

プラスコンテンツ

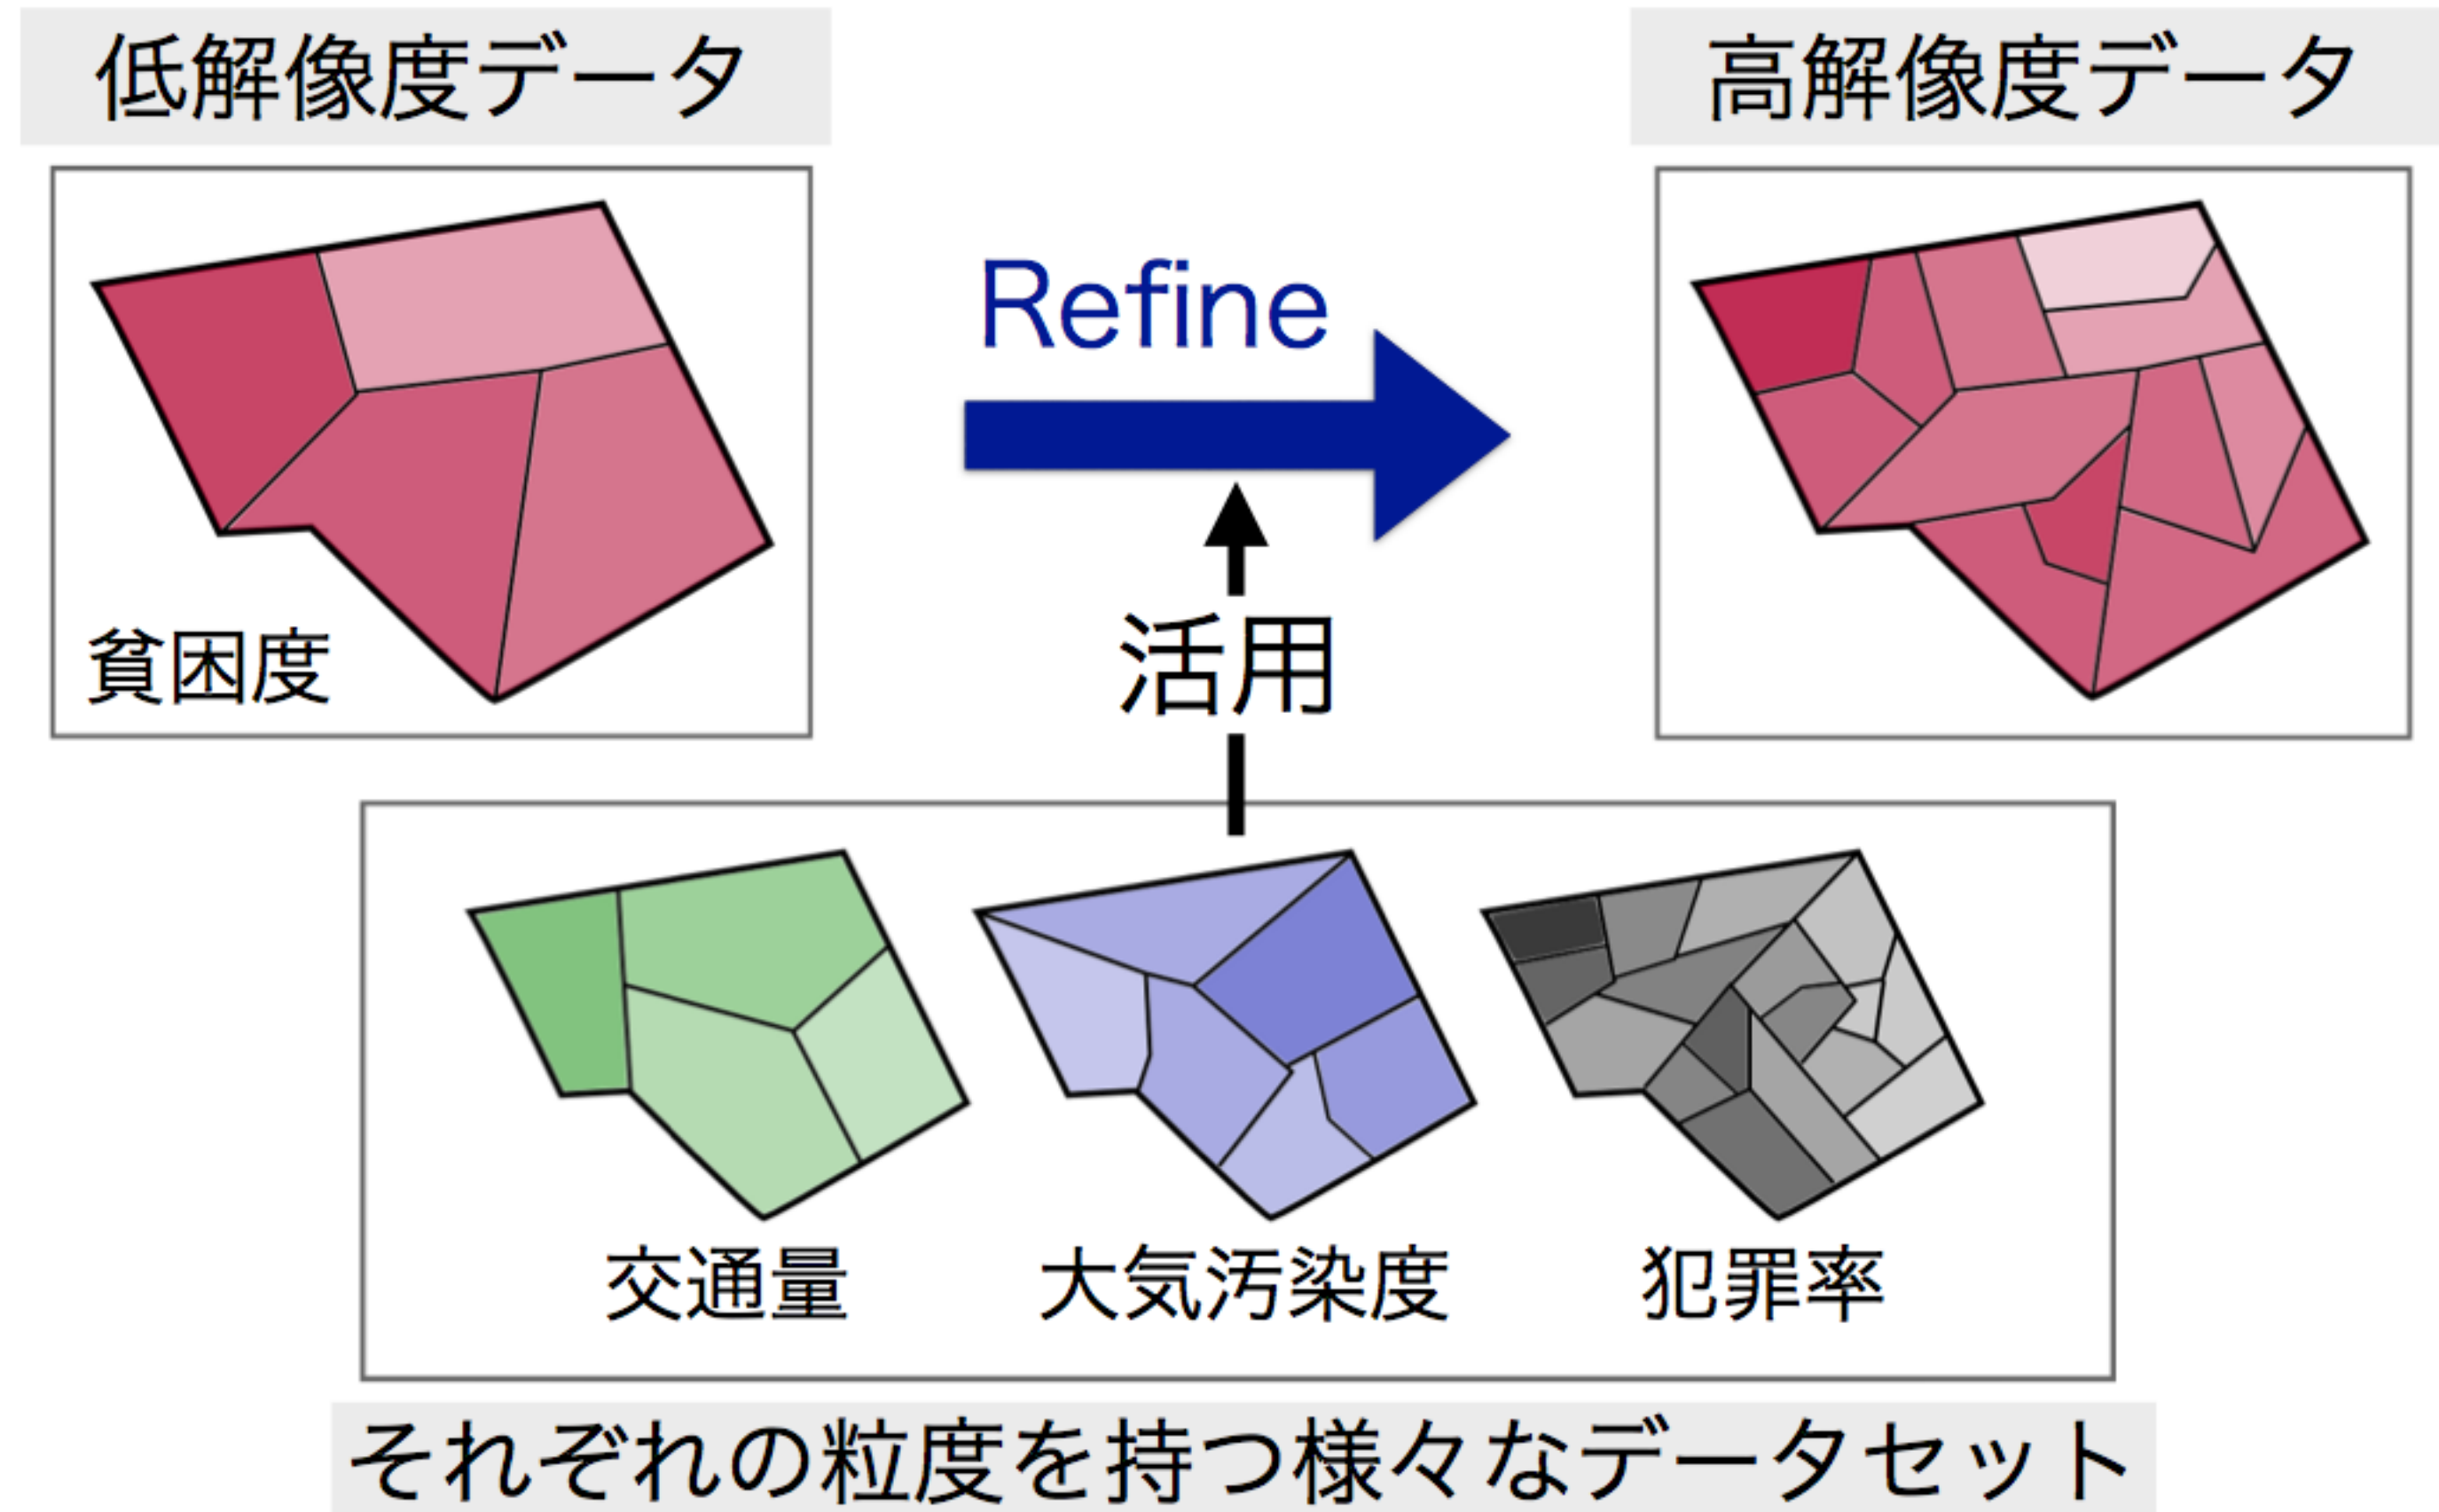
都市における 空間集約データの高解像度化

NTTサービスエボリューション研究所
田中佑典

タスク：粗い粒度に集約されたデータの高解像度版を予測
利点：介入（再開発等）が必要な地域を詳細に絞り込める

※都市における集約データ（種類は問わない）を想定

タスク
空間集約データの高解像度化



関連する出版物
・ Y. Tanaka et al., NeurIPS, 2019.

問題設定

- ・ 入力データ
- ・ 予測 (Refinement)

データセットの種類数： S


S 番目のデータセットに対する X の分割： P_s

↑
入力空間(都市全体の領域)

S 番目のデータセット： $D_s = \{(y_{s,n}, \mathbf{R}_{s,n})\}$ 但し, $\mathbf{R}_{s,n} \in P_s$

↑ ↑ ↑ ↑
データセットID 値 領域 領域ID

データセット毎に様々な粒度の分割に紐づく




問題設定

- ・ 入力データ
- ・ 予測 (Refinement)

