

2025年度第1回公開セミナー
海洋AIコンソーシアムにおける海洋×AIの最前線

サロゲートAIモデルの気象・海況/船舶 への応用

木村 考伸

(古野電気株式会社 技術研究所 第1研究部 知能制御研究室)

2025年12月4日(木)

- 企業紹介

- 演題 1 (データ駆動) :

マルチスケール型GNNに基づく海況モデルによる全球10日間予測

- 演題 2 (非データ駆動) :

物理法則埋め込み型ニューラルネットワークによる船舶流体解析

- 今後の予定

- まとめ

漁業の 見える化



**IEEE
MileStone
(2024)**

魚群探知機を世界ではじめて実用化！

12/3を「魚探の日」として日本記念日協会にて登録

センシングから「安全航行」まで

FURUNO



現況センシング

センシング予測

新たな顧客価値から描く
デジタル化の未来

海難事故ゼロに向けて

自動運航

見えない
ものを見る

情報を
統合する

分析し
判断する

運航支援

認知支援

判断支援

自動運航に向けて


「見えないものを見る」はFURUNOの事業テーマでもあります。船舶の自動運航に向けてFURUNOが貢献できるフィールドとして、2つの支援の展開を目指しています。


支援 1

これまで培ってきた船用電子機器や独自のセンサー技術を生かして周辺状況の把握へとつなげる“認知支援”。

支援 2

収集したデータ情報を分析し周辺状況把握の結果に基づいた避航操船をサポートする“判断支援”。





- **(一般的に)CFDの計算コストは高い**
(数秒のシミュレーションで数日間の計算も普通も)
- **精度を担保しながら、計算量の削減の必要**

サロゲート(代理モデル)とは

FURUNO

高精度なシミュレーションは1回で数時間～数日かかる



多数の設計案を評価するには計算コストが高すぎる。

計算を単純化しすぎると、精度が低く使い物にならない





複雑な物理現象を正しく評価できず、最適な設計を見逃す。

複雑なデータから「本質」だけを抜き出して簡略化する。



結果に大きく影響する「重要な方向(Active Subspace)」を発見



AIがCAEを代替する、**高速・高精度な「代理モデル」**。

少数のシミュレーション結果から入力と出力の関係を学習する。

教師あり学習 (Supervised Learning)

「正解」付きデータで学習

人間が作成したラベルを教詞として、特定の予測タスクを解く。



① マルチスケール型
GNNに基づく海況モ
デルによる全球10日
間予測

自己教師あり学習 (Self-Supervised Learning)



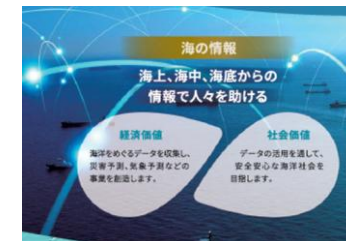
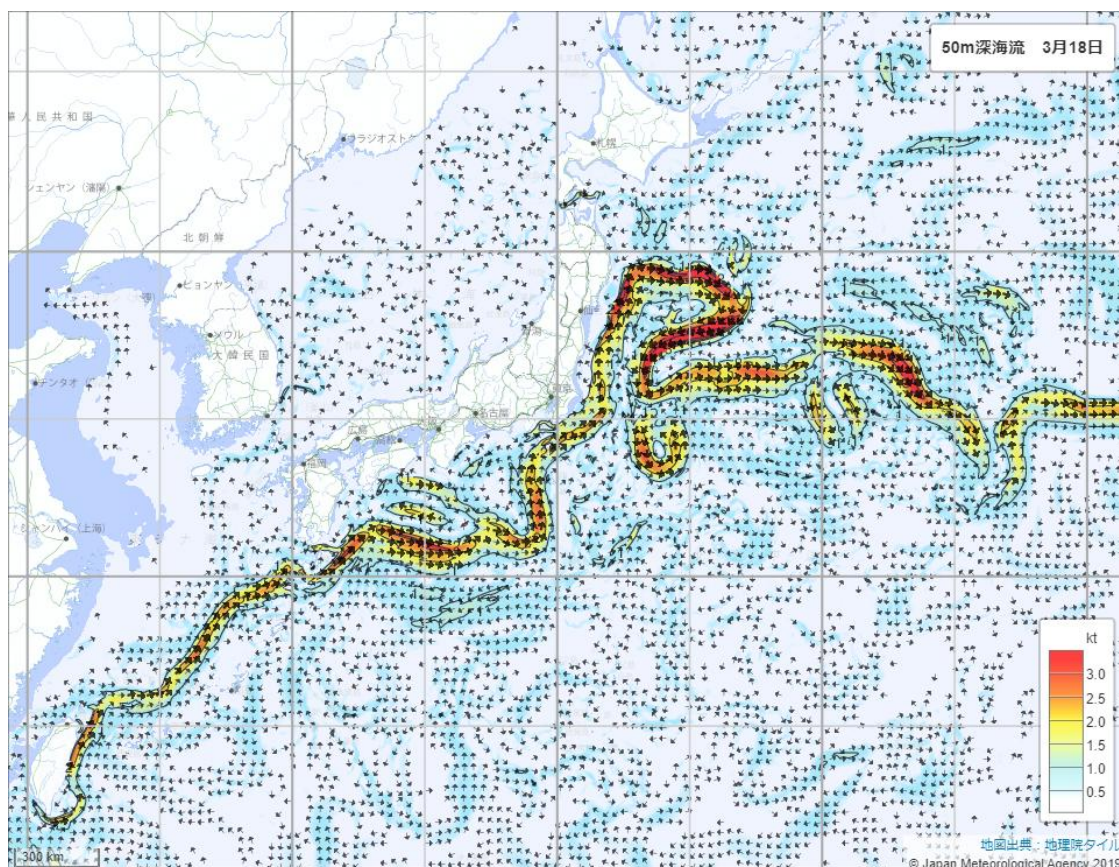
データ自身から「正解」を生成

ラベルなしデータから疑似ラベルを作り、データの本質的な表現を学ぶ。



② 物理法則埋め込み型
ニューラルネットワークに
よる船舶流体解析

① マルチスケール型GNNに基づく海況モデル による全球10日間予測



海洋研究開発機構（JAMSTEC）と、共同研究契約を締結

2024年10月10日

AI海況予測モデルの開発により、高精度かつリアルタイムな海況情報の提供を目指す

古野電気株式会社（本社：兵庫県西宮市、代表取締役社長執行役員：古野幸男、以下 当社）は、海洋研究開発機構（所在地：神奈川県横須賀市、理事長：大和 裕幸、以下 JAMSTEC）と2024年4月に共同研究契約を締結し、「大気・海洋における確率論的予測代理モデルの研究開発」に向けた共同研究を開始しましたのでお知らせします。




