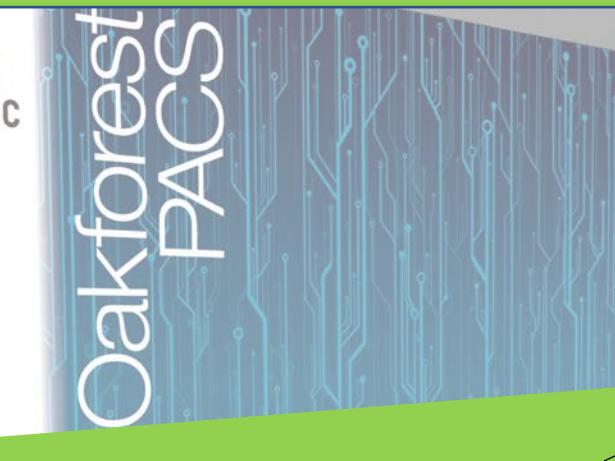


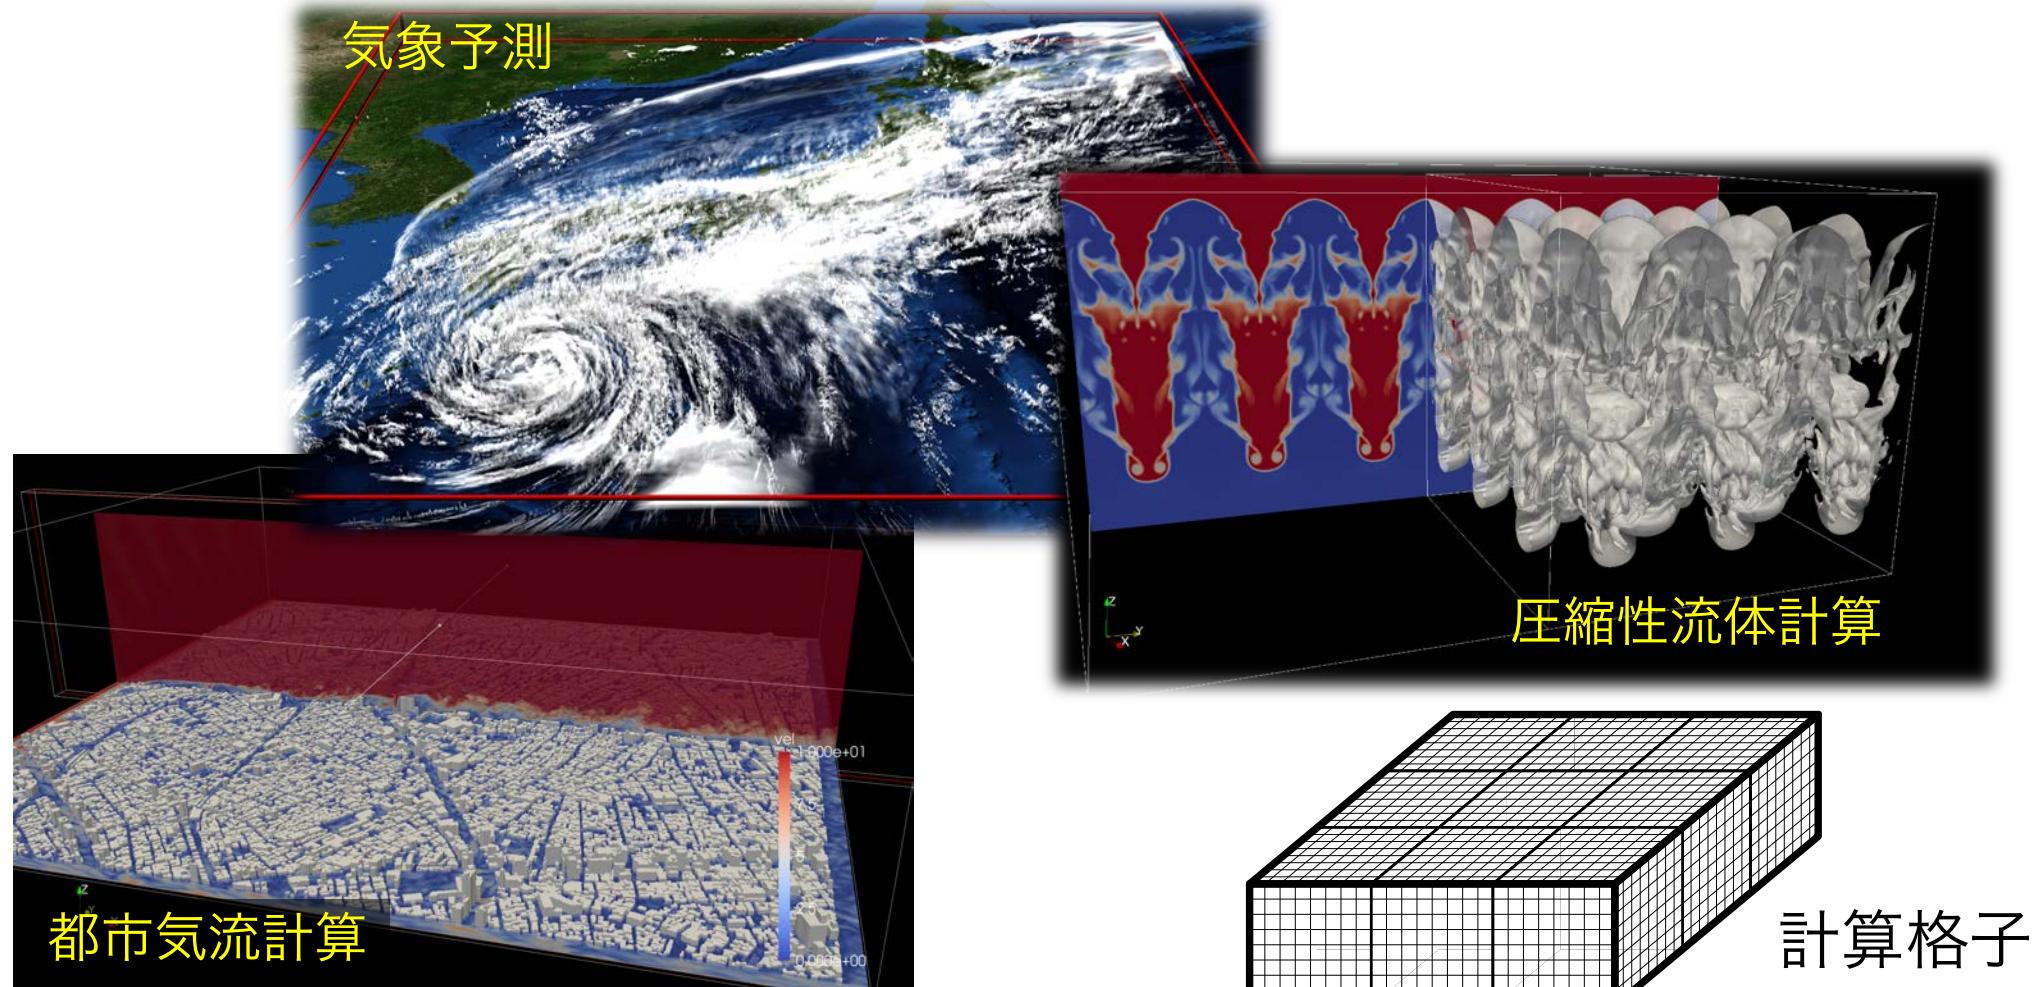


深層学習による 流体シミュレーション結果予測

下川辺 隆史 (東京大学 情報基盤センター)

