

深層展開を用いた 時変グラフ信号の再構成

小島 颯^{*1}， 山田宏樹^{*2}， 野口ひかり^{*1}， 田中雄一^{*3}

^{*1}東京農工大学

^{*2}東京理科大学


^{*3}大阪大学

多種多様・時間変化する膨大なデータ

信号



人体データ



動画像



Image by sipi.usc.edu

ソーシャルネットワーク



Image by macrovector on Freepik

欠損補完

ノイズ除去

二次利用

機械学習 etc.



MSP Lab


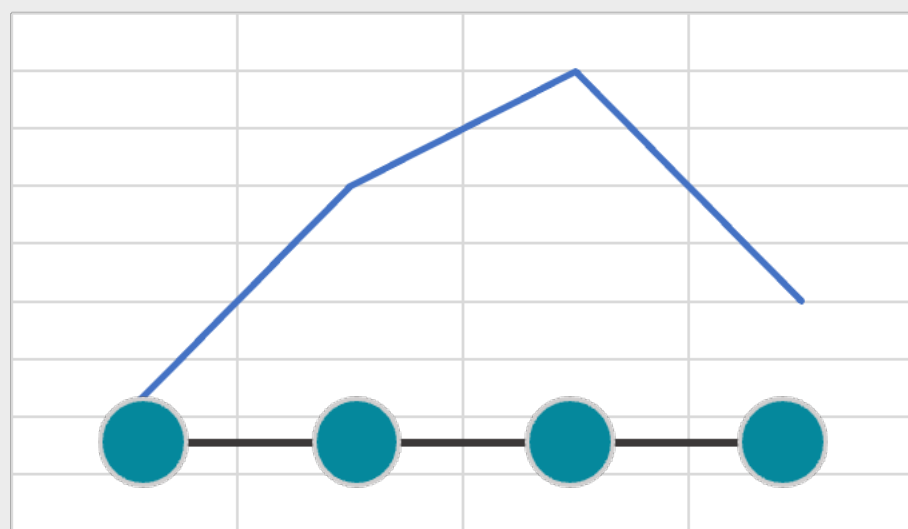
Department of Electrical Engineering and Computer Science



