

第27回計算工学講演会（6月2日）

C-08-01

転移学習ガウス過程回帰サロゲートモデルによる

構造性能解析の計算負荷低減

Transfer learning Gaussian process regression
surrogate model for structural reliability analysis

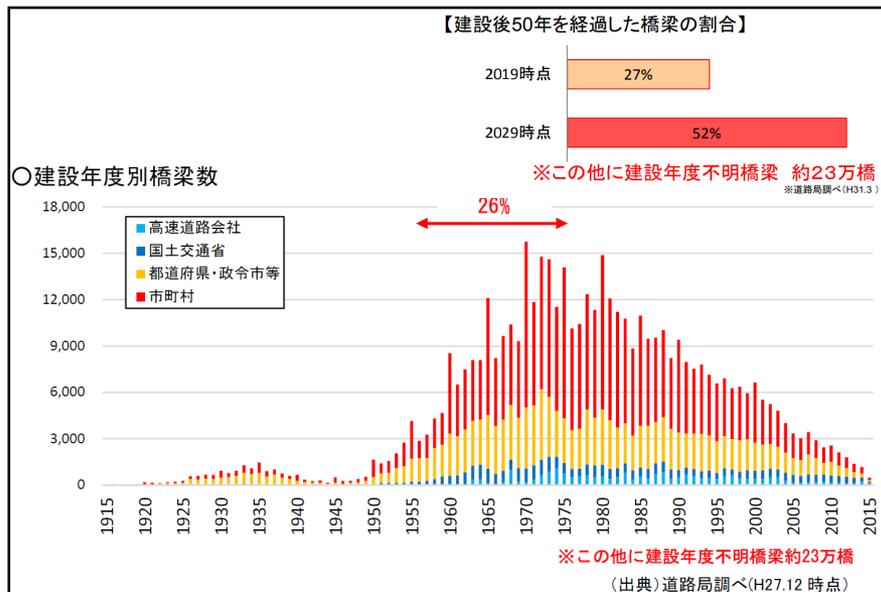
才田大聖（筑波大学大学院）

西尾真由子（筑波大学）



【背景】社会的背景

- 橋梁の多くは高度経済成長期に建設され、老朽化した橋梁が多く存在し、老朽化した橋梁は増加傾向である
- 老朽化した橋梁の運用では、補修補強や架け替えなどの判断やそれらの優先順位決定などの意思決定が求められることがある
- 既存橋梁の性能評価のため、構造状態や劣化損傷などの不確定性を考慮した確率ベースの構造性能解析が必要となる



(国交省, 老朽化対策の取組み)

(国交省近畿地方整備局, 道路老朽化の現状 老朽化の現状)

【橋梁の劣化損傷の様子】



【重大な損傷の事例(橋梁)】



みはらしはし しんやました
■見晴橋(市道 新山下第8号線)は、37歳で損傷を発見

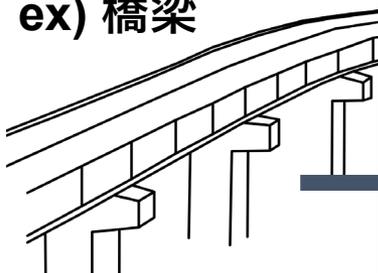
(国交省中部地方整備局, 道路の老朽化対策, 老朽化の現状)

(国交省, 老朽化対策の取組み)