対外発表

- European Geoscience Union'25
- 人工知能学会'25 **（優秀演題賞を受賞）**



海況モデルの利用には膨大な計算コストが



漁業の効率化

漁場探索を支援し、漁獲量向上と省エネ従業に貢献します。



船舶の航行最適化

安全で経済的な最適航路を計画し、燃料費とCO2を削減します。



膨大な計算コスト

物理モデルの計算にはスーパーコンピュータが不可欠です。



限られた利用環境

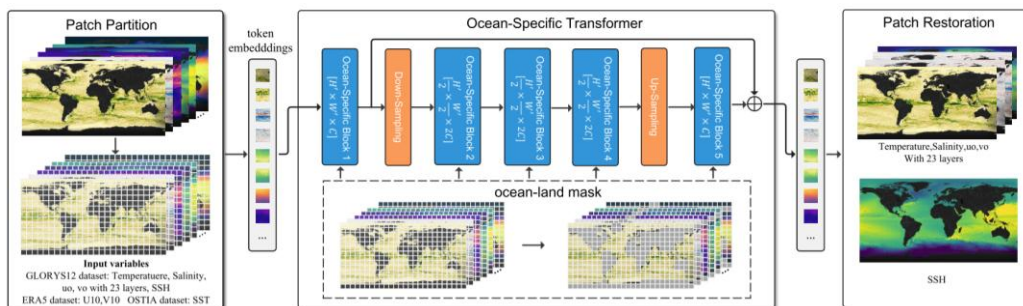
地球シミュレータなど、誰もが自由に使えるわけではありません。

AIを用いたサロゲート海況モデルの研究の進展


- 全球海況予測のサロゲートの可能性の研究
 - e.g : Xiong et al., 2023, Aouni et al.,2024, Zhao et al.,2025
 - 1/4°解像度→現業予報 (e.g. 1/12°解像度)と比べて限定的
- 全球・高解像度(1/12°)モデルの先行研究 : Wang et al.,2024
 - CMEMSによる現業予報*と比較し、長期間にわたり良好な結果(RMSE)

*CMEMS:Copernicus Marine Service

([Global Ocean Physics Analysis and Forecast | Copernicus Marine Service](#))



予測リードタイムごとにモデルを構築




引用 : Wang, X., et al (2024). "XiHe: A Data-Driven Model for Global Ocean Eddy-Resolving Forecasting" (arXiv preprint arXiv:2402.02995).

AIを用いたサロゲート海況モデルの研究の進展

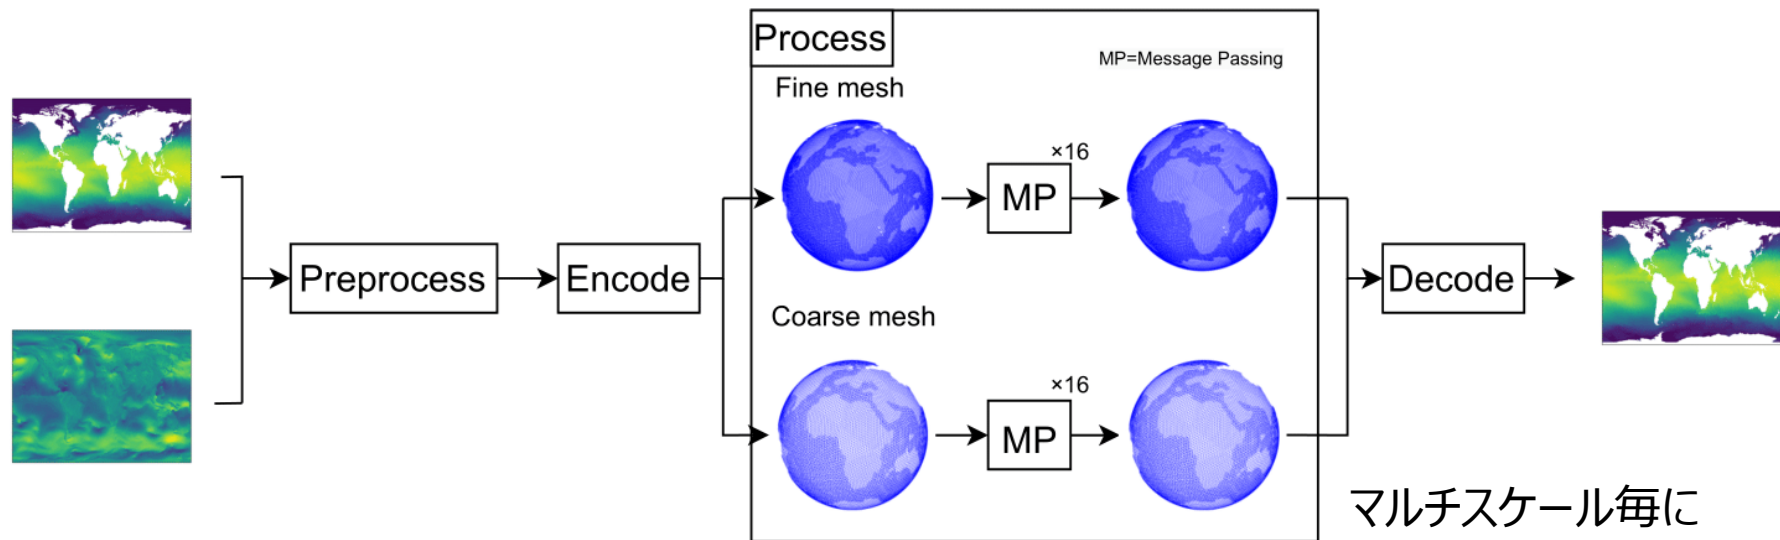
- **全球・高解像度($1/12^\circ$)モデルの先行研究 : Wang et al.,2024**
- 格子を用いたノード構成 (→陸・沿岸地形への対応)
- 時間発展について時間ごとに別モデル (→double penalty effect)
- 海況以外との相互作用を考慮せずクローズ
- **アーキテクチャー(空間・時間発展)が最適か**
- **大気との相互作用を考慮する**