S 番目のデータセットに対して, 高解像度データ D_s^{fine} を予測


低解像度データ



D_s

Refine
→

高解像度データ



$$D_s^{\text{fine}} = \{(y_{s,n}^{\text{fine}}, R_n^{\text{fine}})\}$$

但し, $R_n^{\text{fine}} \in P^{\text{fine}}$


↑
必要に応じて任意の
パーティションを設定

高解像度化のための アイデア

- データの空間相関を捉えて
内挿する
- 同じ都市における他の種類
のデータセットを活用

データの背後に滑らかな関数（ガウス過程）を仮定

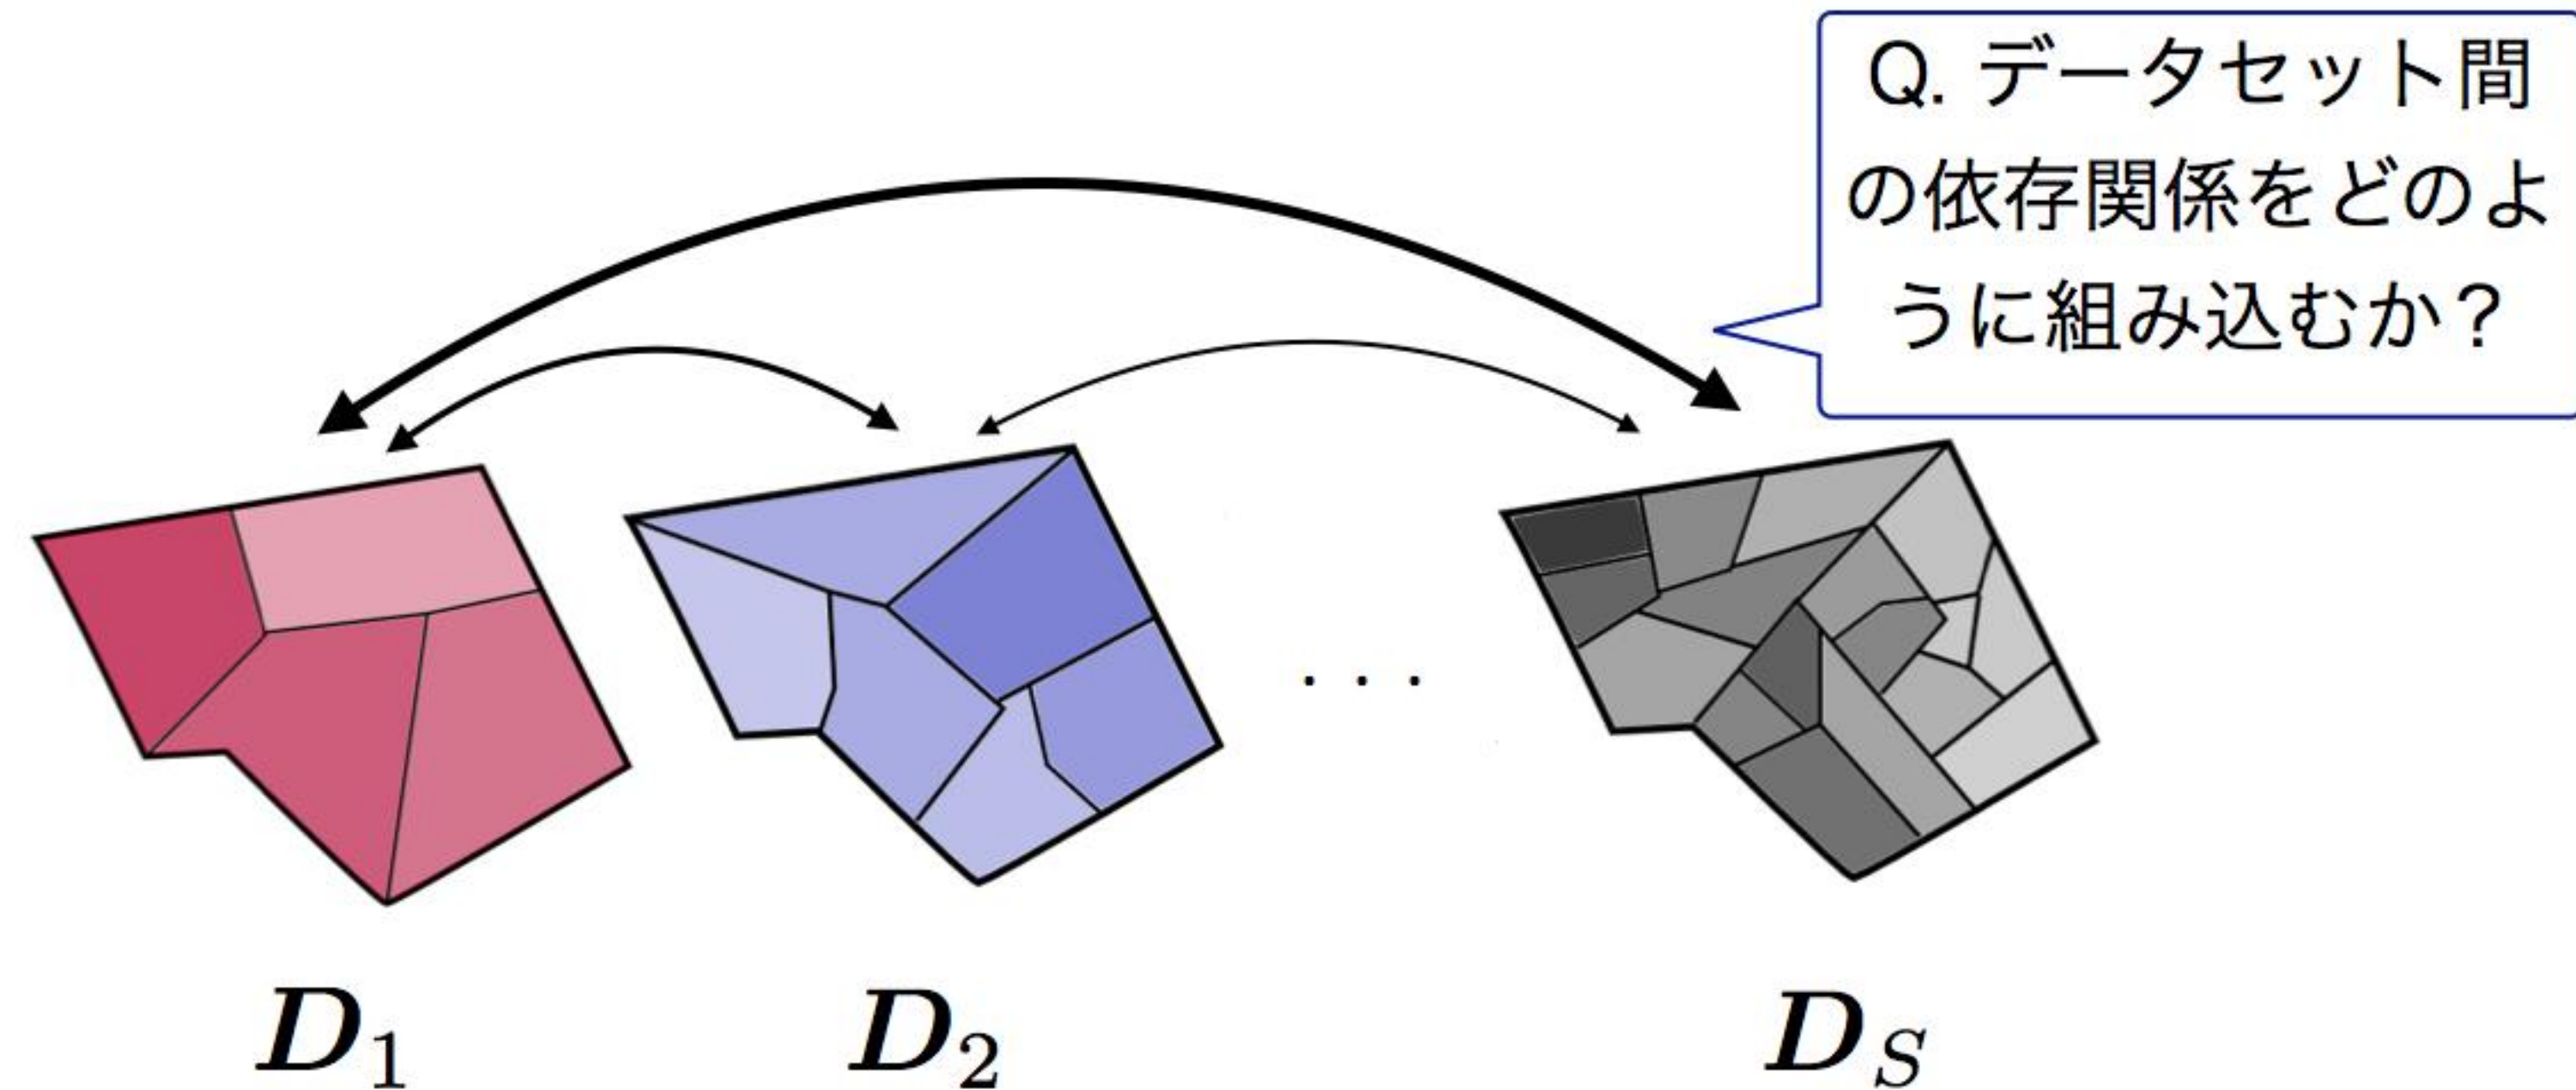
$$f_s(\mathbf{x}) : \mathbf{X} \rightarrow \mathbb{R}, \quad s = 1, \dots, S$$



高解像度化のための アイデア

- データの空間相関を捉えて
内挿する
- 同じ都市における他の種類
のデータセットを活用

データの空間分布の類似性を捉えて
低解像度データの空間補完に活用する



Questions

ガウス過程を基礎として,

Q1. 領域で集約された観測をどのようにモデル化するか？

→ Spatially Aggregated Gaussian Processes with a Single Output (SAGP-S) の定式化

Q2. データセット間の依存関係をどのように組み込むか？

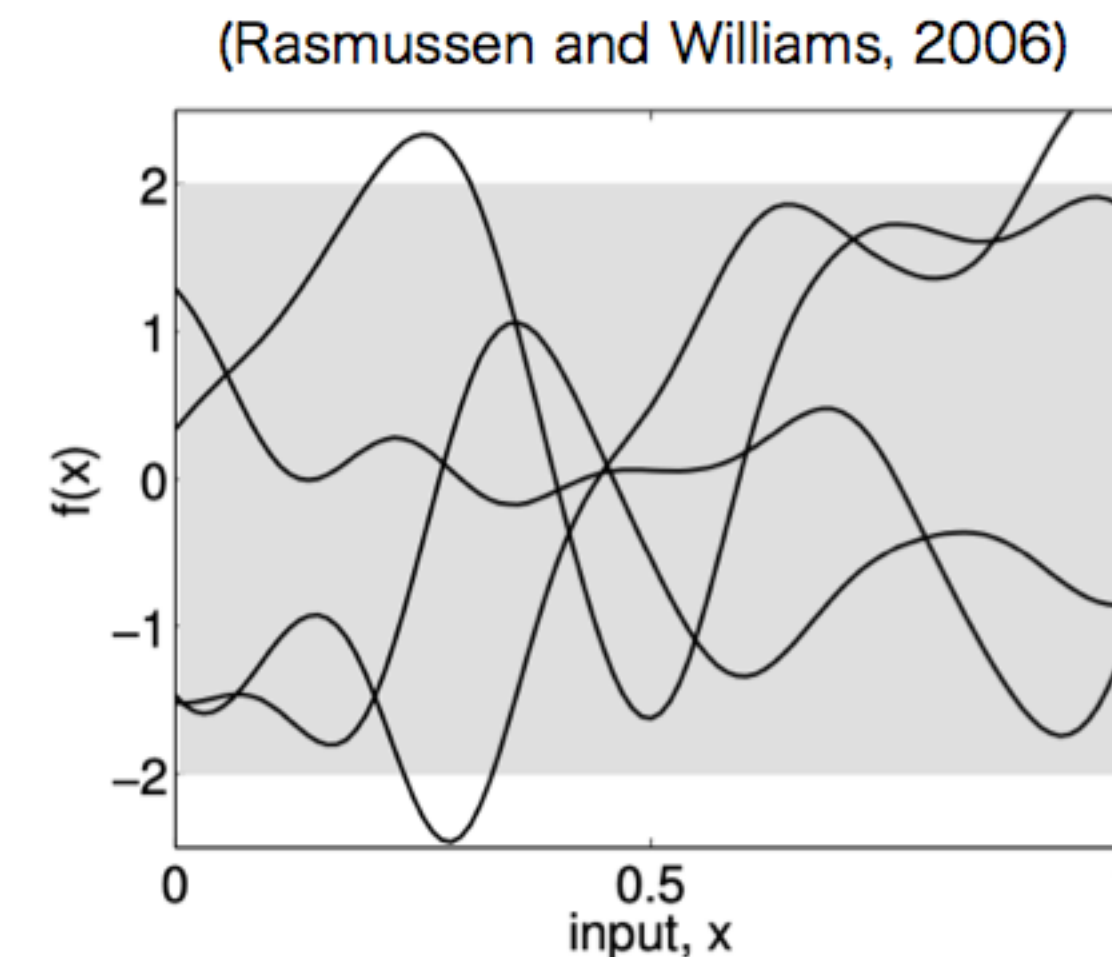
→ 多変量ガウス過程をベースにして集約データを扱うことが可能なSpatially Aggregated Gaussian Processes with Multiple Outputs (SAGP-M) の定式化

Spatially Aggregated
Gaussian Processes
with a Single Output
(SAGP-S)

- 関数 $f(\boldsymbol{x})$ の確率的生成モデル

$$f(\boldsymbol{x}) \sim \mathcal{GP}(m(\boldsymbol{x}), k(\boldsymbol{x}, \boldsymbol{x}'))$$

↑ ↑
平均関数 共分散関数



- ガウス過程の定義

N個の点 $\boldsymbol{x}_1, \dots, \boldsymbol{x}_N$ が与えられたとしたとき,
 $\boldsymbol{f} = (f(\boldsymbol{x}_1), \dots, f(\boldsymbol{x}_N))^T$ は以下のN次元ガウス分布に従う

$$\boldsymbol{f} \sim \mathcal{N}(\boldsymbol{f} \mid \boldsymbol{m}, \boldsymbol{K})$$

\boldsymbol{m} : N次元平均ベクトル. n番目の要素 $m(\boldsymbol{x}_n)$

\boldsymbol{K} : N×N 共分散行列. (n,n')番目の要素 $k(\boldsymbol{x}_n, \boldsymbol{x}_{n'})$

- ガウス過程
- 集約プロセスを持つ観測モデル
- 推定

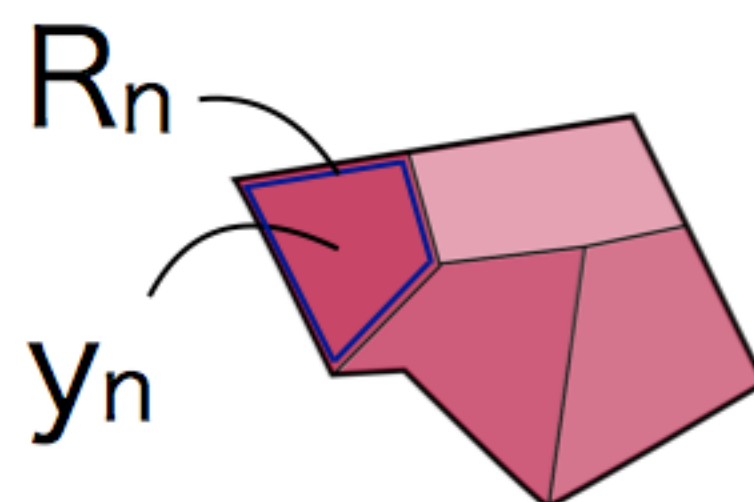
Spatially Aggregated
Gaussian Processes
with a Single Output
(SAGP-S)

$$\text{GP prior : } f(\mathbf{x}) \sim \mathcal{GP}(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}'))$$

観測モデル :

空間集約プロセス (Burgess and Webster, 1980)

$$\mathbf{y} \mid f(\mathbf{x}) \sim \mathcal{N} \left(\mathbf{y} \mid \int_{\mathbf{X}} \mathbf{a}(\mathbf{x}) f(\mathbf{x}) d\mathbf{x}, \sigma^2 \mathbf{I} \right)$$



|P|個の領域

$$\mathbf{a}(\mathbf{x}) = (a_1(\mathbf{x}), \dots, a_{|P|}(\mathbf{x}))^\top$$

$$a_n(\mathbf{x}) = \frac{\mathbb{1}(\mathbf{x} \in \mathbf{R}_n)}{\int_{\mathbf{X}} \mathbb{1}(\mathbf{x}' \in \mathbf{R}_n) d\mathbf{x}'}$$

Indicator function

- ・ ガウス過程
- ・ 集約プロセスを持つ観測モデル
- ・ 推定

※ GP $f(\mathbf{x})$ が積分可能であると仮定. 積分可能な条件は, GPのsample pathが連続かどうかを調べることで議論. 十分条件が知られている (Adler and Taylor, 2007)

