics*, 18 (3): 694-716, September.

< 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 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

Problem becomes

$$\min_{\mathbf{f}} \|\mathbf{Y} - \mathbf{f}\|_2^2 + \lambda \mathbf{f}^T \mathbf{M} \mathbf{f},$$

• Close form solution:

$$\hat{\mathbf{f}} = (\mathbf{I}_n + \lambda \cdot \mathbf{M})^{-1} \cdot \mathbf{Y}.$$

 J. Chen and X. Huo (2009). A Hessian regularized nonlinear time series model. *Journal of Computational and Graphical Statistics*, 18 (3): 694-716, September.

< 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 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

Problem becomes

$$\min_{\mathbf{f}} \|\mathbf{Y} - \mathbf{f}\|_2^2 + \lambda \mathbf{f}^T \mathbf{M} \mathbf{f},$$

Close form solution:

$$\hat{\mathbf{f}} = (\mathbf{I}_n + \lambda \cdot \mathbf{M})^{-1} \cdot \mathbf{Y}.$$

 J. Chen and X. Huo (2009). A Hessian regularized nonlinear time series model. *Journal of Computational and Graphical Statistics, 18* (3): 694-716, September.

#### Background

2 Data Driven Method

#### 3 Theoretical Consideration: Rate of Convergence

#### 4 Asymptotic Optimality of the Generalized Cross Validation

#### 5 Fast Computation

#### 6 Simulations

< 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 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >
## • Rate of convergence: How fast does $\frac{1}{n} \|\hat{f}_n - f\|_2^2$ goes to zero?

- Stone (1982) showed that O(n<sup>-2m+d</sup>) is the optimal rate of convergence for nonparametric regression for *d*-dimensional input, while the up to order *m* partial derivatives of the underlying function *f* are in L<sup>2</sup>(Ω).
- Note we have m = 2.
- Note: we must have 2m > d.

- Rate of convergence: How fast does  $\frac{1}{n} \|\hat{f}_n f\|_2^2$  goes to zero?
- Stone (1982) showed that O(n<sup>-2m/2m+d</sup>) is the optimal rate of convergence for nonparametric regression for *d*-dimensional input, while the up to order *m* partial derivatives of the underlying function *f* are in L<sup>2</sup>(Ω).
- Note we have m = 2.
- Note: we must have 2m > d.

< 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 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

- Rate of convergence: How fast does  $\frac{1}{n} \|\hat{f}_n f\|_2^2$  goes to zero?
- Stone (1982) showed that O(n<sup>-2m/2m+d</sup>) is the optimal rate of convergence for nonparametric regression for *d*-dimensional input, while the up to order *m* partial derivatives of the underlying function *f* are in L<sup>2</sup>(Ω).
- Note we have m = 2.
- Note: we must have 2m > d.

・ロン ・四 ・ ・ ヨン

- Rate of convergence: How fast does  $\frac{1}{n} \|\hat{f}_n f\|_2^2$  goes to zero?
- Stone (1982) showed that  $O(n^{-\frac{2m}{2m+d}})$  is the optimal rate of convergence for nonparametric regression for d-dimensional input, while the up to order m partial derivatives of the underlying function f are in  $L^2(\Omega)$ .
- Note we have m = 2.
- Note: we must have 2m > d.

イロト 人間ト イヨト イヨト

## Preparation: Inner Product in a RKHS

• For  $0 \leq \ell \leq m$ , a semi-inner-product in  $W_2^m(\Omega)$  is defined by

$$\langle f,g \rangle_{\Omega,\ell} = \int_{\Omega} \sum_{|\alpha|=\ell} \frac{\ell!}{\alpha!} (D^{\alpha} f) (D^{\alpha} g) \mathrm{d}x,$$
 (2)

which gives rise to the related semi-norm

$$|f|_{\Omega,\ell}^2 = \int_{\Omega} \sum_{|\alpha|=\ell} \frac{\ell!}{\alpha!} |D^{\alpha}f|^2 \mathrm{d}x.$$
(3)

With T = {X<sub>i</sub>}<sup>n</sup><sub>i=1</sub>, we can also give a discrete version of the aforementioned semi-norm as

$$|f|_{T,\ell}^2 = \frac{1}{n} \sum_{i=1}^n \sum_{|\alpha|=\ell}^{\ell} \frac{\ell!}{\alpha!} |D^{\alpha}f(X_i)|^2.$$
 (