本発表の内容

- **マルチスケールGNNに基づく全球 $1/12^\circ$ 解像度の海況予測モデルを開発**
※気象予測データも入力として活用・**単一モデルの自己回帰**による予測方式
- Wang et al.,2024(ベースライン)と比較し、性能や特徴を明らかにする



1/12°のメッシュを
グラフノードとして
その隣同士の時間発展の
関係性を学ぶ



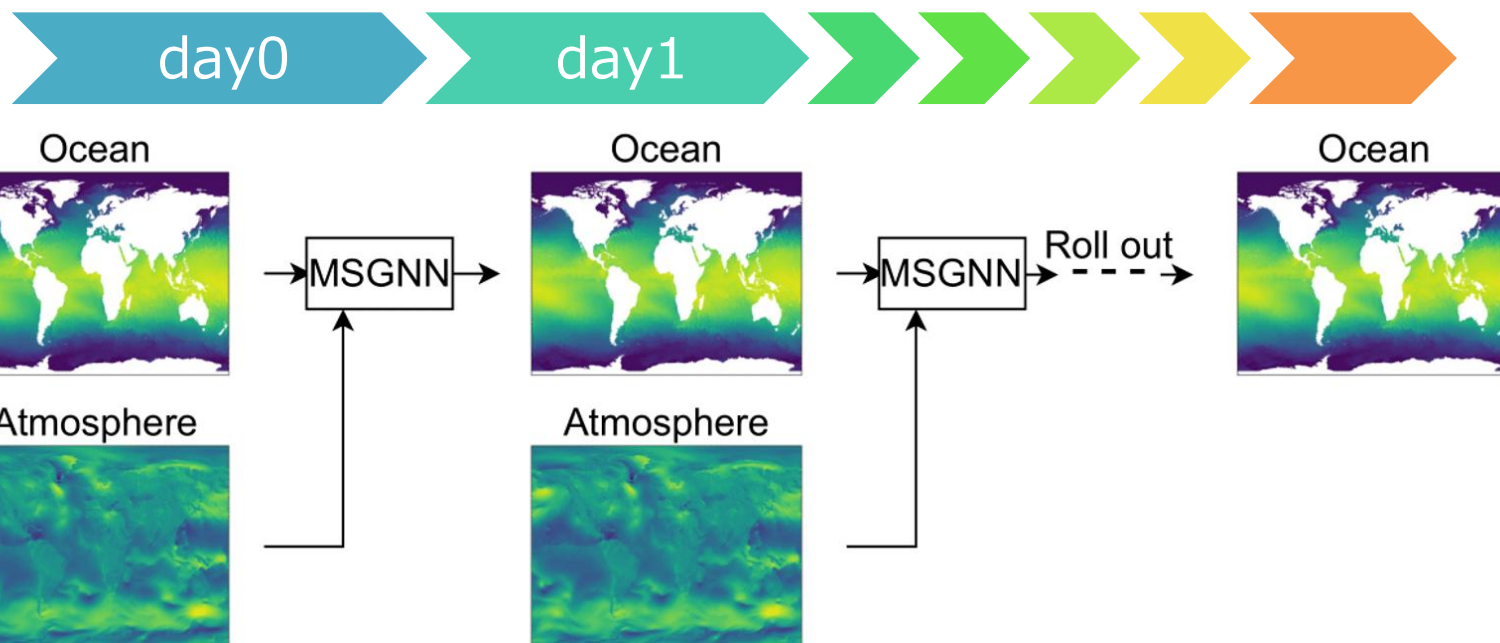
マルチスケール毎に
現象を学習する
仕組みを適用

<海況> (5変数)

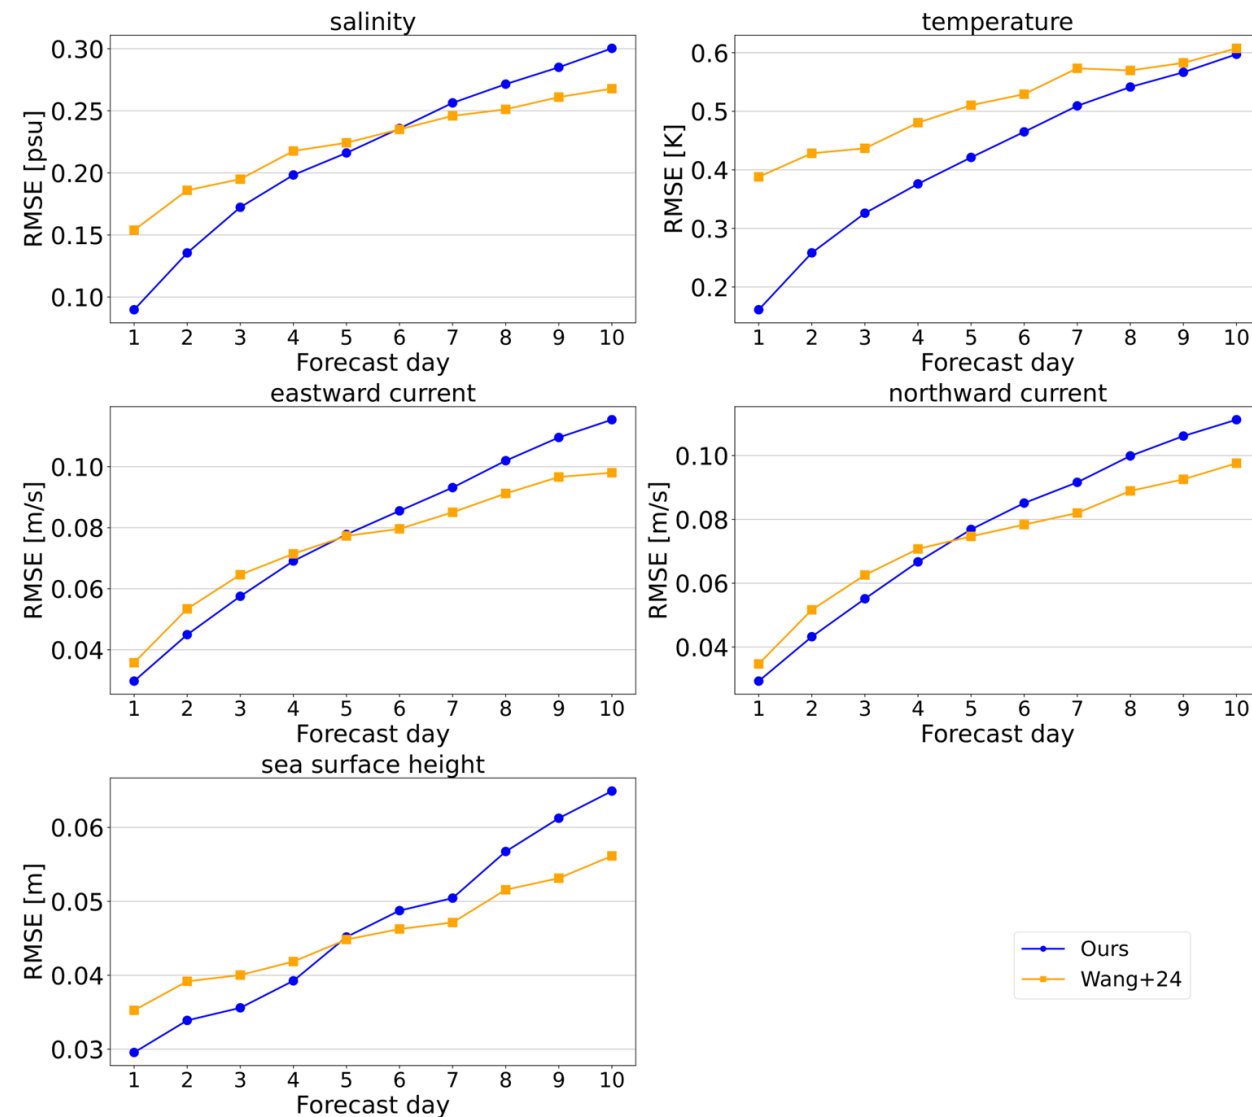
- 水温*
 - 東西流速*
 - 南北流速*
 - 塩分*
 - 海面高度
- (*23層/650m)