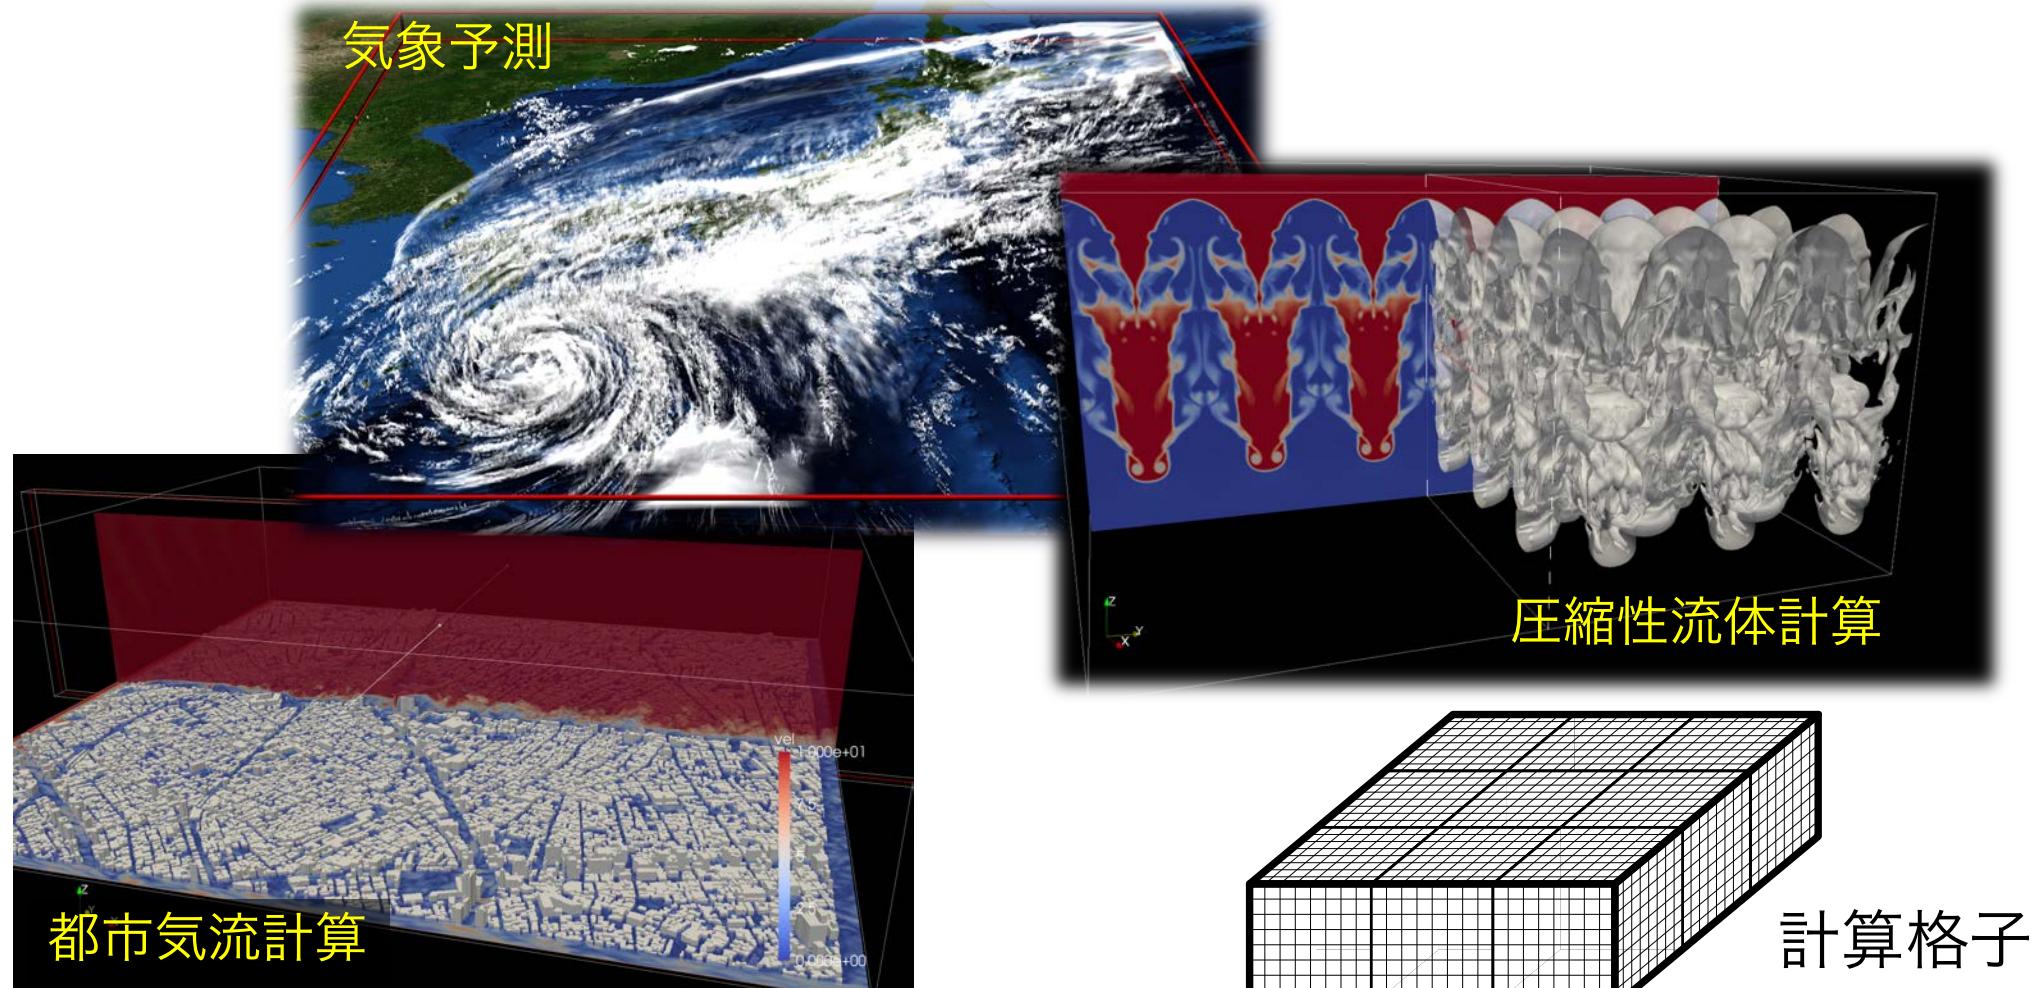


数值流体力学



- 数值流体力学 (CFD) は高性能計算分野で重要なアプリケーション
- CFDシミュレーションは格子、メッシュ、粒子による大規模計算が必要で、多くの計算時間が必要

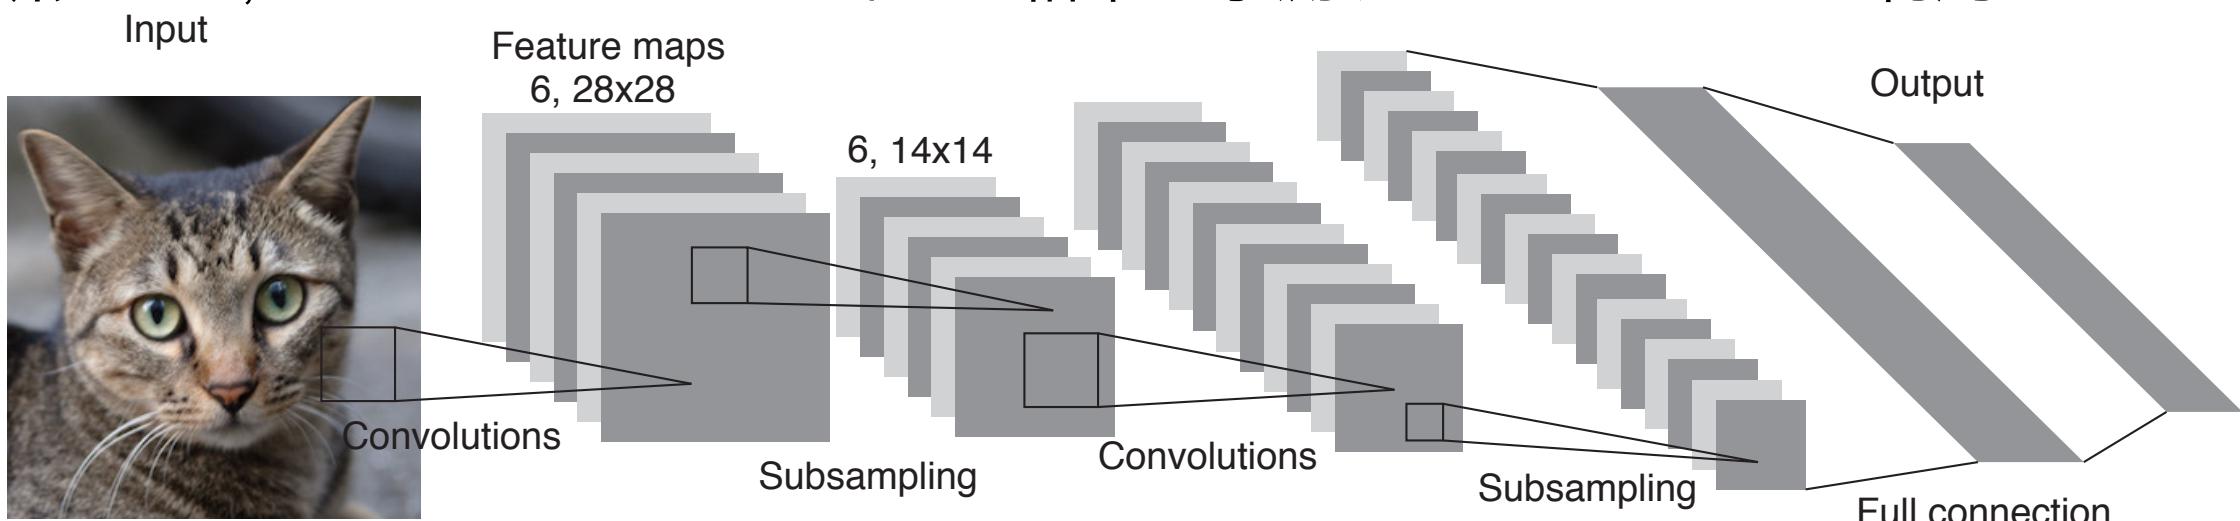
数值流体力学



- ・ 数值流体力学 (CFD) は高性能計算分野で重要なアプリケーション
 - ・ CFDシミュレーションは格子、メッシュ、粒子による大規模計算が必要で、多くの計算時間が必要
- CFDシミュレーションを高速化

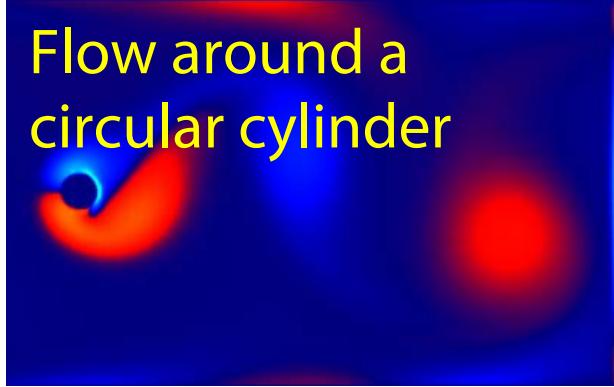
深層学習とニューラルネットワーク

- ・ 深層学習 (Deep learning)
 - ニューラルネットワークに基づいた機械学習手法の一つ
- ・ ディープニューラルネットワーク (Deep neural network, DNN)
 - ・ 入力層と出力層の間に複数の層を持つ
- ・ 置み込みニューラルネットワーク (Convolutional neural network, CNN)
 - ・ DNN の代表的なものの一つ
 - ・ 画像認識や解析、分類問題で高精度
- ・ 本研究では、CFDシミュレーションの結果を予測するためにCNNを利用



CNNによるCFD シミュレーション結果の高速予測の概要

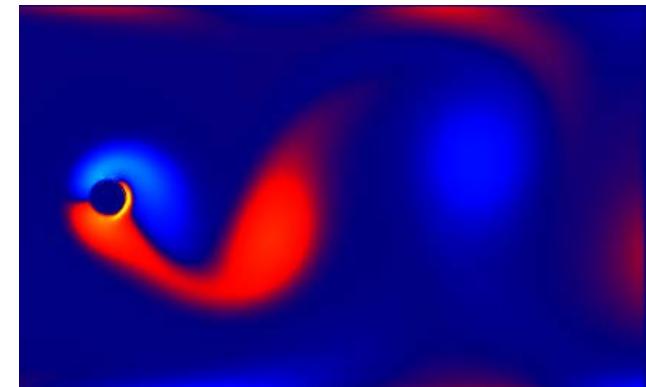
データセット



CFD シミュレーション
(格子ボルツマン法)