【背景】信頼性解析の現状

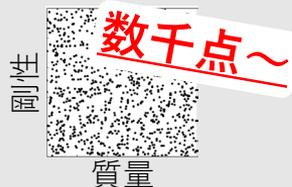
対象構造物

ex) 橋梁



一般的な信頼性解析

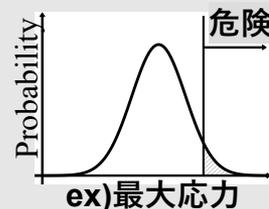
モンテカルロ
サンプリング



橋梁の
解析モデル



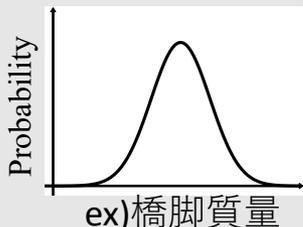
出力応答分布



災害リスク評価

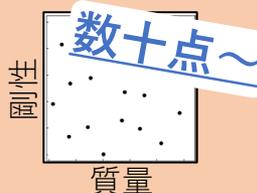
- ・維持管理の策定
- ・防災減災
- ・災害後の復旧

不確定性の
考慮が必要

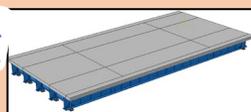


サロゲートモデルを用いた信頼性解析

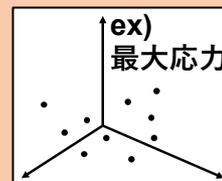
実験計画法
サンプリング



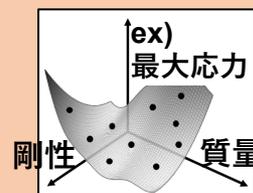
橋梁の
解析モデル



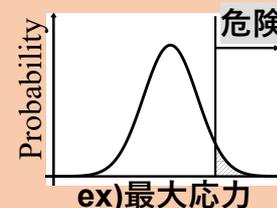
解析データ



機械学習による
サロゲートモデル



出力応答分布



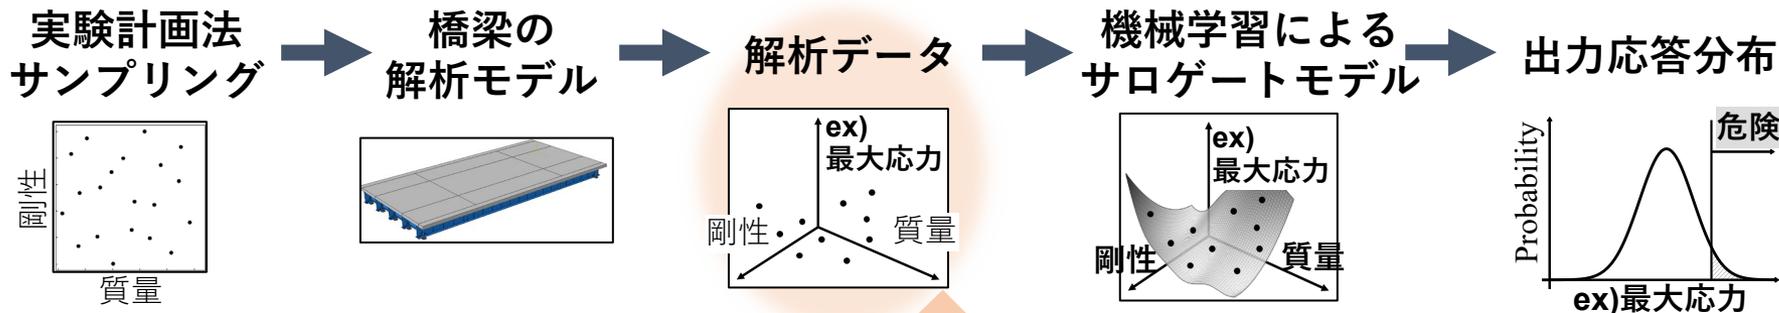
サロゲートモデルにより計算コストが低減

課題点

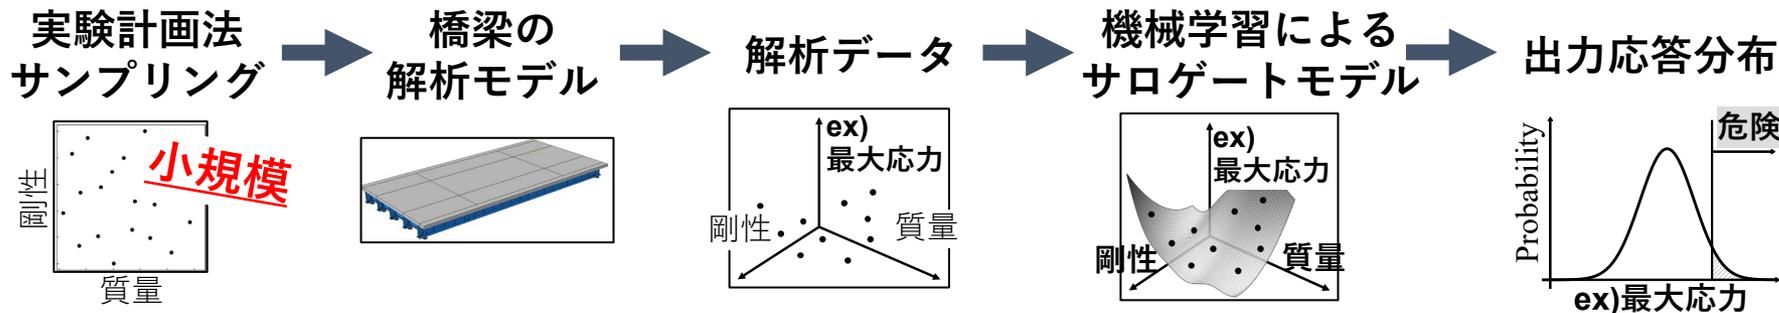
構築されたサロゲートモデルは
対象の解析にのみに有効

目的

橋梁の設計時



既存橋梁の評価時



転移学習により
設計時のデータを活用

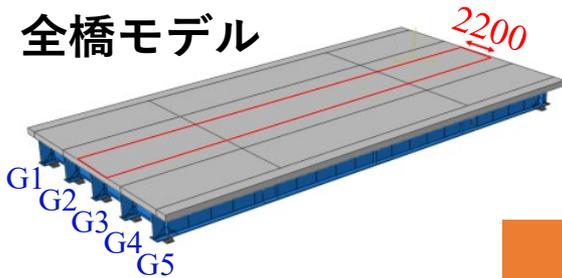
転移学習を用いたARDカーネルによるガウス過程回帰サロゲートモデル (TL-GPRSM) を構築し、既存橋梁の性能評価に適用することで、TL-GPRSM の計算コスト削減効果及びその説明性について検証することで有効性を示す