• Specially,  $|f|_{\Omega,0}^2 = \int_{\Omega} f(x)^2 dx$  and  $|f|_{T,0}^2 = \frac{1}{n} \sum_{i=1}^n f(X_i)^2$ 

Birs 17 / 38

## Preparation: Inner Product in a RKHS

• For  $0 \le \ell \le m$ , a semi-inner-product in  $W_2^m(\Omega)$  is defined by

$$\langle f,g \rangle_{\Omega,\ell} = \int_{\Omega} \sum_{|\alpha|=\ell} \frac{\ell!}{\alpha!} (D^{\alpha} f) (D^{\alpha} g) \mathrm{d}x,$$
 (2)

which gives rise to the related semi-norm

$$|f|_{\Omega,\ell}^2 = \int_{\Omega} \sum_{|\alpha|=\ell} \frac{\ell!}{\alpha!} |D^{\alpha}f|^2 \mathrm{d}x.$$
(3)

With T = {X<sub>i</sub>}<sup>n</sup><sub>i=1</sub>, we can also give a discrete version of the aforementioned semi-norm as

$$|f|_{T,\ell}^2 = \frac{1}{n} \sum_{i=1}^n \sum_{|\alpha|=\ell}^n \frac{\ell!}{\alpha!} |D^{\alpha}f(X_i)|^2.$$
(4)

• Specially,  $|f|_{\Omega,0}^2 = \int_{\Omega} f(x)^2 dx$  and  $|f|_{T,0}^2 = \frac{1}{n} \sum_{i=1}^{n} f(X_i)^2$ 

## Preparation: Inner Product in a RKHS

• For  $0 \le \ell \le m$ , a semi-inner-product in  $W_2^m(\Omega)$  is defined by

$$\langle f, g \rangle_{\Omega, \ell} = \int_{\Omega} \sum_{|\alpha| = \ell} \frac{\ell!}{\alpha!} (D^{\alpha} f) (D^{\alpha} g) \mathrm{d}x,$$
 (2)

which gives rise to the related semi-norm

$$|f|_{\Omega,\ell}^2 = \int_{\Omega} \sum_{|\alpha|=\ell} \frac{\ell!}{\alpha!} |D^{\alpha}f|^2 \mathrm{d}x.$$
(3)

• With  $T = \{X_i\}_{i=1}^n$ , we can also give a discrete version of the aforementioned semi-norm as

$$|f|_{T,\ell}^2 = \frac{1}{n} \sum_{i=1}^n \sum_{|\alpha|=\ell}^n \frac{\ell!}{\alpha!} |D^{\alpha}f(X_i)|^2.$$
(4)

• Specially, 
$$|f|_{\Omega,0}^2 = \int_{\Omega} f(x)^2 dx$$
 and  $|f|_{T,0}^2 = \frac{1}{n} \sum_{i=1}^n f(X_i)^2$ .

## Preparation: Ideal Quadratic form & Sampling Property

Ideal quadratic form. For ℓ = m in (4), we define E<sub>T,m</sub> as the matrix representing the quadratic form

$$|f|_{T,m}^2 = \frac{1}{n} \mathbf{f}^T \mathbf{E}_{T,m} \mathbf{f}$$
(5)

where  $\mathbf{f} = (f(X_1), \dots, f(X_n))^T$  is the vector of function values at the knots of  $T = \{X_i\}_{i=1}^n$ .

Sampling property. For the set of sampling points T = {X<sub>i</sub>}<sup>n</sup><sub>i=1</sub> in domain Ω, we assume that there exists a constant B<sub>0</sub> > 0 such that

$$\frac{\delta_{\max}}{\delta_{\min}} \le B_0,\tag{6}$$

ヘロト 人間ト 人間ト 人間ト

where  $\delta_{\max} = \sup_{X \in \Omega} \inf_{X_i \in \mathcal{T}} ||X - X_i||$ , and  $\delta_{\min} = \min_{j \neq i} ||X_j - X_i||$ .