従来の信号処理

✓ 規則的データの解析
信号・動画像など

✓ 信号補完・圧縮・フィルタリング



拡張



グラフ信号処理

✓ 不規則・不均一データの解析
ソーシャルネットワーク・人体データ^[1]など

✓ 信号補完・圧縮・フィルタリング


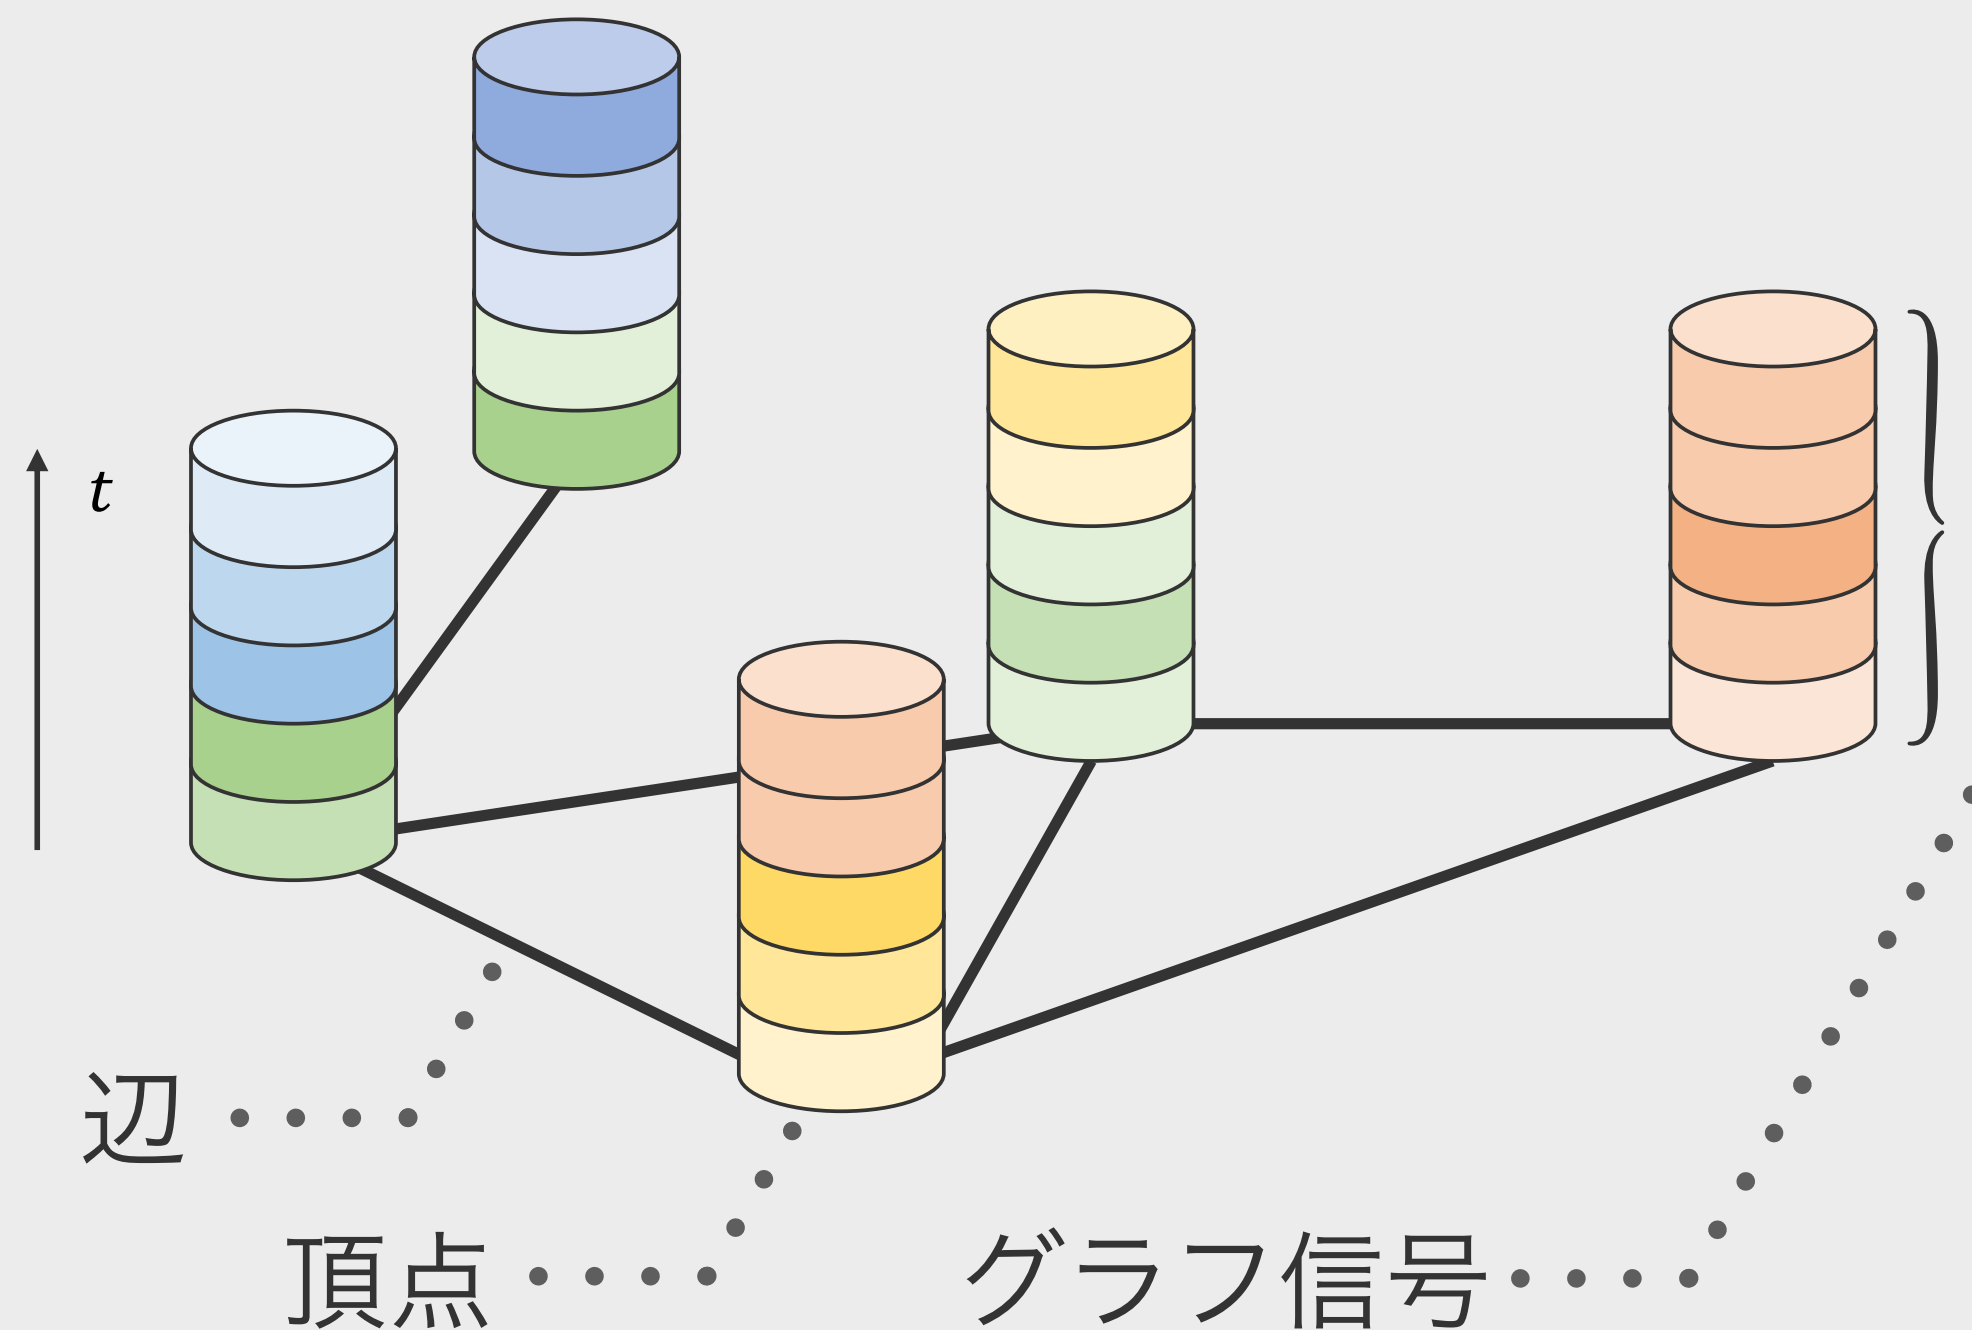


Image by macrovector on Freepik

[1]In-Bed Pose Estimation: Deep Learning with Shallow Dataset, Shuangjun Liu, Yu Yin, and Sarah Ostadabbas

- 時変グラフ信号：固定のグラフ + 時変信号



グラフ：頂点間の接続関係(頂点と辺)


- ・ 頂点
観測地点, 個人, 人体関節点など
- ・ 辺
道路, 友人関係, 骨など

時変信号：頂点上の時系列信号

気温, フォロワー数, 関節の座標など


欠損・ノイズのある複雑な構造の時変データから予測した信号を再構成

(未知の)原信号




ノイズ
・
欠損

観測信号



再構成


再構成信号



静的手法

各時間で別のグラフとみなして処理


- ✓ グラフ信号再構成手法が直接適用できる
- ✓ グラフの時間的特性が利用できない




時変手法

時変グラフ信号を一括で処理

- ✓ 時間的特性を活用できる
- ✓ 従来手法が使えないため拡張する必要がある



信号が**頂点領域**上で滑らかである



Δ_g : 信号値の微小変化

辺で繋がれている頂点の信号値は近い

• Tikhonov Regularization^[1]

$$\min_{\tilde{\mathbf{x}}_t} \underbrace{\|\mathbf{j} \circ \tilde{\mathbf{x}}_t - \mathbf{y}_t\|_F^2}_{\text{データ忠実度}} + \underbrace{\|\mathbf{L}\tilde{\mathbf{x}}_t\|_F^2}_{\text{再構成信号の滑らかさ}}$$

$\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_T]$: 原時変グラフ信号

$\tilde{\mathbf{X}} = [\tilde{\mathbf{x}}_1, \dots, \tilde{\mathbf{x}}_T]$: 再構成時変グラフ信号