Spatially Aggregated
Gaussian Processes
with a Single Output
(SAGP-S)

- ・ ガウス過程
- ・ 集約プロセスを持つ観測モデル
- ・ 推定

GP prior : $f(\mathbf{x}) \sim \mathcal{GP}(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}'))$

観測モデル : $\mathbf{y} \mid f(\mathbf{x}) \sim \mathcal{N}(\mathbf{y} \mid \int_{\mathbf{X}} \mathbf{a}(\mathbf{x}) f(\mathbf{x}) d\mathbf{x}, \sigma^2 \mathbf{I})$


観測データ : $\{(\mathbf{R}_n, y_n)\}_{n=1}^{|P|} \longrightarrow$ Posterior GP : $f^*(\mathbf{x}) \mid \mathbf{y}$

● 周辺尤度

Step 1. リーマン和で表してGPを積分消去

$$p(\mathbf{y}) = \int \mathcal{N}(\mathbf{y} \mid \bar{\mathbf{a}} \bar{\mathbf{f}}, \sigma^2 \mathbf{I}) \underbrace{\mathcal{N}(\bar{\mathbf{f}} \mid \bar{\mathbf{m}}, \bar{\mathbf{K}})}_{\substack{\uparrow \\ \text{I個のグリッド点} \\ \text{におけるGP}}} d\bar{\mathbf{f}}$$

$$= \mathcal{N}(\mathbf{y} \mid \bar{\boldsymbol{\mu}}, \bar{\mathbf{C}})$$



但し, $\bar{\mathbf{a}} = (\mathbf{a}(\mathbf{x}_1), \dots, \mathbf{a}(\mathbf{x}_I)) \Delta$

$$\bar{\boldsymbol{\mu}} = \sum_{i=1}^I \mathbf{a}(\mathbf{x}_i) m(\mathbf{x}_i) \Delta$$

$$\bar{\mathbf{C}} = \sum_{i, i'=1}^I k(\mathbf{x}_i, \mathbf{x}_{i'}) \mathbf{a}(\mathbf{x}_i) \mathbf{a}(\mathbf{x}_{i'})^\top \Delta^2 + \sigma^2 \mathbf{I}$$

Spatially Aggregated
Gaussian Processes
with a Single Output
(SAGP-S)

- ・ ガウス過程
- ・ 集約プロセスを持つ観測モデル
- ・ 推定

GP prior : $f(\mathbf{x}) \sim \mathcal{GP}(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}'))$

観測モデル : $\mathbf{y} \mid f(\mathbf{x}) \sim \mathcal{N}(\mathbf{y} \mid \int_{\mathbf{X}} \mathbf{a}(\mathbf{x}) f(\mathbf{x}) d\mathbf{x}, \sigma^2 \mathbf{I})$

観測データ : $\{(\mathbf{R}_n, y_n)\}_{n=1}^{|\mathbf{P}|} \longrightarrow$ Posterior GP : $f^*(\mathbf{x}) \mid \mathbf{y}$

● 周辺尤度

Step 2. $\Delta \rightarrow 0$ の極限をとる

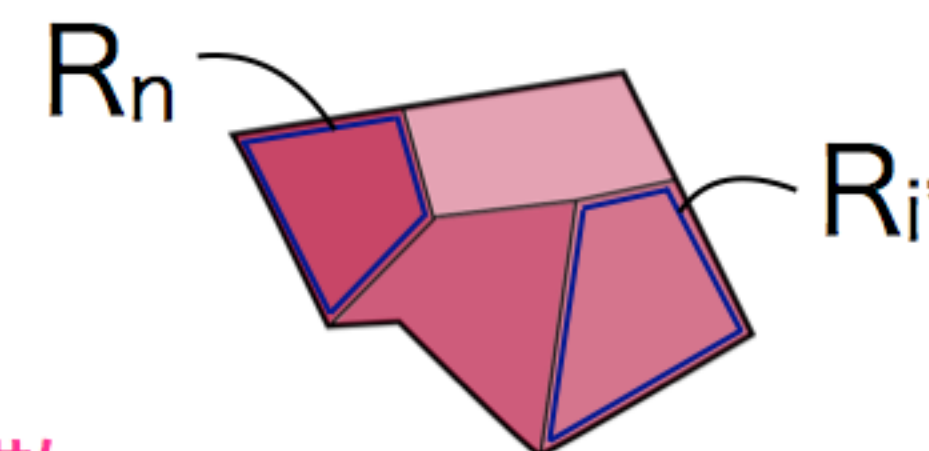
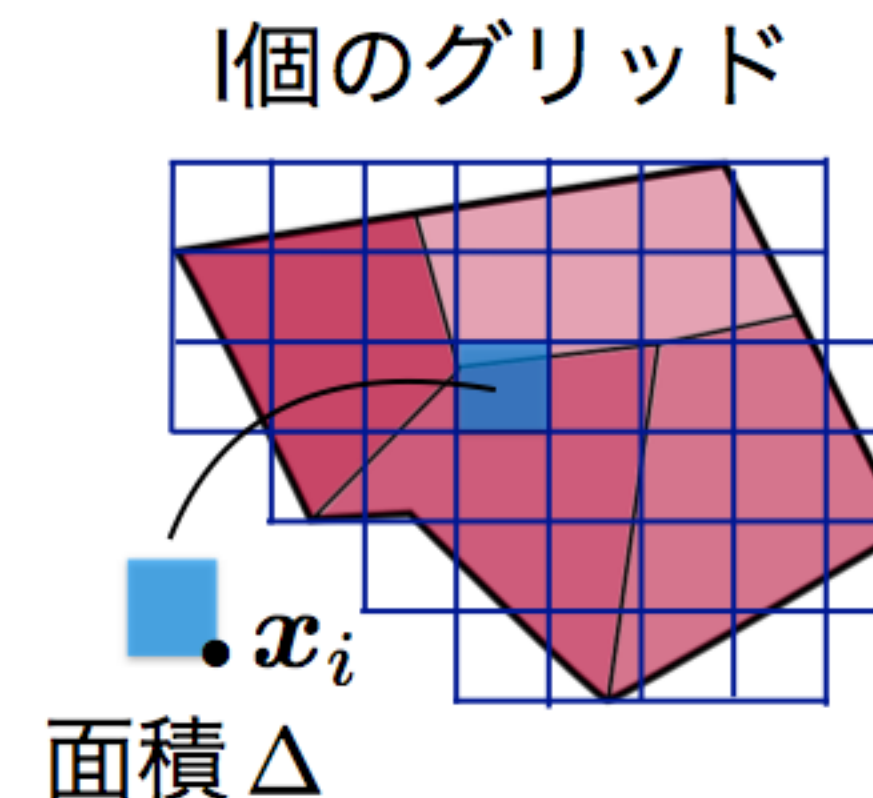
$$p(\mathbf{y}) = \mathcal{N}(\mathbf{y} \mid \bar{\boldsymbol{\mu}}, \bar{\mathbf{C}})$$

$$\bar{\boldsymbol{\mu}} = \sum_{i=1}^I \mathbf{a}(\mathbf{x}_i) m(\mathbf{x}_i) \Delta \rightarrow \int_{\mathbf{X}} \mathbf{a}(\mathbf{x}) m(\mathbf{x}) d\mathbf{x} = \boldsymbol{\mu}$$

$$\bar{\mathbf{C}} = \sum_{i, i'=1}^I k(\mathbf{x}_i, \mathbf{x}_{i'}) \mathbf{a}(\mathbf{x}_i) \mathbf{a}(\mathbf{x}_{i'})^\top \Delta^2 + \sigma^2 \mathbf{I}$$

$$\rightarrow \iint_{\mathbf{X} \times \mathbf{X}} k(\mathbf{x}, \mathbf{x}') \mathbf{a}(\mathbf{x}) \mathbf{a}(\mathbf{x}')^\top d\mathbf{x} d\mathbf{x}' + \sigma^2 \mathbf{I} = \mathbf{C}$$

観測領域 $\{\mathbf{R}_n\}$ と $\{\mathbf{R}_{n'}\}$ の共分散



Spatially Aggregated
Gaussian Processes
with a Single Output
(SAGP-S)

- ・ ガウス過程
- ・ 集約プロセスを持つ観測モデル
- ・ 推定

GP prior : $f(\mathbf{x}) \sim \mathcal{GP}(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}'))$

観測モデル : $\mathbf{y} \mid f(\mathbf{x}) \sim \mathcal{N}(\mathbf{y} \mid \int_{\mathbf{X}} \mathbf{a}(\mathbf{x}) f(\mathbf{x}) d\mathbf{x}, \sigma^2 \mathbf{I})$


観測データ : $\{(\mathbf{R}_n, y_n)\}_{n=1}^{|P|} \longrightarrow$ Posterior GP : $f^*(\mathbf{x}) \mid \mathbf{y}$

● 周辺尤度

$$p(\mathbf{y}) = \mathcal{N}(\mathbf{y} \mid \boldsymbol{\mu}, \mathbf{C})$$


$$\boldsymbol{\mu} = \int_{\mathbf{X}} \mathbf{a}(\mathbf{x}) m(\mathbf{x}) d\mathbf{x}$$

$$\mathbf{C} = \iint_{\mathbf{X} \times \mathbf{X}} k(\mathbf{x}, \mathbf{x}') \mathbf{a}(\mathbf{x}) \mathbf{a}(\mathbf{x}')^\top d\mathbf{x} d\mathbf{x}' + \sigma^2 \mathbf{I}$$



➔ 領域のサイズや形を考慮した共分散を算出可能

- ・ 領域が大きいほど分散は小さく (サンプルが増える)
- ・ 特異な形 (細長い領域等) をした領域にも対応



Spatially Aggregated
Gaussian Processes
with a Single Output
(SAGP-S)

- ・ ガウス過程
- ・ 集約プロセスを持つ観測モデル
- ・ 推定

GP prior : $f(\mathbf{x}) \sim \mathcal{GP}(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}'))$

観測モデル : $\mathbf{y} \mid f(\mathbf{x}) \sim \mathcal{N}(\mathbf{y} \mid \int_{\mathbf{X}} \mathbf{a}(\mathbf{x}) f(\mathbf{x}) d\mathbf{x}, \sigma^2 \mathbf{I})$

観測データ : $\{(\mathbf{R}_n, y_n)\}_{n=1}^{|\mathbf{P}|} \longrightarrow$ Posterior GP : $f^*(\mathbf{x}) \mid \mathbf{y}$

- Posterior GP (導出の手順は同じ)


$$f^*(\mathbf{x}) \mid \mathbf{y} \sim \mathcal{GP}(m^*(\mathbf{x}), k^*(\mathbf{x}, \mathbf{x}'))$$

$$m^*(\mathbf{x}) = m(\mathbf{x}) + \mathbf{h}(\mathbf{x})^\top \mathbf{C}^{-1}(\mathbf{y} - \boldsymbol{\mu})$$

$$k^*(\mathbf{x}, \mathbf{x}') = k(\mathbf{x}, \mathbf{x}') - \mathbf{h}(\mathbf{x})^\top \mathbf{C}^{-1} \mathbf{h}(\mathbf{x}')$$

$$\text{但し, } \mathbf{h}(\mathbf{x}) = \int_{\mathbf{X}} \mathbf{a}(\mathbf{x}') k(\mathbf{x}', \mathbf{x}) d\mathbf{x}'$$

任意の点 \mathbf{x} と観測領域 $\{\mathbf{R}_n\}$ との共分散



Questions

ガウス過程を基礎として,


Q1. 領域で集約された観測をどのようにモデル化するか？

→ Spatially Aggregated Gaussian Processes with a Single Output (SAGP-S) の定式化

Q2. データセット間の依存関係をどのように組み込むか？

→ 多変量ガウス過程をベースにして集約データを扱うことが可能なSpatially Aggregated Gaussian Processes with Multiple Outputs (SAGP-M) の定式化

Multivariate approach



$$D = \bigcup_{s=1}^S D_s \quad \text{但し, } D_s = \{(\mathbf{R}_{s,n}, y_{s,n}) \mid n = 1, \dots, |\mathbf{P}_s|\}$$