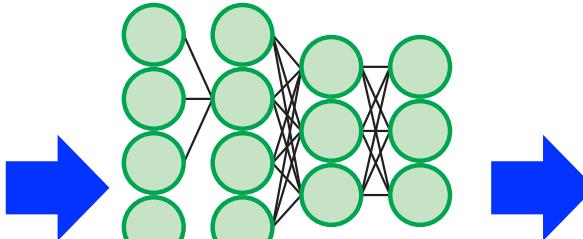
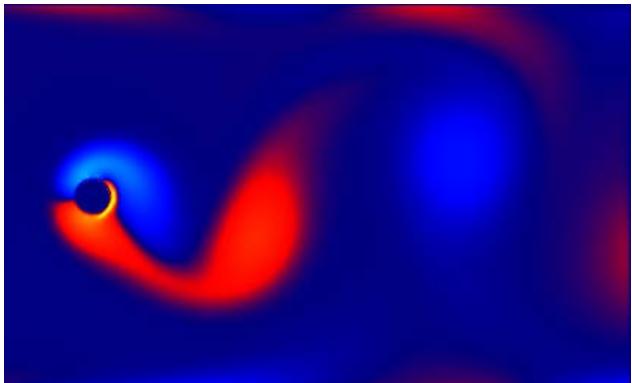


$$f_i(x + c_i \Delta t, t + \Delta t) = f_i(x, t) + \Omega_i(x, t)$$
$$\Omega_i(x, t) = -\frac{1}{\tau} (f_i(x, t) - f_i^{eq}(x, t))$$



学習

予測



流れの予測

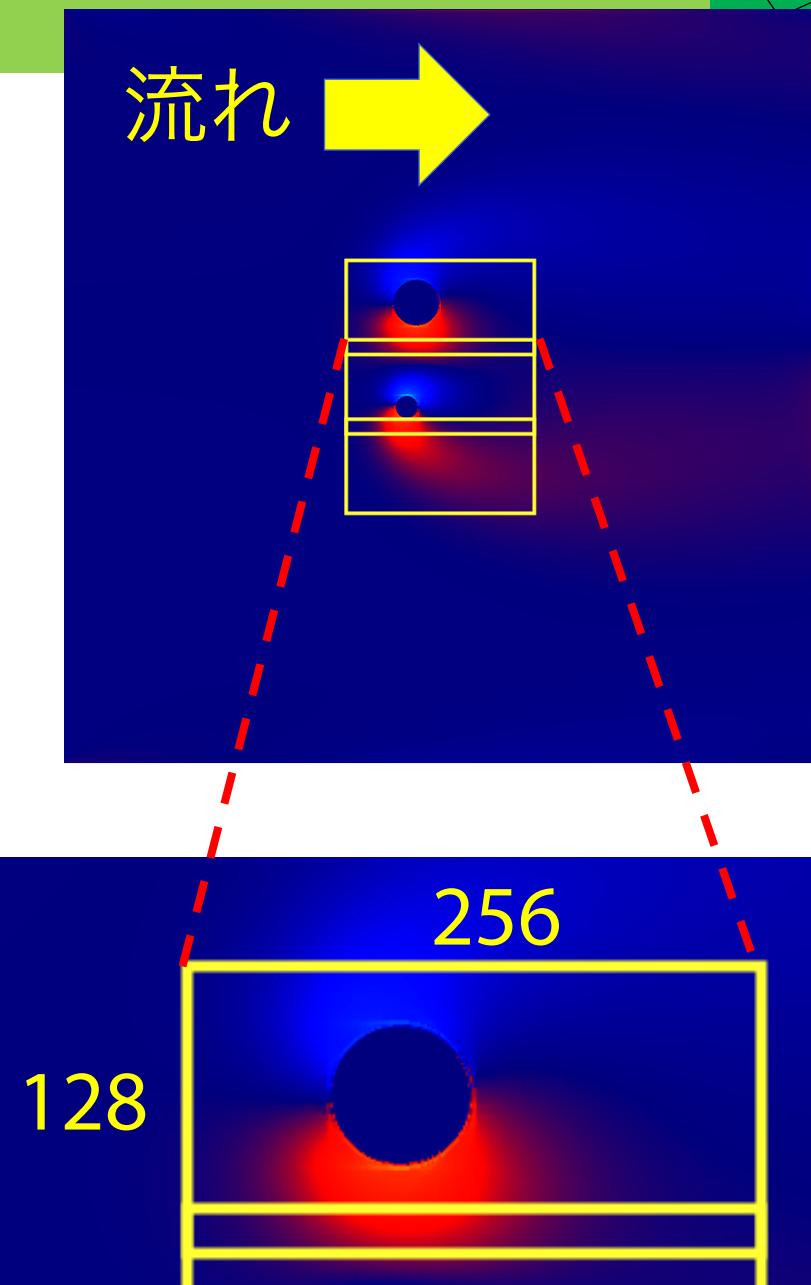
CNN によるシミュレーション結果の予測

CNNで「高速なシミュレータ」を構築

定常流計算の予測

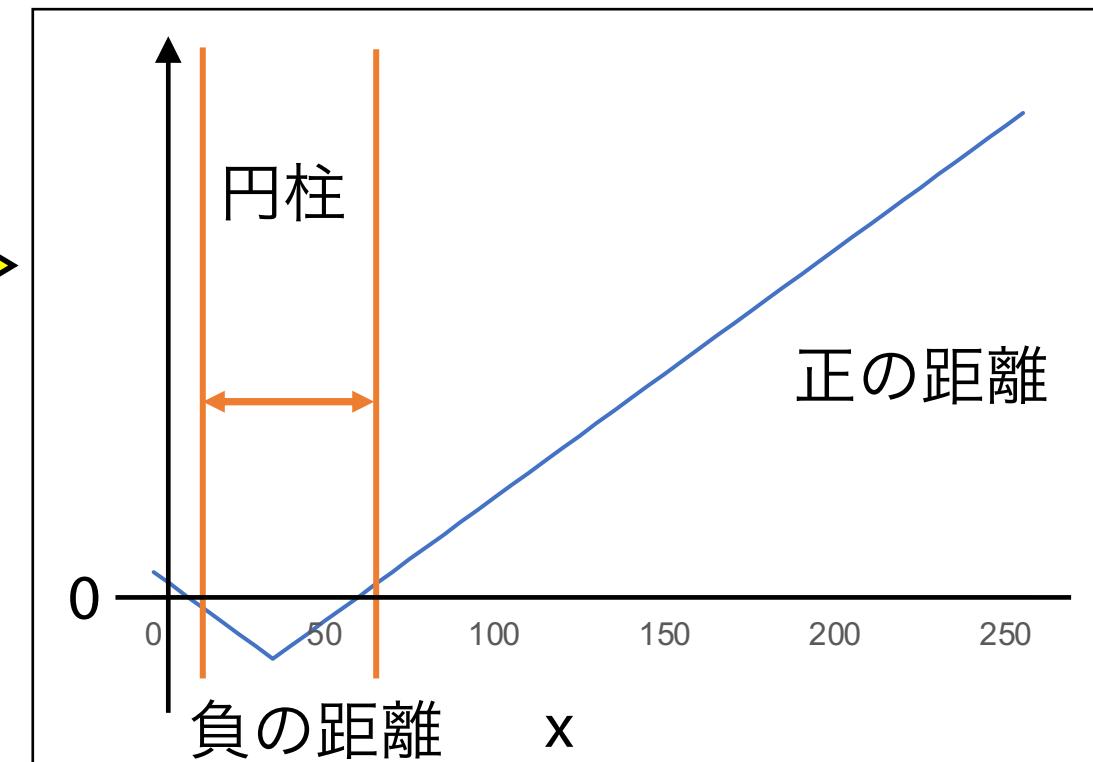
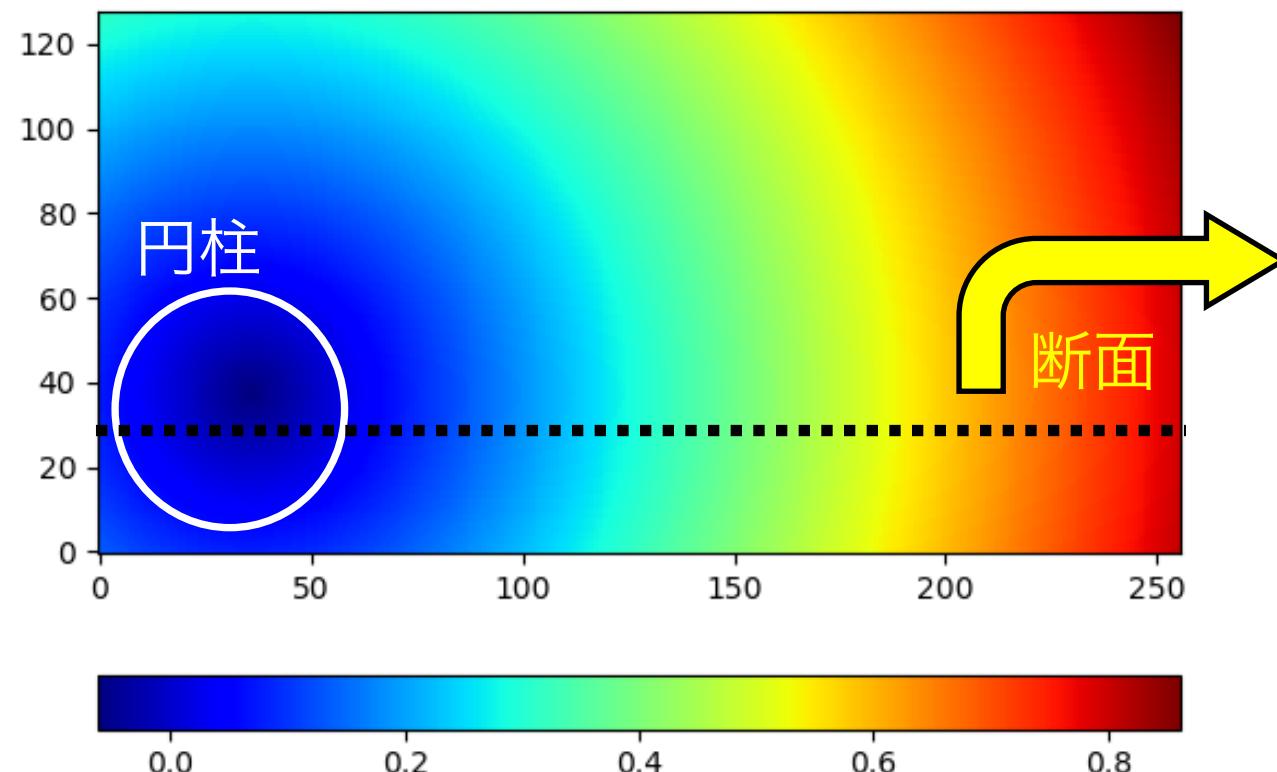
問題設定とデータセット