橋梁のFEモデル

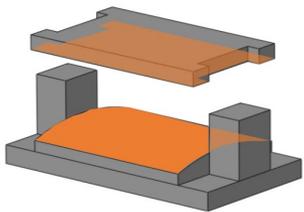
解析モデル：標準的な単純1桁橋

支間長	: 20000 mm	鋼製線支承	: ソリッド要素
幅員	: 10700 mm	要素数	: 104799
主桁各部材	: シェル要素	解析ソフト	: Abaqus
床版	: シェル要素		

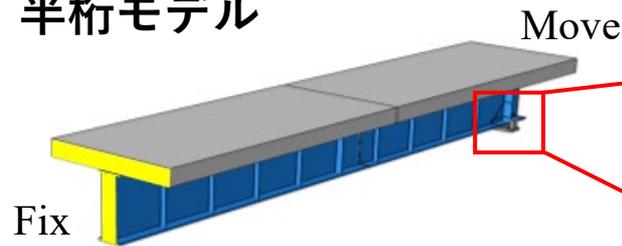
全橋モデル



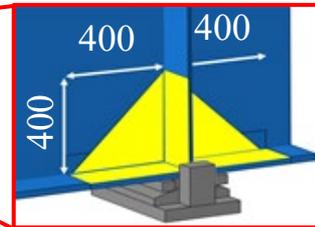
摩擦の考慮



半桁モデル



腐食領域



全橋モデルと挙動が一致するように調整

松島史弥：桁端部劣化損傷を有する鋼桁橋の構造信頼性評価のためのセンシング法の検討，横浜国立大学大学院，修士論文，2017.

➡境界面の摩擦を考慮した高計算コストなモデル

不確定性の設定

FE モデルパラメータ(単位)			設計時		劣化損傷時	
			Nominal	COV	Nominal	COV
#1	D_c	RC床版密度 (kg/m ³)	2400	0.0171	*	*
#2	E_s	上部工鋼部材ヤング率 (GPa)	200	0.0450	*	*
#3	E_c	RC床版ヤング率 (GPa)	25	0.0167	22.5	0.0333
#4	E_b	線支承鋼ヤング率 (GPa)	200	0.0450	*	*
#5	V_s	上部鋼部材ポアソン比	0.3	0.0910	*	*
#6	V_c	RC床版ポアソン比	0.2	0.0167	*	*
#7	V_b	線支承鋼ポアソン比	0.3	0.0910	*	*
#8	C_f	線支承摩擦係数	0.2	0.0167	0.9	0.0333
#9	T_{uf1}	主桁端部上フランジ板厚 (m)	0.0190	0.0121	*	*
#10	T_{uf2}	主桁上フランジ板厚 (m)	0.0300	0.0121	*	*
#11	T_w	主桁ウェブ板厚 (m)	0.0090	0.0121	*	*
#12	T_{bf1}	主桁端部下フランジ板厚 (m)	0.0270	0.0121	*	*
#13	T_{bf2}	主桁下フランジ板厚 (m)	0.0300	0.0121	*	*
#14	T_{stc}	鉛直補剛材板厚 / 桁端部 (m)	0.0130	0.0121	*	*
#15	T_{stm}	鉛直補剛材板厚 / 支間中央部 (m)	0.0100	0.0121	*	*
#16	T_{stn}	鉛直補剛材板厚 / その他(m)	0.0065	0.0121	*	*
#17	T_{bf-d}	腐食領域板厚 / 下フランジ (m)	-	-	0.025	0.0270
#18	T_{w-d}	腐食領域板厚 / ウェブ (m)	-	-	0.008	0.0162
#19	T_{st-d}	腐食領域板厚 / 鉛直補剛材 (m)	-	-	0.012	0.0162

※既往研究などを参考に決定

信頼性解析の概要

不確定パラメータ

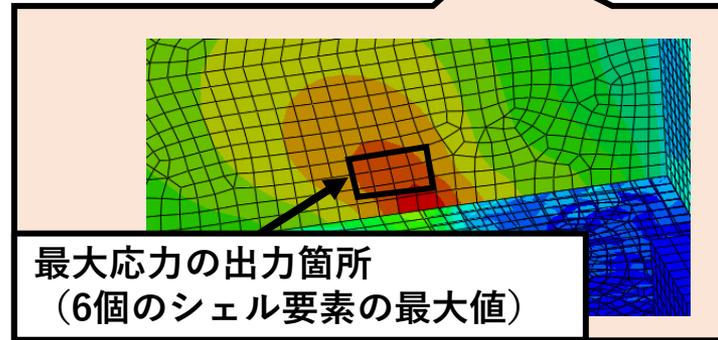
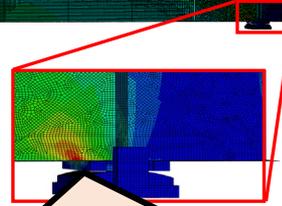
FE 解析
(設計活荷重を载荷)

最大ミーゼス応力分布
(各500データ)