- $\{y_s\}$ の同時確率をモデル化

$$p(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_S)$$

- 基本的な考え方
- 先行研究 (多変量GP)
- SAGP-M
- 実験設定
- 結果
- まとめ

- S次元ガウス過程 $f(\mathbf{x}) = (f_1(\mathbf{x}), \dots, f_S(\mathbf{x}))^\top$

L個の潜在ガウス過程の線形混合により依存関係を導入

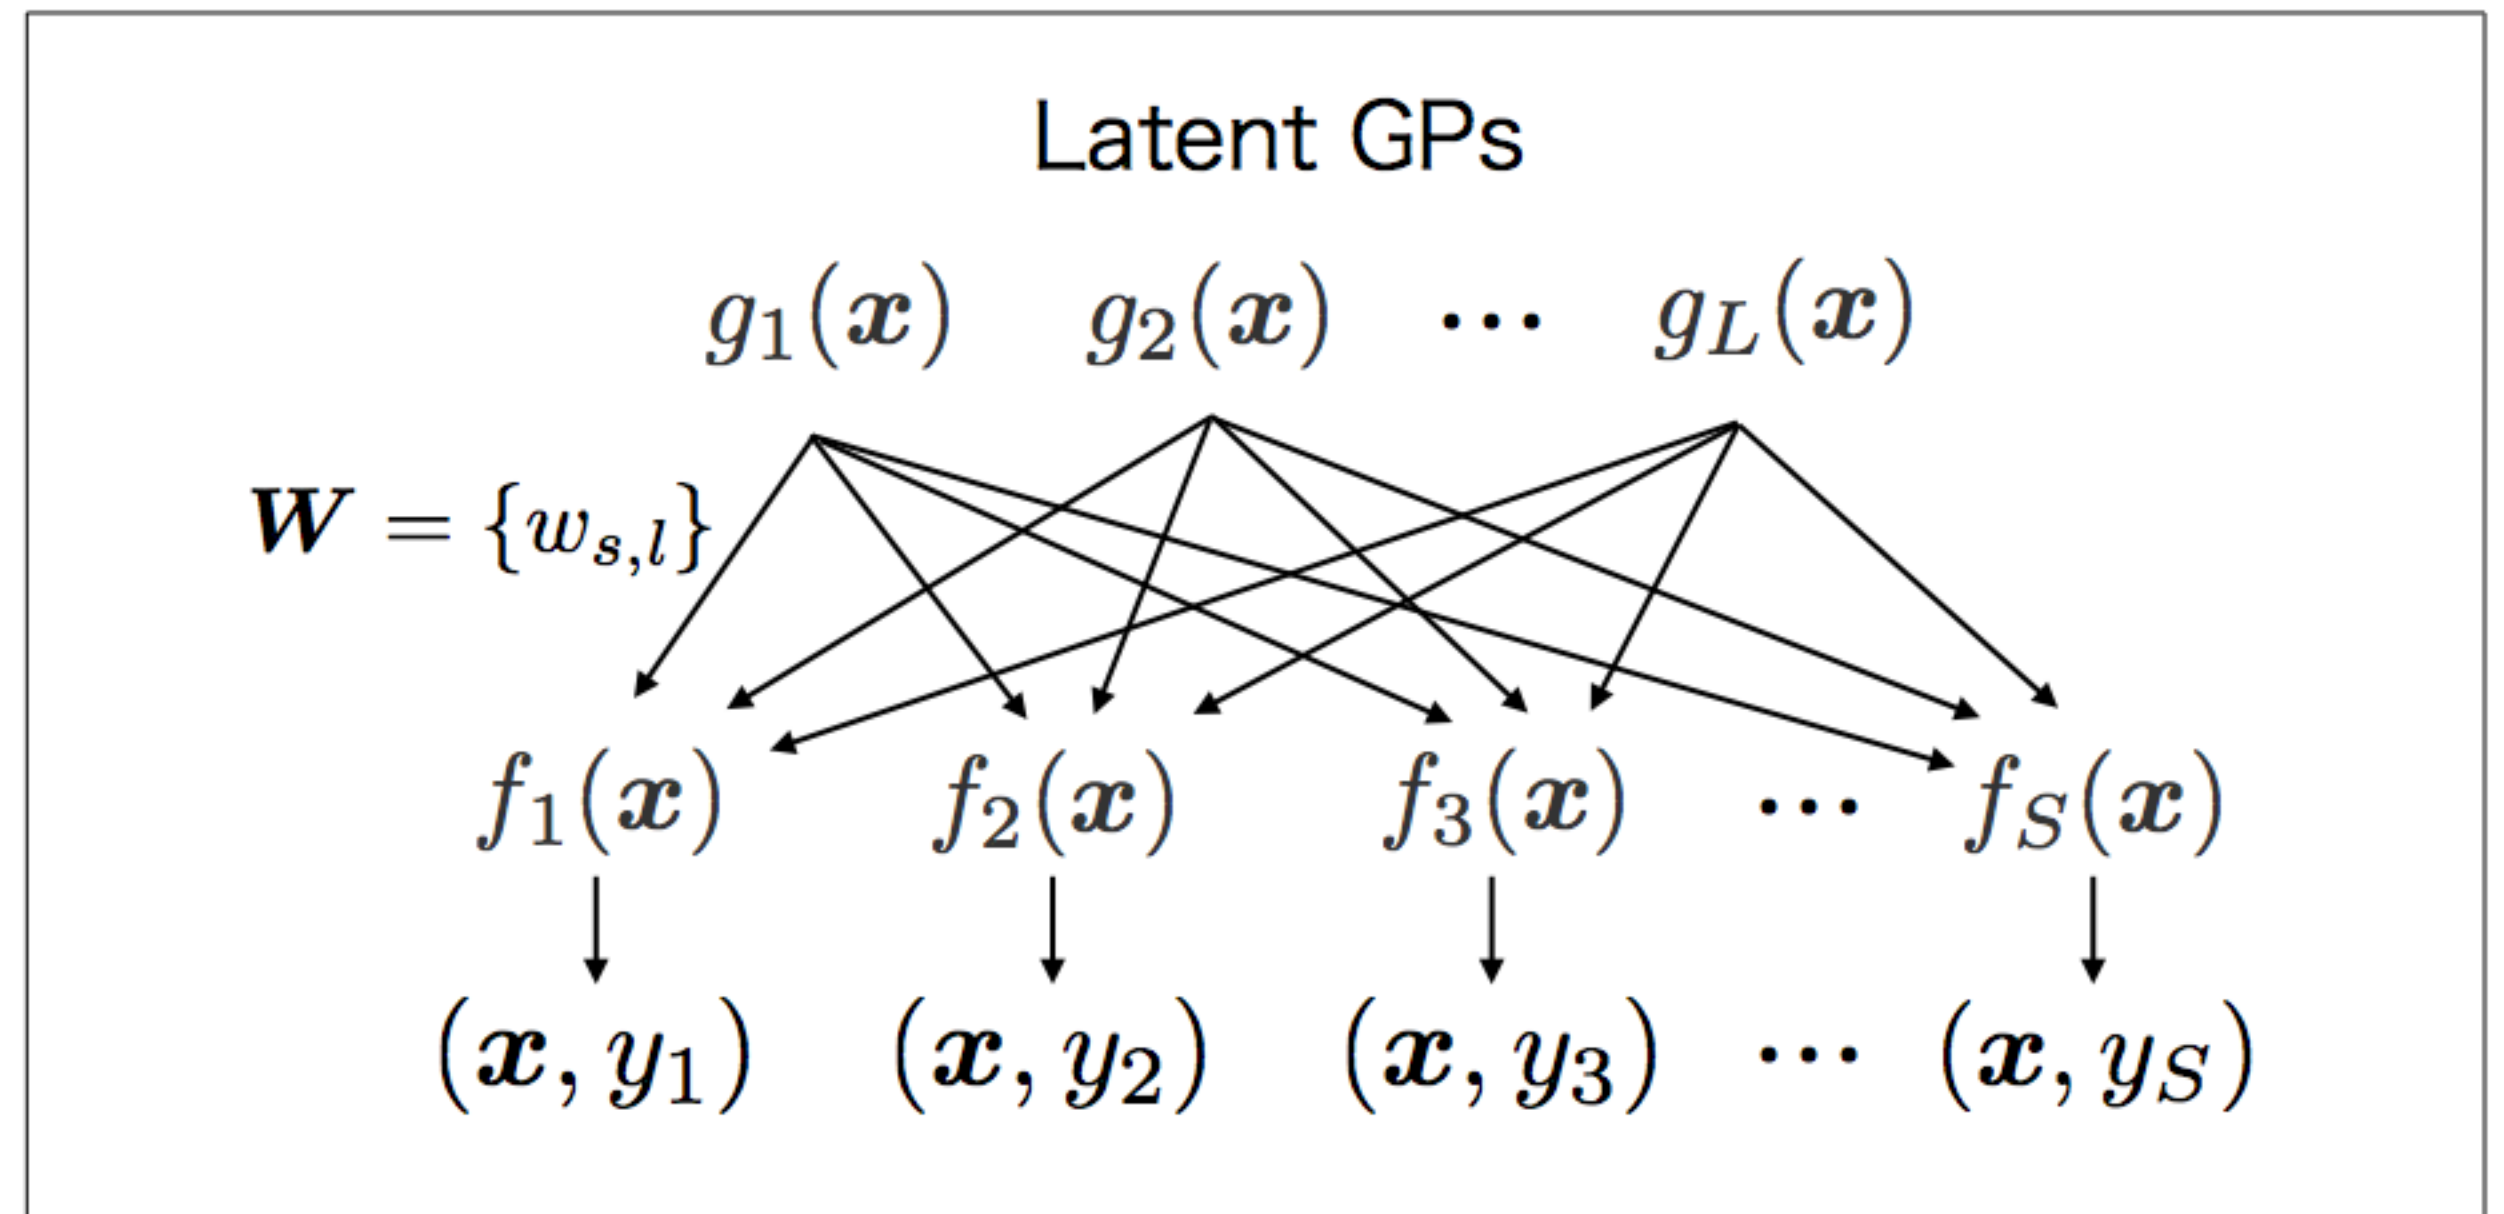
Linear Model of Coregionalization (LMC) (Alvarez, Rosasco, and Lawrence, 2012)

Multivariate approach

$$f(\mathbf{x}) = \mathbf{W}g(\mathbf{x}) + \mathbf{n}(\mathbf{x})$$

\uparrow \uparrow \swarrow
 S×L 重み行列 L個の潜在ガウス過程 S次元ガウス過程 (回帰残差)

- 基本的な考え方
- 先行研究 (多変量GP)
- SAGP-M
- 実験設定
- 結果
- まとめ



Multivariate approach

- S次元ガウス過程 $f(\mathbf{x}) = (f_1(\mathbf{x}), \dots, f_S(\mathbf{x}))^\top$

L個の潜在ガウス過程の線形混合により依存関係を導入

$$f(\mathbf{x}) \sim \mathcal{GP}(m(\mathbf{x}), K(\mathbf{x}, \mathbf{x}'))$$

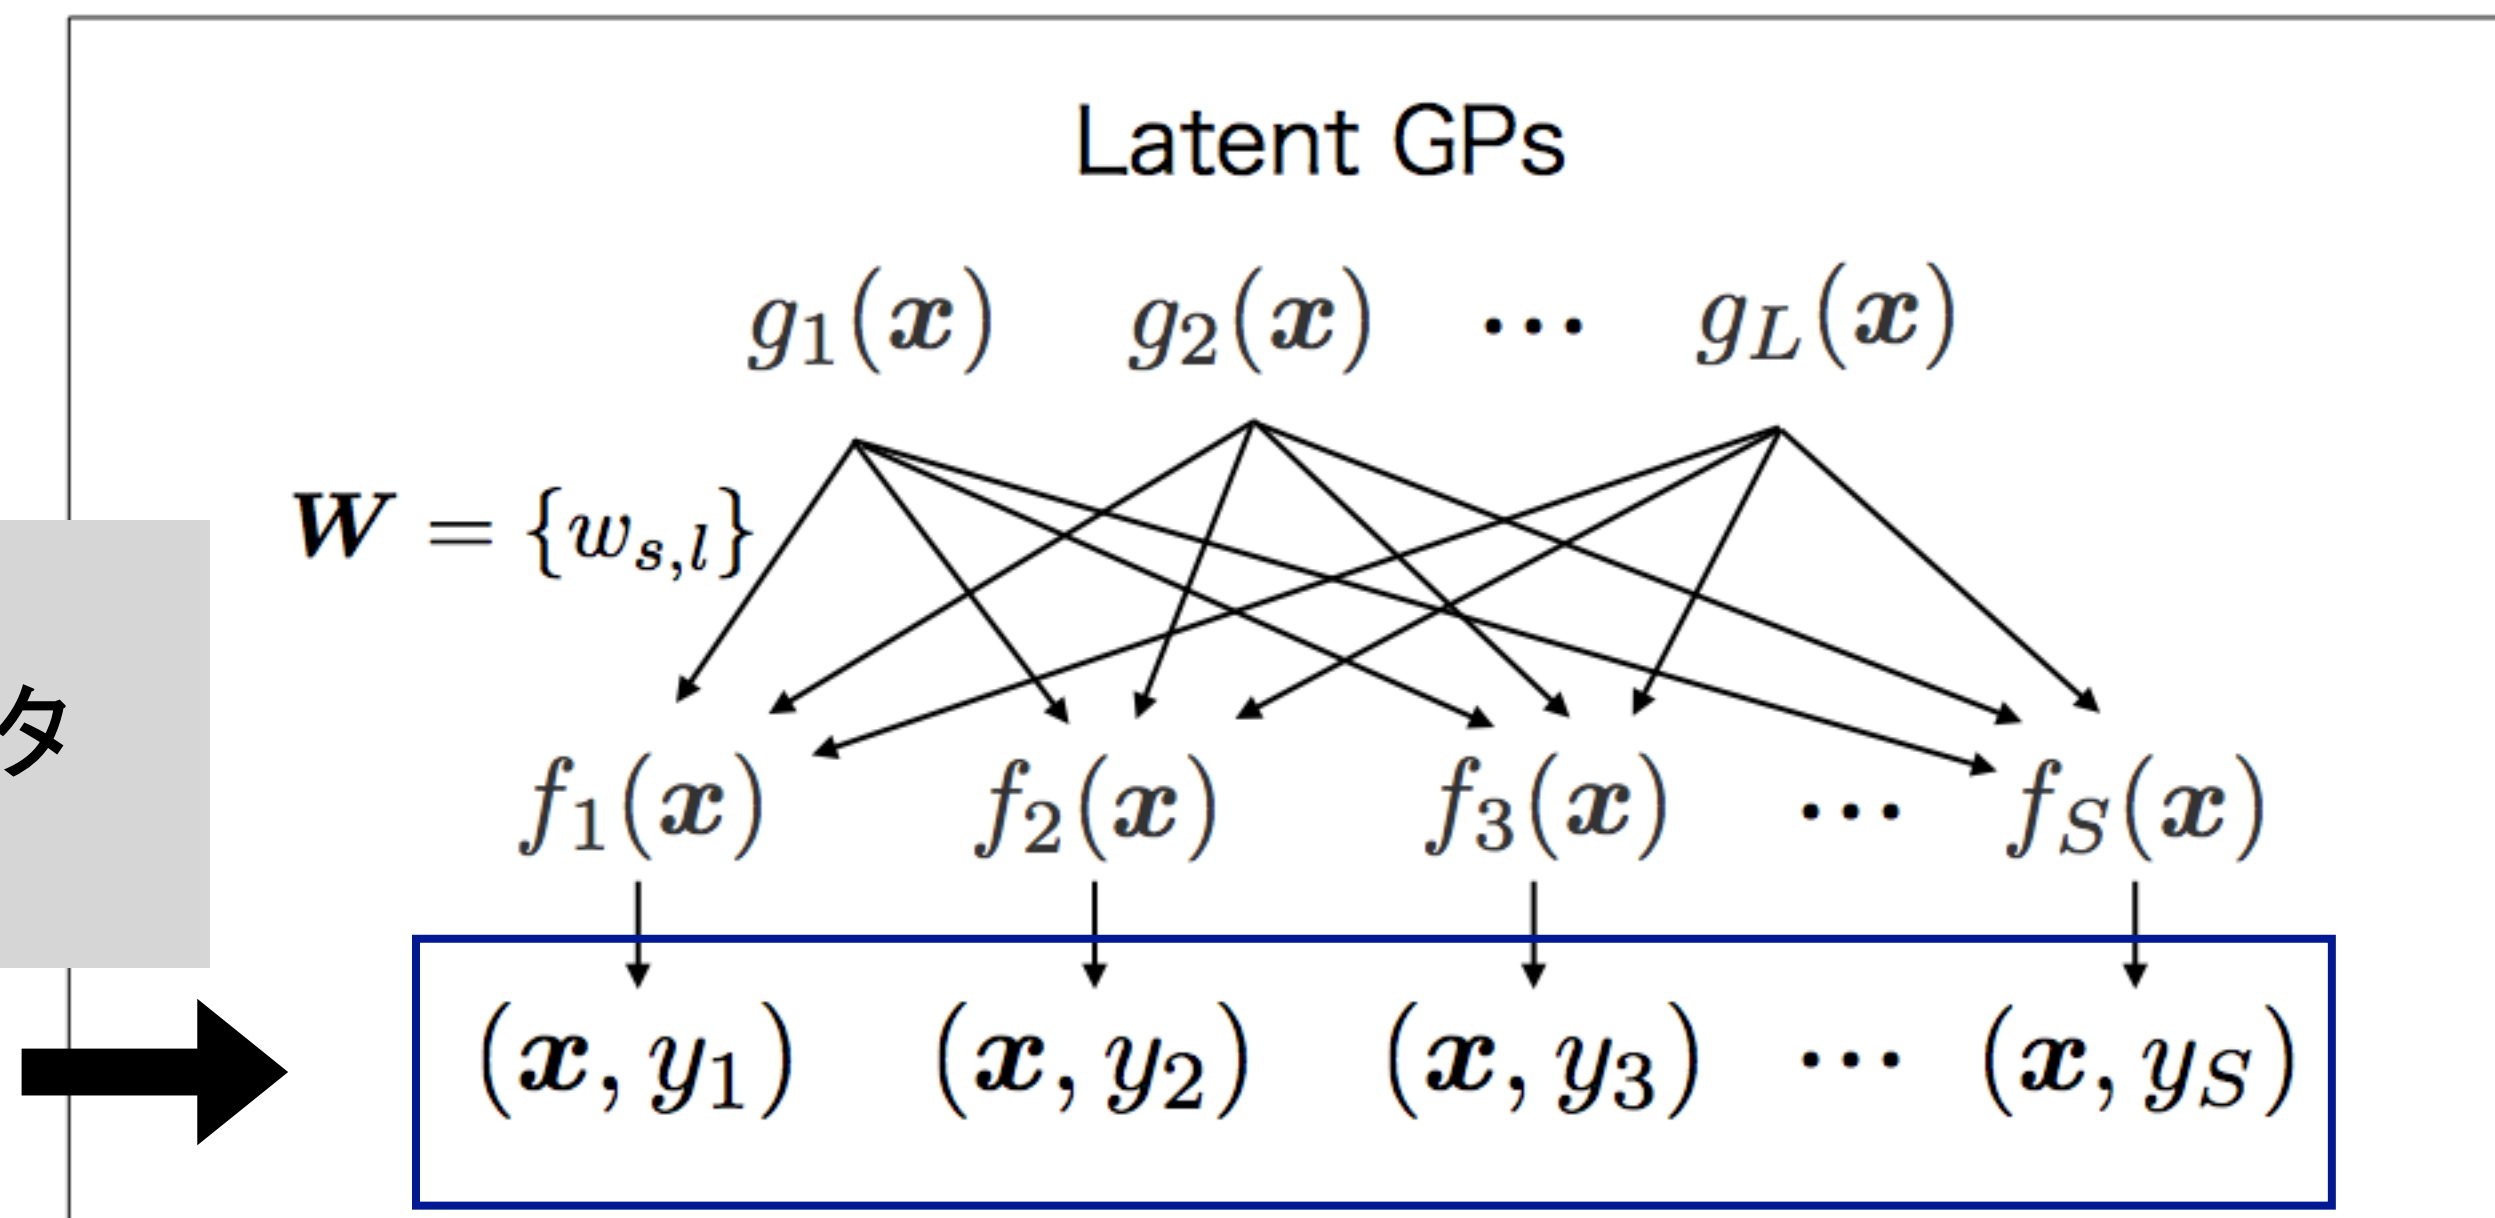
$$m(\mathbf{x}) = \mathbf{W}\nu(\mathbf{x})$$

