



データ同化による乱流モデルパラメータの最適化と ロバスト性に関する研究

2023/03/03
モルゲンロット株式会社
中村昌道



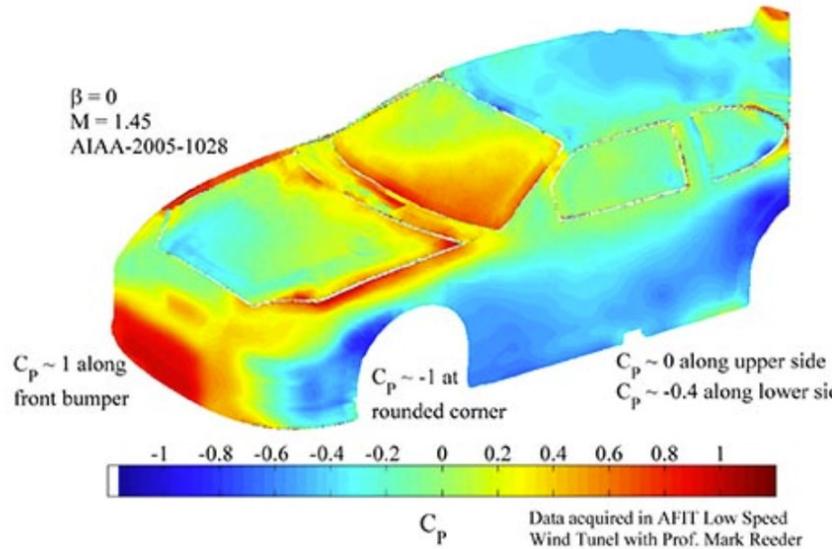
1. データ同化による乱流モデルパラメータの最適化
2. 表面形状の自動生成に関する研究



データ同化による 乱流モデルパラメータの最適化

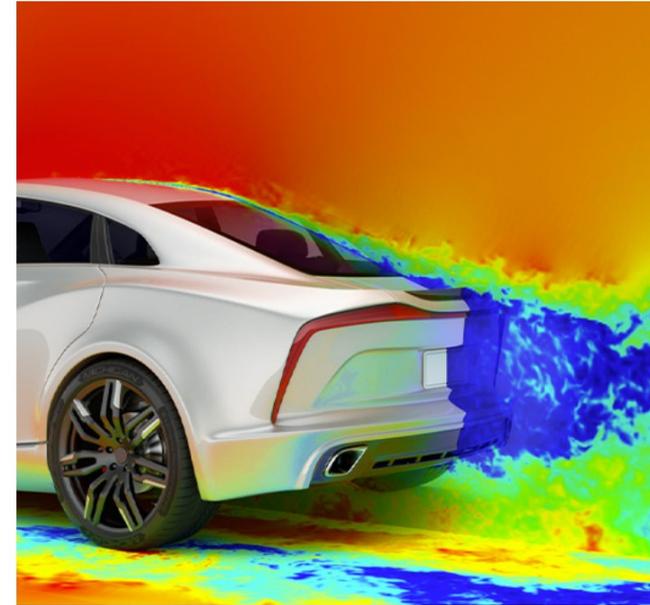


設計開発における実験と解析の特徴



感圧塗料による圧力測定

<https://www.seika-di.com/measurement/combustion/psp.html>



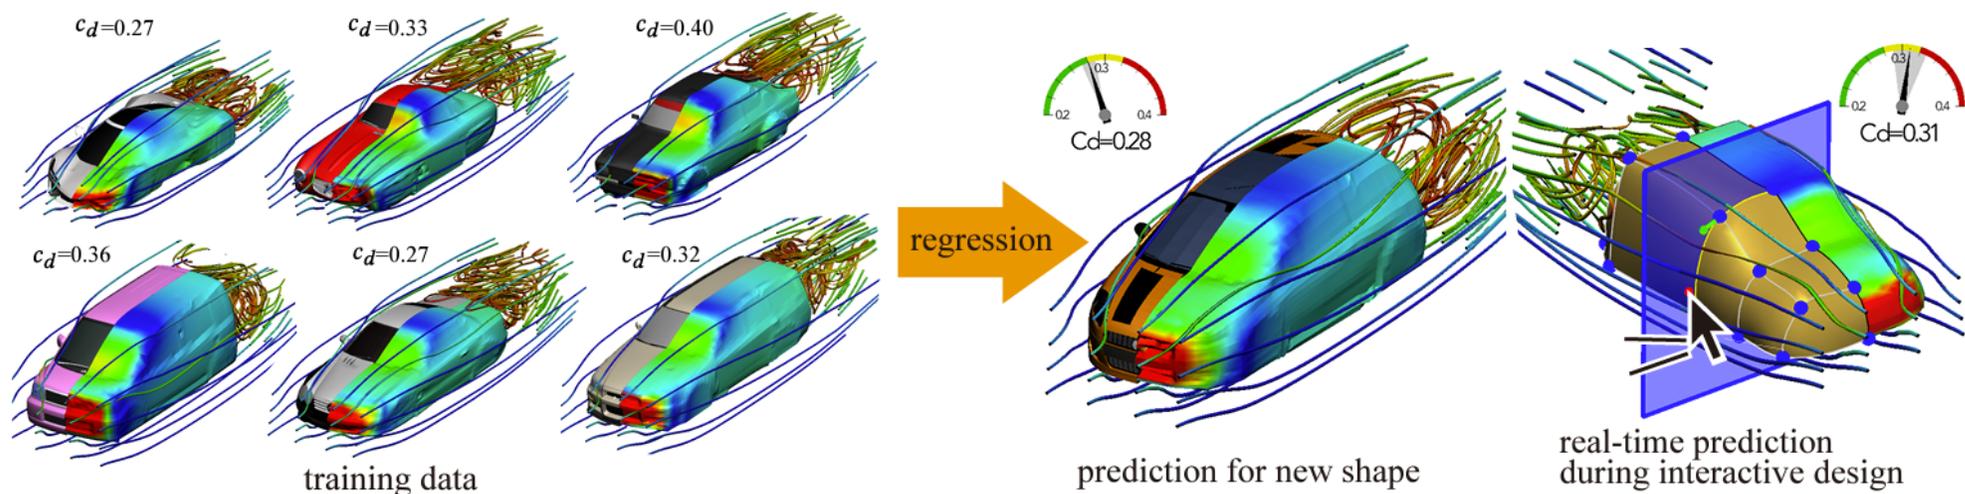
LBMによる大規模解析

<https://www.altairjp.co.jp/altair-cfd-capabilities/>

- ・近年はEFDおよびCFDともに非定常現象の計測や大規模化に向けた開発が進められている。
- ・設計開発ではリードタイムの短縮や最適化に向けて空力性能の高速な推定が要求されている。