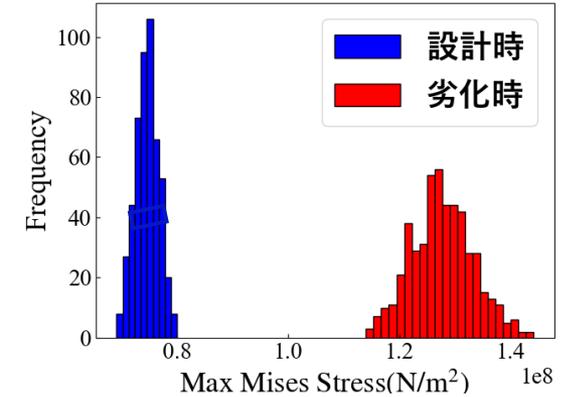
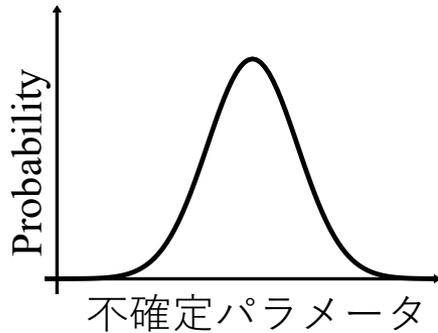
設計時：16変数
劣化時：19変数



半桁モデル



最大応力の出力箇所
(6個のシェル要素の最大値)

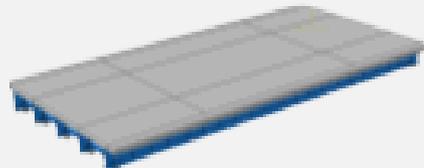


信頼性解析の入力と出力

入力

設計時：16変数
劣化時：19変数

FEM 解析



出力

最大ミーゼス応力

ガウス過程回帰(GPR)

ガウス過程回帰

$$y = f(\mathbf{x})$$

$$f \sim GP(\mathbf{0}, k(\mathbf{x}, \mathbf{x}'))$$

$$\mathbf{y} \sim \mathcal{N}(\mathbf{0}, \mathbf{K})$$

\mathbf{x} : 入力ベクトル

\mathbf{y} : 出力ベクトル

k : カーネル関数

\mathbf{K} : カーネル行列

カーネル行列

$$K_{nm} = k(\mathbf{x}_n, \mathbf{x}_m)$$

K_{nm} : カーネル行列の要素

ARDカーネル関数

ARD: Automatic Relevance Determination

$$k(\mathbf{r}) = \sigma \left(1 + \sqrt{5} \sum_{i=1}^D \frac{r_i}{l_i} + \frac{5}{3} \sum_{i=1}^D \frac{r_i^2}{l_i^2} \right) \exp \left(-\sqrt{5} \sum_{i=1}^D \frac{r_i}{l_i} \right)$$

Matern5/2 カーネル

特性長スケール (l_i)