潜在ガウス過程の平均関数

$$K(\mathbf{x}, \mathbf{x}') = \mathbf{W}\Gamma(\mathbf{x}, \mathbf{x}')\mathbf{W}^\top + \Lambda(\mathbf{x}, \mathbf{x}')$$

潜在ガウス過程の共分散関数 ノイズプロセスの共分散関数

問題点
点に紐づくデータを前提

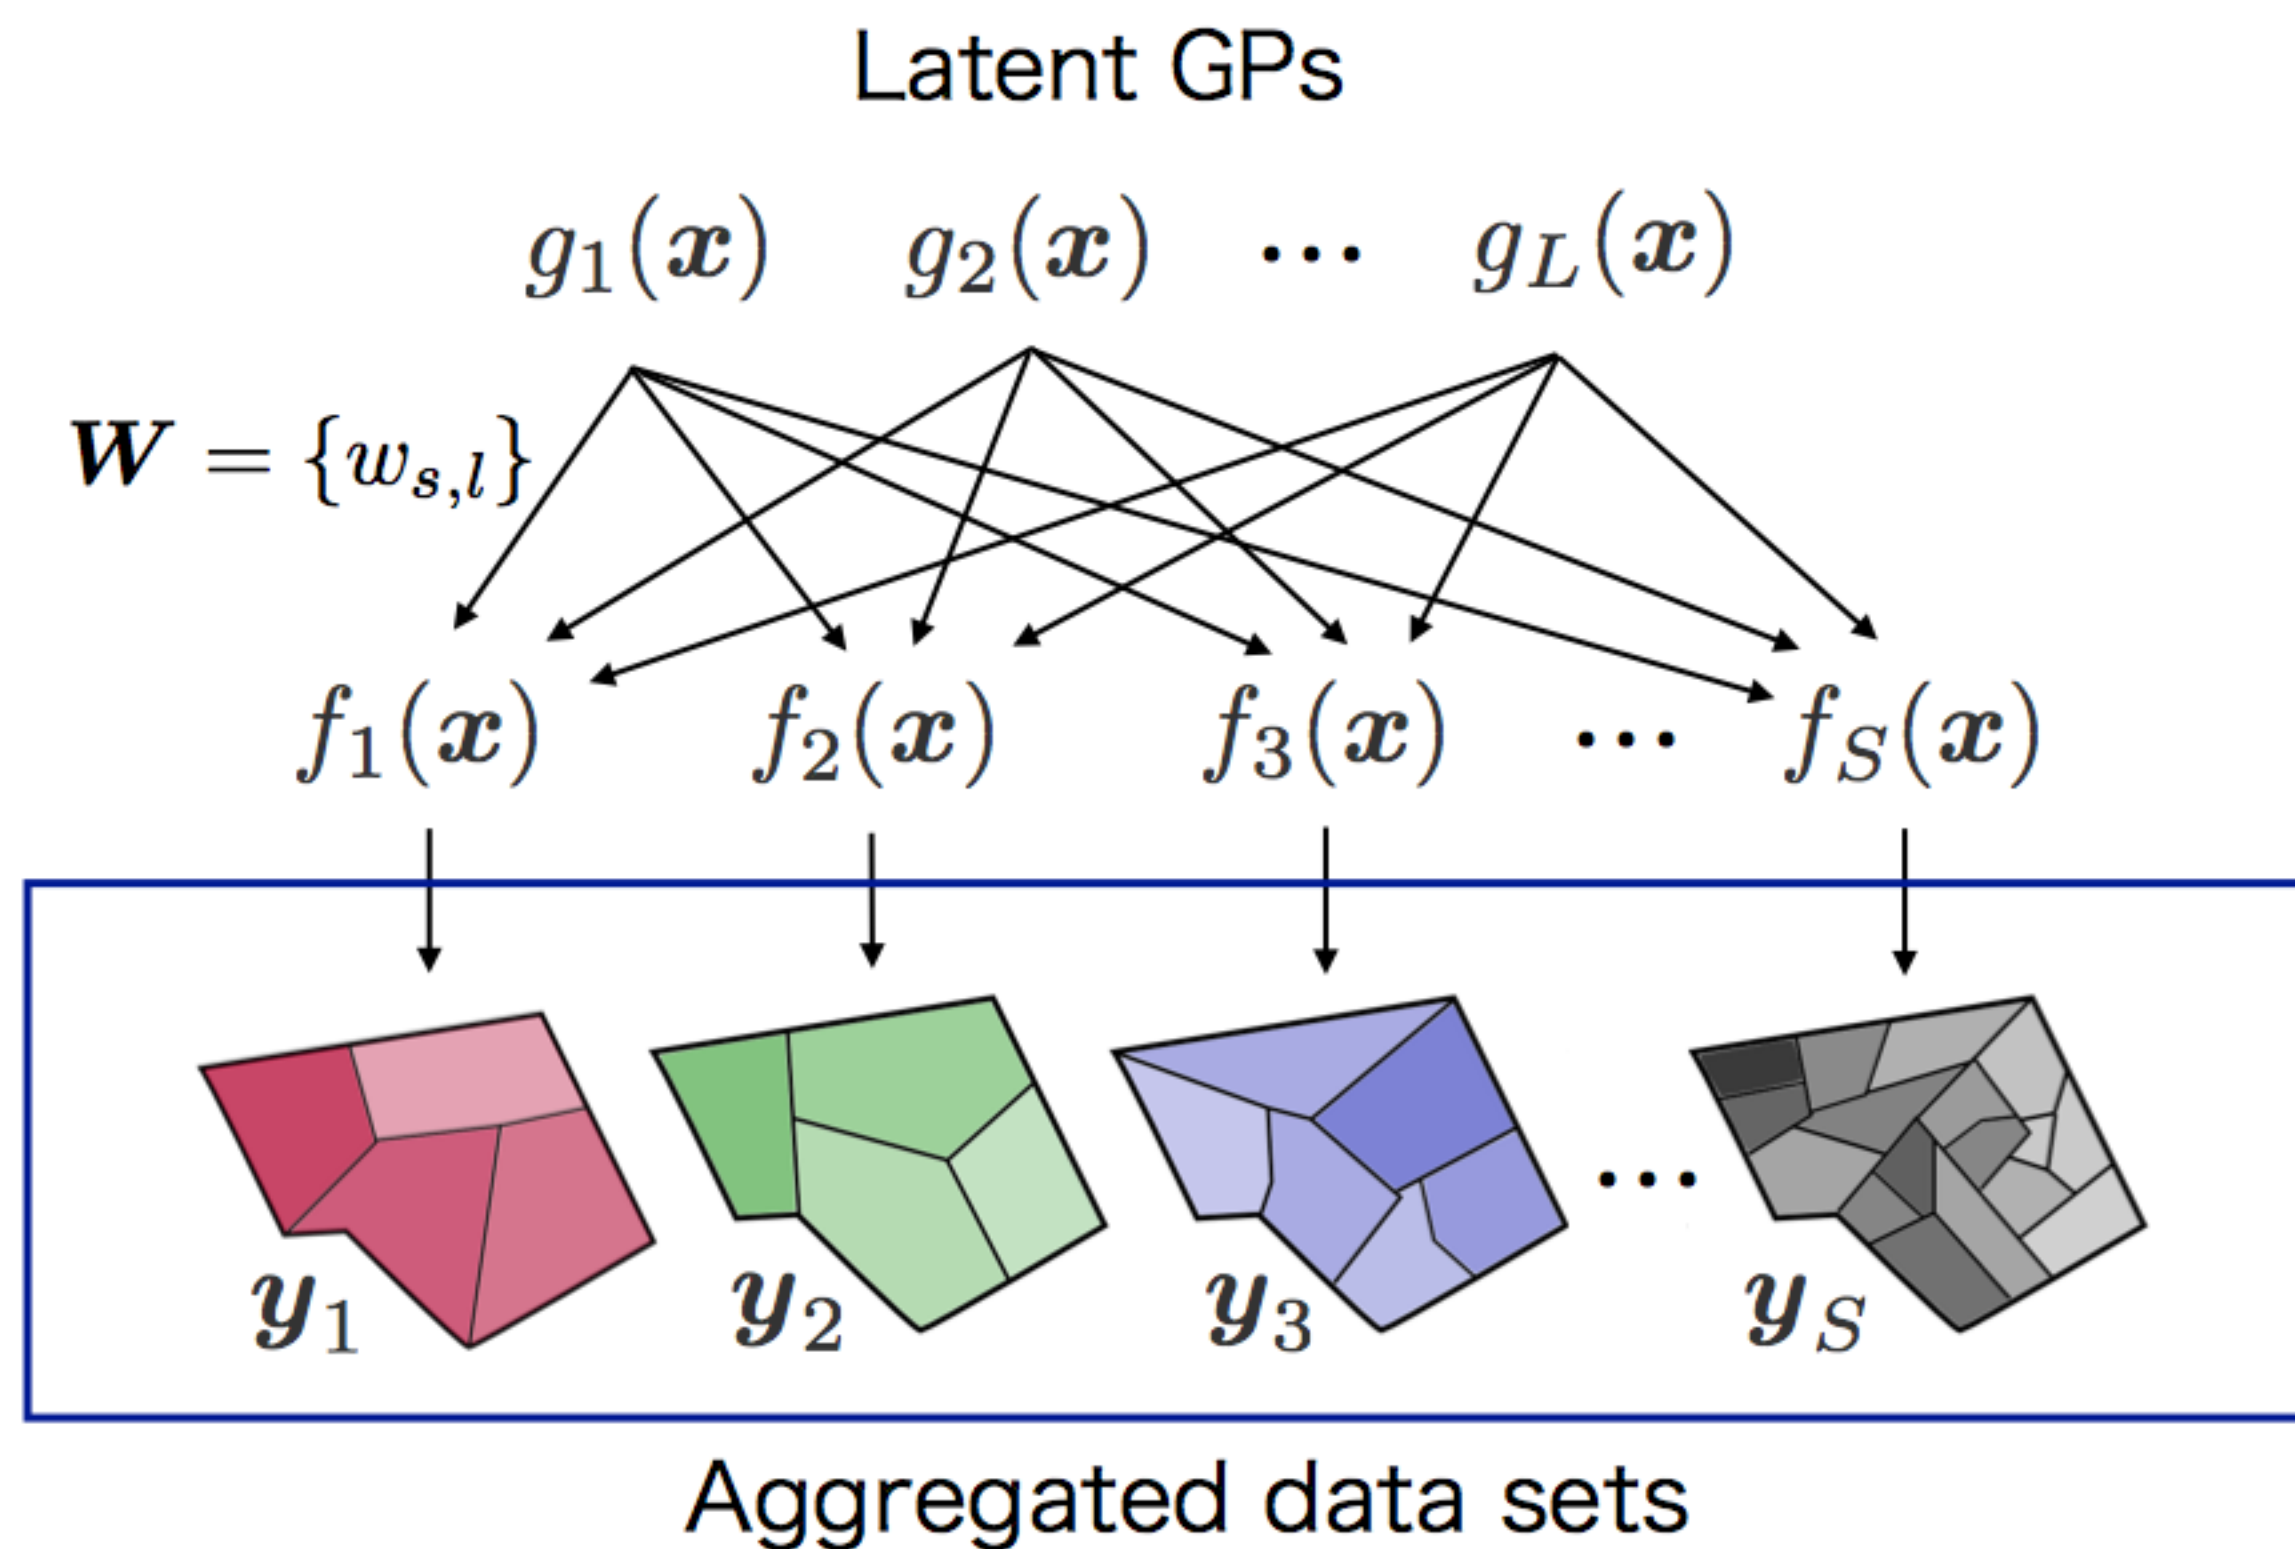


- 基本的な考え方
- 先行研究 (多変量GP)
- SAGP-M
- 実験設定
- 結果
- まとめ

Multivariate approach

- S次元ガウス過程の観測モデルに集約プロセスを組み込む
 - ▶ 集約データから多変量GP $f(\mathbf{x})$ を学習可能
 - ▶ 潜在GPをデータセット間で共有することで、低解像度データの共分散を効果的に学習可能