\mathbf{j} : サンプルング行列

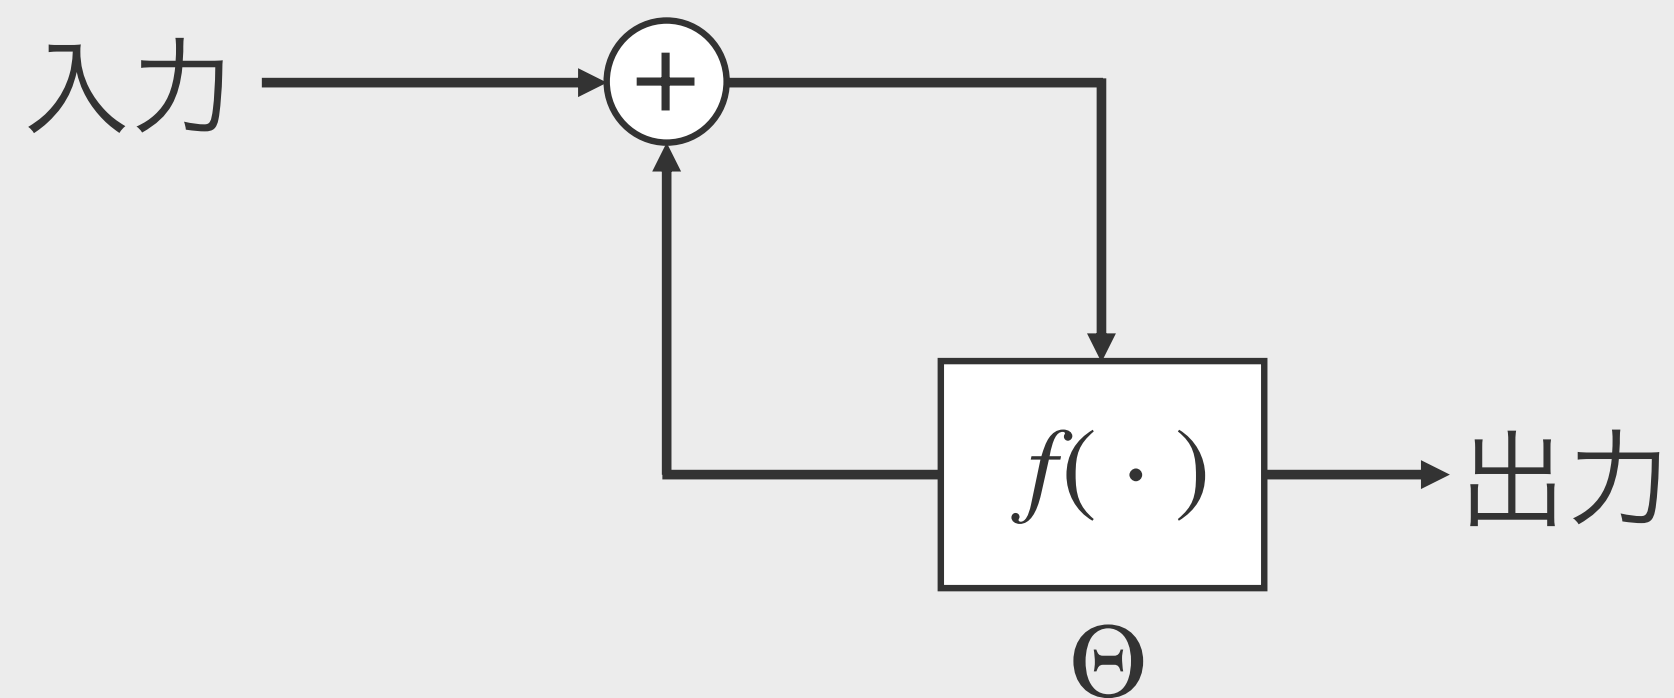
\mathbf{L} : グラフラプラシアン

共役勾配法を利用して解かれる

[1] <http://ieeexplore.ieee.org/document/7952890/>

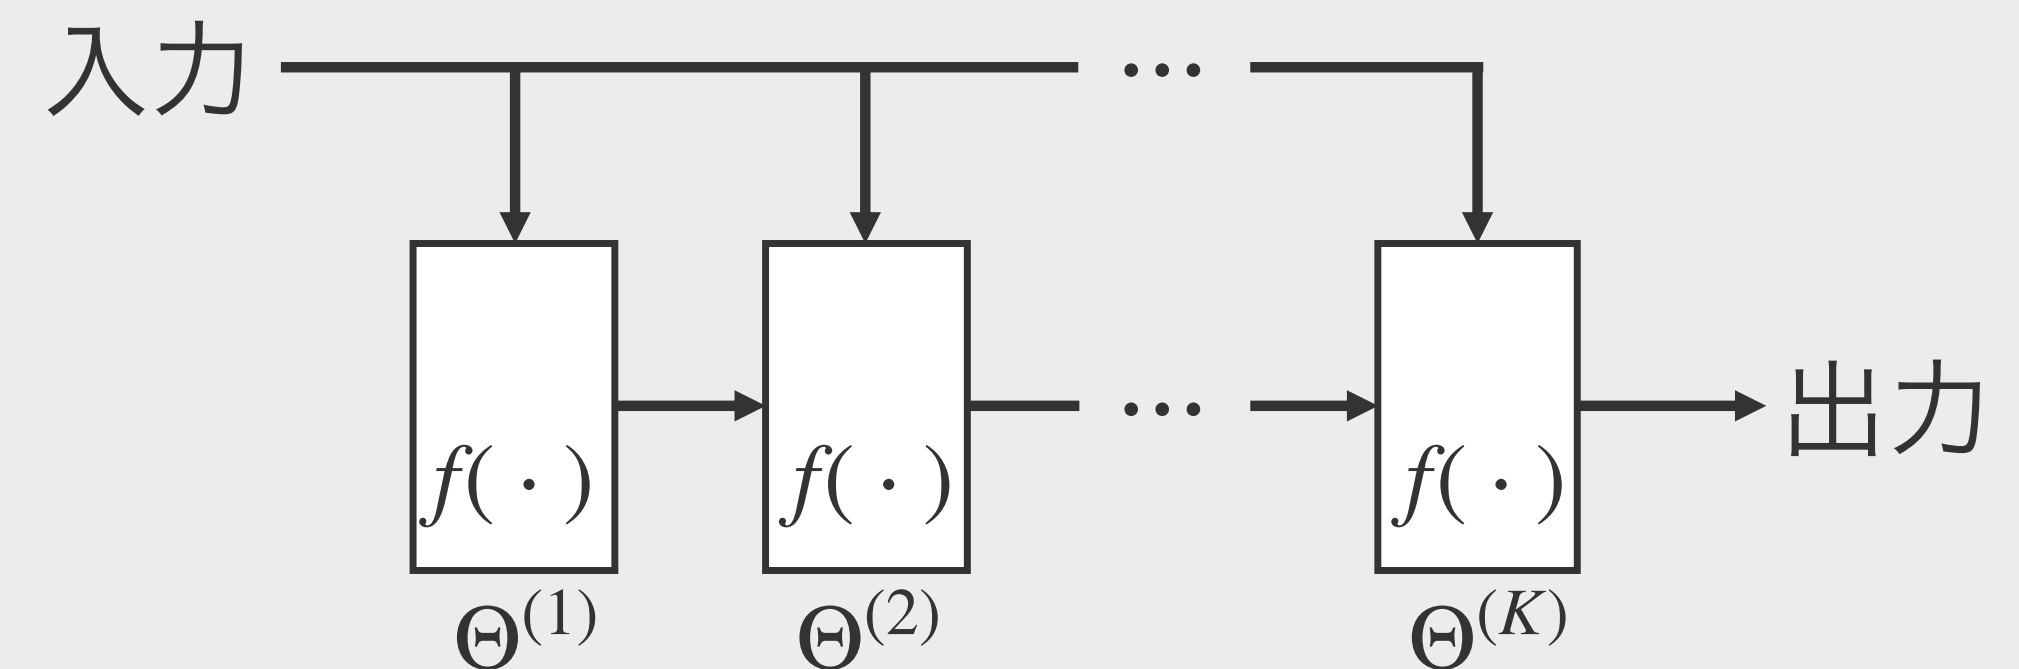
- 反復型アルゴリズムを深層ニューラルネットワークとして表現

反復型アルゴリズム



- 反復計算で解を求める
- 所定の計算回数or更新値が小さくなったら終了
- パラメータは固定

深層展開



- 順方向のニューラルネットで解を求める
- グラントゥルースとの誤差を最小化
- パラメータをBP法により学習
- 各層で異なるパラメータを利用可能

適切なパラメータを学習可能

→ 性能向上

実験項目

- ・**欠損**に対する性能比較
ノイズ強度を固定し測定率を変化
- ・**ノイズ**に対する性能比較
測定率を固定しノイズ強度を変化

サンプリング演算子 ノイズ項

$$\mathbf{Y} = \mathbf{J} \circ (\mathbf{X} + \mathbf{V})$$

観測信号 原信号

比較手法

- OGTR^[1] : 時変手法
- Tikhonov^[2] : 静的な手法
- Sobolev^[3] : 時変手法
- DAU^[4] : 時変手法