出力に対する入力変数ごとの寄与度を表す

l_i が小さいほど寄与度が大きくなる

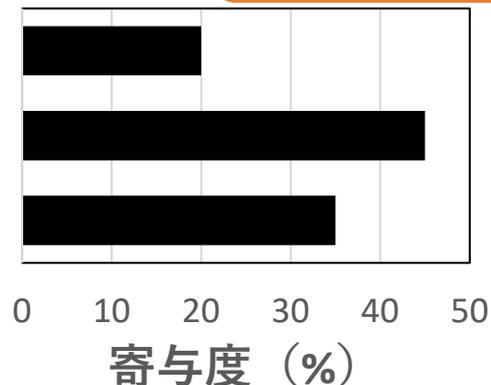
ARDカーネル

入力パラメータの
寄与度を推定

ポアソン比

ヤング率

板厚



転移学習のデータ

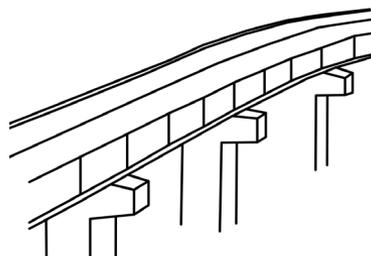
Source Data: 設計時のデータ

最大応力

y^S

不確定
パラメータ

x^S



転移学習

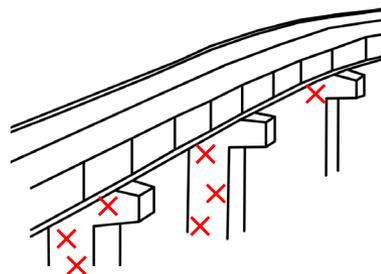
Target Data: 劣化損傷時のデータ

最大応力

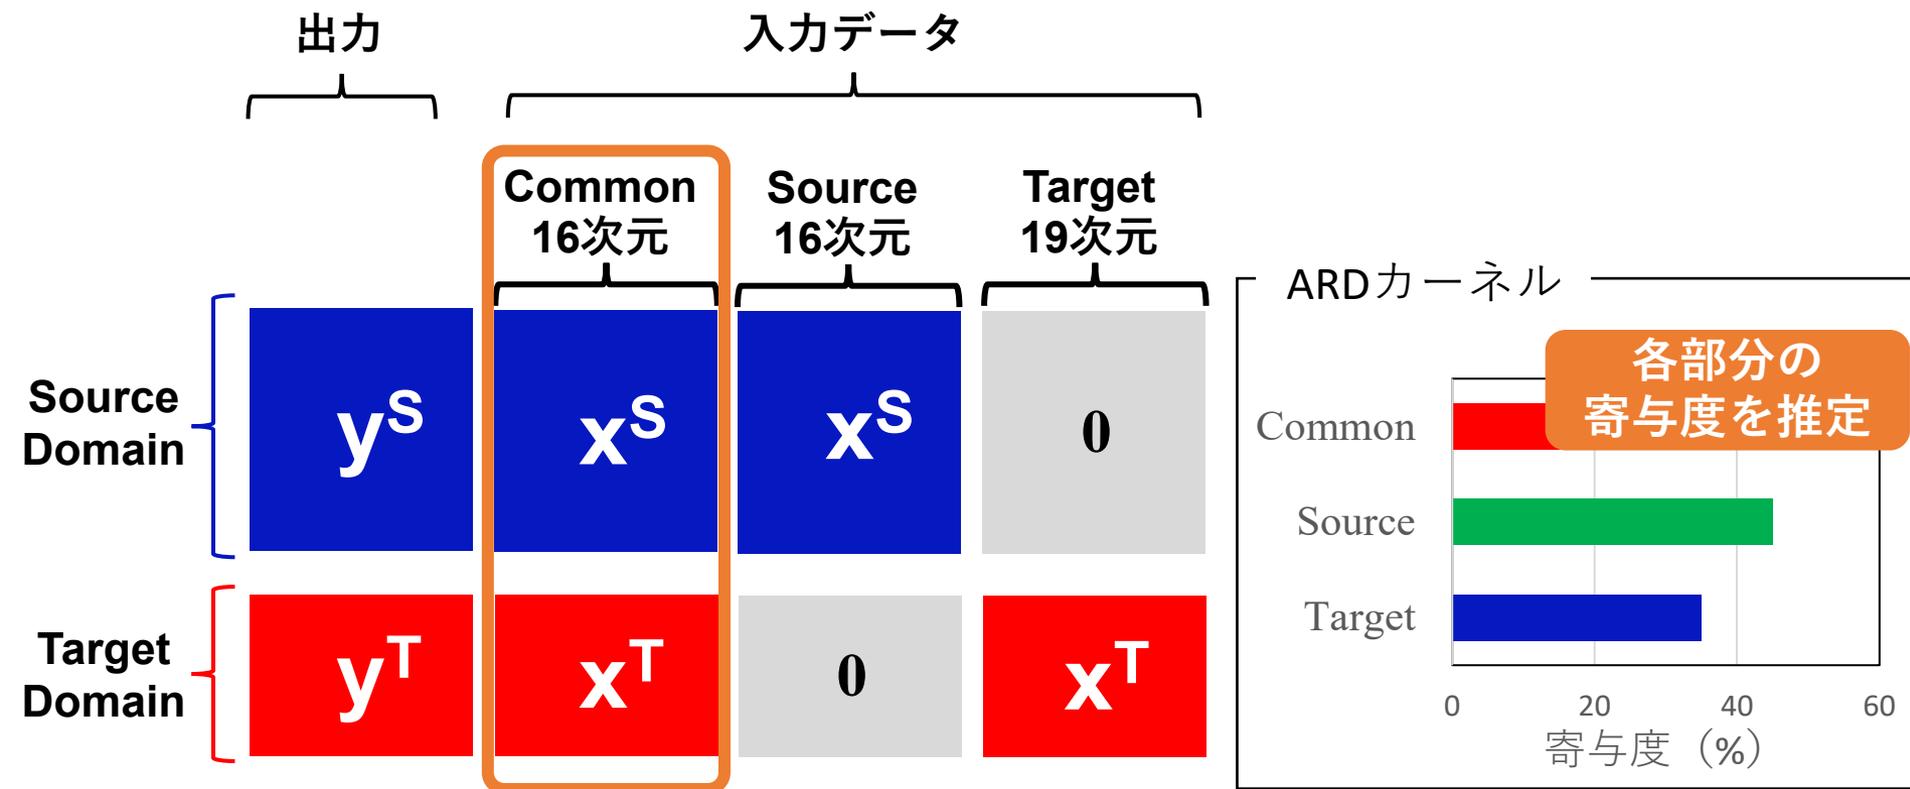
y^T

不確定
パラメータ

x^T



ガウス過程回帰における転移学習



Common部分の寄与が大きいくほど、
転移学習の効果が大きい

検証方法

評価方法

- ① 訓練データから**転移学習ガウス過程回帰サロゲートモデル (TL-GPRSM)** を構築
- ② TL-GPRSMでテストデータ点における出力を予測
- ③ TL-GPRSMの性能を以下の指標等で比較
 1. 二乗平均平方根誤差パーセント (**RMSPE**)

$$\text{RMSPE} = 100 \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right)^2}$$