<気象> (10変数)

- 東西風速
- 南北風速
- 降水量
- 気温
- 湿度
- 日射量
- 長波放射
- 顕熱
- 潜熱
- 海面気圧



	本研究
ベースアーキテクチャー	Multi-scale graph neural network
時間発展	単一モデル・自己回帰型モデル
気象	ERA5 (学習), GFS (推論)
学習データ(期間)	1993 - 2017
学習データ	GLORYS12 (Copernicus Marine Service)
鉛直層	23 (~650m)




全ての変数でリードタイム4日
以内の精度は同等以上

※真値は海洋再解析データ


予測結果例①：空間分解能

FURUNO


再解析



本研究



Wang+24



本研究の方が、過度な平滑化が抑えられている

• 予測方式の違い

- 本研究 : 自己回帰方式 → タイムステップが1日で固定
- Wang + 24 : リードタイム毎にモデル構築 → タイムステップ=リードタイム (10日)

• 予測後半になるにつれ、本研究の方がRMSEが悪化することと整合的*

*RMSEは空間構造の位置ずれに対して厳しい指標であり (Double Penalty Effect) 、平滑化された予測ほど値が良くなりやすい。

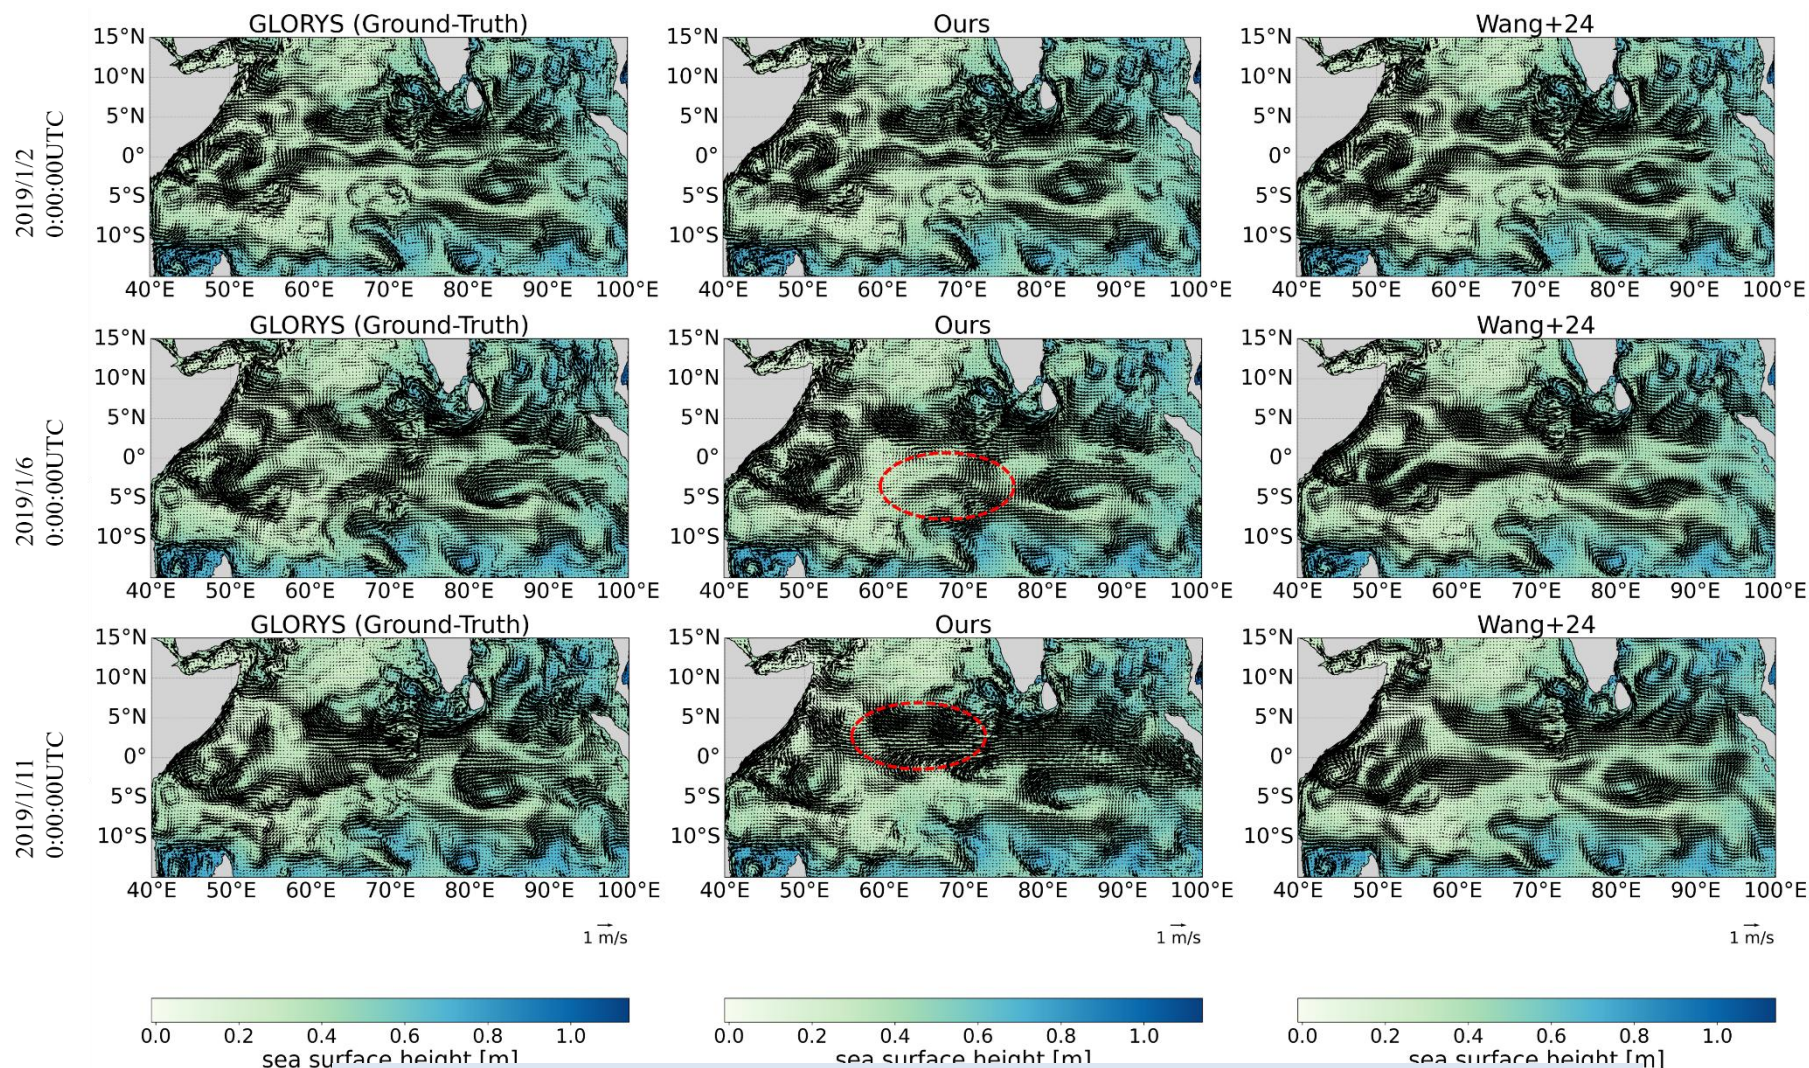