- 定常流計算（時間変化のない流れ）
 - 計算領域に物体があり、x軸の正方向へ流れる
- 格子ボルツマン法
 - D2Q9モデル（速度に9変数用いる）
 - レイノルズ数 $Re = 20$
 - 領域サイズ: 1024×1024
 - 6種類の物体:
 - 角柱 (3-7角形)
 - 円柱
- 学習用データサイズ: 256×128 (切り出し)
 - 訓練: 3528
 - 評価: 1176



符号付き距離関数

- 物体表面を0として、物体外を正の距離、物体内を負の距離で表す。
- 複雑な形状を表現可能で、CNNによる予測で精度向上に有効であることが知られている。



定常流を予測するネットワーク構造

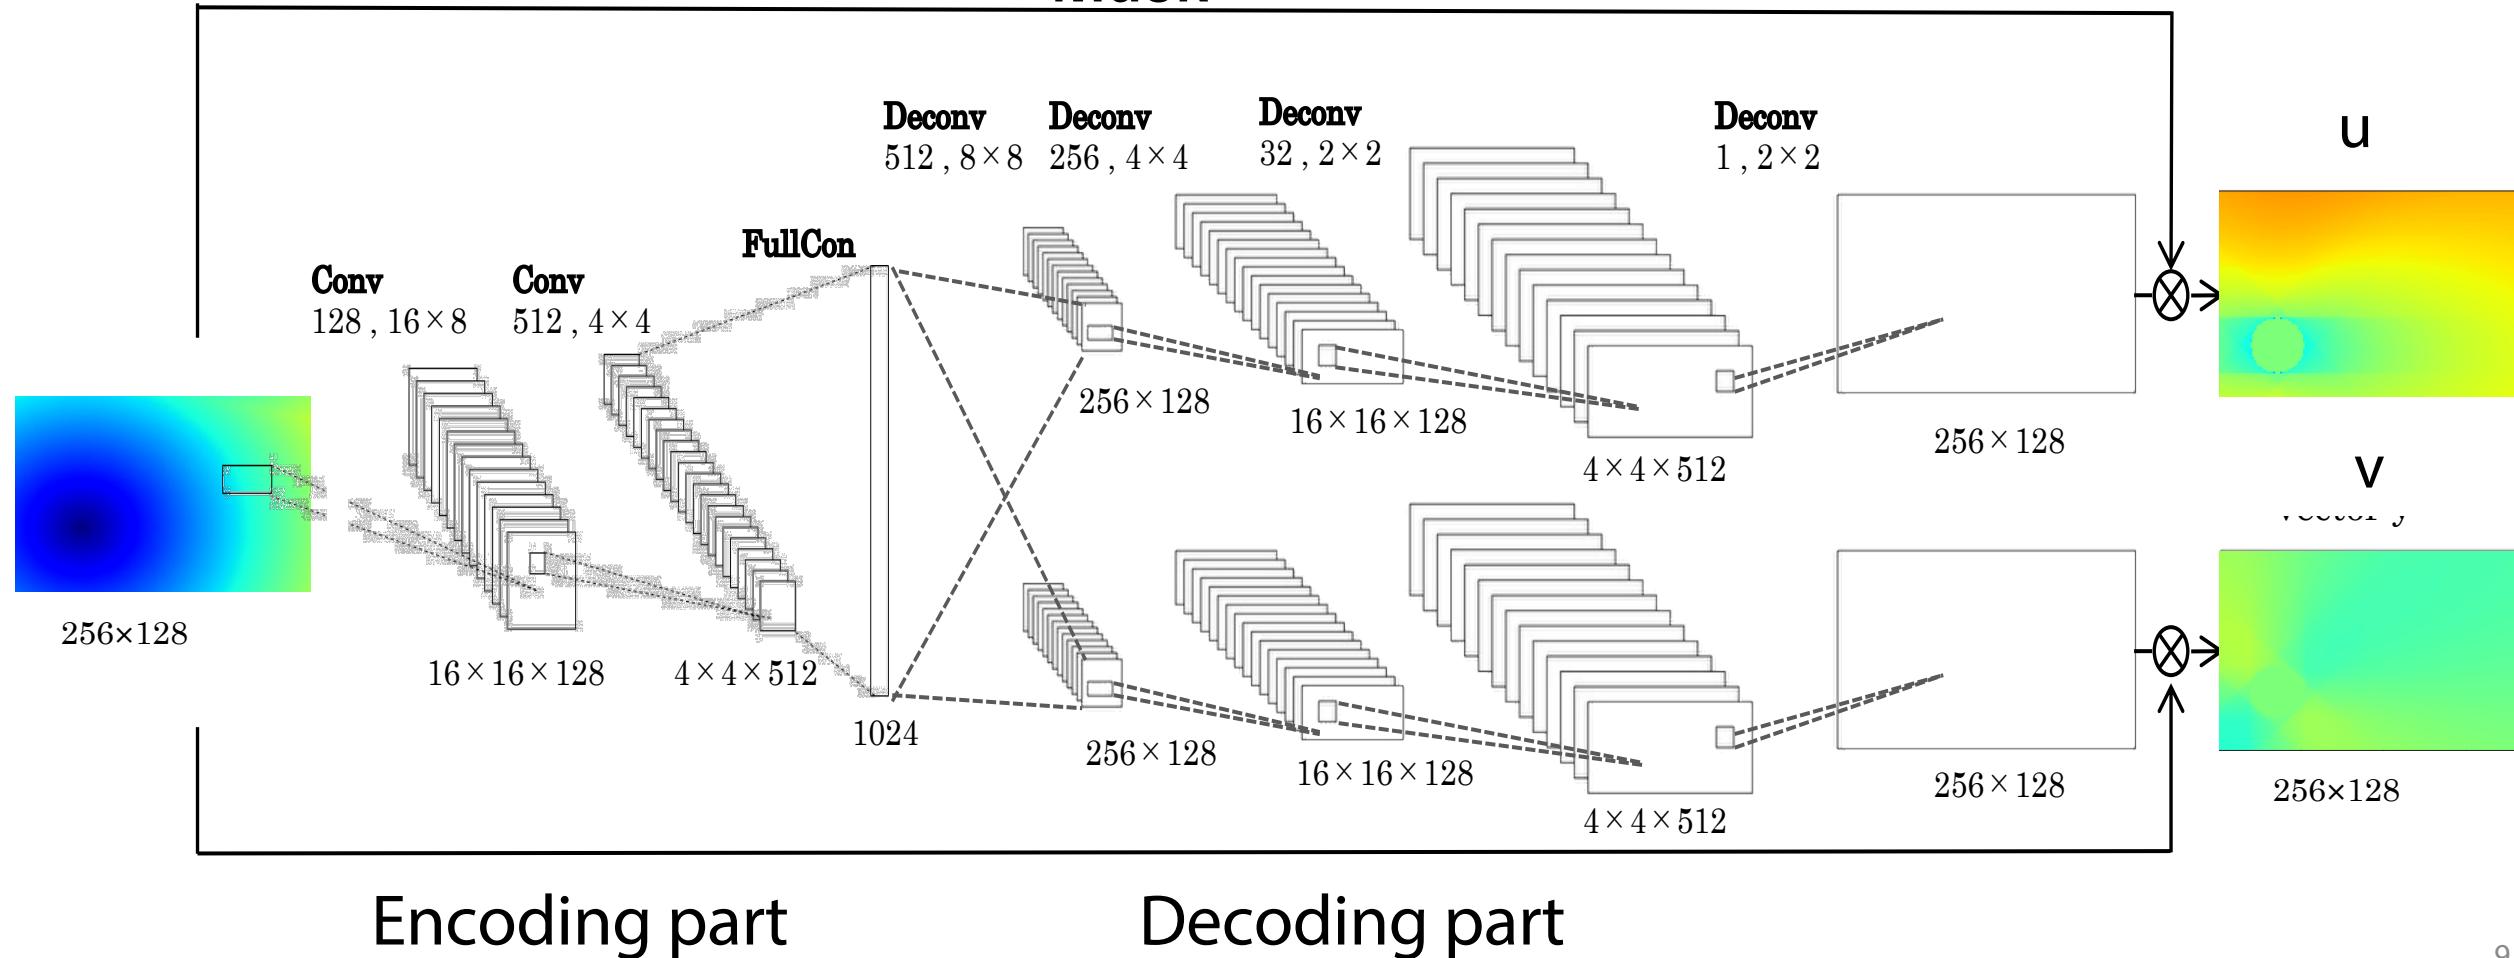
入力:

符号付き距離関数 (物体形状)
境界における流速

出力:

全領域の流速

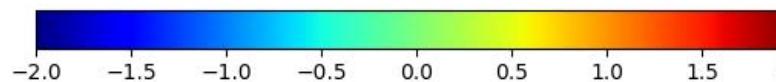
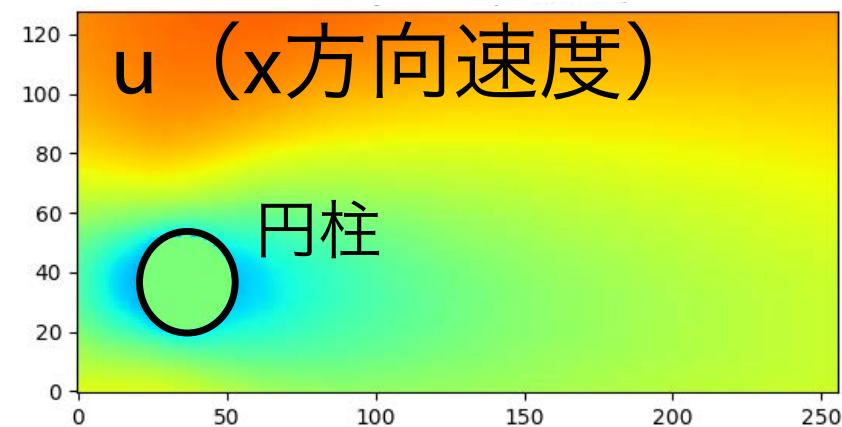
Mask



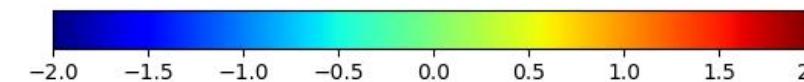
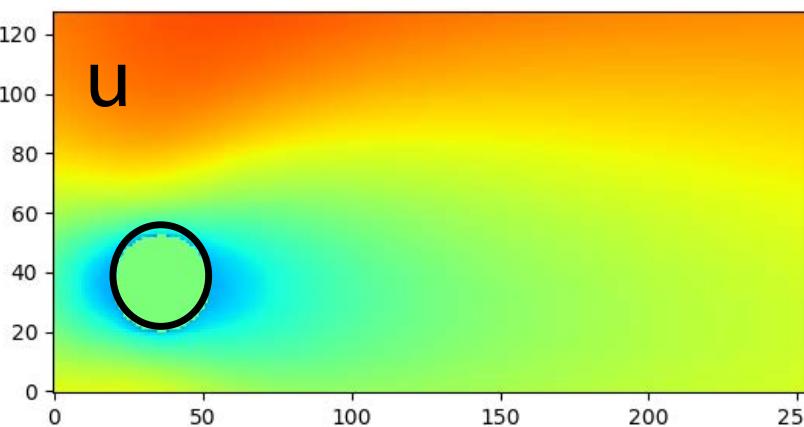
単一領域におけるCNNによる予測



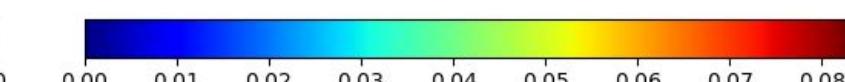
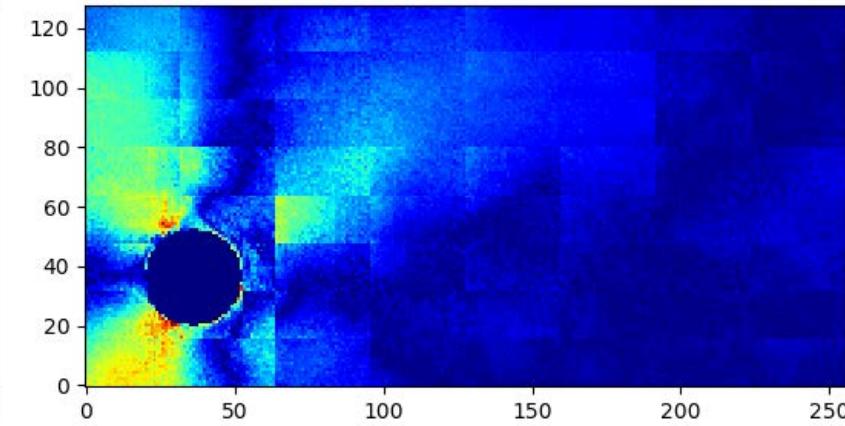
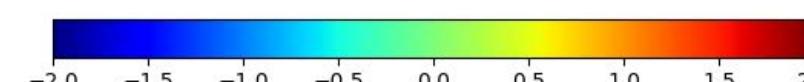
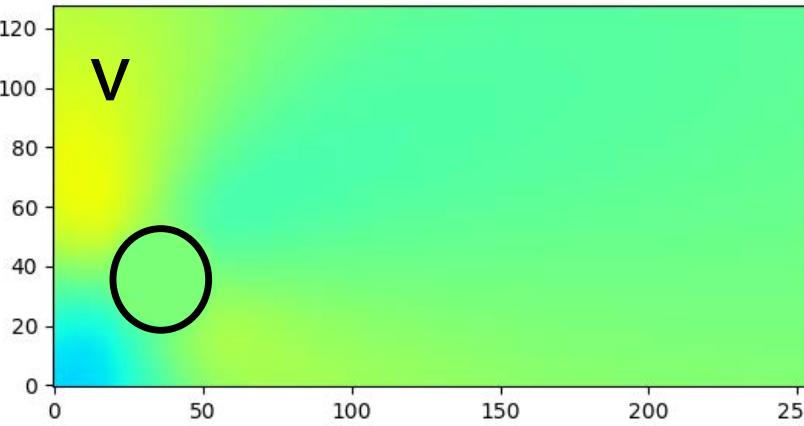
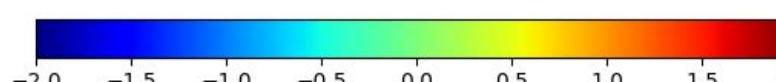
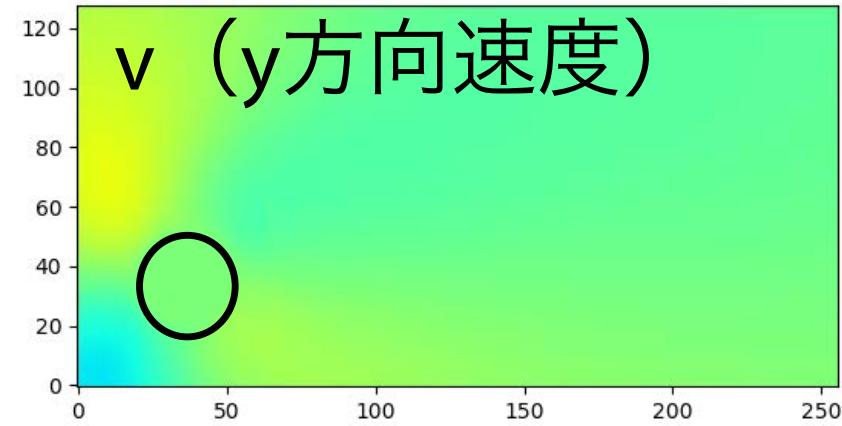
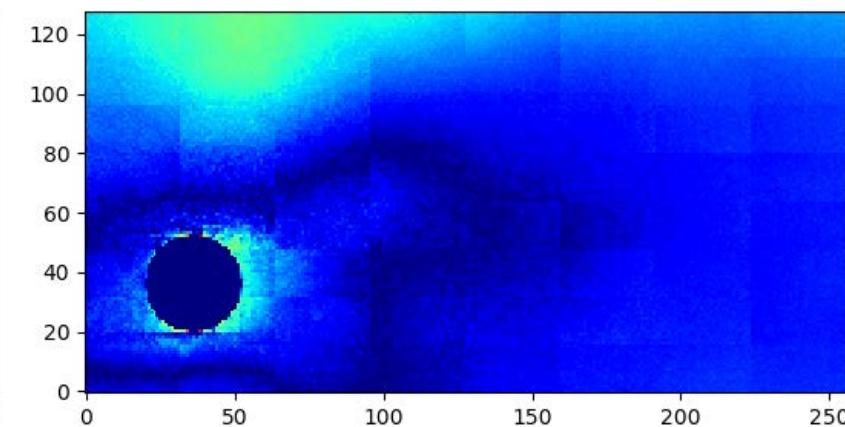
CNNによる予測