2. **最大応力の分布形状**
3. ARDカーネルの特性長スケールでの**寄与度推定**

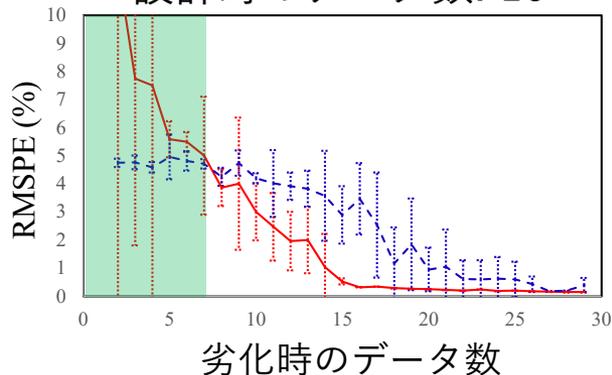
【結果】 TL-GPRSMの精度

最大応力の予測（学習10回試行）

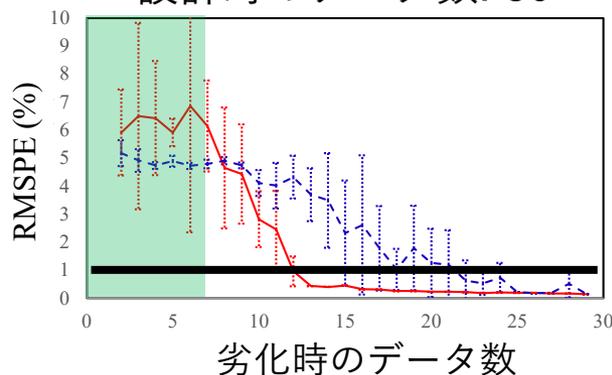
- TL-GPRSM
- 転移学習なしサロゲートモデル

$$\text{RMSPE} = 100 \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right)^2}$$

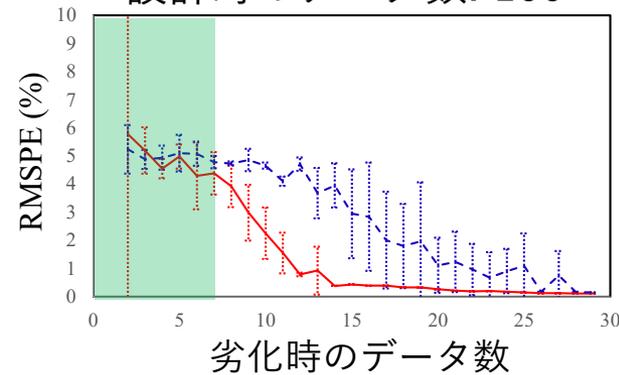
設計時のデータ数: 10



設計時のデータ数: 30



設計時のデータ数: 100



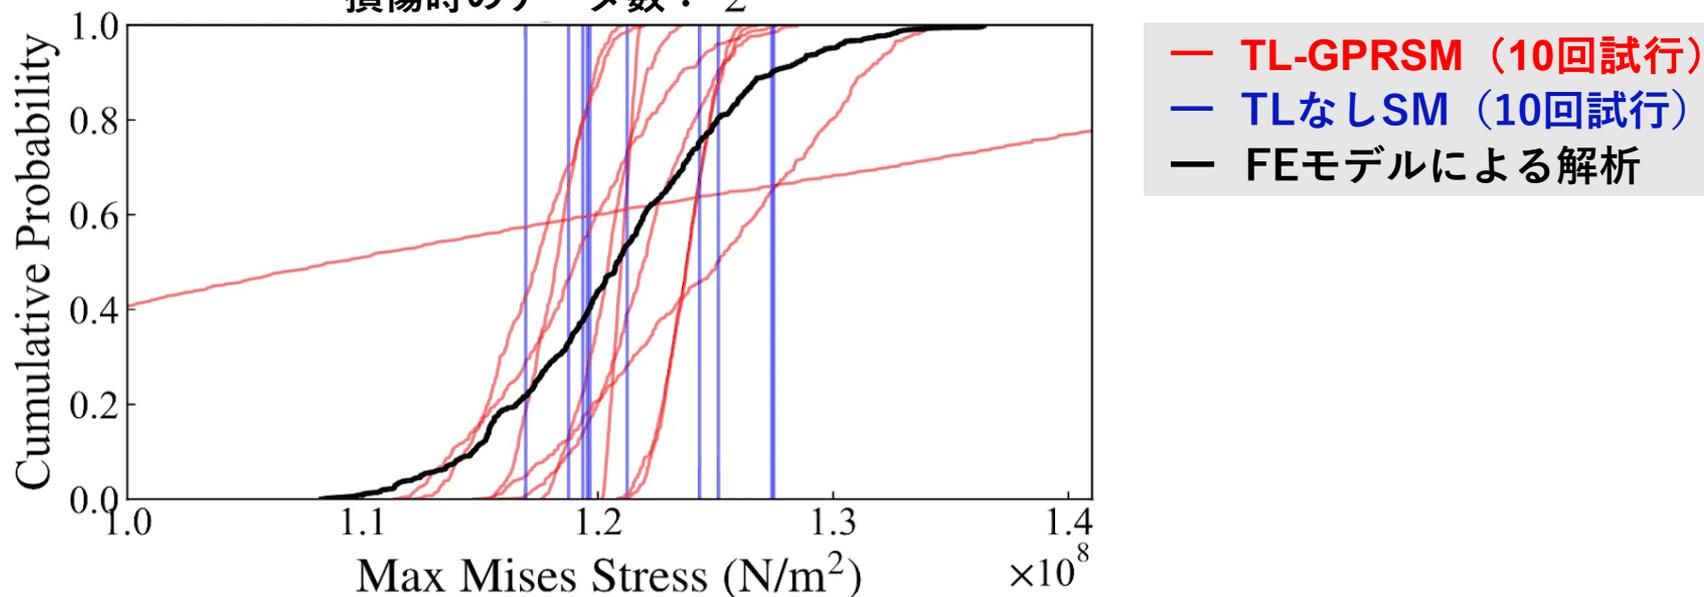
- 設計時のデータ数に関わらず、TL-GPRSMは訓練データ数に対する収束が速く、転移学習なしのサロゲートモデルよりも場合によっては**40%程度小さいデータ数で収束する**
- 設計時のデータ数が多いほど、劣化時のデータ数が少ない領域で高精度なTL-GPRSMが構築された