- 繰り返し回数 : 50 iteration
- 比較手法のパラメータ : グリッドサーチ
- 提案手法のパラメータ : 学習
- 評価項目 : RMSE

[1] <http://ieeexplore.ieee.org/document/7979523/>
 [2] <http://ieeexplore.ieee.org/document/7952890/>
 [3] <https://ieeexplore.ieee.org/document/9730033/>
 [4] <https://ieeexplore.ieee.org/document/9413406/>

データセット

人工データセット

$$\mathbf{x}_1 = \frac{1}{S} \mathbf{U} \hat{g}(\Lambda)^\top \mathbf{f}_1$$

$$\mathbf{x}_t = \mathbf{x}_{t-1} + \mathbf{L}^{-1/2} \mathbf{f}_t$$

$$\mathbf{L} = \mathbf{U} \Lambda \mathbf{U}^\top$$


\mathbf{f}_t : 乱数ベクトル

$\hat{g}(\Lambda)$: グラフローパスフィルタ

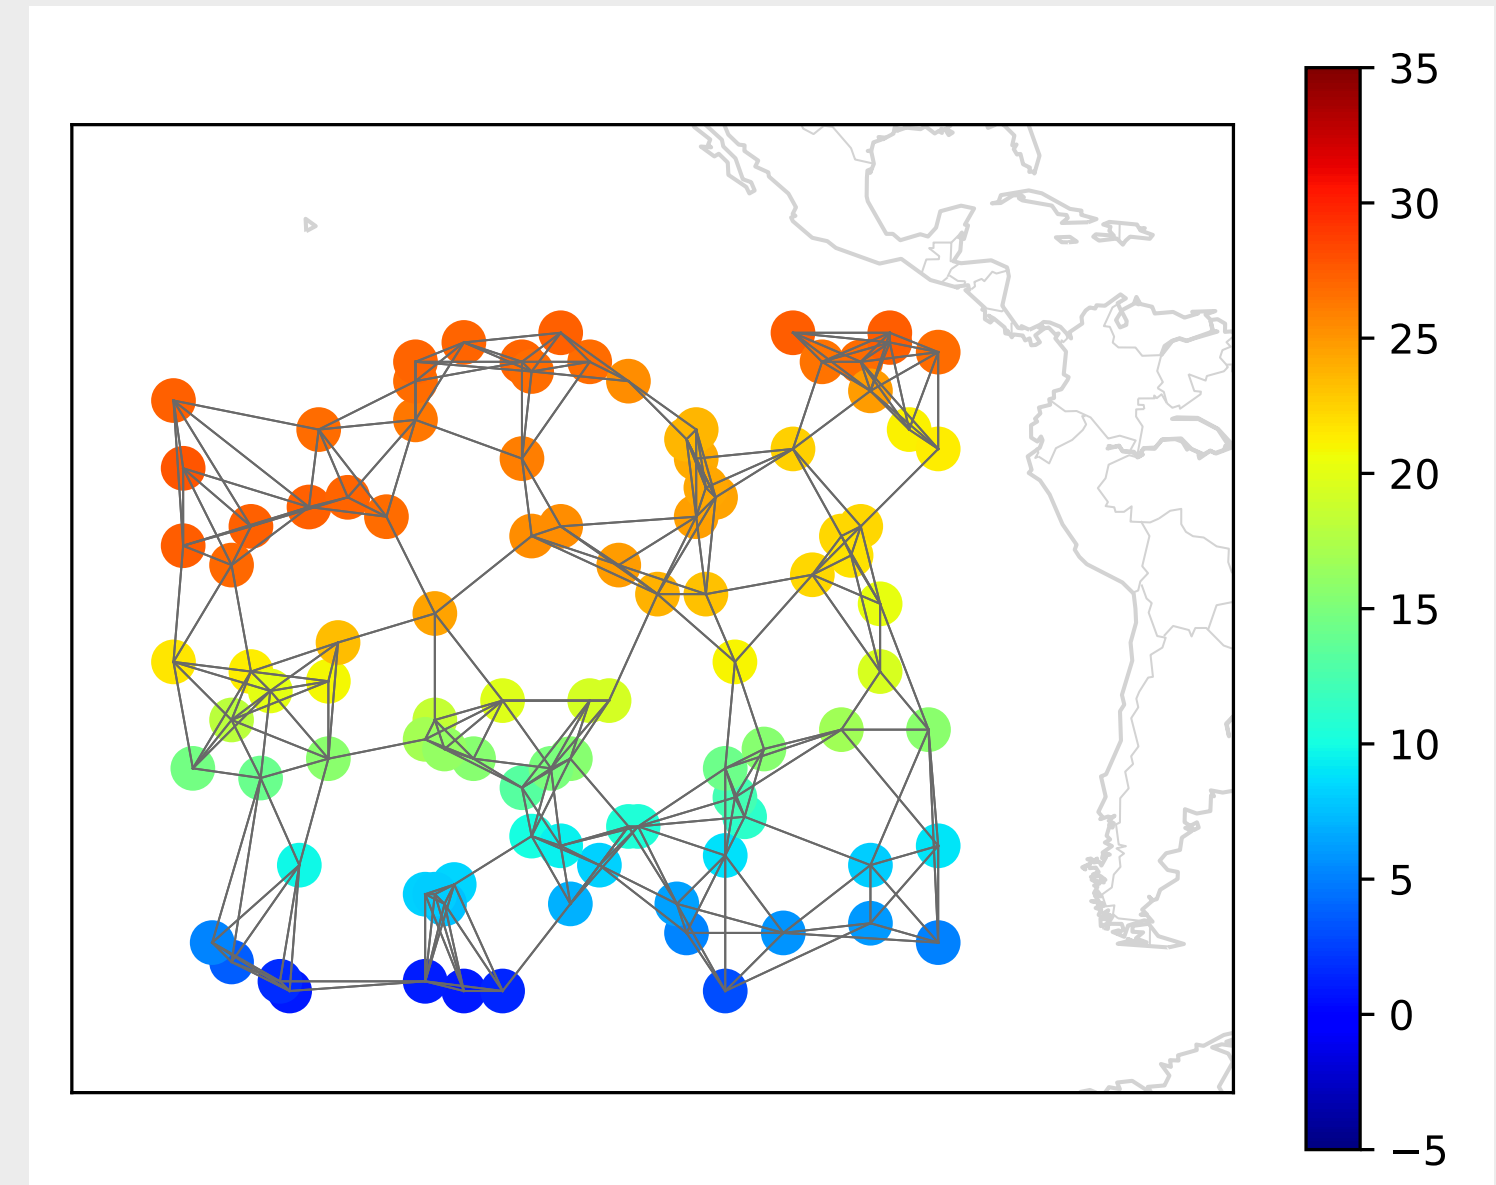
頂点数 : 100

時間数 : 600

グラフ : kNN (k=5)