格子ボルツマン法による結果



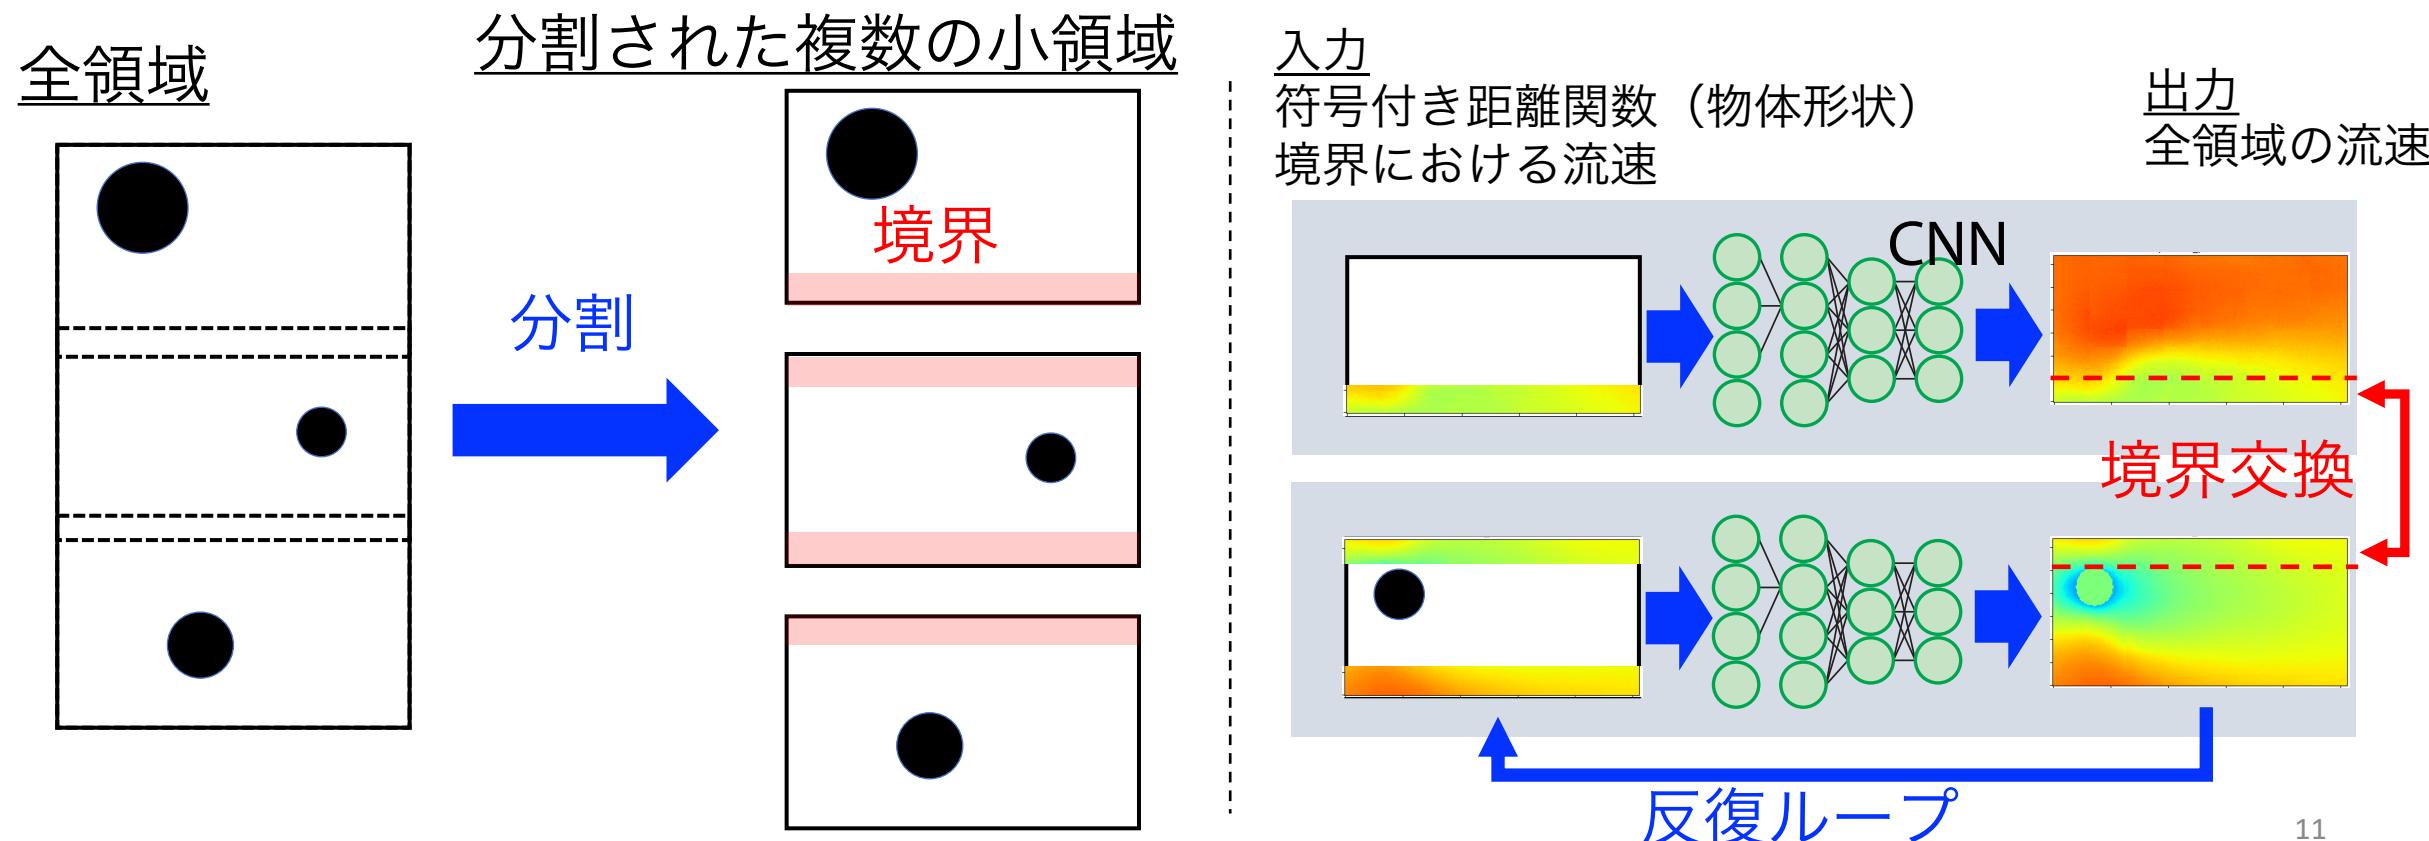
誤差 $\text{Err} = |\text{CNN} - \text{LBM}|$



Loss: 7.3×10^{-5}

CNNと境界交換による複数領域における予測手法

- ・ 単一領域予測：学習に用いた領域サイズの予測しかできない、GPUメモリ容量に制限
- ・ 計算領域を複数小領域に分割し、複数小領域にまたがるシミュレーション結果を予測
 - ・ 単一領域に対し学習したネットワークモデルで各小領域の結果を予測
 - ・ 複数の小領域間で予測値の**整合性を保つ**ため、隣接する分割領域間で境界交換し、推論し、予測値が収束するまで、これを繰り返す

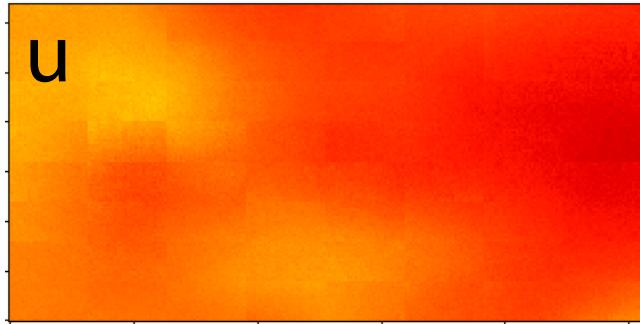


複数領域における予測

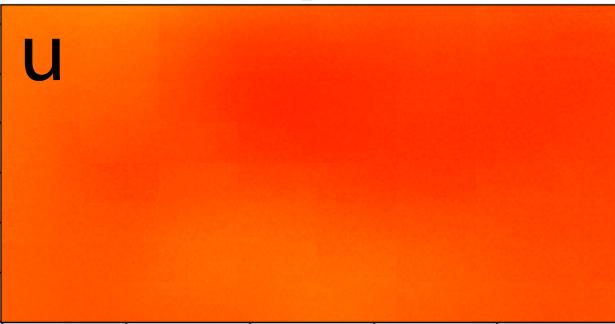


CNNによる予測

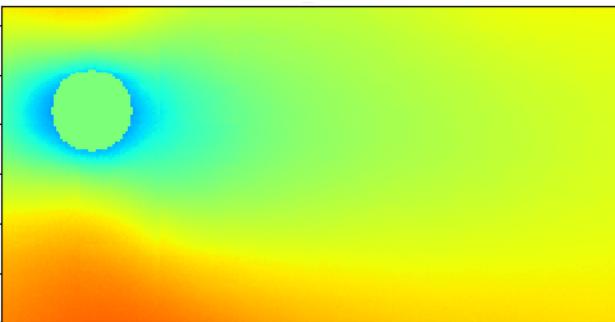
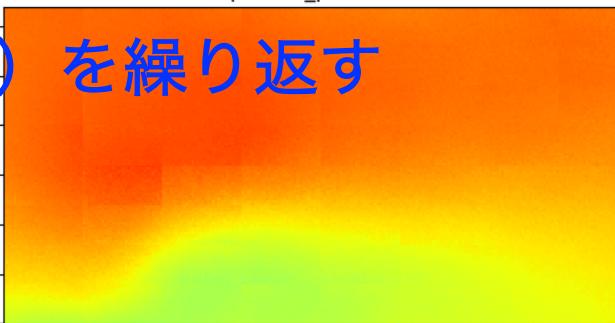
初期予測



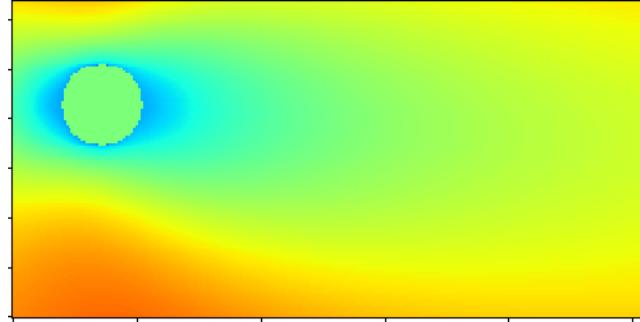
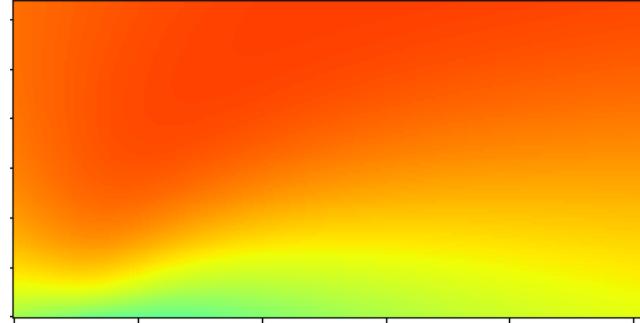
最終予測（収束）