機械学習などの手法を用いた高速な空力性能の推定手法に注目

機械学習による解析の高速化

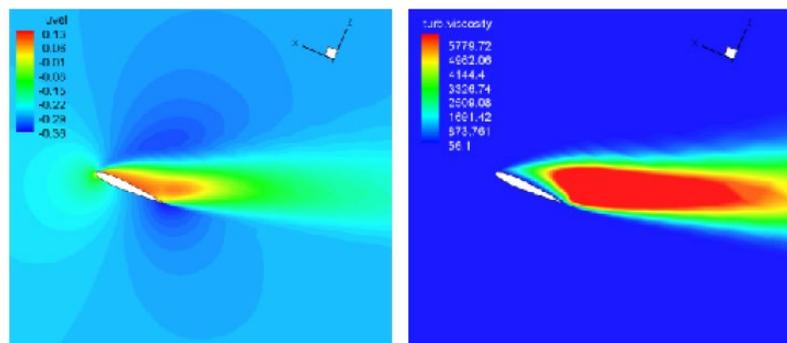


(Umetani et al., 2018.)

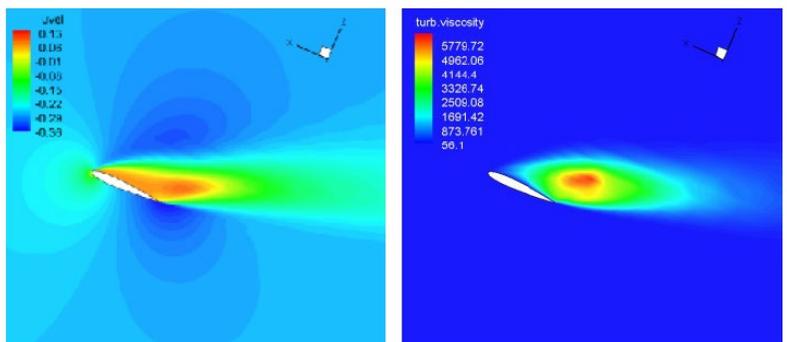
- 事前にネットワークに学習させることで入力された形状に対して瞬時に空力性能を推定。
- 学習には多くの教師データが必要。
- 形状の変化に対してどの範囲で適用が可能かどうか不明瞭。