実データセット (海面水温データセット)




頂点数 : 100


時間数 : 216(ヶ月)

グラフ : kNN (k=5)


欠損に対する復元性能




ノイズに対する復元性能



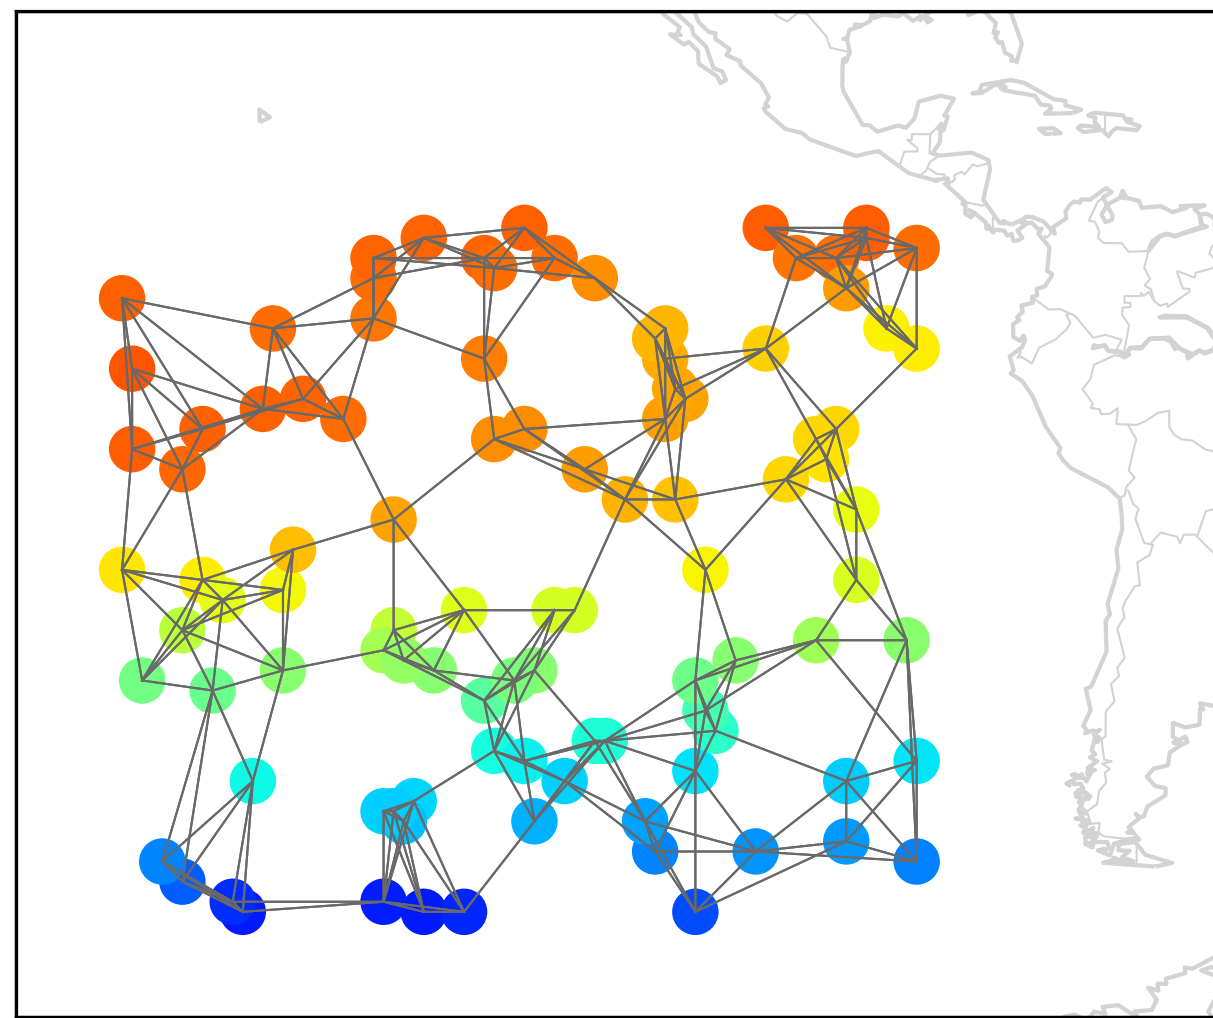
欠損に対する復元性能



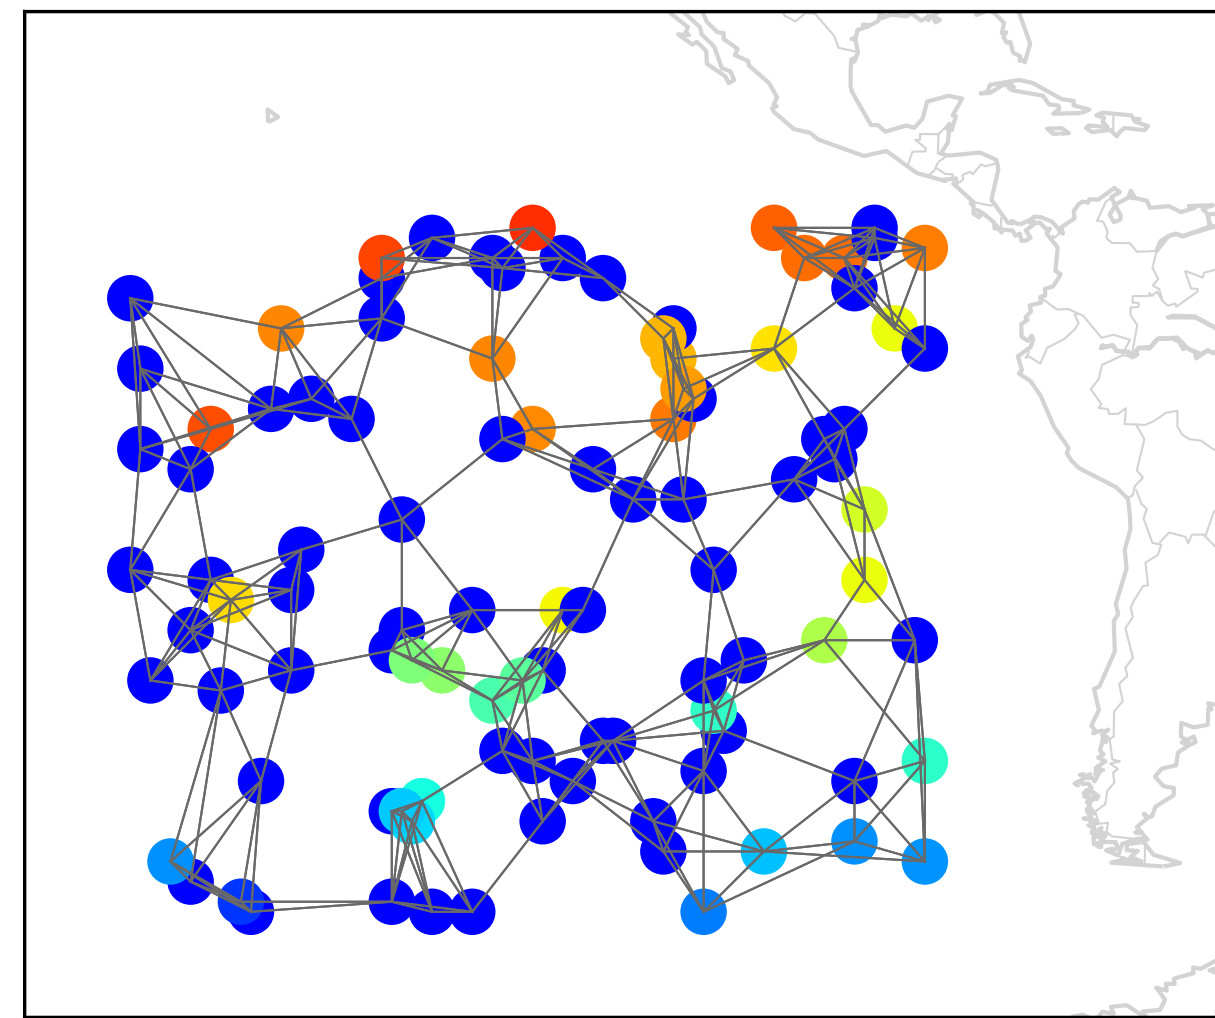
ノイズに対する復元性能






原信号



観測信号



再構成信号



研究概要

深層展開を用いた**時変グラフ信号の再構成手法**を提案

実験

人工データセット・海面水温データセット
サンプリングレート・ノイズレベルを変化させ再構成性能を比較