(CNN + 境界交換) を繰り返す



格子ボルツマン法による結果

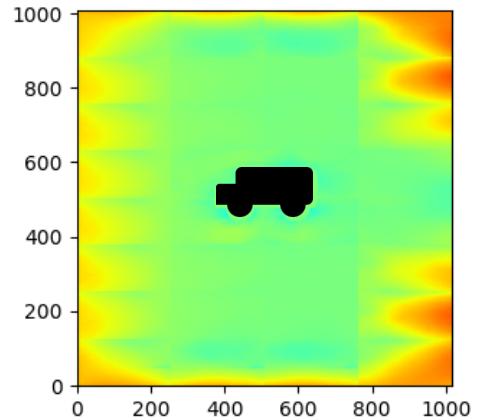


大きな領域における予測

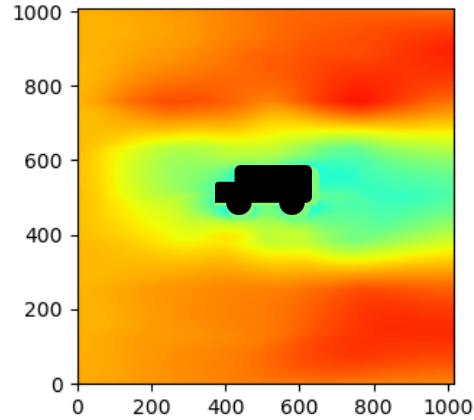
CNNによる予測

初期予測

u (x方向速度)

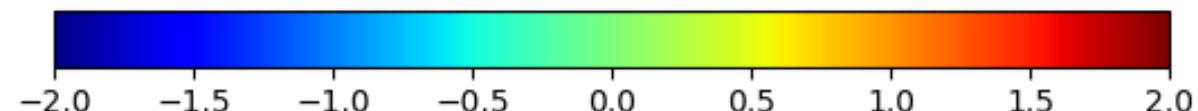
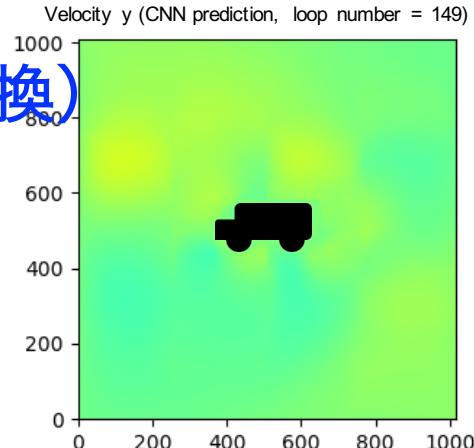
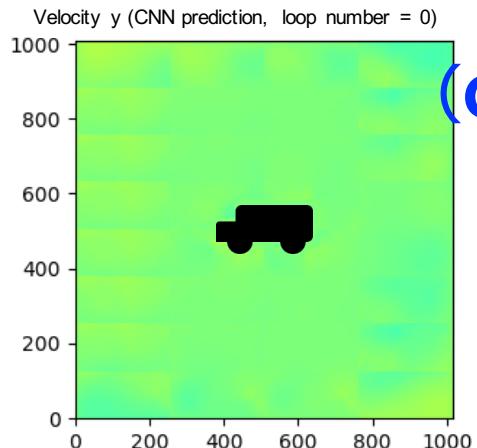


最終予測（収束）

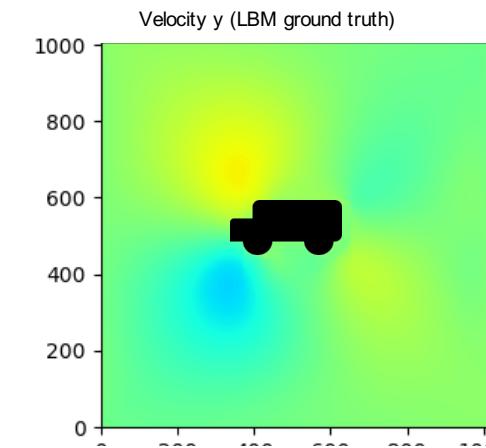
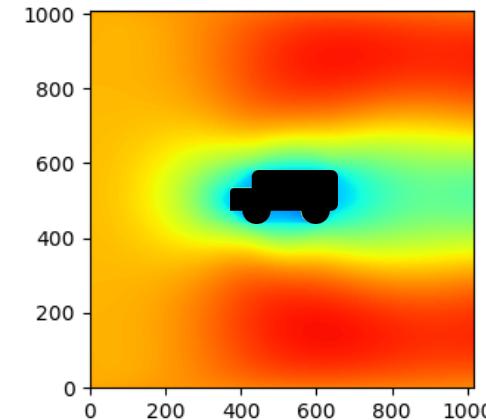


(CNN + 境界交換)
を繰り返す

v (y方向速度)