教師データの生成においても高速な解析が必要

データ同化によるRANSの解析精度向上



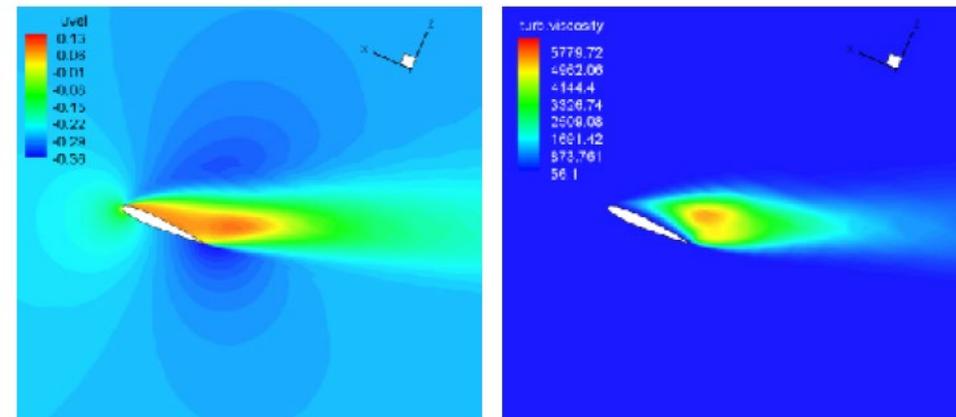
(a) u (b) μ_t
SA-R乱流モデルでの解析結果



(a) u (b) μ_t

Menter SST乱流モデルでの解析結果

EnKF

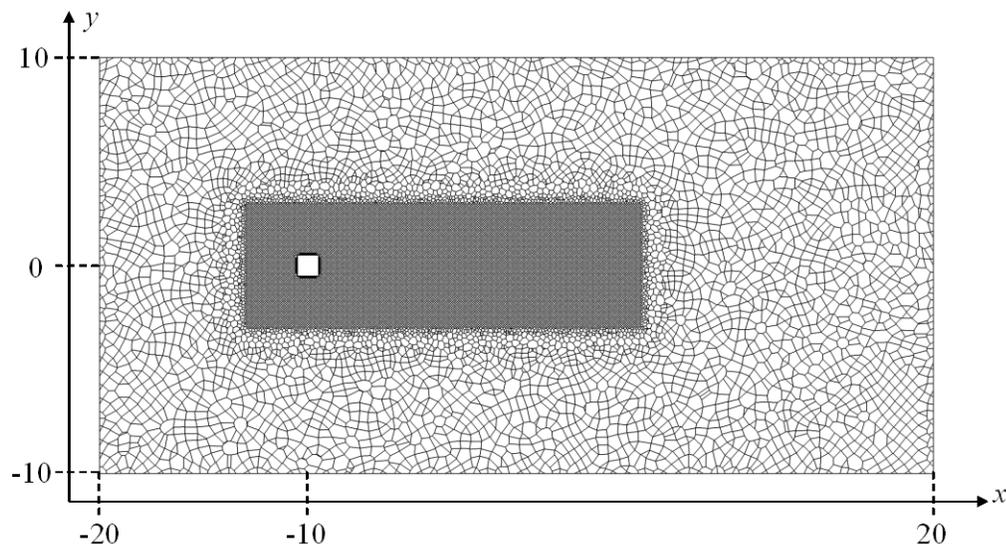


(a) u (b) μ_t
データ同化されたSA-R乱流モデルでの解析結果

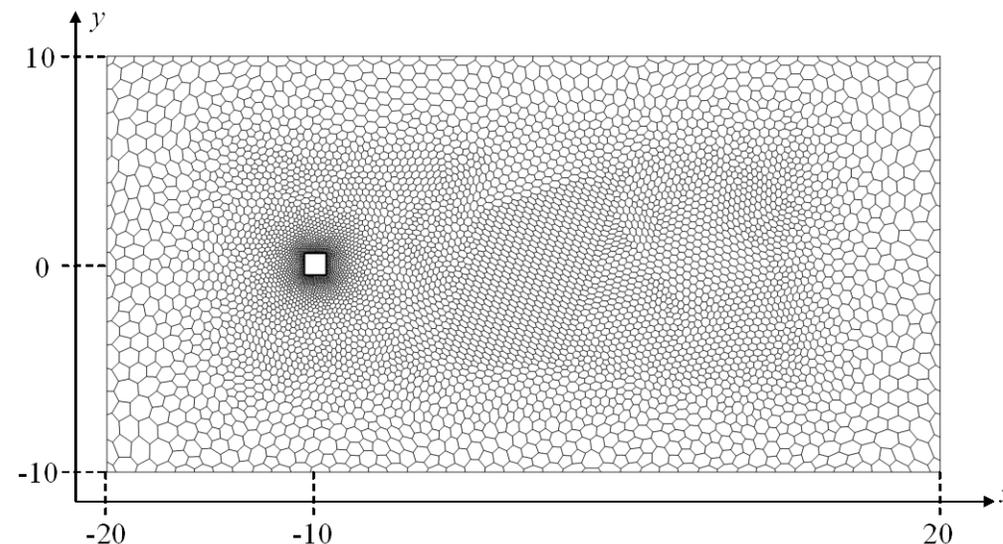
(Kato et al., 2012.)

- ・アンサンブルカルマンフィルタ(EnKF)によりRANSへの高次の解析結果の同化が研究された。
- ・形状が変化した場合にどのような推定精度となるかが把握できていない。

計算対象および解析手法



LESの計算格子:100,000点



RANSの計算格子:6,000点

- LESによる高解像度な解析結果をRANSによる低解像度解析にデータ同化する。
- RANSの格子は解像度が低く通常の解析では精度が低い。
- LESにはWALEモデルを使用し、RANSには $k - \epsilon$ モデルを使用した。
- LESの計算には32並列で平均値を得るまで28時間程度を要するがRANSは5分程度。

データ同化手法

システムの状態方程式: $\mathbf{x}_{t+1} = f(\mathbf{x}_t)$
 $\mathbf{y}_t = \mathbf{H}\mathbf{x}_t + \mathbf{w}_t$

アンサンブルメンバ: $\mathbf{X}_t^f = (\mathbf{x}_t^{f(1)}, \mathbf{x}_t^{f(2)}, \dots, \mathbf{x}_t^{f(N)})$

カルマンフィルタによる
状態量の更新: $\mathbf{K}_t = \mathbf{V}_t^f \mathbf{H}^T (\mathbf{H}\mathbf{V}_t^f \mathbf{H}^T + \mathbf{R}_t)^{-1}$
 $\mathbf{x}_t^a = \mathbf{x}_t^f + \mathbf{K}_t (\mathbf{y}_t - \mathbf{H}\mathbf{x}_t^f)$

$$\hat{\mathbf{X}}_t^f = \frac{1}{N} \mathbf{X}_t^f \mathbf{1}_{1 \times N}$$

$$\delta \mathbf{X}_t^f = \mathbf{X}_t^f - \hat{\mathbf{X}}_t^f$$

$$\hat{\mathbf{V}}_t^f = \frac{1}{N-1} \delta \mathbf{X}_t^f (\delta \mathbf{X}_t^f)^T$$

自己組織化モデルの状態量: $\mathbf{x}_t = (\mathbf{p}^T, \mathbf{u}^T, \mathbf{v}^T, C_\mu, C_{1e}, C_{2e}, C_t, \sigma_k, \sigma_e)^T$

- データ同化手法にはアンサンブルカルマンフィルタを適用。
- アンサンブルメンバは20とした。
- カルマンフィルタ係数は逆行列補題により導出。
- 自己組織化モデルにより同化によって乱流モデルパラメータも最適化。

観測ノイズの適応的最適化

観測ノイズ R_t は通常は観測機器の精度などから決定するが、定量的な決定が困難

観測ノイズ R_t の適応的最適化:

$$E_t = Y_t - HX_t^f$$
$$R_t = \frac{1}{N-1} E_t E_t^T - H_t \hat{V}_t^f H_t^T$$

(Berry et al., 2013.)