結果

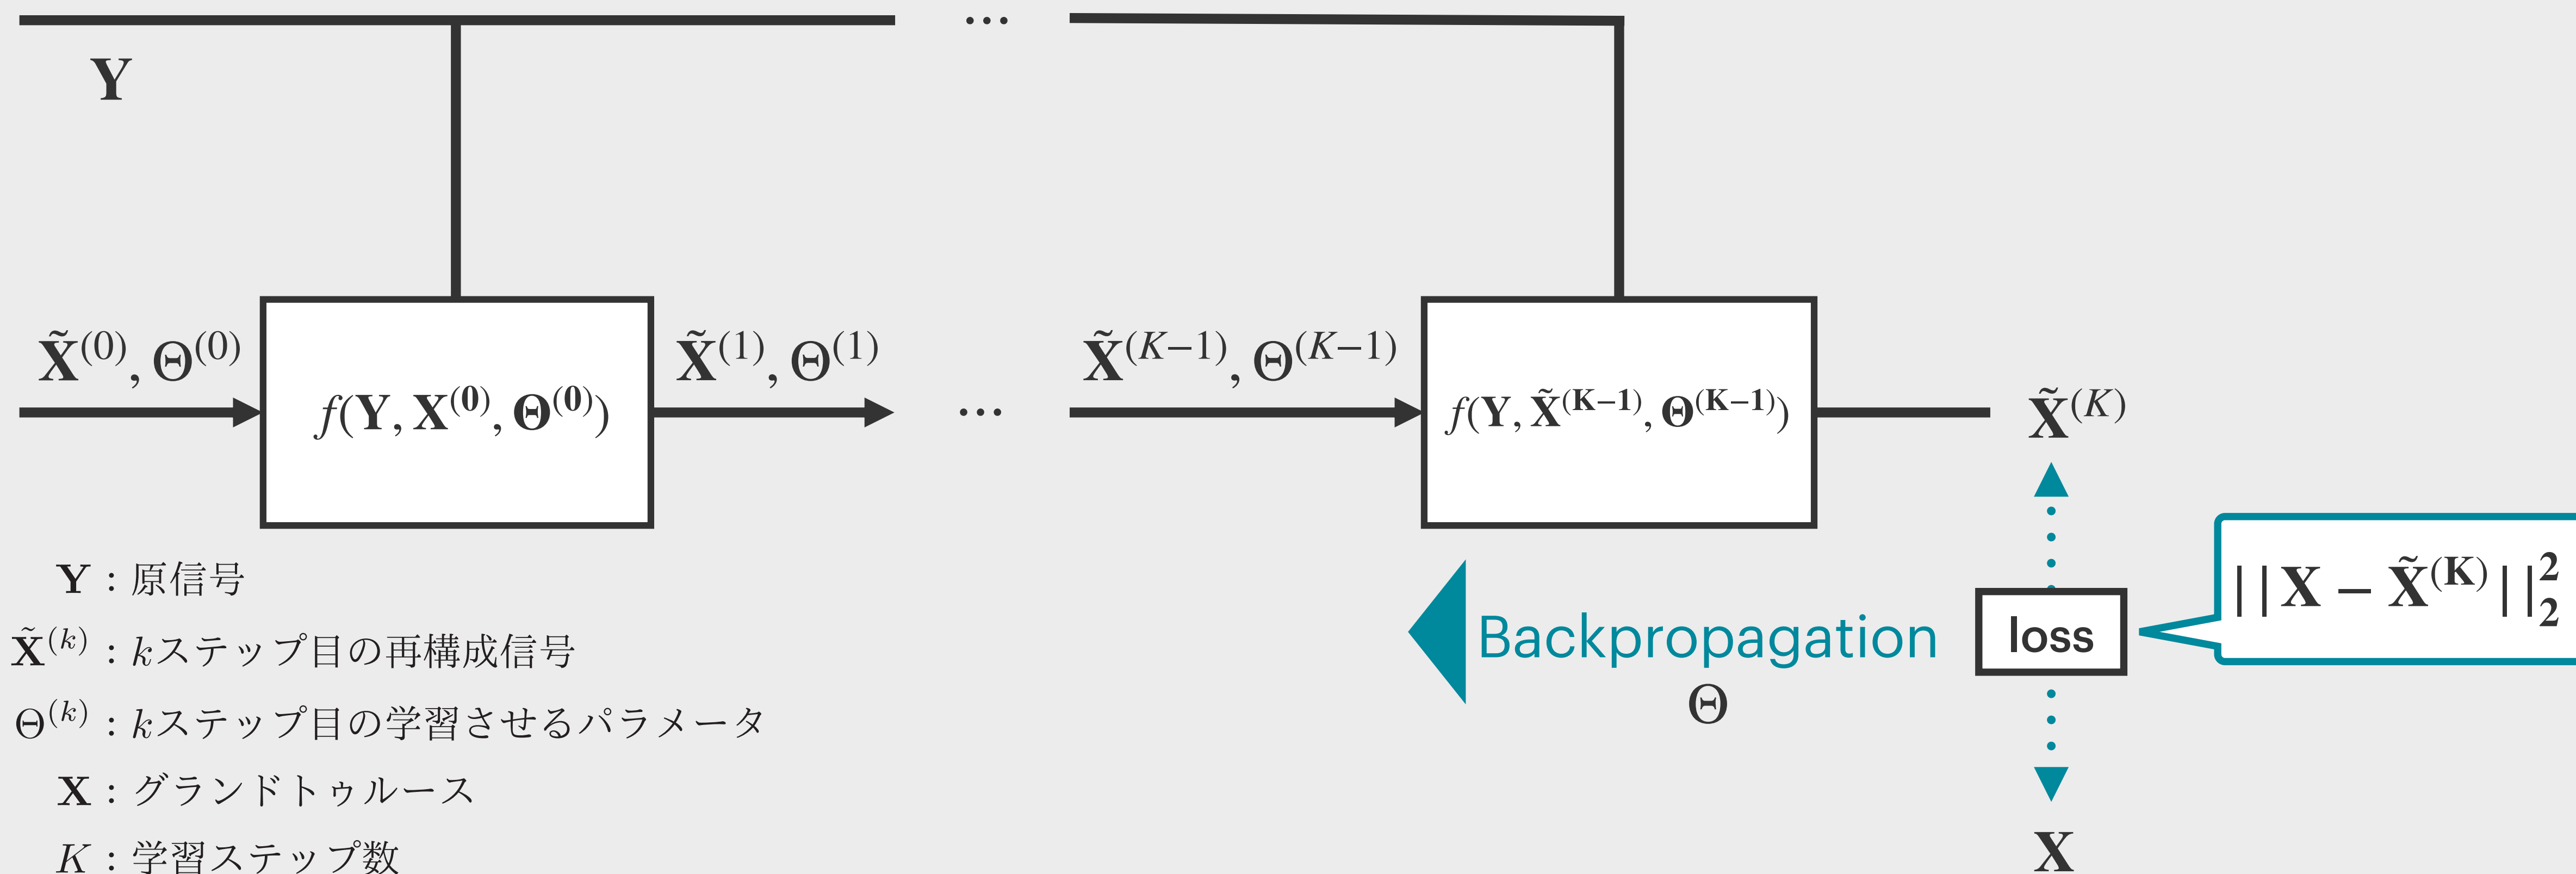
低測定率
高ノイズ の場合に特に高い再構成性能

発表状況

ICASSP 2023投稿済, 査読中

深層展開を用いた 時変グラフ信号の再構成


- 深層展開を用いてハイパーパラメータを学習



時間的に変化する複雑な構造を持つデータ



人体ポーズデータ[1]



気温[2]



ソーシャルネットワーク[3]

一般に計測されたデータにはノイズや破損が存在

ノイズ除去・再構成の必要性

[1] In-Bed Pose Estimation: Deep Learning with Shallow Dataset, Shuangjun Liu, Yu Yin, and Sarah Ostadabbas