予測結果例②：時間発展

FURUNO

再解析

本研究

Wang+24


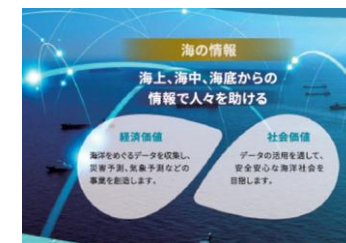
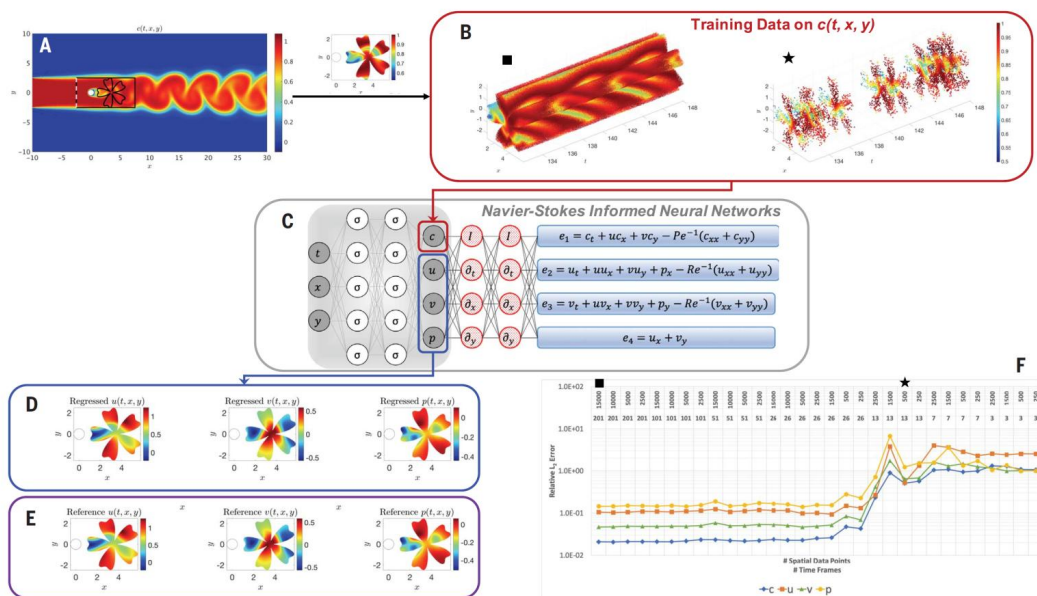


流れ場の時間発展をベースラインと比べ良好に表現


GNNを用いたデータ駆動型サロゲート海況モデルを構築

- 本研究でのマルチスケール型GNNアーキテクチャーを用いた高解像度 ($1/12^\circ$)モデルを構築し、従来研究との優位性を示した
- 自己回帰モデルにより時間発展を維持しつつ平滑化を抑制できており、RMSEと整合的
- 今後は大気だけでなく他のデータ型との相互作用を考慮したデータ駆動型の可能性を検討していく。
- 海況モデルを用いたアプリケーション開発を促進していく。

物理法則埋め込み型ニューラルネットワークによる船舶流体解析



引用 : M. Raissi et al. , "Hidden fluid mechanics: Learning velocity and pressure fields from flow visualizations." Science367,1026-1030(2020).DOI:10.1126/science.aaw4741