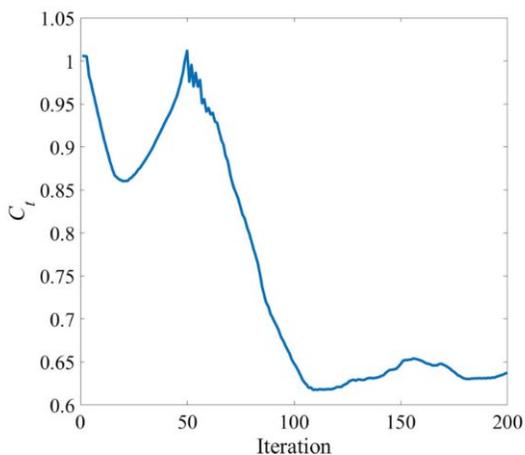
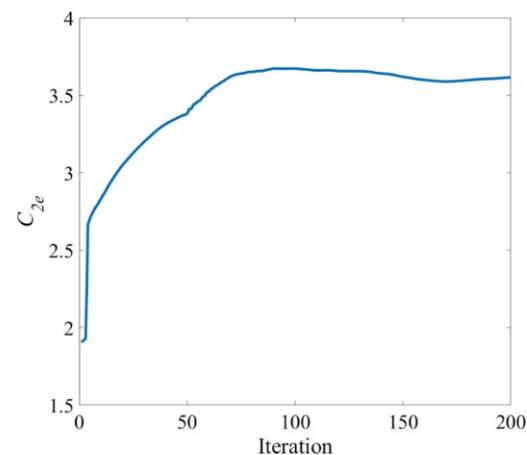
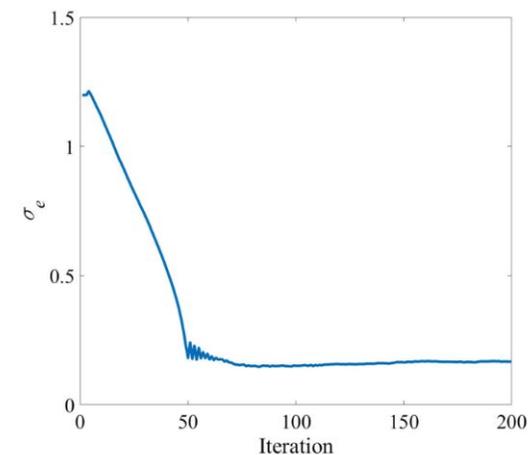
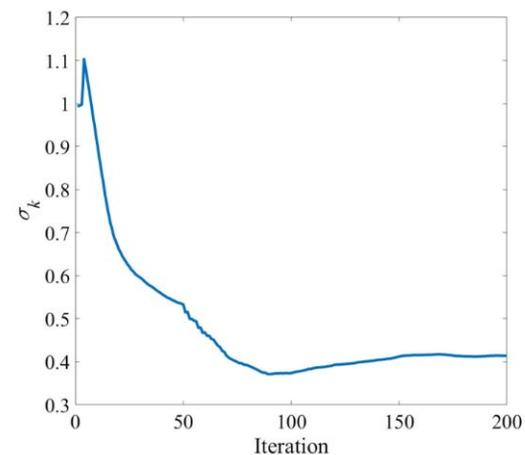
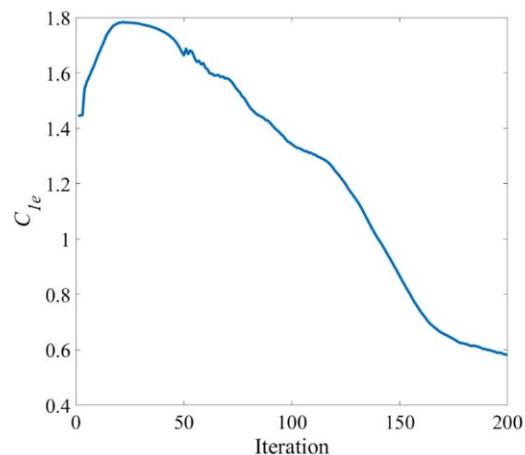
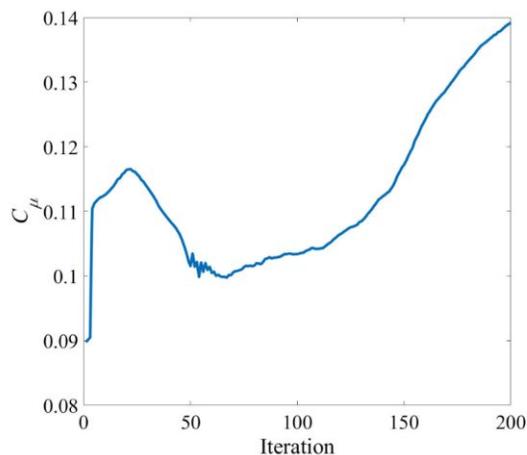
流体場においては巨大な行列であり計算が困難

特異値分解による低次元化:

$$H \delta X_t^f = U \Sigma W^T$$
$$\sigma_{est}^2 = \frac{1}{N(N-1)} \left[\left\| U^T (HX_t^f - Y_t) \right\|_F^2 - \|\Sigma\|_F^2 \right]$$