## Preparation: Ideal Quadratic form & Sampling Property

Ideal quadratic form. For ℓ = m in (4), we define E<sub>T,m</sub> as the matrix representing the quadratic form

$$|f|_{T,m}^2 = \frac{1}{n} \mathbf{f}^T \mathbf{E}_{T,m} \mathbf{f}$$
(5)

where  $\mathbf{f} = (f(X_1), \dots, f(X_n))^T$  is the vector of function values at the knots of  $T = \{X_i\}_{i=1}^n$ .

Sampling property. For the set of sampling points T = {X<sub>i</sub>}<sup>n</sup><sub>i=1</sub> in domain Ω, we assume that there exists a constant B<sub>0</sub> > 0 such that

$$\frac{\delta_{\max}}{\delta_{\min}} \le B_0,\tag{6}$$

where 
$$\delta_{\max} = \sup_{X \in \Omega} \inf_{X_i \in T} ||X - X_i||$$
, and  $\delta_{\min} = \min_{j \neq i} ||X_j - X_i||$ .

Birs

## Property of the Domain $\Omega$

- A Lipschitz domain (or domain with Lipschitz boundary) is a set in Euclidean space whose boundary is sufficiently regular in the sense that it can be thought of as locally being the graph of a Lipschitz continuous function.
- Ω be an open set of ℝ<sup>d</sup> satisfying a uniform cone condition: there exist a radius r > 0 and an angle θ ∈ (0, π/2) such that for any X ∈ Ω a unit vector ζ(X) ∈ ℝ<sup>d</sup> exists such that the cone

 $C(X,\zeta(X),r,\theta) = \{X + t\mathbf{s} : \mathbf{s} \in \mathbb{R}^d, \|\mathbf{s}\| = 1, \zeta(X)^T \mathbf{s} \ge \cos\theta, 0 \le t \le r\}$ (7)

is entirely contained in  $\Omega$ .

U<sup>m</sup><sub>2</sub>(Ω) = {f ∈ W<sup>m</sup><sub>2</sub>(Ω) | <u>B</u>|f|<sup>2</sup><sub>Ω,m</sub> ≤ |f|<sup>2</sup><sub>Ω,m</sub> ≤ B|f|<sup>2</sup><sub>Ω,m</sub>} be a class of functions with bilaterally bounded constraint on their *m*th-order derivatives, where the constants <u>B</u>, B > 0 do not depend on functions f.

Birs

ヘロト 人間 ト 人 ヨ ト 人 ヨ トー

## Property of the Domain $\Omega$

- A Lipschitz domain (or domain with Lipschitz boundary) is a set in Euclidean space whose boundary is sufficiently regular in the sense that it can be thought of as locally being the graph of a Lipschitz continuous function.
- Ω be an open set of R<sup>d</sup> satisfying a uniform cone condition: there exist a radius r > 0 and an angle θ ∈ (0, π/2) such that for any X ∈ Ω a unit vector ζ(X) ∈ R<sup>d</sup> exists such that the cone

$$C(X,\zeta(X),r,\theta) = \{X + t\mathbf{s} : \mathbf{s} \in \mathbb{R}^d, \|\mathbf{s}\| = 1, \zeta(X)^T \mathbf{s} \ge \cos\theta, 0 \le t \le r\}$$
(7)

### is entirely contained in $\Omega$ .

U<sup>m</sup><sub>2</sub>(Ω) = {f ∈ W<sup>m</sup><sub>2</sub>(Ω) | <u>B</u>|f|<sup>2</sup><sub>Ω,m</sub> ≤ |f|<sup>2</sup><sub>T,m</sub> ≤ B|f|<sup>2</sup><sub>Ω,m</sub>} be a class of functions with bilaterally bounded constraint on their *m*th-order derivatives, where the constants <u>B</u>, B > 0 do not depend on functions f.

Birs

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

## Property of the Domain $\Omega$

- A Lipschitz domain (or domain with Lipschitz boundary) is a set in Euclidean space whose boundary is sufficiently regular in the sense that it can be thought of as locally being the graph of a Lipschitz continuous function.
- Ω be an open set of R<sup>d</sup> satisfying a uniform cone condition: there exist a radius r > 0 and an angle θ ∈ (0, π/2) such that for any X ∈ Ω a unit vector ζ(X) ∈ R<sup>d</sup> exists such that the cone

$$C(X,\zeta(X),r,\theta) = \{X + t\mathbf{s} : \mathbf{s} \in \mathbb{R}^d, \|\mathbf{s}\| = 1, \zeta(X)^T \mathbf{s} \ge \cos\theta, 0 \le t \le r\}$$
(7)

is entirely contained in  $\Omega$ .