【結果】 最大応力の予測分布

最大応力の予測累積分布 (学習10回試行)

設計時のデータ数：30

損傷時のデータ数：2

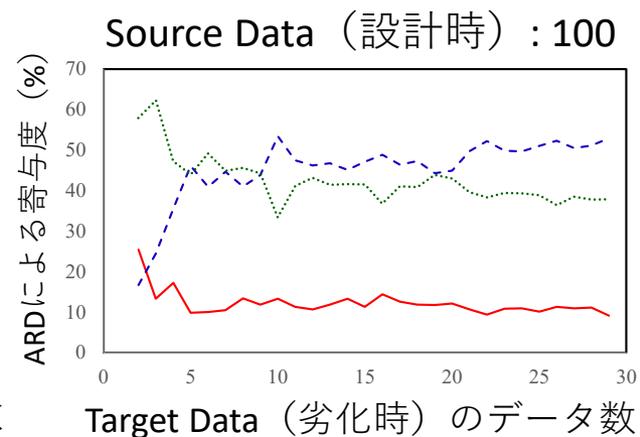
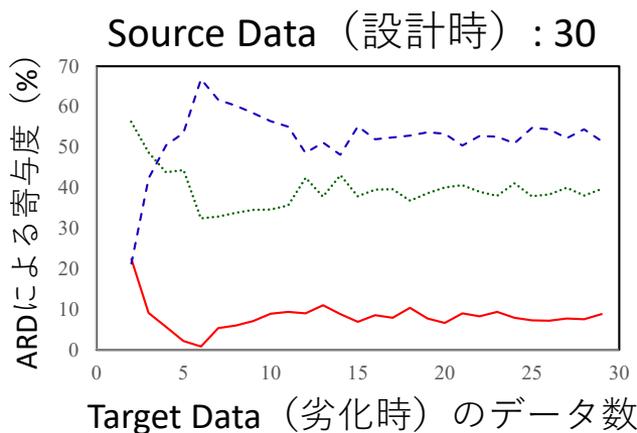
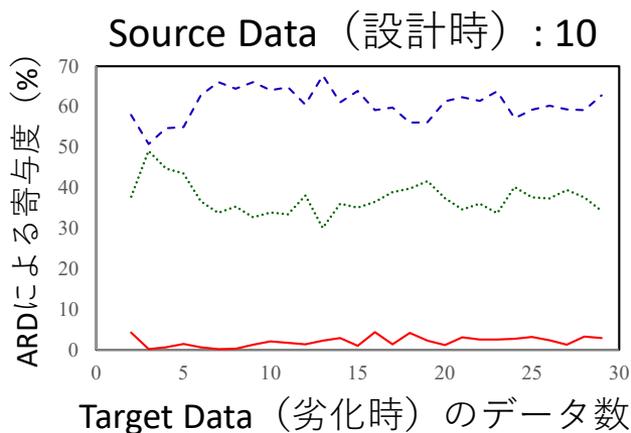
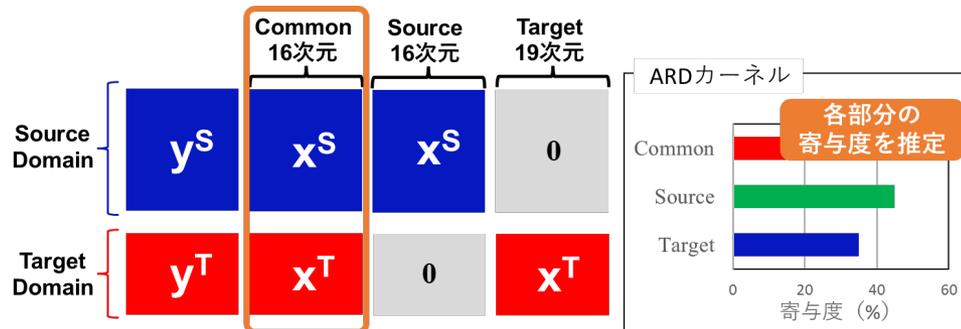