カルマンフィルタの更新ステップで観測ノイズも更新

同化ステップごとの乱流モデルパラメータの変化



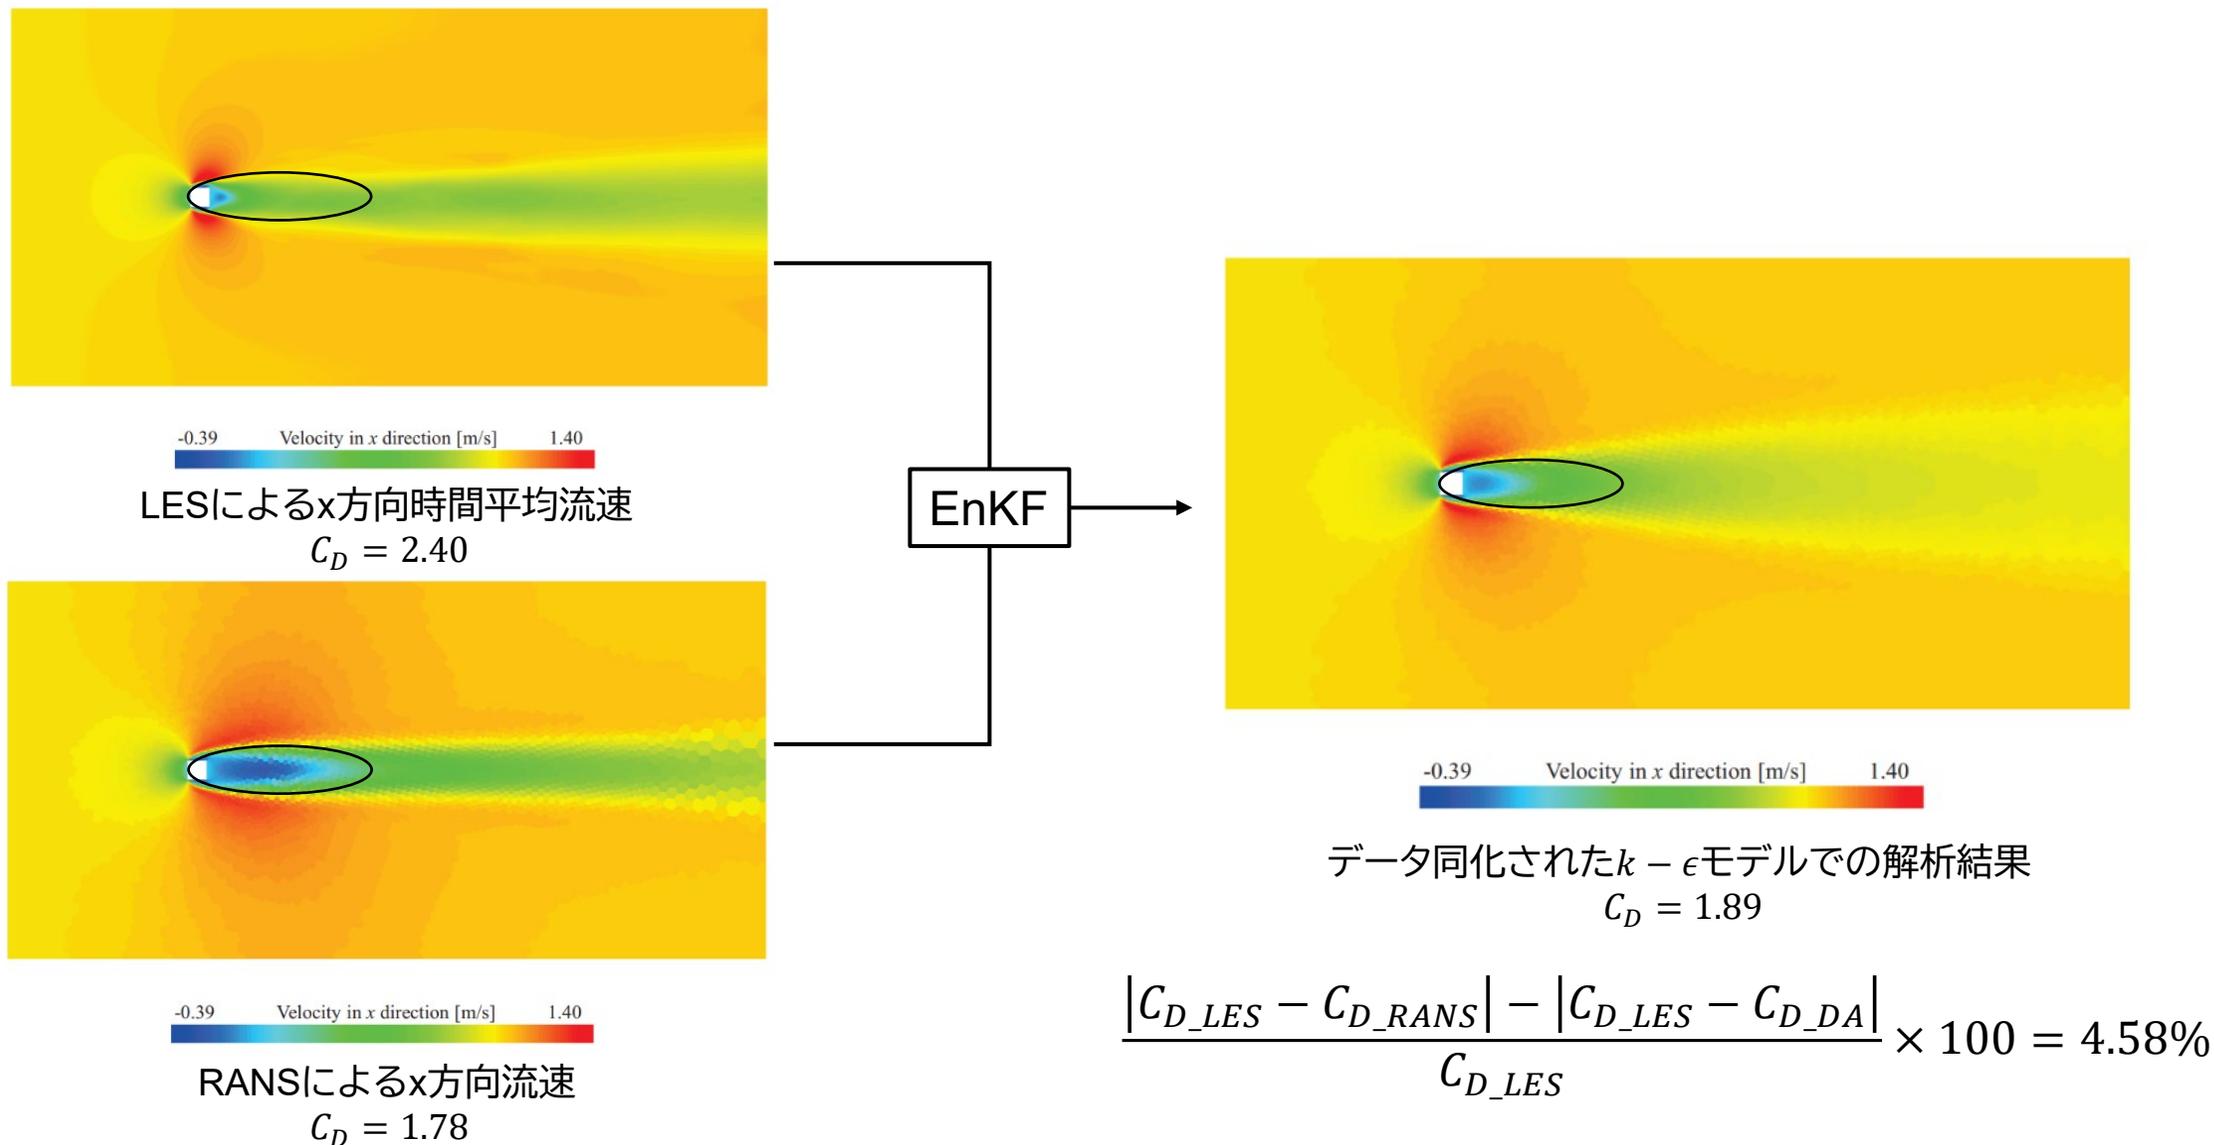
$C_\mu = 0.09$
 $C_{1e} = 1.44$
 $C_{2e} = 1.9$
 $C_t = 1.0$
 $\sigma_k = 1.0$
 $\sigma_e = 1.0$



$C_\mu = 0.1392$
 $C_{1e} = 0.5821$
 $C_{2e} = 3.6154$
 $C_t = 0.6373$
 $\sigma_k = 0.4133$
 $\sigma_e = 0.1666$