U<sub>2</sub><sup>m</sup>(Ω) = {f ∈ W<sub>2</sub><sup>m</sup>(Ω) | <u>B</u>|f|<sup>2</sup><sub>Ω,m</sub> ≤ |f|<sup>2</sup><sub>Π,m</sub> ≤ B|f|<sup>2</sup><sub>Ω,m</sub>} be a class of functions with bilaterally bounded constraint on their *m*th-order derivatives, where the constants <u>B</u>, B > 0 do not depend on functions f.

## A few theorems, Step 1

 Bound the eigenvalues of the ideal quadratic form. Let e<sub>1</sub> ≤ · · · ≤ e<sub>n</sub> be the eigenvalues of E<sub>T,m</sub> in ascending order.

#### I heorem

Let  $\Omega$  be an open bounded Lipschitz domain satisfying the uniform cone condition, and the sample points  $\{X_j\}_{j=1}^n$  fulfill the assumption of (6). Then there exist constants  $C_3$ ,  $C_4 > 0$  such that

$$C_3\rho_j\leq e_j\leq C_4\rho_j,$$

where  $\rho_1 \leq \rho_2 \leq \cdots \leq \rho_n$  are the first n eigenvalues of the variational eigenvalue problem

$$\langle \phi, \psi \rangle_{\Omega,m} = \rho \langle \phi, \psi \rangle_{\Omega,0}, \quad \forall \ \psi \in W_2^m(\Omega).$$

ヘロン 人間と 人間と 人間と

## A few theorems, Step 1

Bound the eigenvalues of the ideal quadratic form. Let e<sub>1</sub> ≤ ··· ≤ e<sub>n</sub> be the eigenvalues of E<sub>T,m</sub> in ascending order.

#### Theorem

Let  $\Omega$  be an open bounded Lipschitz domain satisfying the uniform cone condition, and the sample points  $\{X_j\}_{j=1}^n$  fulfill the assumption of (6). Then there exist constants  $C_3, C_4 > 0$  such that

$$C_3\rho_j\leq e_j\leq C_4\rho_j,$$

where  $\rho_1 \leq \rho_2 \leq \cdots \leq \rho_n$  are the first n eigenvalues of the variational eigenvalue problem

$$\langle \phi, \psi \rangle_{\Omega,m} = \rho \langle \phi, \psi \rangle_{\Omega,0}, \quad \forall \ \psi \in W_2^m(\Omega).$$

イロト イポト イヨト イヨト 二日

### • Using a known rate from functional analysis

#### Theorem

Let  $\Omega$  be an open bounded Lipschitz domain satisfying the uniform cone condition, and  $\{e_1 \leq \cdots \leq e_n\}$  the eigenvalues of  $\mathbf{E}_{T,m}$  in ascending order. Then there exist constants  $C_5, C_6 > 0$  such that for  $m(d) = \frac{(d+m-1)!}{d!(m-1)!} < j \leq n$  we have

$$C_5 j^{\frac{2m}{d}} \le e_j \le C_6 j^{\frac{2m}{d}}.$$
(8)

イロト イ部ト イヨト イヨト 三日

### • Using a known rate from functional analysis

#### Theorem

Let  $\Omega$  be an open bounded Lipschitz domain satisfying the uniform cone condition, and  $\{e_1 \leq \cdots \leq e_n\}$  the eigenvalues of  $\mathbf{E}_{T,m}$  in ascending order. Then there exist constants  $C_5$ ,  $C_6 > 0$  such that for  $m(d) = \frac{(d+m-1)!}{d!(m-1)!} < j \leq n$  we have

$$C_5 j^{\frac{2m}{d}} \le e_j \le C_6 j^{\frac{2m}{d}}.$$
(8)

◆□▶ ◆□▶ ◆□▶ ◆□▶ ─ □

### • Property of eigenvalues.

#### Theorem

Let  $\mu_1 \leq \cdots \leq \mu_n$  be the eigenvalues of the matrix **M** in (1). There exist constants  $C_7, C_8 > 0$  such that for  $m^{(d)} < j \leq n$  we have

$$C_7 j^{\frac{2m}{d}} \leq \mu_j \leq C_8 j^{\frac{2m}{d}}.$$

イロト イ理ト イヨト イヨト

• Property of eigenvalues.