格子ボルツマン法による結果

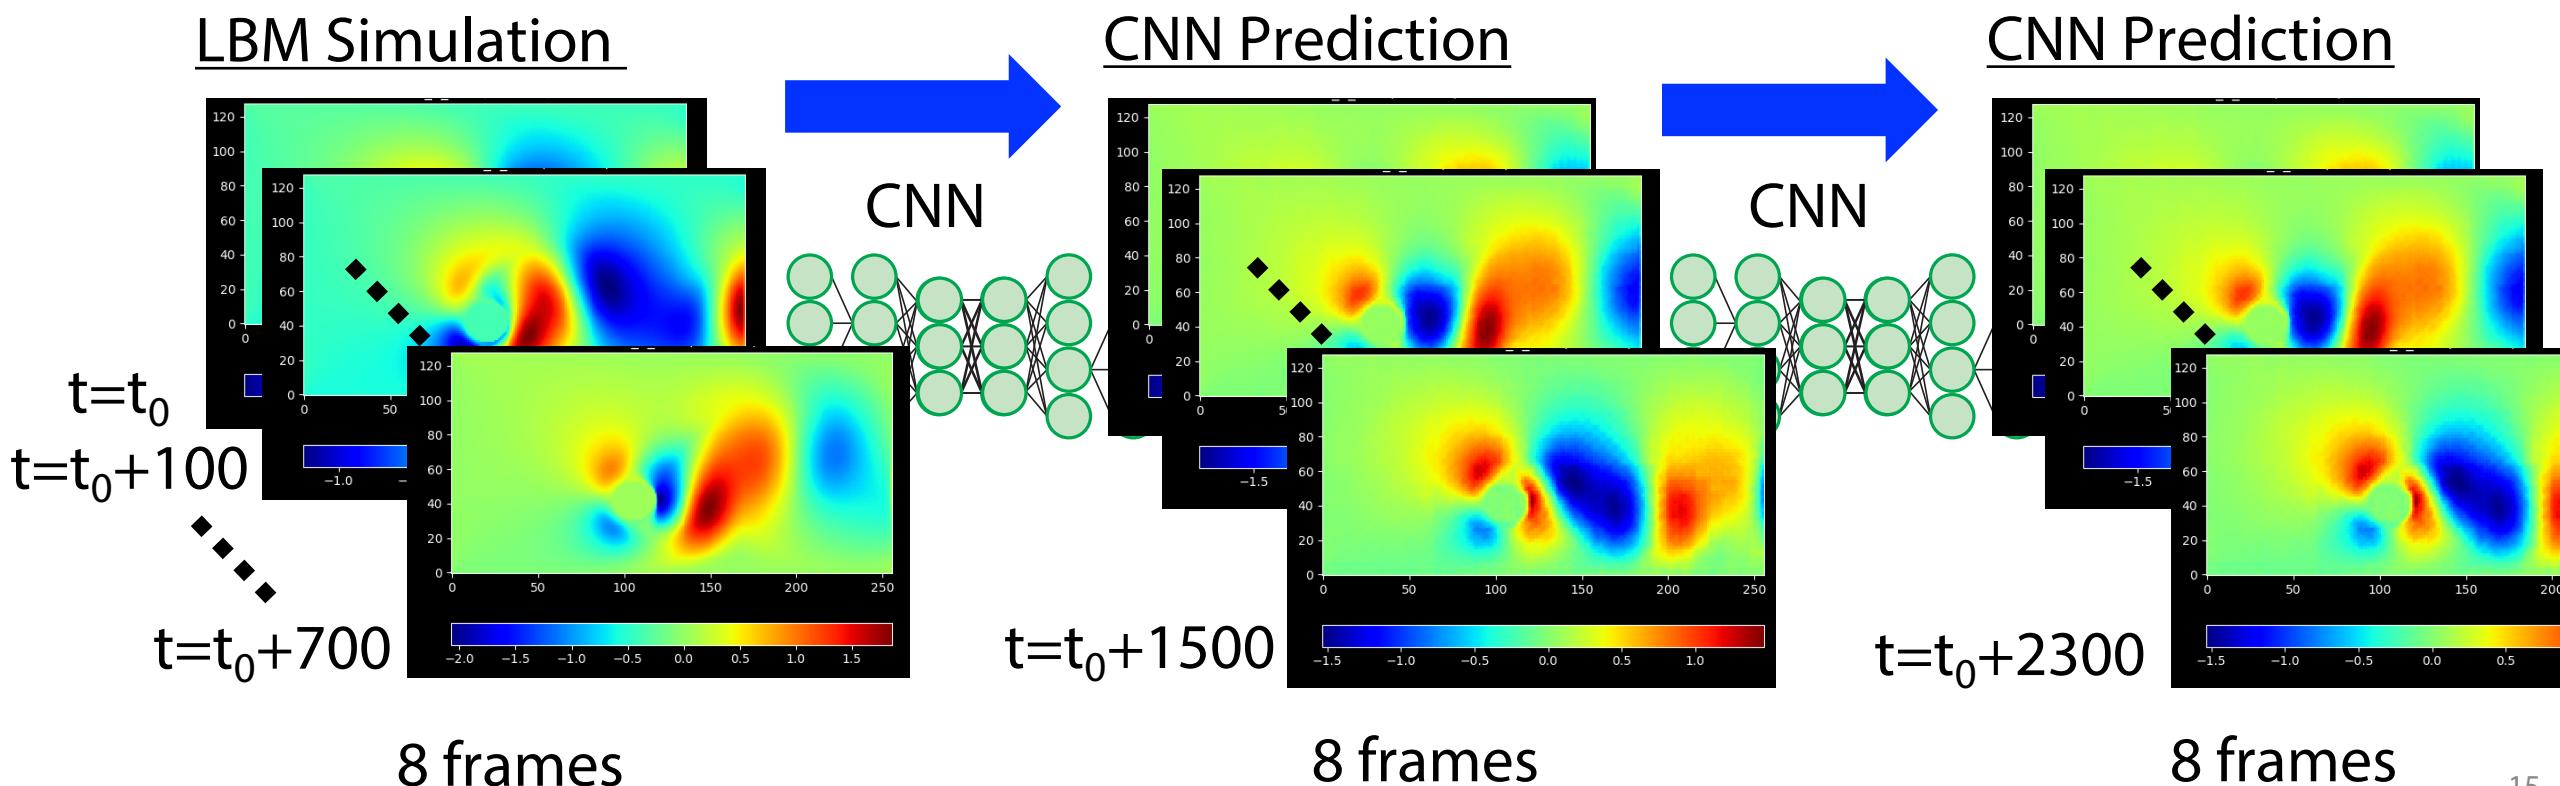


4 × 8 小領域

非定常流計算の予測

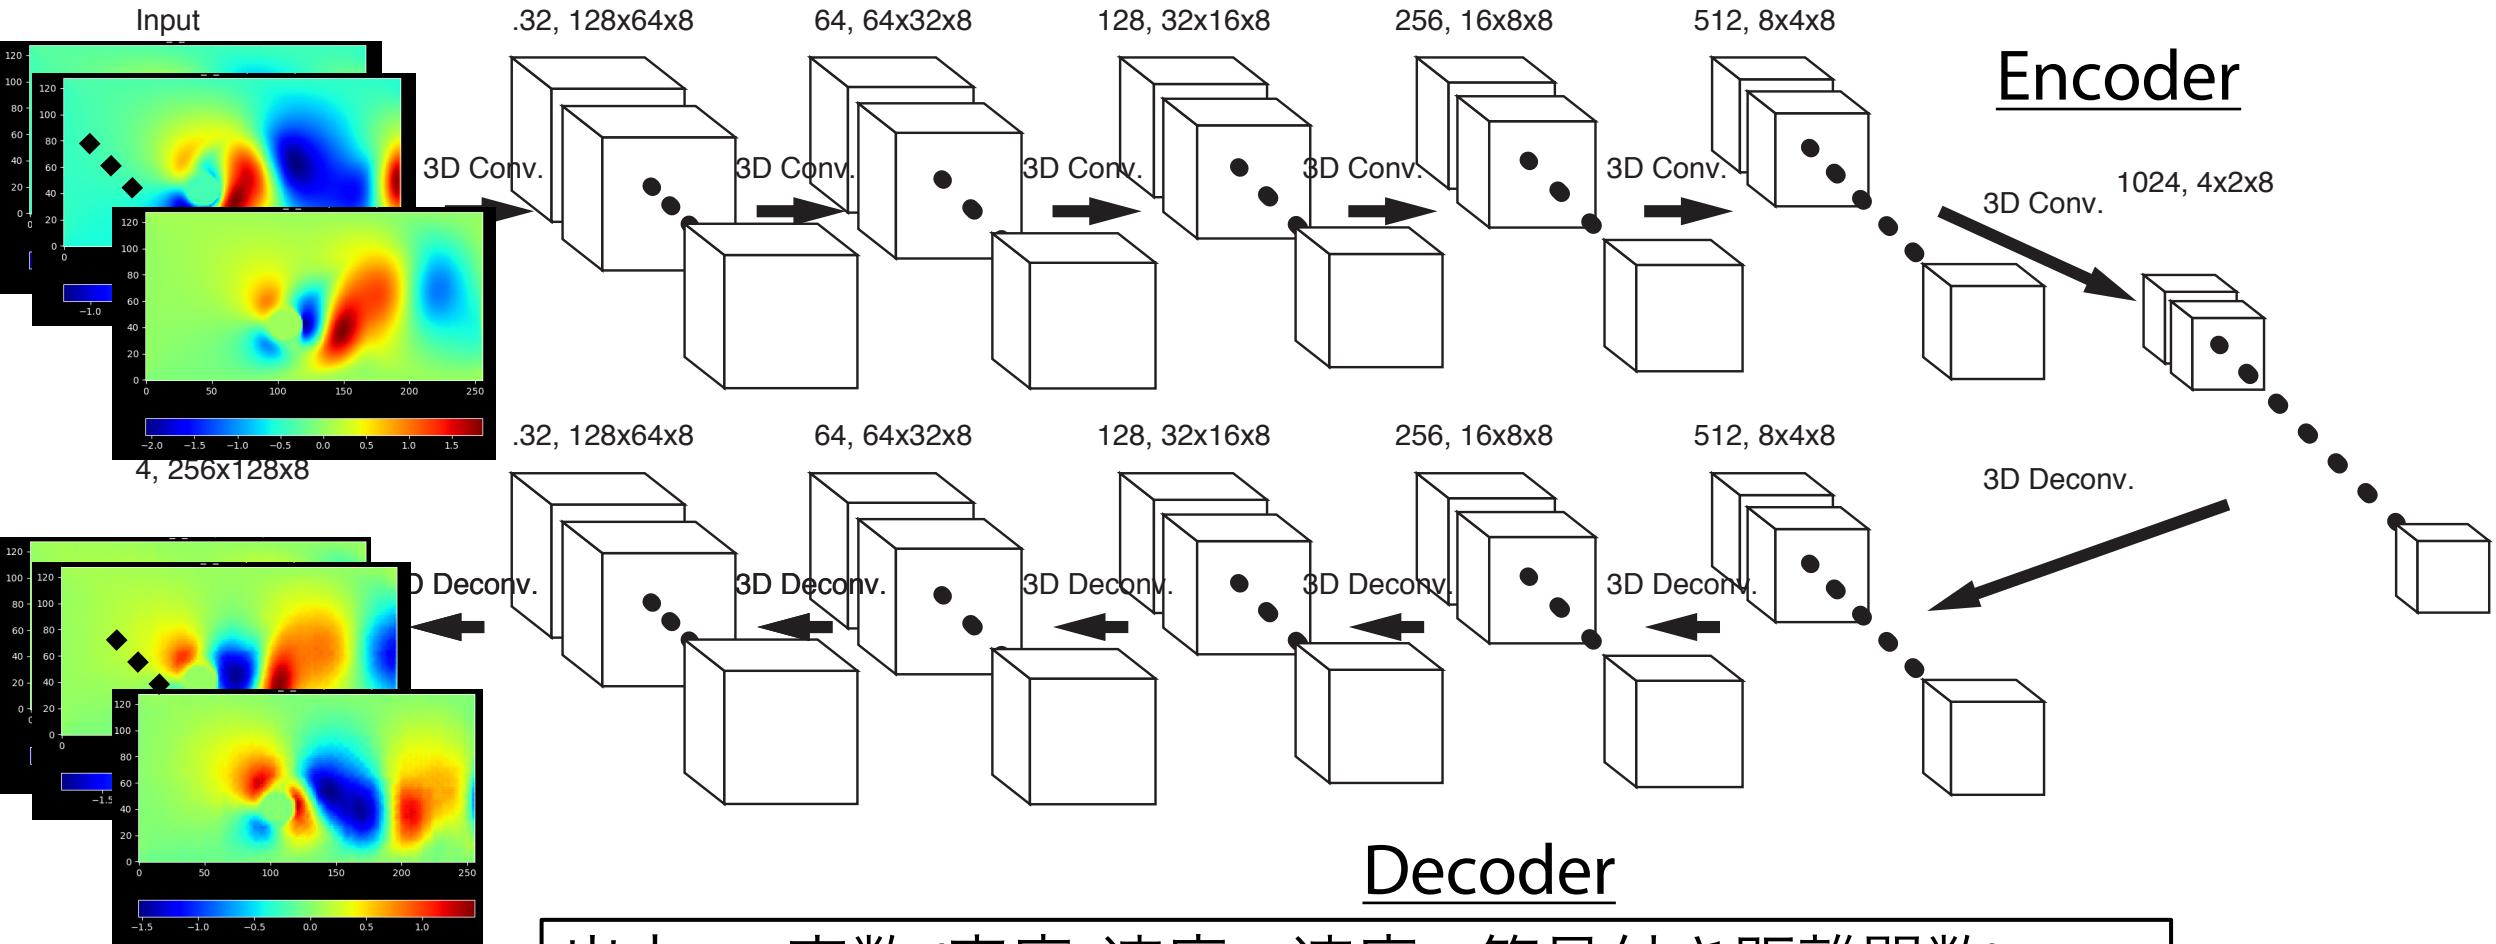
非定常流れの予測の概要

- 格子ボルツマン法 (D2Q9モデル) による円柱周りの流れ
- 3次元のCNNにより時間的に変化する流れを予測
 - 入力：シミュレーションの100ステップ間隔の8フレーム (t_0, \dots, t_0+700)
 - 出力：続く8フレームを (t_0+800, \dots, t_0+1500) を予測
- CNNによる予測結果を入力することで、さらに先にフレームを予測



時間変化する流れを予測するネットワーク構造

入力: 4変数(密度, 速度u, 速度v, 符号付き距離関数),
256x128x8 フレーム ($t=t_0, t_0+100, \dots t_0+700$)



出力: 4変数(密度, 速度u, 速度v, 符号付き距離関数),
256x128x8 フレーム ($t=t_0+800, t_0+900, \dots t_0+1500$)

時間変化する流れの予測

まとめ

- ・数値流体力学は、多くの計算資源を必要とし、スパコンを用いる重要なアプリケーションである。
- ・近年、画像認識で注目されている深層学習を用いて、流体計算の結果を予測する研究を進めている。
- ・定常流計算の予測
 - ・CNNと境界交換を用いることで複数領域にまたがる予測を実現
 - ・複数領域にまたがる予測は、学習に用いるデータの領域サイズやGPUメモリ容量の制限を受けず、大規模な計算領域の予測が可能
- ・非定常流計算の予測
 - ・3次元のCNNを用いることで、時間変化する流れを予測することを確認した。

Thank you for watching