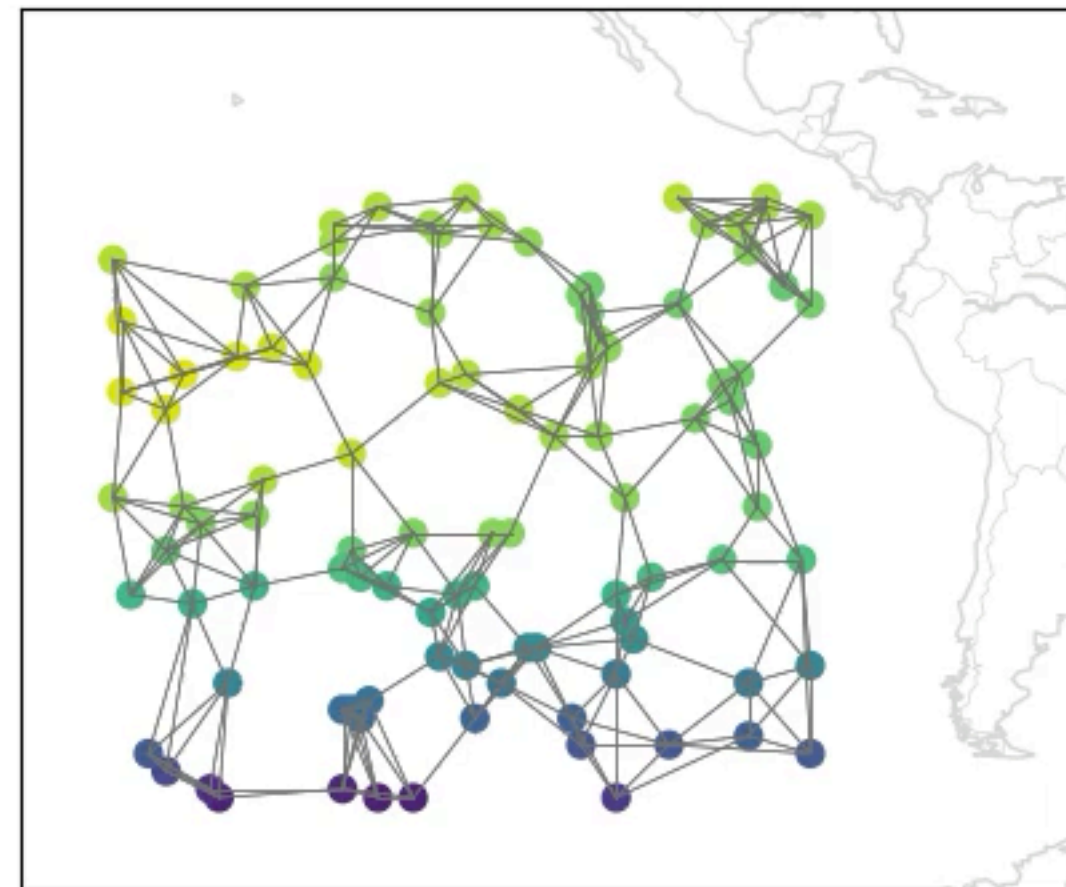
[2] Graph Normalized-LMP Algorithm for Signal Estimation Under Impulsive Noise, Yan, Yi and Adel, Radwa and Kuruoglu, Ercan

[3] https://all-free-download.com/free-vector/download/social_media_infographic_design_human_icons_combination_style_6826181.html