#### Theorem

Let  $\mu_1 \leq \cdots \leq \mu_n$  be the eigenvalues of the matrix **M** in (1). There exist constants  $C_7, C_8 > 0$  such that for  $m^{(d)} < j \leq n$  we have

$$C_7 j^{\frac{2m}{d}} \leq \mu_j \leq C_8 j^{\frac{2m}{d}}.$$

- 4 聞 と 4 直 と 4 耳 と

### • Asymptotic rate of convergence

#### Theorem

Let  $\hat{\mathbf{f}}_n(\lambda) = \mathbf{A}_n(\lambda)\mathbf{y} = (\mathbf{I}_n + \lambda \mathbf{M})^{-1}\mathbf{y}$  be the CDS estimator from the multivariate model with the order m > d/2 and denote  $r_n(\lambda) = n^{-1} \|\hat{\mathbf{f}}_n(\lambda) - \mathbf{f}\|^2$ . If  $n \to \infty$  and  $\lambda \sim n^{-2m/(2m+d)}$  is chosen, then  $E[\mathbf{r}_n(\lambda)] = O(n^{-\frac{2m}{2m+d}})$ 

• The above matches the optimal rate in Stone (1982).

<ロト < 団ト < 団ト < 団ト

### • Asymptotic rate of convergence

#### Theorem

Let  $\hat{\mathbf{f}}_n(\lambda) = \mathbf{A}_n(\lambda)\mathbf{y} = (\mathbf{I}_n + \lambda \mathbf{M})^{-1}\mathbf{y}$  be the CDS estimator from the multivariate model with the order m > d/2 and denote  $r_n(\lambda) = n^{-1} \|\hat{\mathbf{f}}_n(\lambda) - \mathbf{f}\|^2$ . If  $n \to \infty$  and  $\lambda \sim n^{-2m/(2m+d)}$  is chosen, then  $E[r_n(\lambda)] = O(n^{-\frac{2m}{2m+d}}).$ 

< ロ > < 四 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

### • Asymptotic rate of convergence

### Theorem

Let 
$$\hat{\mathbf{f}}_n(\lambda) = \mathbf{A}_n(\lambda)\mathbf{y} = (\mathbf{I}_n + \lambda \mathbf{M})^{-1}\mathbf{y}$$
 be the CDS estimator from the multivariate model with the order  $m > d/2$  and denote  $r_n(\lambda) = n^{-1} \|\hat{\mathbf{f}}_n(\lambda) - \mathbf{f}\|^2$ . If  $n \to \infty$  and  $\lambda \sim n^{-2m/(2m+d)}$  is chosen, then  $E[r_n(\lambda)] = O(n^{-\frac{2m}{2m+d}}).$ 

• The above matches the optimal rate in Stone (1982).

< 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 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

## Background

- 2 Data Driven Method
- 3 Theoretical Consideration: Rate of Convergence

### Asymptotic Optimality of the Generalized Cross Validation

### 5 Fast Computation

## 6 Simulations

→ □ → → □ → → □

### $\bullet\,$ Choose the parameter $\lambda$ via the Generalized Cross Validation

• Let  $\hat{\mathbf{f}}_n(\lambda) = \mathbf{A}_n(\lambda)\mathbf{y} = (\mathbf{I}_n + \lambda \mathbf{M})^{-1}\mathbf{y}$  be the estimator of CDS model with the order *m* and denote  $r_n(\lambda) = n^{-1} \|\hat{\mathbf{f}}_n(\lambda) - \mathbf{f}\|^2$ . The asymptotic optimality of GCV is defined as

$$\frac{r_n(\hat{\lambda}_G)}{\inf_{\lambda \in \mathbb{R}_+} r_n(\lambda)} \longrightarrow_p 1 \tag{9}$$

< 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 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

where  $\longrightarrow_{p}$  means the convergence in probability.