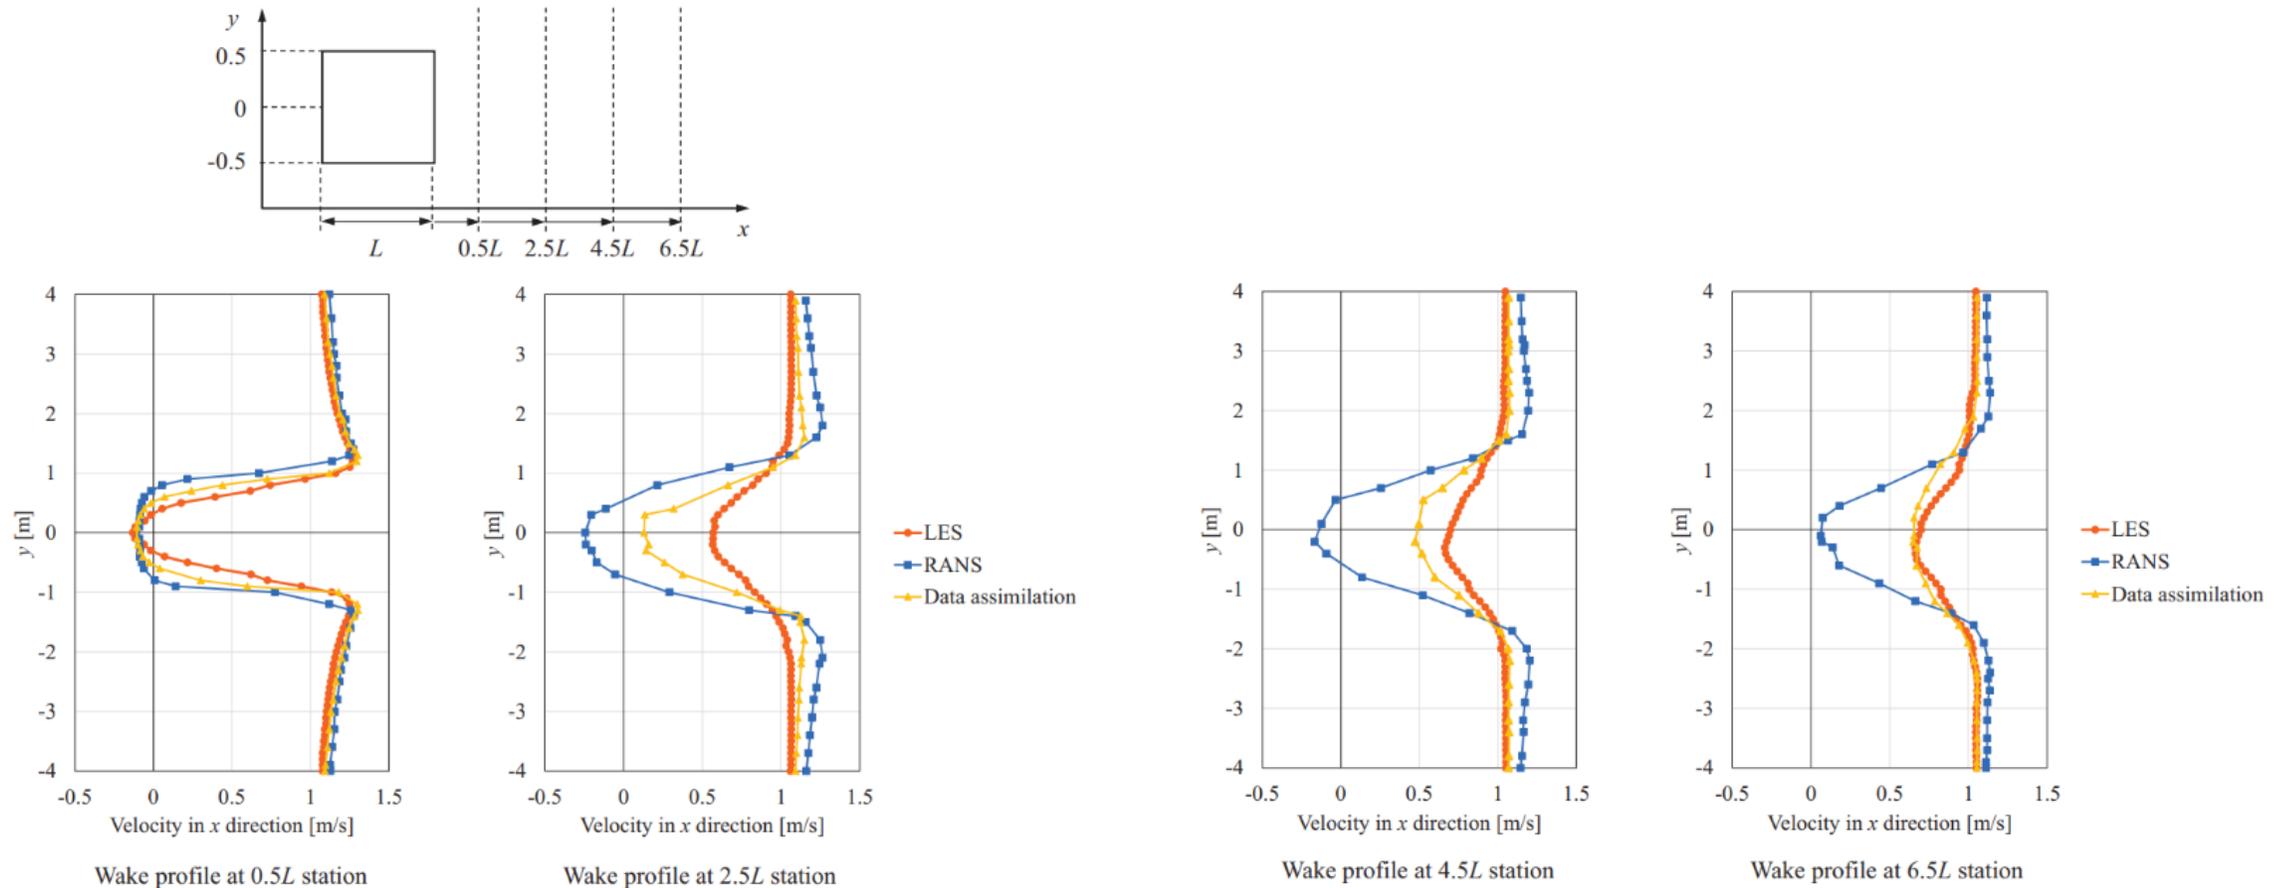
- 適応的最適化によりほとんどのパラメータが自動的に収束
- 手でパラメータを調整した場合と比較しても同等の値に収束