CO₂削減率：約20%～

停泊時・荷役時

- ・陸電利用※1
- ・蓄電池の利用

※1 将来の給電インフラの普及により高いCO₂削減効果が得られる技術

運航効率改善

- ・ウェザールーティング
- ・陸上サポート
- ・船速最適化

約8%削減

離着岸時間短縮

- ・高性能スラスト
- ・特殊舵
- ・高効率甲板機器※2；
甲板機器の電動化・自動化

※2 省エネと船員労務負荷低減・安全性向上を両立する技術

推進効率改善・抵抗低減

- ・高効率エンジン
- ・高効率プロペラ、省エネ付加物
- ・低摩擦軸受
- ・特殊舵
- ・低摩擦塗料
- ・CFDによる最適設計

約13%削減

(参考) 建造コスト上昇分(試算)：通常の船価に対して約15～20%アップ

注：コストは499GTをベースに算出しているが、コンセプトは749GT等でも活用可能

船型による流体解析は
航行＋造船にとって重要

引用：令和5年国土交通省海事局「内航カーボンニュートラルに向けた今後の施策」



(<200.0m)




CFD計算


- 数千万メッシュ
- 船が移動しながら波、潮流、風との相互作用



統合
CAD化




実スケール・実時間の
仮想実験として再現



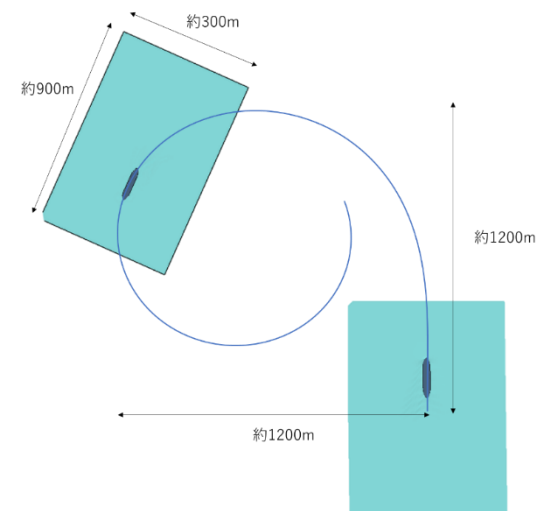
計算の高速化の必要性

(船型)形状データがない



- 水中での船型が推進性能を決める
- 設計があれば造船できるため、設計図は門外不出(運航会社にも)
- 業界内(造船所間)でも共有されない

シミュレーションデータがない



- 実スケール船(200m程度)の試験の再現のためマルチコアCPUでも数週間かかる
- 様々な船型に対するシミュレーションデータを準備できない

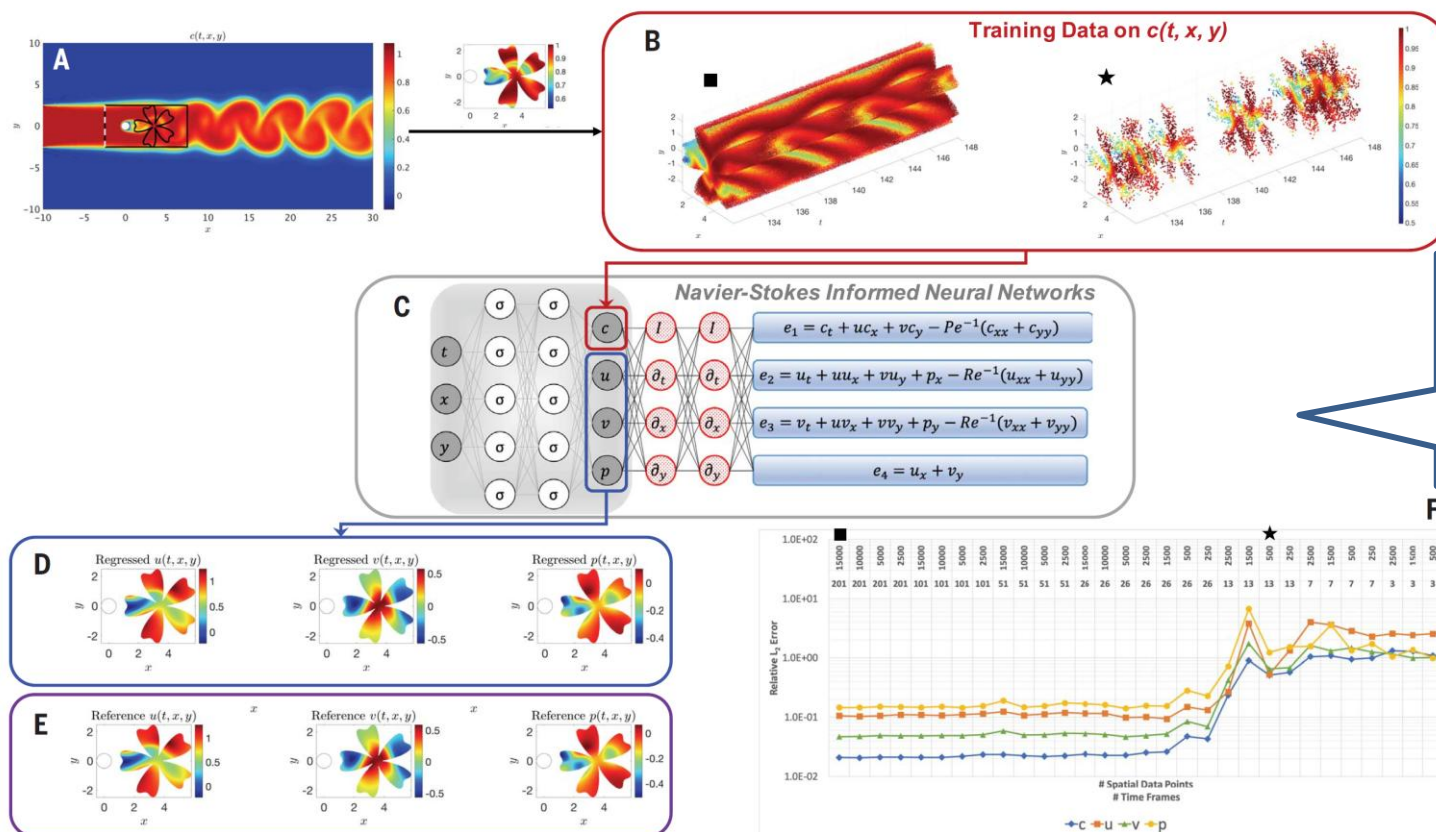
本発表の内容

- 教師データを前提としない学習を試行
- 船型など物体形状に依存しない汎用的なモデル
- 流場を含めた時間発展に対応できるモデル

- M. Raissi et al. , "Hidden fluid mechanics: Learning velocity and pressure fields from flow visualizations." Science367,1026-1030(**2020**).DOI:10.1126/science.aaw4741