- 基本的な考え方
- 先行研究 (多変量GP)
- **SAGP-M**
- 実験設定
- 結果
- まとめ



Multivariate approach

- ・ 基本的な考え方
- ・ 先行研究 (多変量GP)
- ・ **SAGP-M**
- ・ 実験設定
- ・ 結果
- ・ まとめ

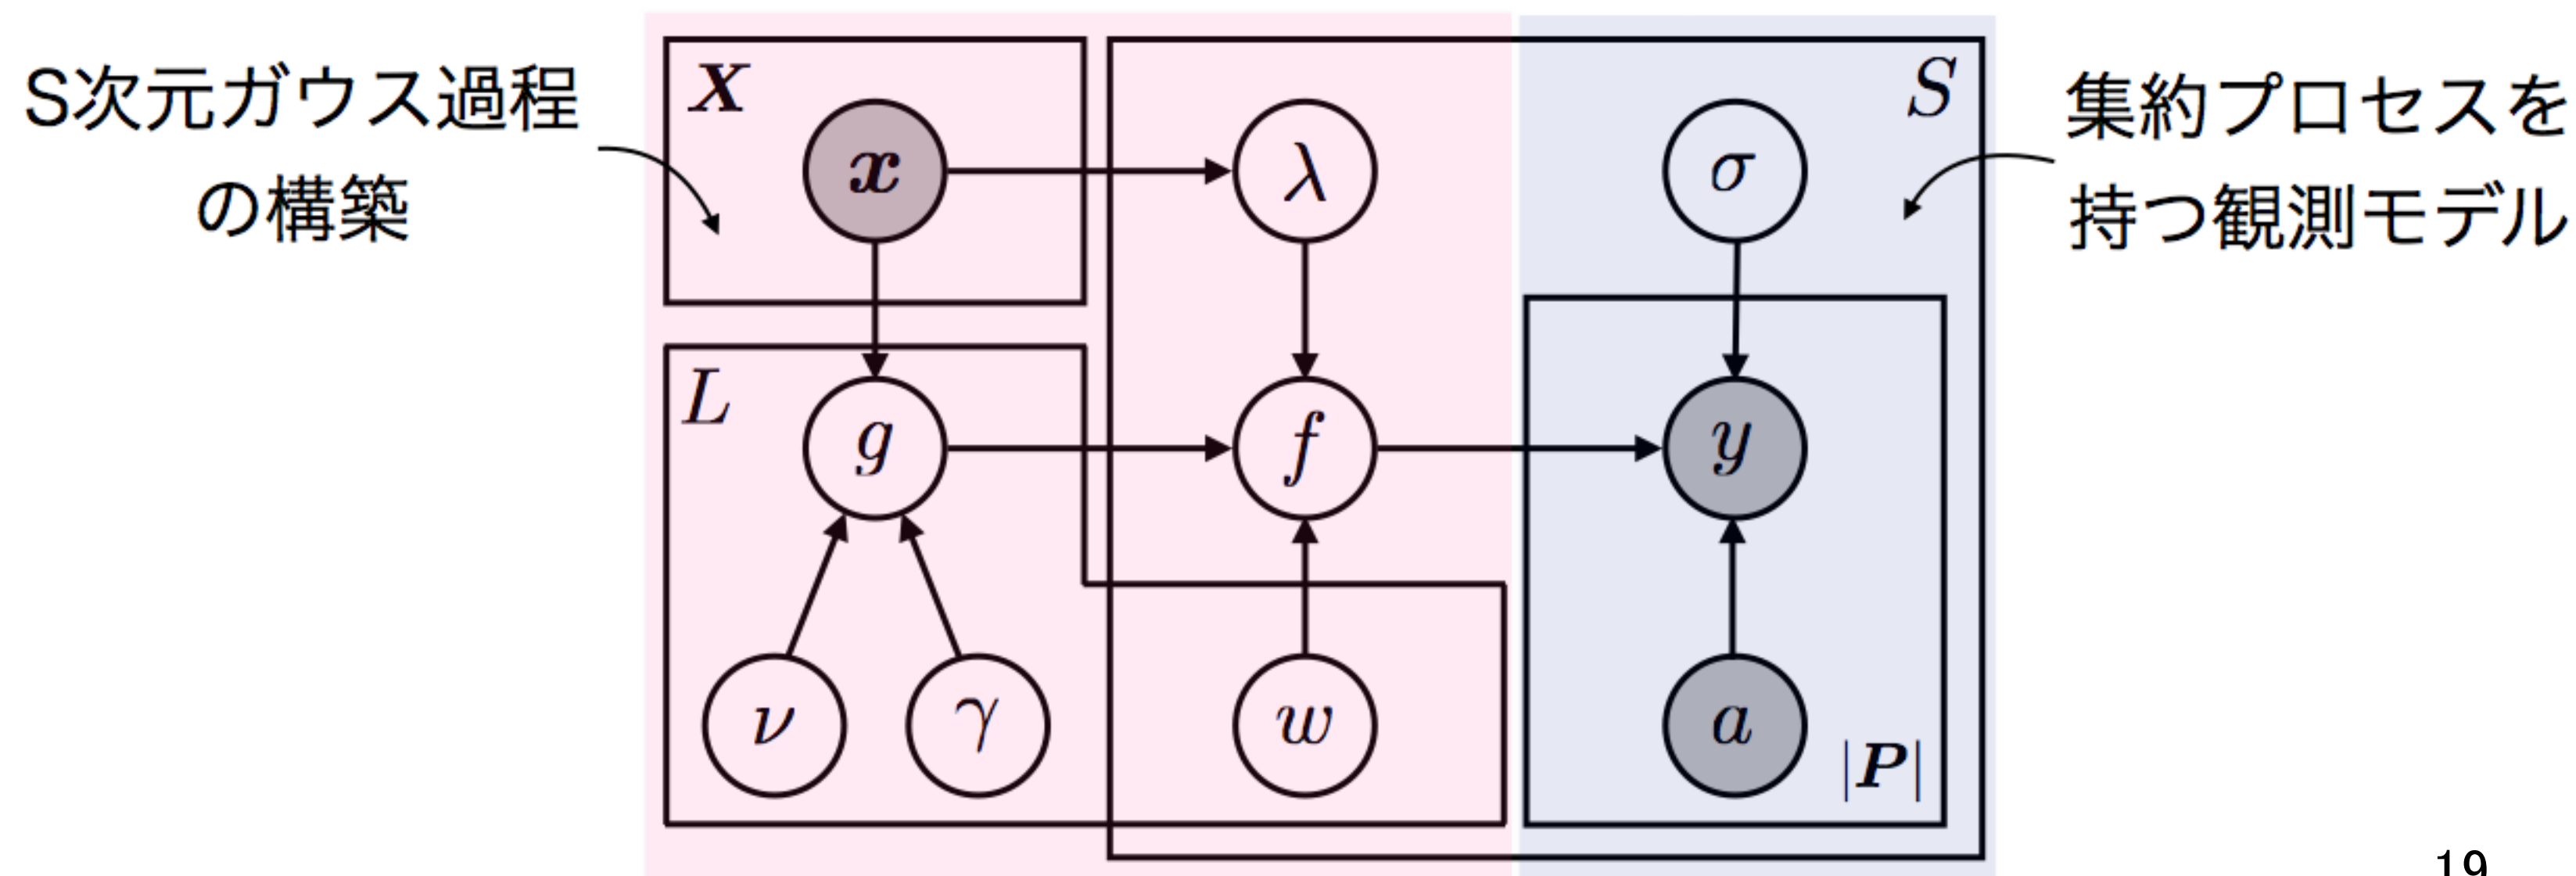
- ・ S次元ガウス過程の観測モデルに集約プロセスを組み込む
- ・ S次元ガウス過程 $f(\mathbf{x}) \sim \mathcal{GP}(m(\mathbf{x}), K(\mathbf{x}, \mathbf{x}'))$
- ・ 観測モデル

$$\mathbf{y} \mid f(\mathbf{x}) \sim \mathcal{N}\left(\mathbf{y} \mid \int_{\mathbf{X}} \mathbf{A}(\mathbf{x}) f(\mathbf{x}) d\mathbf{x}, \boldsymbol{\Sigma}\right)$$

$$\mathbf{y} = (\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_S)^\top$$

$$\mathbf{A}(\mathbf{x}) = \text{diag}(\mathbf{a}_1(\mathbf{x}), \dots, \mathbf{a}_S(\mathbf{x}))$$

$$\mathbf{a}_s(\mathbf{x}) = (a_{s,1}(\mathbf{x}), \dots, a_{s,|P_s|}(\mathbf{x}))^\top$$



Multivariate approach

- ・ 基本的な考え方
- ・ 先行研究 (多変量GP)
- ・ **SAGP-M**
- ・ 実験設定
- ・ 結果
- ・ まとめ

- ・ 周辺尤度 (導出手順はSAGP-Sと同様)

$$p(\mathbf{y}) = \mathcal{N}(\mathbf{y} \mid \boldsymbol{\mu}, \mathbf{C})$$

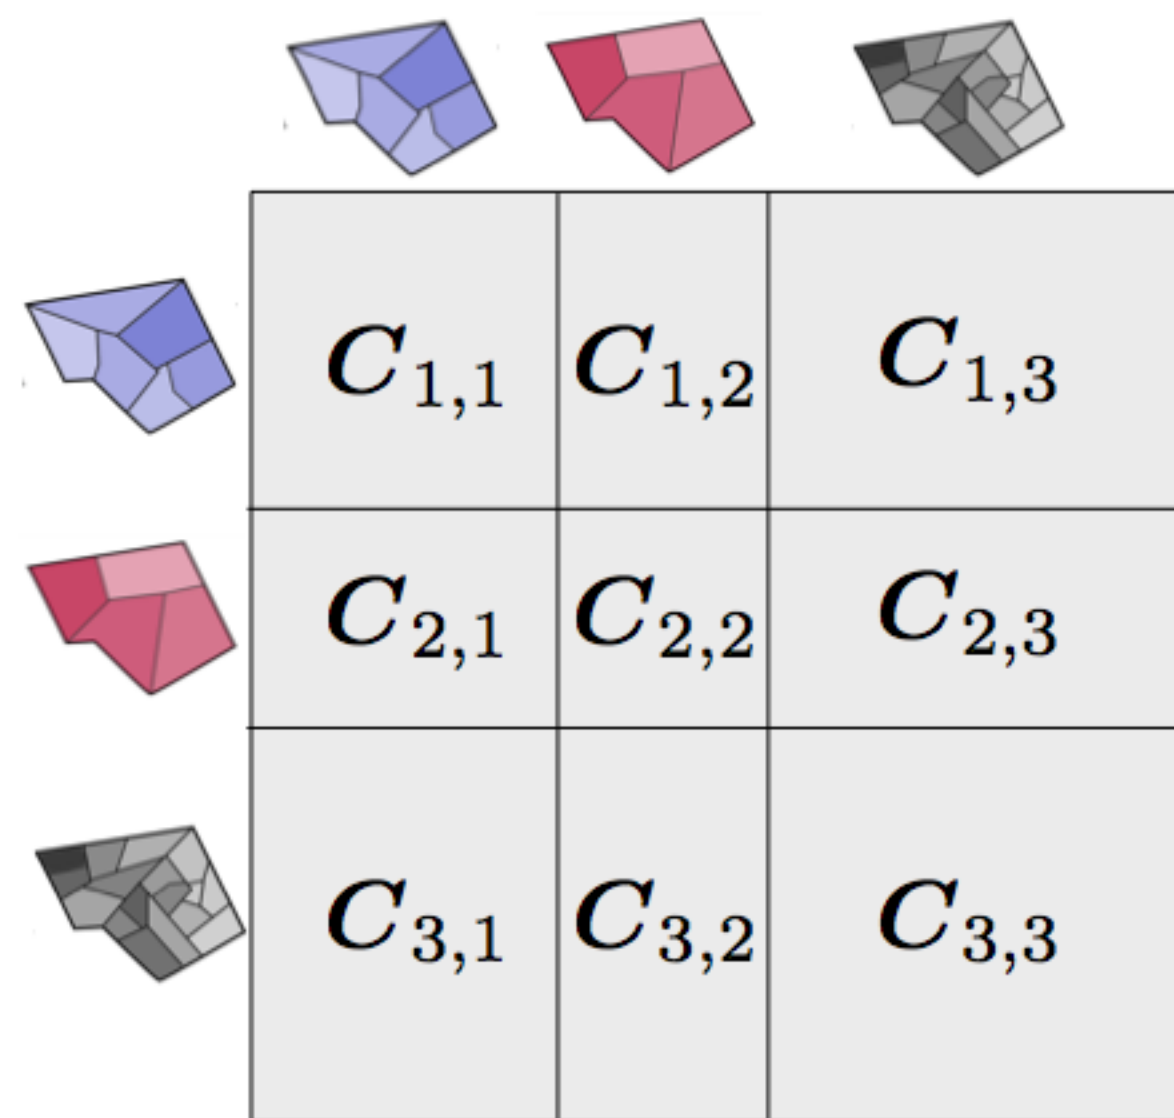
$$\boldsymbol{\mu} = \int_{\mathbf{X}} \mathbf{A}(\mathbf{x}) \underline{m(\mathbf{x})} d\mathbf{x}$$

↑ S次元ガウス過程の平均関数

$$\mathbf{C} = \iint_{\mathbf{X} \times \mathbf{X}} \mathbf{A}(\mathbf{x}) \underline{K(\mathbf{x}, \mathbf{x}')} \mathbf{A}(\mathbf{x}')^\top d\mathbf{x} d\mathbf{x}' + \boldsymbol{\Sigma}$$

↑ S次元ガウス過程の共分散関数

S×Sのブロック行列



S=3の場合

(s,s')番目のブロック

$$C_{s,s'} = \iint_{\mathbf{X} \times \mathbf{X}} k_{s,s'}(\mathbf{x}, \mathbf{x}') \mathbf{a}_s(\mathbf{x}) \mathbf{a}_{s'}(\mathbf{x}')^\top d\mathbf{x} d\mathbf{x}' + \delta_{s,s'} \sigma_s^2 \mathbf{I}$$

集約データセット間の共分散を
評価可能

Multivariate approach

- ・ 基本的な考え方
- ・ 先行研究 (多変量GP)
- ・ **SAGP-M**
- ・ 実験設定
- ・ 結果
- ・ まとめ

- Posterior GP (導出手順はSAGP-Sと同様)