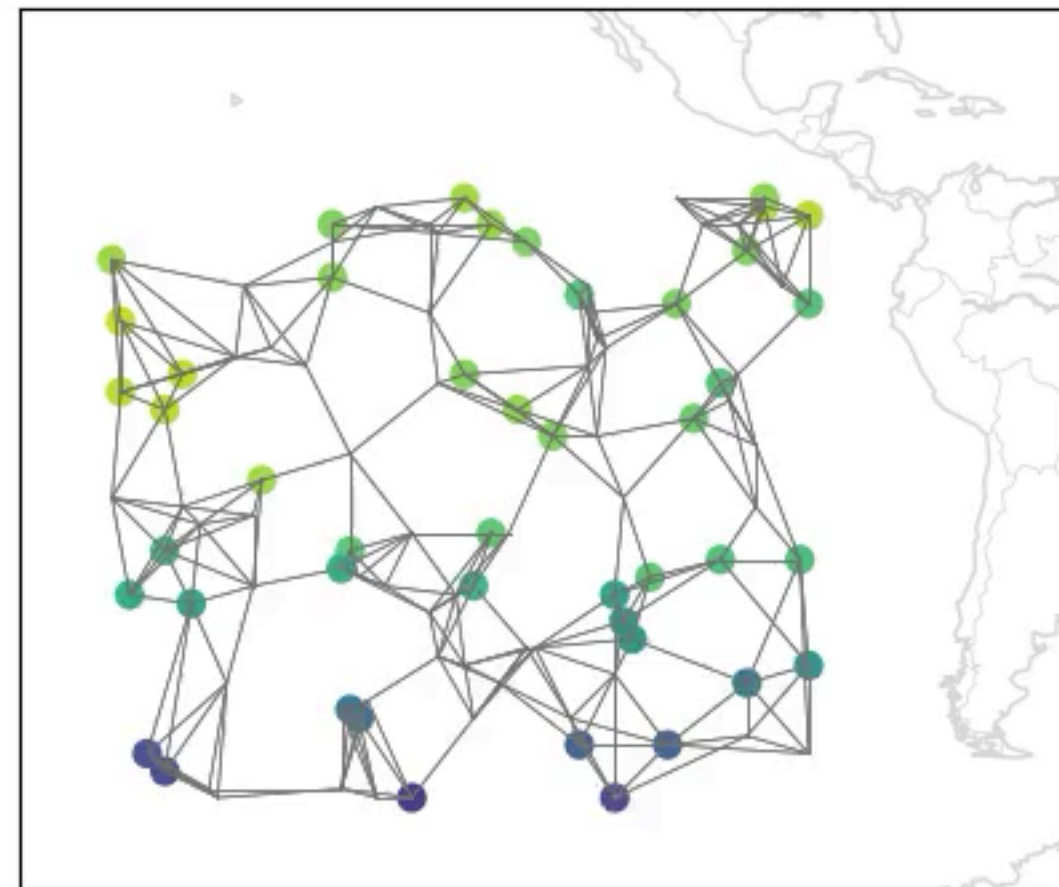
問題設定

- ・ 頂点数：100，時間数：600，繰り返し層数：50
- ・ 信号をランダムサンプリング→ノイズ付与
- ・ 実験用のデータで学習，テスト用のデータで実験
- ・ サンプリングレート・ノイズレベルを変化


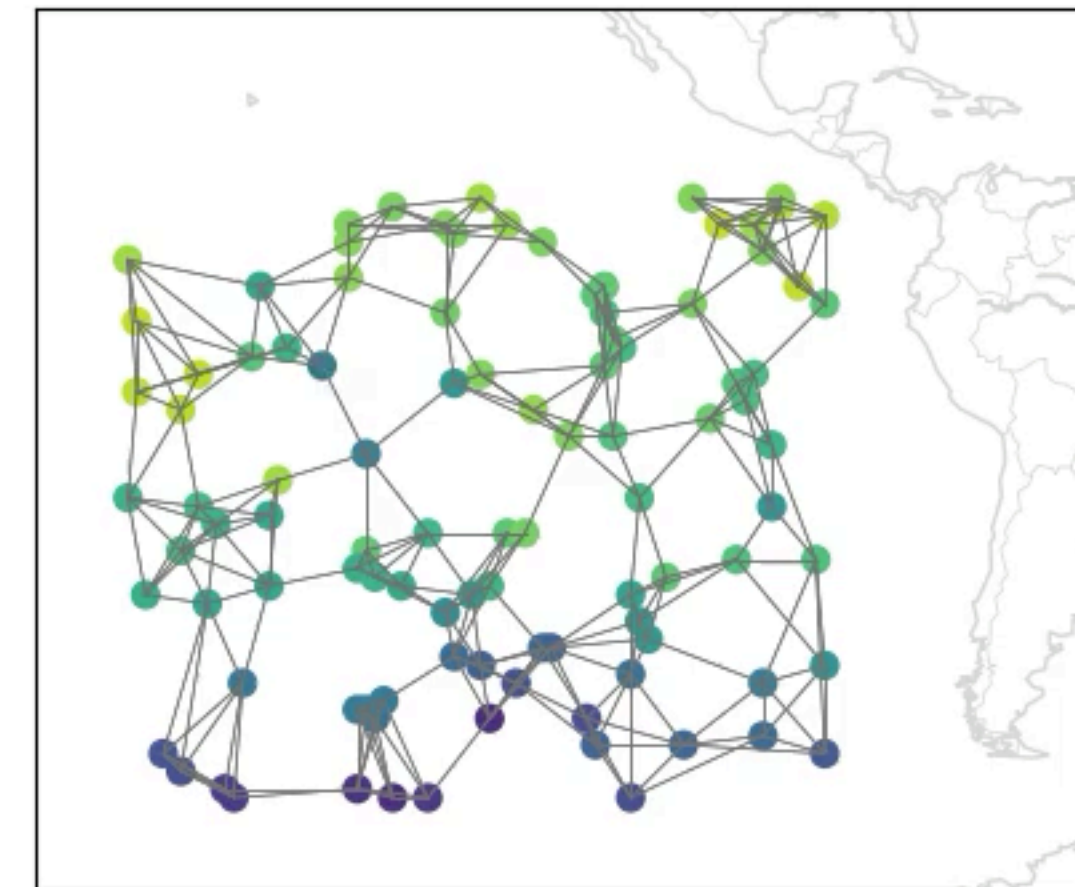
原信号



観測信号



再構成信号



グラフ作用素

隣接行列

: \mathbf{A}

度数行列

: $D_{n,n} = \sum_m a_{n,m}$ グラフラプラシアン : $\mathbf{L} = \mathbf{D} - \mathbf{A}$

ラプラシアン二次形式

$$S_2(\mathbf{x}) = \mathbf{x}^\top \mathbf{L} \mathbf{x}$$

$$S_2(\mathbf{X}) = \text{tr}(\mathbf{X}^\top \mathbf{L} \mathbf{X})$$