RANSとLESおよびデータ同化の解析結果の比較



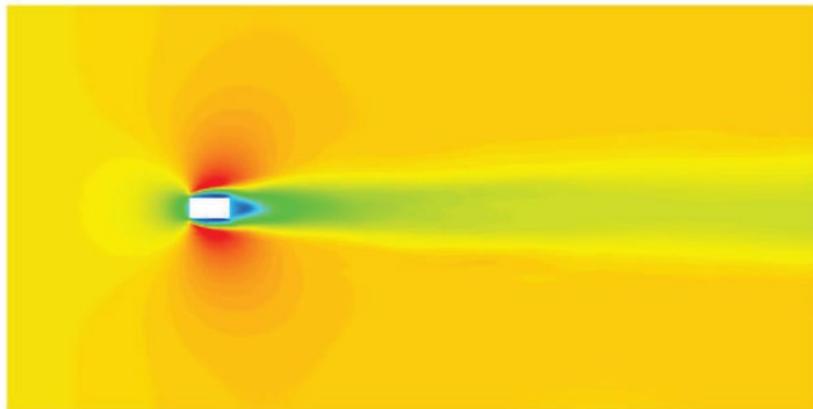
データ同化によりLESに対する後流の減速域の再現性が向上

角柱後流の流速の比較

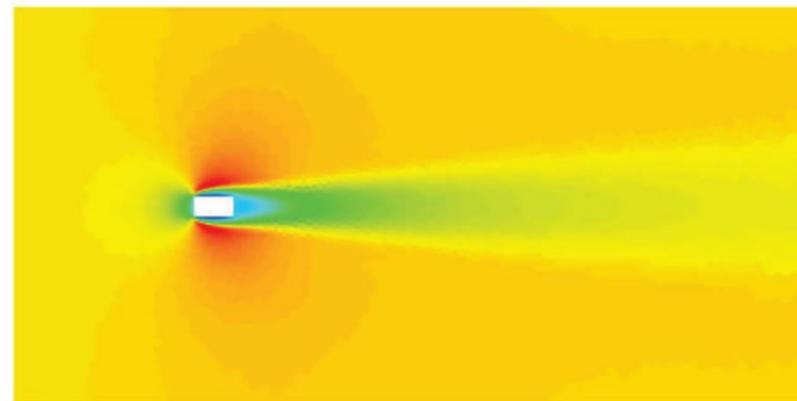


- RANSでは逆流域が角柱後方の $4.5L$ まで分布している。
- LESは逆流域が $2.5L$ までの範囲で消失している。
- データ同化されたRANSはLESの傾向に近づいており、 $2.5L$ までの範囲で逆流域が消失している。

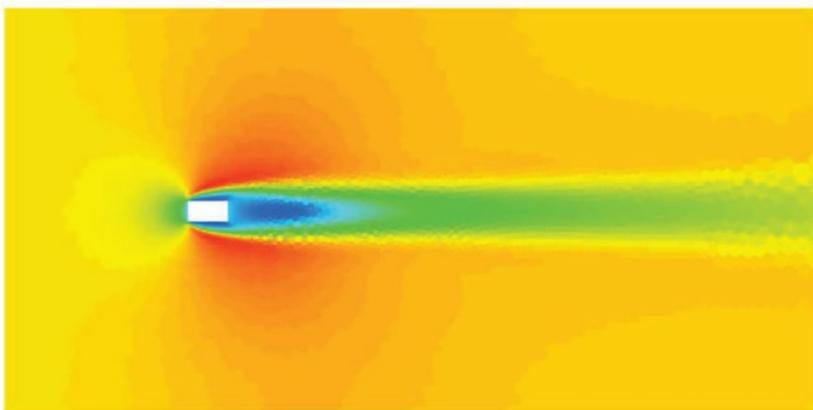
断面形状が変化したケースへのパラメータの適用



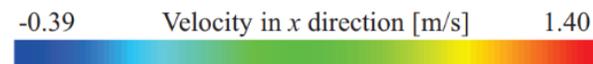
LESによるx方向時間平均流速



データ同化されたk - εモデルでの解析結果



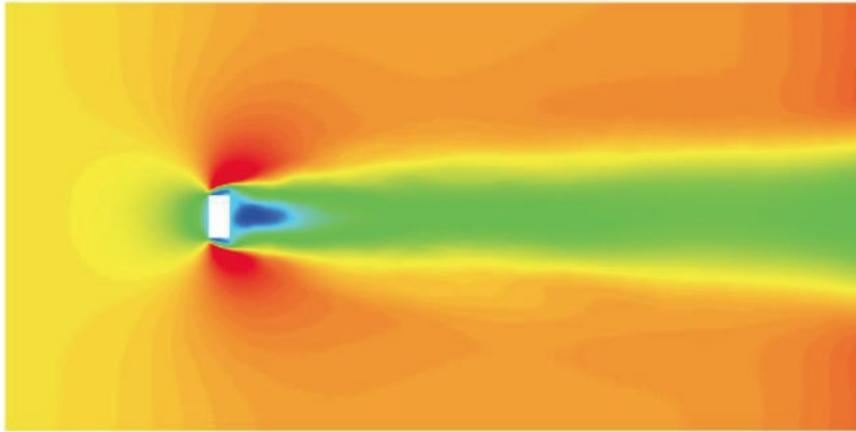
RANSによるx方向流速



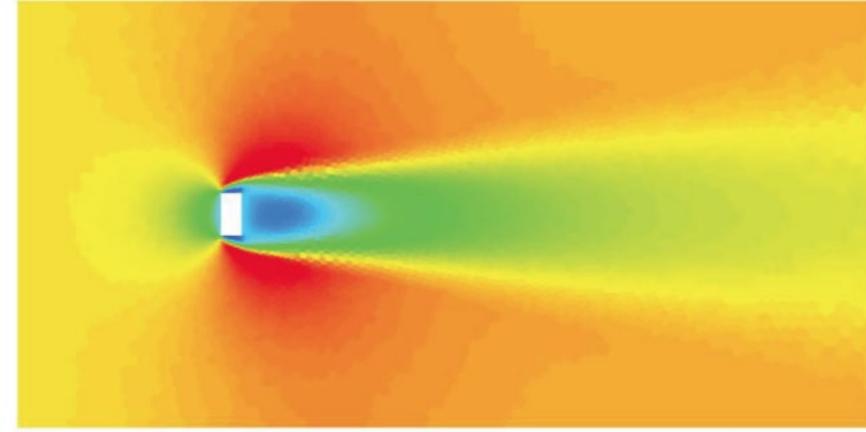
$$\frac{|C_{D_LES} - C_{D_RANS}| - |C_{D_LES} - C_{D_DA}|}{C_{D_LES}} \times 100 = -7.04\%$$