流体の支配方程式
(ナビエ・ストークス方程式)

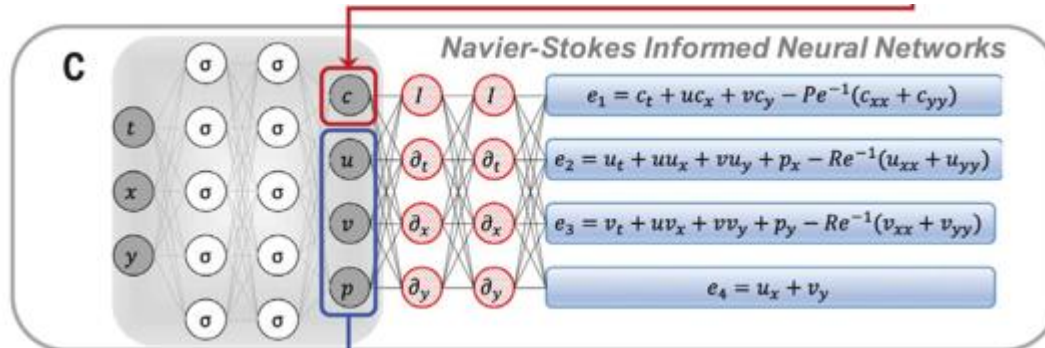
$$\rho \left(\frac{\partial \mathbf{u}}{\partial t} + (\mathbf{u} \cdot \nabla) \mathbf{u} \right) - (-\nabla p + \mu \nabla^2 \mathbf{u} + \mathbf{f}) = 0$$



NS方程式との差(..=0)を
損失関数に
(**Physics informed**)

● 一般的なPINN（メッシュレス）


座標・時刻を入力し、所望の物理量を得る



- ジオメトリを柔軟に設定可
(どこでもサンプリングできる)
- 複数の環境を同時に対応するのは難しい

● メッシュありのPINN

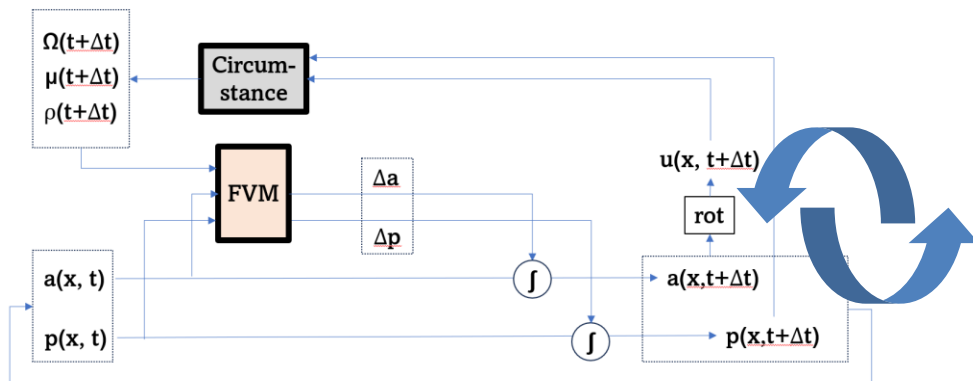
物理量の情報を持つメッシュを入力し、単位時刻後のメッシュを得る



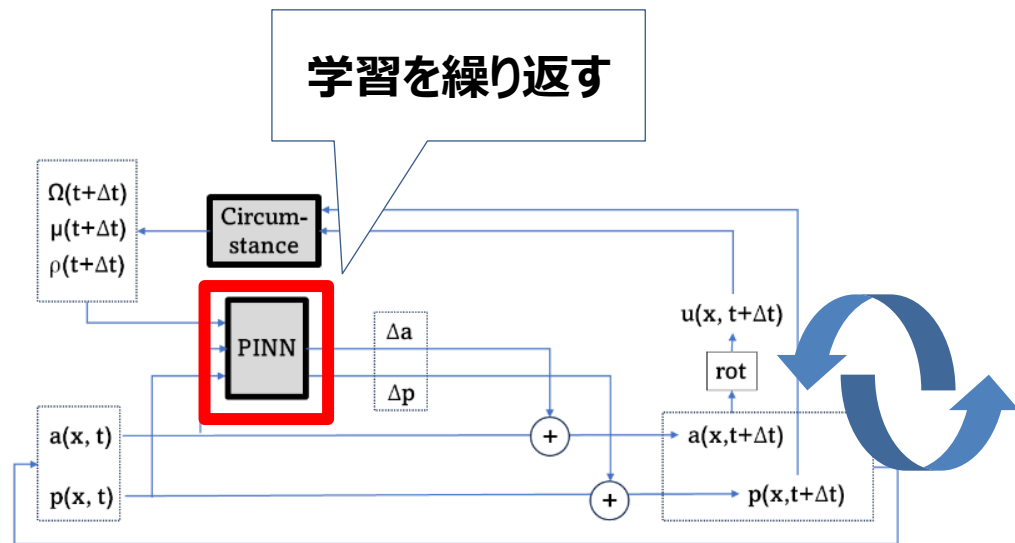
- 複数環境の学習が比較的容易
(モデルの再利用性高)
- メッシュ分割コストが高い
(非構造メッシュの場合)

	教師あり学習	PINNベースの手法
		 $\rho \left(\frac{\partial \mathbf{u}}{\partial t} + (\mathbf{u} \cdot \nabla) \mathbf{u} \right) - (-\nabla p + \mu \nabla^2 \mathbf{u} + \mathbf{f}) = 0$
コンセプト	現象(データ)をそのまま再現するように学習する	物理法則から導き出される特徴をAIに学習させる
必要なもの	<ul style="list-style-type: none"> ・大量の(本物・完成品の)CAD ・大量のCFD結果データ 	<ul style="list-style-type: none"> ・(大量の)基本形状 ・支配(物理)方程式
原理	存在するデータで 直接学習	物理方程式からデータを生成しつつ学習 (矛盾点を修正するように学習)
競合	<ul style="list-style-type: none"> ・海技研 (日本) ・Ansys (米国) ・RICOS (日本) 	中国(防衛研究所) ボン大学など
高速化	10-100倍程度	10-100倍程度