- $\bullet\,$  Choose the parameter  $\lambda$  via the Generalized Cross Validation
- Let  $\hat{\mathbf{f}}_n(\lambda) = \mathbf{A}_n(\lambda)\mathbf{y} = (\mathbf{I}_n + \lambda \mathbf{M})^{-1}\mathbf{y}$  be the estimator of CDS model with the order *m* and denote  $r_n(\lambda) = n^{-1} \|\hat{\mathbf{f}}_n(\lambda) \mathbf{f}\|^2$ . The asymptotic optimality of GCV is defined as

$$\frac{r_n(\hat{\lambda}_G)}{\inf_{\lambda \in \mathbb{R}_+} r_n(\lambda)} \longrightarrow_p 1 \tag{9}$$

where  $\longrightarrow_{p}$  means the convergence in probability.

# (A.1) $\inf_{\lambda \in \mathbb{R}_+} nE[r_n(\lambda)] \to \infty.$

(A.2) There exists a sequence  $\{\lambda_n\}$  such that  $r_n(\lambda_n) \longrightarrow_p 0$  (the convergence in probability).

(A.3) Let  $0 \le \kappa_1 \le \cdots \le \kappa_n$  be the eigenvalues of  $\mathbf{K}_n(\lambda) = \lambda \mathbf{M}$ . For any  $\ell$  such that  $\frac{\ell}{n} \to 0$ , then  $\frac{\left(n^{-1}\sum_{i=\ell+1}^n \kappa_i^{-1}\right)^2}{n^{-1}\sum_{i=\ell+1}^n \kappa_i^{-2}} \to 0$  as  $n \to \infty$ .

◆□▶ ◆□▶ ◆□▶ ◆□▶ ─ □

- (A.1)  $\inf_{\lambda \in \mathbb{R}_+} nE[r_n(\lambda)] \to \infty.$
- (A.2) There exists a sequence  $\{\lambda_n\}$  such that  $r_n(\lambda_n) \longrightarrow_p 0$  (the convergence in probability).

(A.3) Let  $0 \le \kappa_1 \le \cdots \le \kappa_n$  be the eigenvalues of  $\mathbf{K}_n(\lambda) = \lambda \mathbf{M}$ . For any  $\ell$  such that  $\frac{\ell}{n} \to 0$ , then  $\frac{\left(n^{-1}\sum_{i=\ell+1}^n \kappa_i^{-1}\right)^2}{n^{-1}\sum_{i=\ell+1}^n \kappa_i^{-2}} \to 0$  as  $n \to \infty$ .

- (A.1)  $\inf_{\lambda \in \mathbb{R}_+} nE[r_n(\lambda)] \to \infty.$
- (A.2) There exists a sequence  $\{\lambda_n\}$  such that  $r_n(\lambda_n) \longrightarrow_p 0$  (the convergence in probability).

(A.3) Let 
$$0 \le \kappa_1 \le \cdots \le \kappa_n$$
 be the eigenvalues of  $\mathbf{K}_n(\lambda) = \lambda \mathbf{M}$ . For any  $\ell$  such that  $\frac{\ell}{n} \to 0$ , then  $\frac{\left(n^{-1}\sum_{i=\ell+1}^n \kappa_i^{-1}\right)^2}{n^{-1}\sum_{i=\ell+1}^n \kappa_i^{-2}} \to 0$  as  $n \to \infty$ .

(日) (圖) (E) (E) (E)

### • Formal result

#### Theorem

Under conditions (A.1), (A.2) and (A.3),  $\mathbf{\hat{f}}_{n}(\hat{\lambda}_{G})$  is asymptotically optimal, where  $\hat{\lambda}_{G}$  is the GCV choice.

Birs 27 / 38

イロト イヨト イヨト イヨト

### • Formal result

#### Theorem

Under conditions (A.1), (A.2) and (A.3),  $\hat{\mathbf{f}}_n(\hat{\lambda}_G)$  is asymptotically optimal, where  $\hat{\lambda}_G$  is the GCV choice.