任意の点 x での予測が可能


$$f^*(x) \sim \mathcal{GP}(m^*(x), K^*(x, x'))$$

$$m^*(x) = m(x) + H(x)^\top C^{-1}(y - \mu)$$

$$K^*(x, x') = K(x, x') - H(x)^\top C^{-1}H(x')$$

$$H(x) = \int_{\mathbf{X}} A(x')K(x', x) dx'$$

所望の領域において $f^*(x)$ を積分すれば領域における予測が可能



$$R_n^{\text{fine}} \in P^{\text{fine}}$$

Multivariate approach

- ・ 基本的な考え方
- ・ 先行研究 (多変量GP)
- ・ SAGP-M
- ・ **実験設定**
- ・ 結果
- ・ まとめ

- ・ ニューヨーク, シカゴで公開されている実データを使用して提案モデルの有効性を検証

(a) New York City

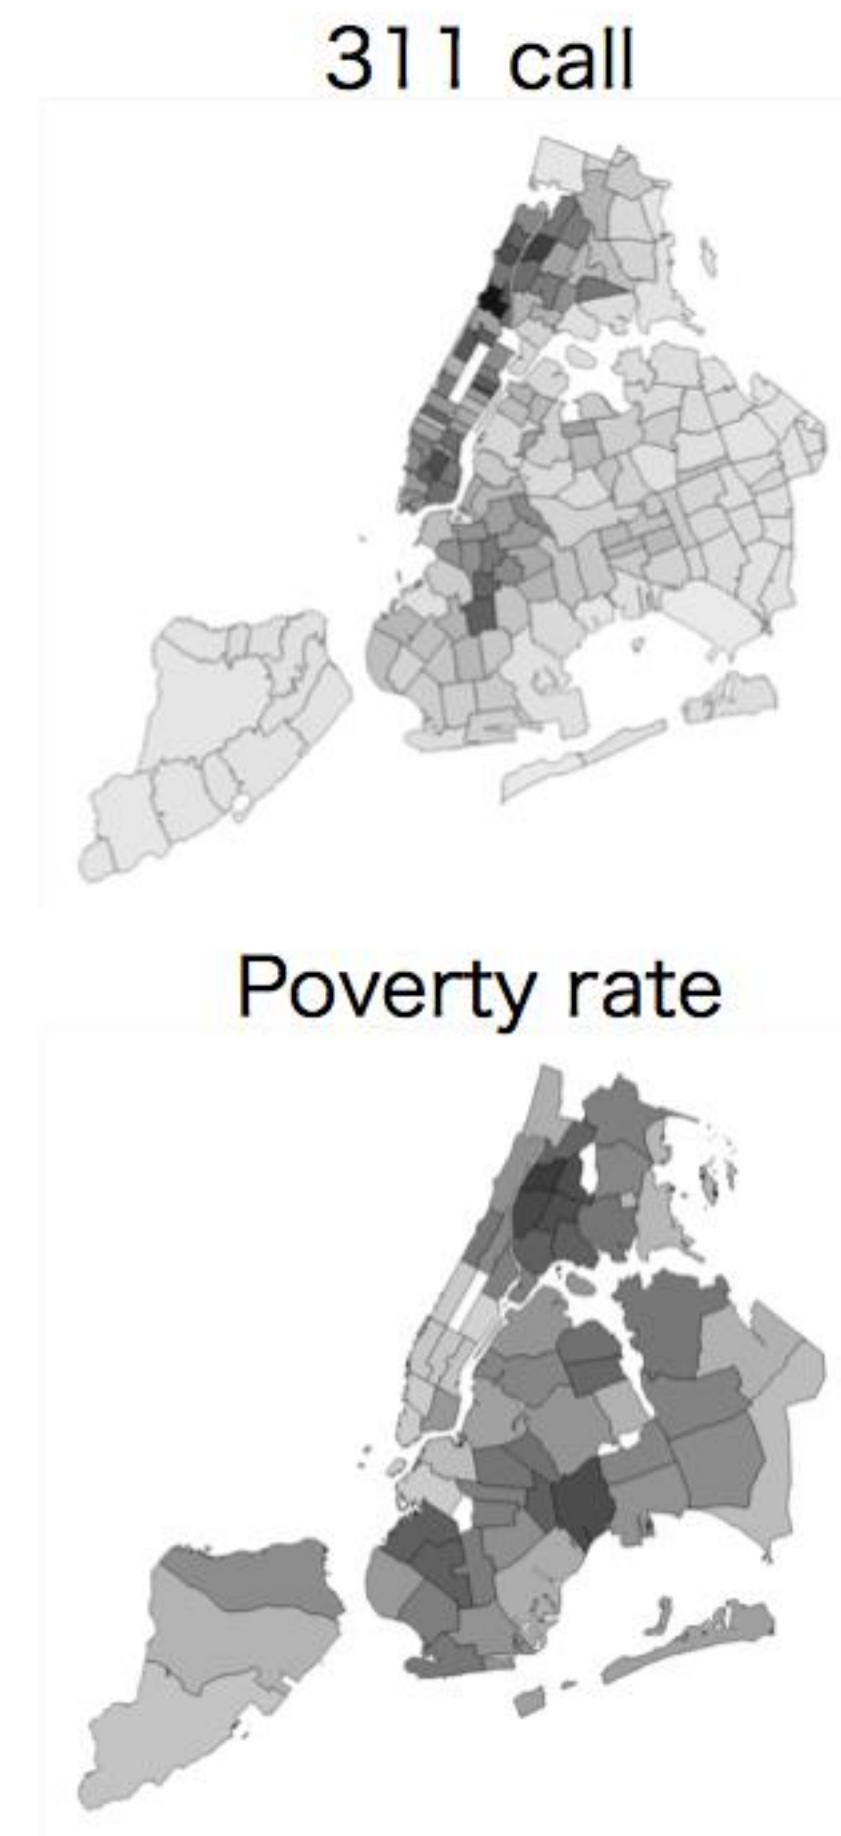
Data	Partition	#regions	Time range
PM2.5	UHF42	42	2009 – 2010
Poverty rate	Community district	59	2009 – 2013
Unemployment rate	Community district	59	2009 – 2013
Mean commute	Community district	59	2009 – 2013
Population	Community district	59	2009 – 2013
Recycle diversion rate	Community district	59	2009 – 2013
Crime	Police precinct	77	2010 – 2016
Fire incident	Zip code	186	2010 – 2016
311 call	Zip code	186	2010 – 2016
Public telephone	Zip code	186	2016

(b) Chicago

Data	Partition	#regions	Time range
Crime	Police Precinct	25	2012
Poverty rate	Community district	77	2008 – 2012
Unemployment rate	Community district	77	2008 – 2012

<https://opendata.cityofnewyork.us/>

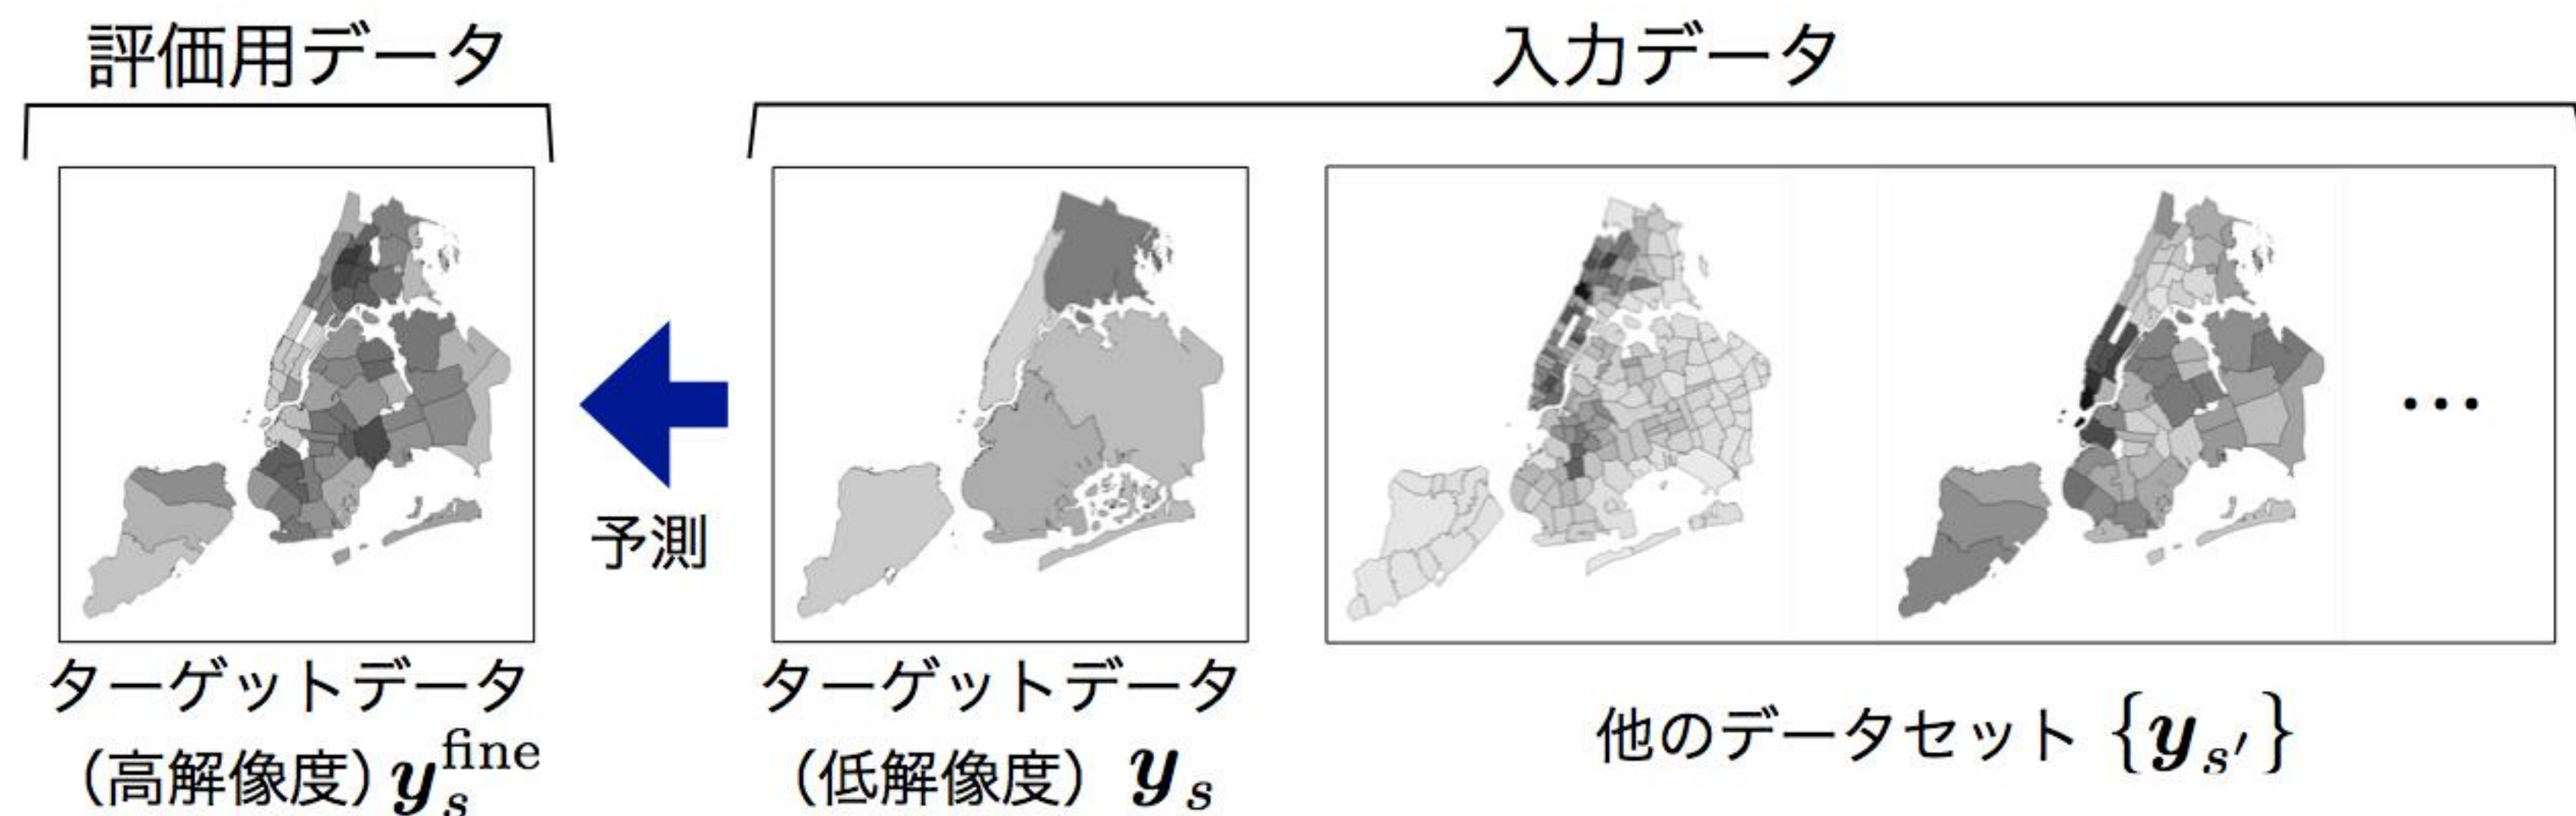
<https://data.cityofchicago.org/>



Multivariate approach

- ・ 基本的な考え方
- ・ 先行研究 (多変量GP)
- ・ SAGP-M
- ・ **実験設定**
- ・ 結果
- ・ まとめ

● 検証方法



評価指標：Mean Absolute Percentage Errors (MAPE)

$$\frac{1}{|P^{\text{fine}}|} \sum_{n=1}^{|P^{\text{fine}}|} \left| \frac{\begin{array}{c} \text{予測値} \\ \downarrow \\ y_{s,n}^* \end{array} - \begin{array}{c} \text{真の値} \\ \downarrow \\ y_{s,n}^{\text{fine}} \end{array}}{y_{s,n}^{\text{fine}}} \right|$$

Multivariate approach

- ・ 基本的な考え方
- ・ 先行研究 (多変量GP)
- ・ SAGP-M
- ・ **実験設定**
- ・ 結果
- ・ まとめ

- SAGP-Mの設定
 - ▶ 全てのGPの平均は0に固定.
 - ▶ 共分散関数はSquared-exponential kernelを使用
 - ▶ 領域積分は300m × 300mのグリッドで近似
 - ▶ 最適化問題はL-BFGS (Liu and Nocedal, 1989) を使用
 - ▶ 潜在ガウス過程の個数Lは{1, ..., S-1}の中から交差検証で決定
- 比較手法
 - ▶ SAGP-S: 集約プロセスを考慮したガウス過程回帰
 - ▶ 2-stage SAGP model: Regression approachに基づく提案法
 - ▶ SLFM: 多変量ガウス過程回帰(サンプルは領域の重心に紐づけ)
(Teh, Seeger, and Jordan, 2005)
↑
LMCをガウス過程で実現したもの