$X(t + \Delta t) \leftarrow F_{\theta}(X(t))$: 逐次的推論



▶ 制約条件から近隣を決定する



▶ 動かしてから修正する




学習ステップ

- ① AIを使って流体を1ステップ
- ② 物理方程式との矛盾量を計算
- ③ 矛盾を修正するようにAIを修正
- ④ ①に戻る

- 以下の損失関数を1ステップごとに計算し、各シナリオにおいて記憶する

内容	重み	
流体保存則	中	$\nabla \cdot \mathbf{u} = 0$
ナビエ・ストークス	中	$\rho \left(\frac{\partial \mathbf{u}}{\partial t} + (\mathbf{u} \cdot \nabla) \mathbf{u} \right) - (-\nabla p + \mu \nabla^2 \mathbf{u} + \mathbf{f}) = 0$
境界条件(物体)	大	滑りなし/ディリクレ条件 $(\mathbf{u}(x, t) - \mathbf{u}_{bc}(x, t) = 0 \quad x \in \Gamma)$
境界条件 (inlet/outlet)	-	壁なし(遠方境界)



■ 学習の流れ

Initialize θ randomly or from pretrained model

Set $t = 0$

While $t < T$:

- (1) Compose input $X(t)$ from $u(t)$, $p(t)$, and geometry
- (2) $X'(t+\Delta t) \leftarrow F\theta(X(t))$ // predict next step
- (3) Evaluate $L_{\text{total}}(\dots)$
- (4) Update θ via gradient-based optimization
- (5) $X(t+\Delta t) \leftarrow F\theta(X(t))$ // recompute final step
- (6) $t \leftarrow t+\Delta t$




end while

- メッシュ数 :
96x96x128

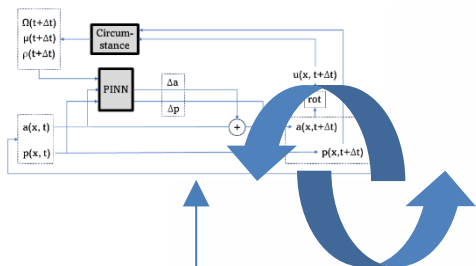
- ニューラルネット : **CNN**
各格子メッシュに速度ポテンシャル a および圧力 p を持つ

- 定常速度 :
一定速度を持つため相対座標として場は一定量の速度を持つ(一様流れ)



学習に 用いる 物体

内容	重み
立方体状	
球体状	
円柱状	


- ① 登録シナリオから選択
- ② 1ステップ動かす
- ③ ニューラルネットに入力
- ④ 学習
- ⑤ ①に戻る(必要に応じてリセット)



シナリオごとの値を
ニューラルネットに入力



- 不動円柱に一樣流を当てることにより、流体挙動を観察する





実験条件

- メッシュ数 :
96x96x128
- ニューラルネット : **CNN**
各格子メッシュに速度ポテンシャル ϕ および圧力 p を持つ
- 定常速度 :
相対速度一定(一樣流れ)
- 境界条件 :
 - 壁あり(#1結果)
 - 壁なし(#2結果)

※レイノルズ数(Reynolds Number, Re) :


- ナビエ・ストークス方程式を無次元化すると $Re = \frac{\rho UL}{\mu} = \frac{UL}{\nu}$ が表出
→物理スケールに依らない物理的指標
- [慣性力]÷[粘性力]。大きくなると慣性力が勝り層流剥離、乱流移行、非定常渦の生成などが見られる。



結果#2 (リファレンス法(CFD)との比較)


FURUNO

(A) 提案手法




: x方向の速度成分

(B) リファレンス
(従来法・CFD)




: x方向の速度成分

差分
($|A - B|$)



- 2000ステップ数(収束を確認後)
- CFDと同様に物体周りの流体が表現され、後方についても一定の一致が見られる

ITTCの国際機関で1979年頃に設定され、
数式で表現された理想的な船型。



実験条件

- メッシュ数 :
1024 x128x128
→大規模化

- CNN
上記同様

- 定常速度 :
相対速度0(一様流れなし)
- 境界条件 :
 - 壁あり(底面は流れ影響)

数式模型 (一般化Wigley模型)

$$\eta = (1 - \zeta^{Z_1})(1 - \xi^{X_1}) + \zeta^{Z_1}(1 - \zeta^{Z_2})(1 - \xi^{X_2})^{X_3}$$

Where,

$$X_1 = \frac{C_w}{1 - C_w}$$

$$X_2 = \max\left(2, \frac{C_p}{1 - C_p}\right) \text{ (basic value)}$$

$$X_3 = \frac{1}{C_p^2} \text{ (basic value)}$$

$$Z_1 = \frac{C_b - SC_m}{C_w - C_b - S(1 - C_m)}$$


$$Z_2 = \frac{C_m}{1 - C_m} \frac{C_w - C_p}{C_w - C_b - S(1 - C_m)}$$

$$S = \frac{\Gamma\left(\frac{1}{X_2} + 1\right) \Gamma(X_3 + 1)}{\Gamma\left(\frac{1}{X_2} + X_3 + 1\right)}$$


当該船体の学習ありと、
基本形状のみの学習との差を見る

(基本形状のみ)

船体なし



船体あり



- 船体学習の有り無しで、船体前方流れ(船体周辺の流れ)に差が見られる

▶ 適切な(形状)学習が必要

PINNを用いた非データ駆動型サロゲート(船舶)流体力学モデルを試作

- 本研究でのPINNを用いた3次元メッシング型の自己教師あり学習についてシリンダーやWigley船型に対して有効に動作することが確認できた。
- 今後は船舶への応用に向けて、高レイノルズ数の対応、二相流への対応を進める。
- 船型設計や運航に対して精度高い予測データを提供できるか今後検討していく。



- AIを用いた データ駆動型、非データ駆動型のサロゲートモデルを試行し、技術的な可能性を示した。
- サロゲートモデルは精度を担保しつつ、高速化やデータ入力の柔軟さから今後ますます活用されていくと考えられる。
- データ(センシング)+AI+物理シミュレーションを共創できるパートナーを募集中。

A close-up, profile shot of a woman with long, straight, light brown hair. She is looking out towards the right side of the frame, where a bright, hazy sunset or sunrise is visible over a body of water. The lighting is soft and warm, highlighting the texture of her hair and the contours of her face. The background is a blurred expanse of water and sky.

*CHALLENGE
the
INVISIBLE.*