- 4 同 ト - 4 三 ト

## Background

- 2 Data Driven Method
- 3 Theoretical Consideration: Rate of Convergence
- 4 Asymptotic Optimality of the Generalized Cross Validation

## 5 Fast Computation

## 6 Simulations

< ロ > < 同 > < 回 > < 回 > < 回

- Sparsity of design matrix **M**; Recall  $\hat{\mathbf{f}} = (\mathbf{I}_n + \lambda \cdot \mathbf{M})^{-1} \cdot \mathbf{Y}$
- The number of nonzeros of **M** is strictly less than  $(k+1)^2 n$
- Roughly 3kn as shown in numerical experiments
- M can be permutated to a band matrix by the symmetric reverse Cuthill-Mckee ordering (1969) with  $O(k \log(k)n)$  complexity
- See an example on the next page...

(日) (同) (三) (三)

- Sparsity of design matrix **M**; Recall  $\hat{\mathbf{f}} = (\mathbf{I}_n + \lambda \cdot \mathbf{M})^{-1} \cdot \mathbf{Y}$
- The number of nonzeros of **M** is strictly less than  $(k+1)^2 n$
- Roughly 3kn as shown in numerical experiments
- M can be permutated to a band matrix by the symmetric reverse Cuthill-Mckee ordering (1969) with  $O(k \log(k)n)$  complexity
- See an example on the next page...

イロト イヨト イヨト

- Sparsity of design matrix **M**; Recall  $\hat{\mathbf{f}} = (\mathbf{I}_n + \lambda \cdot \mathbf{M})^{-1} \cdot \mathbf{Y}$
- The number of nonzeros of **M** is strictly less than  $(k+1)^2 n$
- Roughly 3kn as shown in numerical experiments
- M can be permutated to a band matrix by the symmetric reverse Cuthill-Mckee ordering (1969) with  $O(k \log(k)n)$  complexity
- See an example on the next page...

- Sparsity of design matrix **M**; Recall  $\hat{\mathbf{f}} = (\mathbf{I}_n + \lambda \cdot \mathbf{M})^{-1} \cdot \mathbf{Y}$
- The number of nonzeros of **M** is strictly less than  $(k+1)^2 n$
- Roughly 3kn as shown in numerical experiments
- **M** can be permutated to a band matrix by the symmetric reverse Cuthill-Mckee ordering (1969) with  $O(k \log(k)n)$  complexity

See an example on the next page...

イロト 人間ト イヨト イヨト

- Sparsity of design matrix **M**; Recall  $\hat{\mathbf{f}} = (\mathbf{I}_n + \lambda \cdot \mathbf{M})^{-1} \cdot \mathbf{Y}$
- The number of nonzeros of **M** is strictly less than  $(k+1)^2 n$
- Roughly 3kn as shown in numerical experiments
- **M** can be permutated to a band matrix by the symmetric reverse Cuthill-Mckee ordering (1969) with  $O(k \log(k)n)$  complexity
- See an example on the next page...

## **Results of Reordering**



Birs 30 / 38
#### • p is the bandwidth of reordered matrix M

- A band  $LDL^{T}$  decomposition procedure, plus other steps, can find all eigenvalues with  $pn^{2}$  complexity. We observe that  $p \approx O((kn)^{0.5})$ . So the overall complexity is  $O(n^{2.5})$ .
- The above so far is an empirical observation

< ロト < 同ト < ヨト < ヨト

- p is the bandwidth of reordered matrix M
- A band  $LDL^{T}$  decomposition procedure, plus other steps, can find all eigenvalues with  $pn^{2}$  complexity. We observe that  $p \approx O((kn)^{0.5})$ . So the overall complexity is  $O(n^{2.5})$ .
- The above so far is an empirical observation

- p is the bandwidth of reordered matrix M
- A band  $LDL^{T}$  decomposition procedure, plus other steps, can find all eigenvalues with  $pn^{2}$  complexity. We observe that  $p \approx O((kn)^{0.5})$ . So the overall complexity is  $O(n^{2.5})$ .
- The above so far is an empirical observation

## Background

- 2 Data Driven Method
- 3 Theoretical Consideration: Rate of Convergence
- 4 Asymptotic Optimality of the Generalized Cross Validation
- 5 Fast Computation