SAGP-MはSLFMを集約データを扱えるように拡張したもの

Multivariate approach

- ・ 基本的な考え方
- ・ 先行研究（多変量GP）
- ・ SAGP-M
- ・ 実験設定
- ・ **結果**
- ・ まとめ

- 高解像度データの予測性能の比較
 - ▶ 比較手法に比べて同等以上の性能を達成

t検定の結果 ★：P < 0.05において有意差あり ★★：P < 0.01において有意差あり

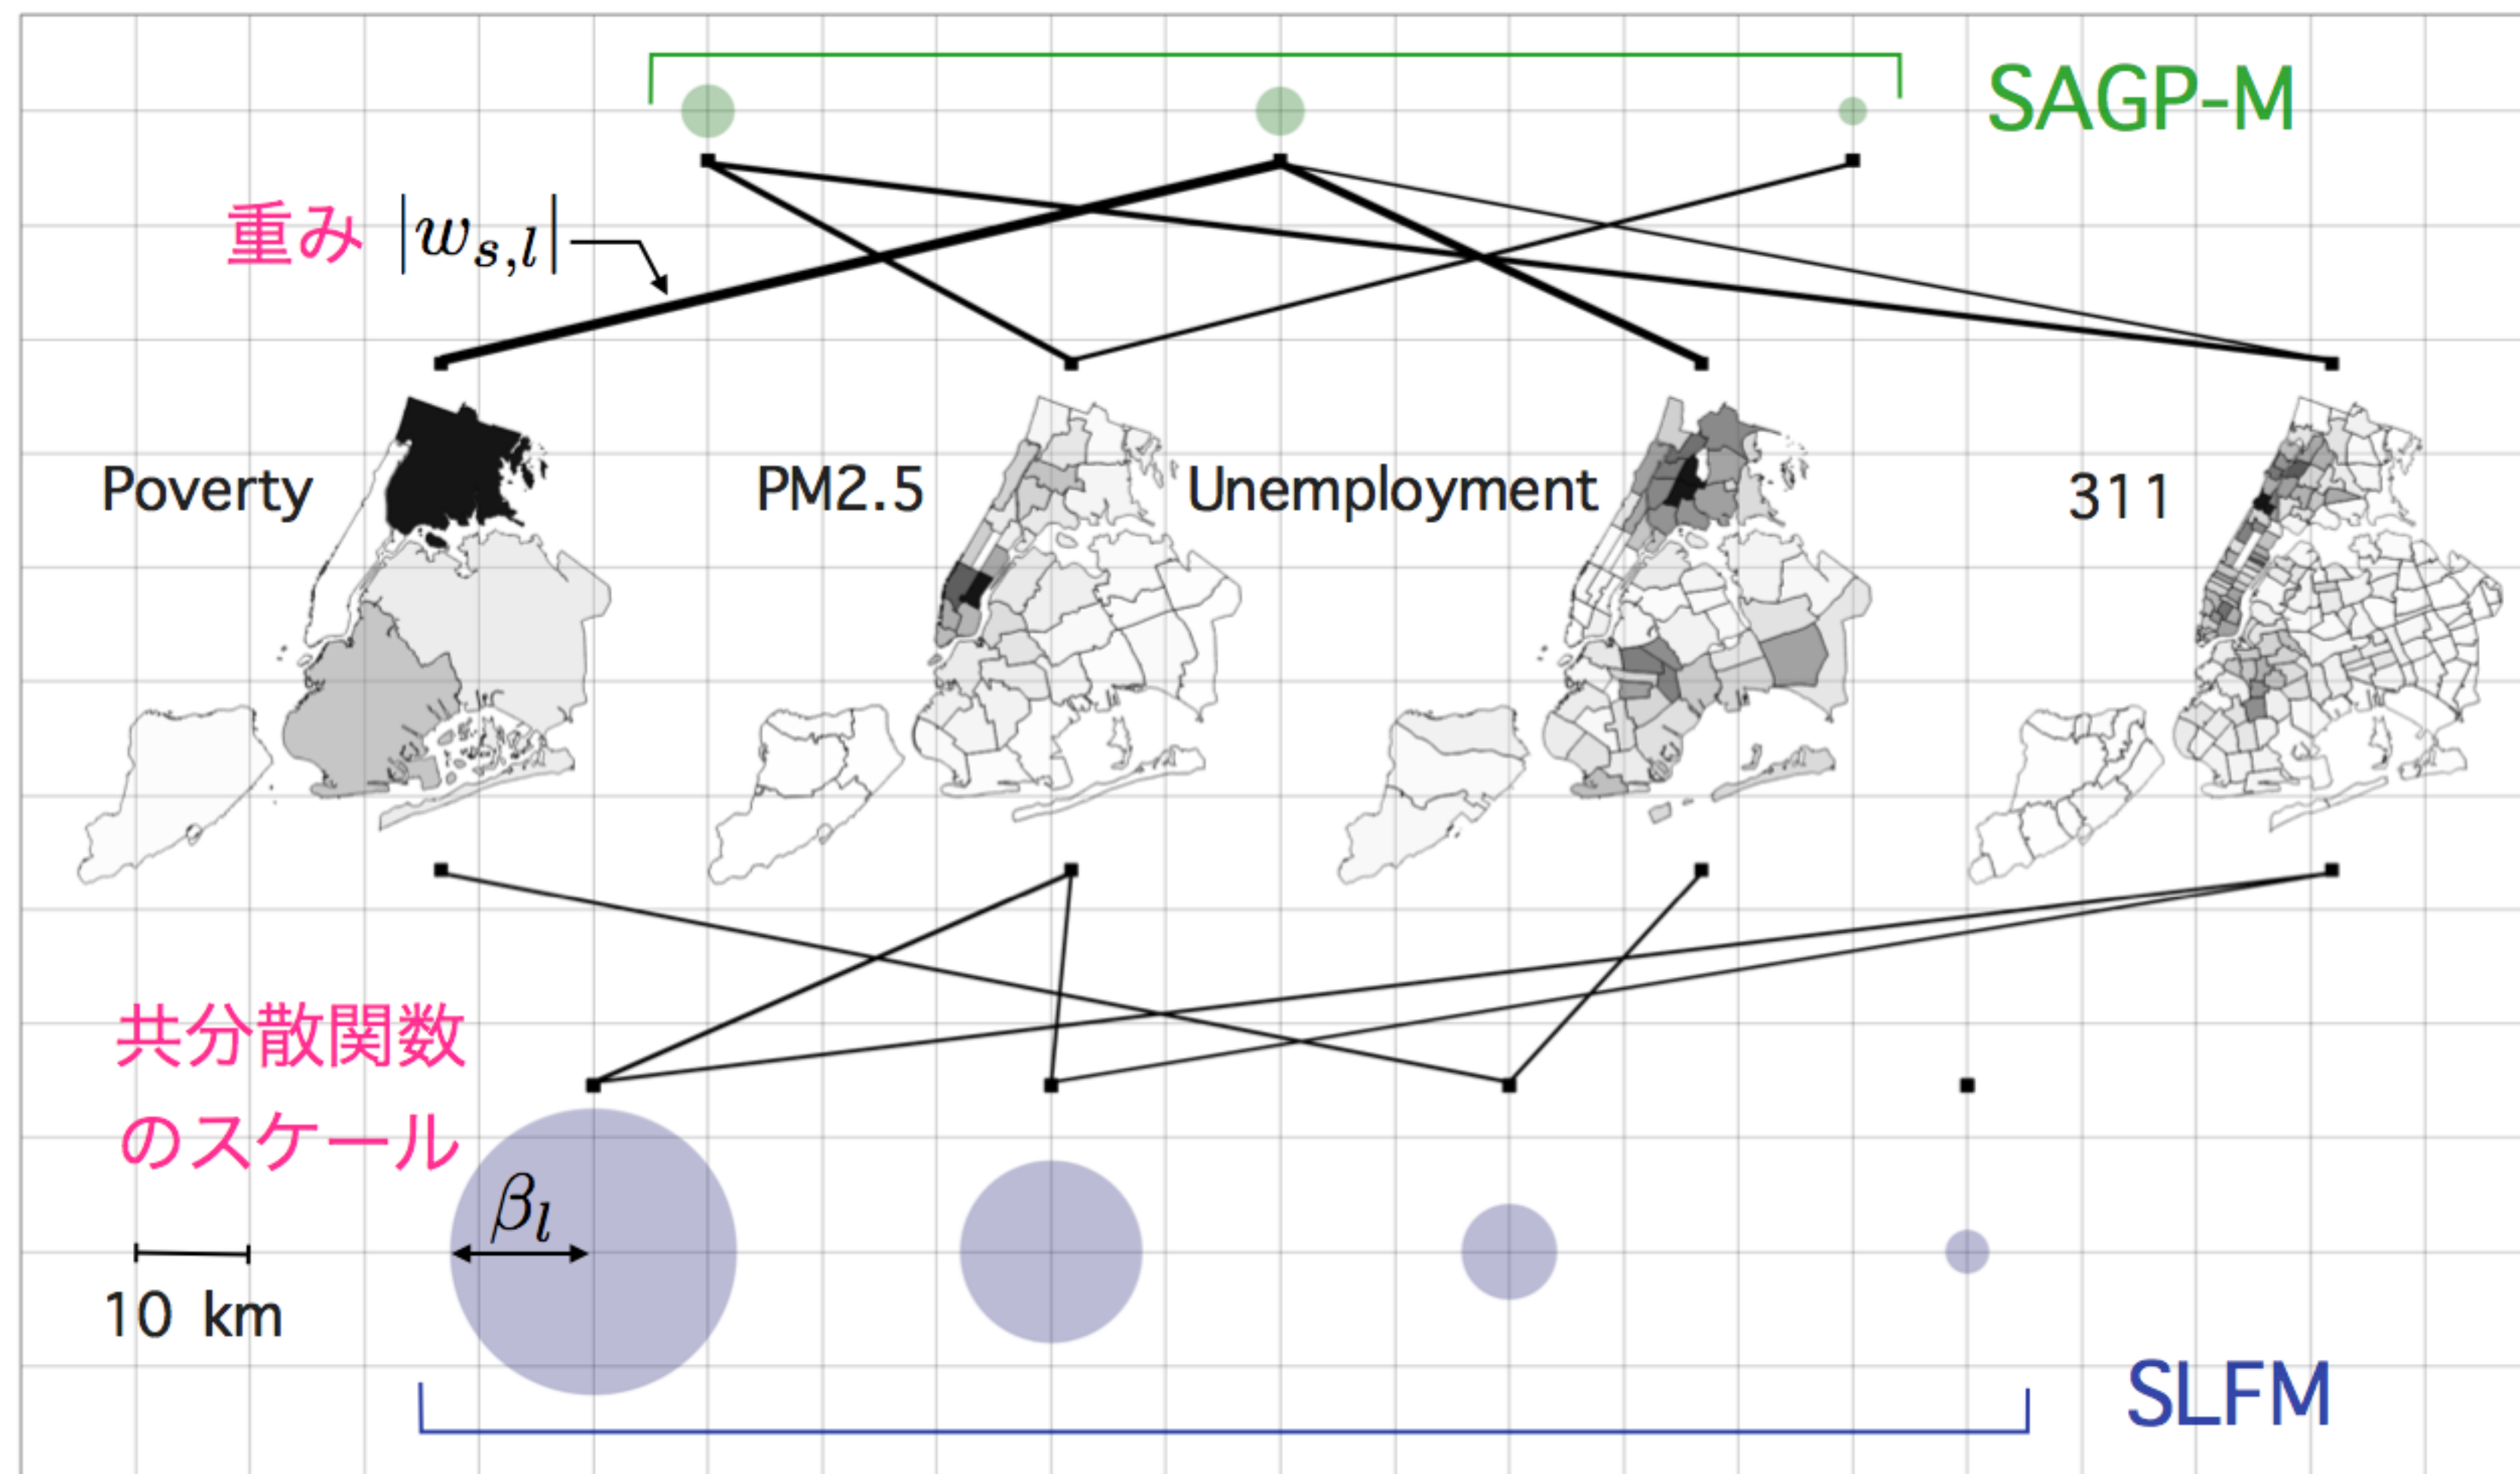
(a) New York City				
	SAGP-S	2-stage SAGP model	SLFM	SAGP-M
PM2.5	0.053 ± 0.007	0.042 ± 0.005	0.036 ± 0.005 (6)	0.030 ± 0.005* (5)
Poverty rate	0.281 ± 0.034	0.218 ± 0.021	0.207 ± 0.025 (4)	0.181 ± 0.021** (3)
Unemployment rate	0.232 ± 0.025	0.154 ± 0.021	0.195 ± 0.024 (3)	0.165 ± 0.020 (4)
Mean commute	0.076 ± 0.010	0.052 ± 0.005	0.057 ± 0.007 (4)	0.048 ± 0.007 (5)
Population	0.371 ± 0.040	0.321 ± 0.039	0.337 ± 0.039 (3)	0.282 ± 0.034* (4)
Recycle diversion rate	0.282 ± 0.034	0.191 ± 0.023	0.222 ± 0.032 (4)	0.162 ± 0.022** (4)
Crime	0.525 ± 0.112	0.413 ± 0.086	0.401 ± 0.053 (2)	0.334 ± 0.048** (2)
Fire incident	0.793 ± 0.148	0.560 ± 0.106	0.500 ± 0.052 (4)	0.402 ± 0.040* (5)
311 call	0.069 ± 0.005	0.061 ± 0.004	0.061 ± 0.004 (6)	0.050 ± 0.004** (3)
Public telephone	0.099 ± 0.008	0.089 ± 0.008	0.086 ± 0.008 (4)	0.079 ± 0.008 (5)

(b) Chicago				
	SAGP-S	2-stage SAGP model	SLFM	SAGP-M
Poverty rate	0.423 ± 0.063	0.274 ± 0.035	0.335 ± 0.052 (2)	0.255 ± 0.030** (2)
Unemployment rate	0.405 ± 0.041	0.257 ± 0.030	0.278 ± 0.025 (2)	0.228 ± 0.021* (2)

Multivariate approach

- ・ 基本的な考え方
- ・ 先行研究 (多変量GP)
- ・ SAGP-M
- ・ 実験設定
- ・ 結果
- ・ まとめ

- 推定されたパラメータの可視化 (ターゲット: poverty rate)
 - ▶ SAGP-Mが予測に重要な関係性 (例: pov.とunem.)を抽出



Multivariate approach

- ・ 基本的な考え方
- ・ 先行研究 (多変量GP)
- ・ SAGP-M
- ・ 実験設定
- ・ 結果
- ・ **まとめ**

貢献

- 多変量ガウス過程に基づいて, 集約データを高解像度化するための確率モデルを提案
 - ・ 潜在GPをデータセット間で共有することで, 低解像度データの共分散関数を効果的に学習可能
- 実データを用いて提案モデルの有効性を検証

今後の展望

- 大規模なデータ取得が難しい都市への対応. 都市間での転移学習技術の開発