- TL-GPRSMは転移学習なしサロゲートモデルよりも訓練データ数に対する**予測分布の収束が速い**
- 同数の訓練データ数で、TL-GPRSMは転移学習なしサロゲートモデルよりも**FEモデルによる結果に近い分布形状を予測**できた

【結果】 ARDによるパラメータの寄与度推定結果

各部ごとの寄与度

- Common部
- Target部
- Source部



- Sourceデータ数が多いほどCommon部の寄与度が高くなり、
転移学習の効果が大きいといえた
- Sourceデータ数 : 30のときと、Sourceデータ数 : 100のときでは、
大体同じ寄与度へと収束していた

【結果】 ARDによるパラメータの寄与度推定結果

各不確定パラメータの寄与度

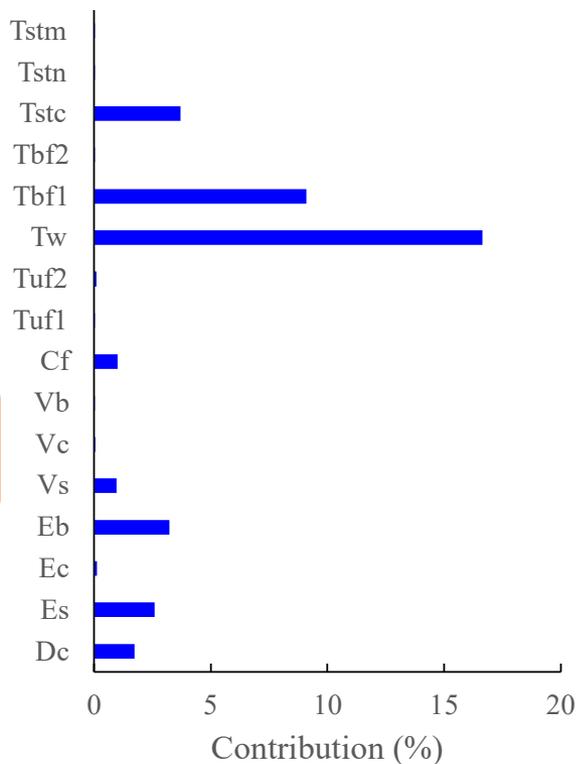
設計時のデータ数: 30

劣化時のデータ数: 15

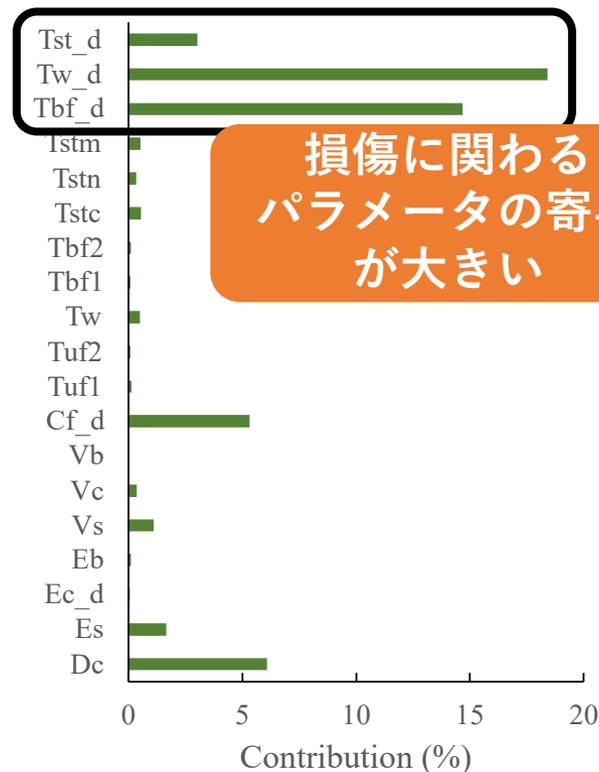
Common部



Source部



Target部



- ARDで適切に寄与度を推定できている

まとめ

結論

- 転移学習ガウス過程回帰代替モデル(TL-GPRSM)を提案し、腐食損傷を受けた鋼板桁橋の活荷重性能評価に適用し、設計時のデータを損傷後の解析に利用した。
- Sourceデータ（設計時のデータ）数に関わらず、TL-GPRSMは転移学習なしのサロゲートモデルよりも小さいデータ数で高精度であった。
- TL-GPRSMによる最大応力の累積分布の予測値は、同数の劣化時のデータを用いた場合、転移学習を行わないサロゲートモデルよりも数値結果に近かった。
- 転移学習の効果は、ARDカーネルから計算される共通部分の寄与度から判断することができ、Sourceデータの数が多いほど、転移学習が効果的であると判断された。
- ARDにより個々のパラメータの寄与度まで知ることができ、劣化損傷に関連するパラメータの寄与度が高いことがわかった。

展望

- カーネル関数の検討により、さらに入出力間の特徴を捉え、計算コストを低減できる可能性がある
- アダプティブサンプリングにより、サロゲートモデルの性能に大きな影響を与える点を優先的にサンプリングし、さらに計算コストを低減できる可能性がある