### • CDS (our method): completely-data-drive smoothing,

- Soap film (Wood et al. JRSSB 2008)
  - based on penalty function



- TPS: thin-plate splines
  - with Ω = ℝ<sup>d</sup>, you have φ(z) = ||z x<sub>i</sub>||<sup>2</sup> log ||z x<sub>i</sub>|| in 2-D as basis functions

イロト イヨト イヨト イヨト

## • CDS (our method): completely-data-drive smoothing,

### • Soap film (Wood et al. JRSSB 2008)

• based on penalty function

$$R(f) = \int_{\Omega} \left( \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \right)^2 dx dy$$

- TPS: thin-plate splines
  - with Ω = ℝ<sup>d</sup>, you have φ(z) = ||z − x<sub>i</sub>||<sup>2</sup> log ||z − x<sub>i</sub>|| in 2-D as basis functions

- CDS (our method): completely-data-drive smoothing,
- Soap film (Wood et al. JRSSB 2008)
  - based on penalty function

$$R(f) = \int_{\Omega} \left( \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \right)^2 dx dy$$

- TPS: thin-plate splines
  - with Ω = ℝ<sup>d</sup>, you have φ(z) = ||z − x<sub>i</sub>||<sup>2</sup> log ||z − x<sub>i</sub>|| in 2-D as basis functions

イロト イヨト イヨト

- CDS (our method): completely-data-drive smoothing,
- Soap film (Wood et al. JRSSB 2008)
  - based on penalty function

$$R(f) = \int_{\Omega} \left( \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \right)^2 dx dy$$

- TPS: thin-plate splines
  - with  $\Omega = \mathbb{R}^d$ , you have  $\phi(z) = ||z x_i||^2 \log ||z x_i||$  in 2-D as basis functions

(日) (圖) (E) (E) (E)

- CDS (our method): completely-data-drive smoothing,
- Soap film (Wood et al. JRSSB 2008)
  - based on penalty function

$$R(f) = \int_{\Omega} \left( \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \right)^2 dx dy$$

- TPS: thin-plate splines
  - with  $\Omega = \mathbb{R}^d$ , you have  $\phi(z) = ||z x_i||^2 \log ||z x_i||$  in 2-D as basis functions

ヘロト 人間ト 人間ト 人目ト

## Recall the Irregular Domains





Birs 34 / 38

20

15

10

-30 -20 -10

0 10

## Horseshoe Example



Figure: The first, second, and third rows are for n = 1000, 2000, 5000, respectively. From left to right the noise is dominated by  $\sigma = 0.1, 1, 10$ .

Birs 35 / 38

Image: A = 1

# Regular Domain [0, 1]<sup>2</sup>



xiaoming@isye.gatech.edu (Georgia Tech)

Estimation on Irregular Domains

(ロ) (部) (目) (日) (日)

Letter "R"



Figure: The RMSE is scaled by log<sub>10</sub>.

xiaoming@isye.gatech.edu (Georgia Tech)

Estimation on Irregular Domains

<ロト < 団ト < 団ト < 団ト

- The idea of using local estimates to replace an analytical penalty function—*complete data driven approach*—seems appealing.
  - Numerical experiments demonstrate promise
  - 2 Theoretical justification is provided
- Acknowledgment: Partially supported by NSF.
- Thank You!

- The idea of using local estimates to replace an analytical penalty function—*complete data driven approach*—seems appealing.
  - Numerical experiments demonstrate promise
    - Theoretical justification is provided
- Acknowledgment: Partially supported by NSF.
- Thank You!

- The idea of using local estimates to replace an analytical penalty function—*complete data driven approach*—seems appealing.
  - Numerical experiments demonstrate promise
  - Theoretical justification is provided
- Acknowledgment: Partially supported by NSF.
- Thank You!

- The idea of using local estimates to replace an analytical penalty function—*complete data driven approach*—seems appealing.
  - Numerical experiments demonstrate promise
  - Theoretical justification is provided
- Acknowledgment: Partially supported by NSF.

Thank You!

・ロン ・四 ・ ・ ヨン

- The idea of using local estimates to replace an analytical penalty function—*complete data driven approach*—seems appealing.
  - Numerical experiments demonstrate promise
  - Theoretical justification is provided
- Acknowledgment: Partially supported by NSF.
- Thank You!

イロト 人間ト イヨト イヨト