- 主流方向に断面長さが2倍になった場合でも減速域の再現性が向上する。
- 抵抗係数の再現性は同化した場合に低下してしまう。

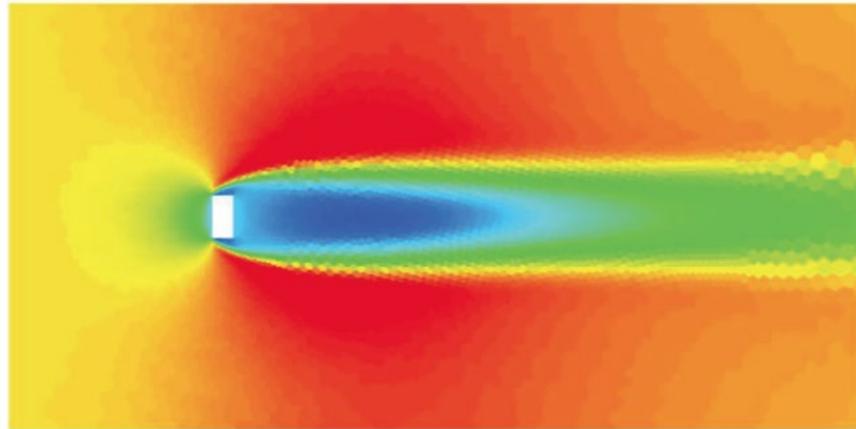
断面形状が鉛直方向に変化したケースへのパラメータ適用



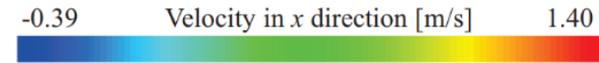
LESによるx方向時間平均流速



データ同化されたk - εモデルでの解析結果



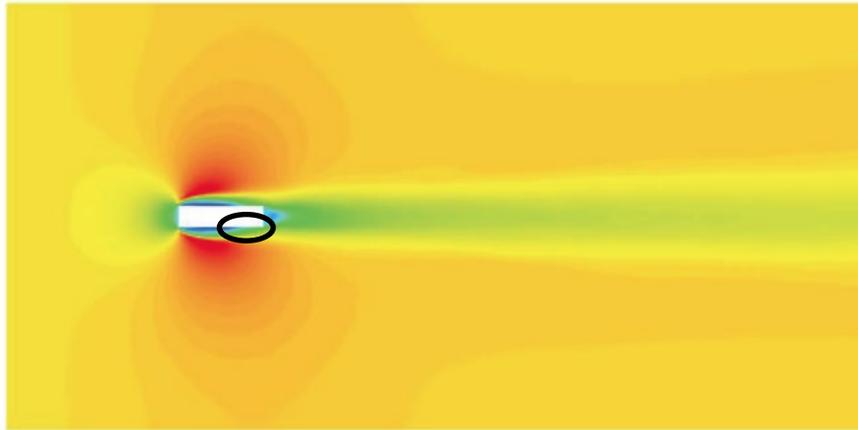
RANSによるx方向流速



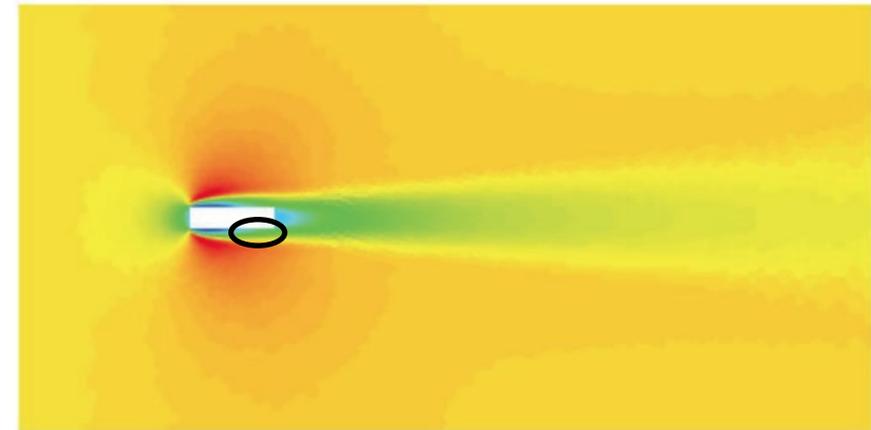
$$\frac{|C_{D_LES} - C_{D_RANS}| - |C_{D_LES} - C_{D_DA}|}{C_{D_LES}} \times 100 = 5.01\%$$

- 主流と鉛直方向に断面長さが2倍になった場合でも減速域の再現性が向上する。
- 抵抗係数の再現性は同化した形状と同等以上に向上する。

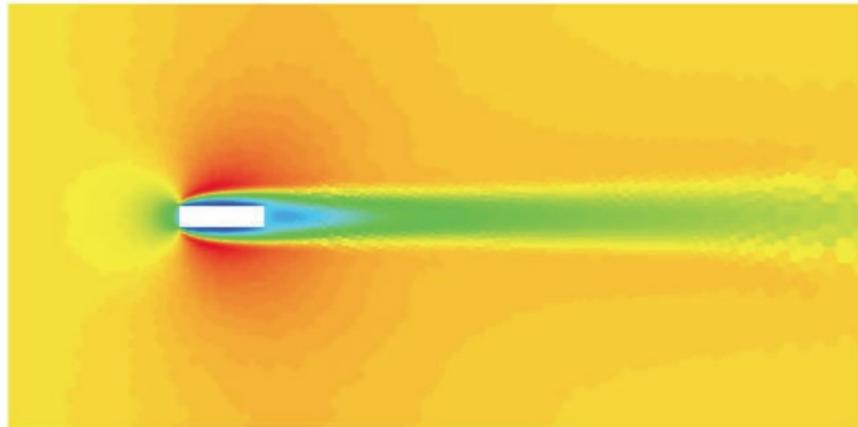
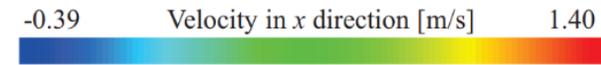
断面形状の変化分を増大させたケースへのパラメータ適用



LESによるx方向時間平均流速



データ同化されたk-epsilonモデルでの解析結果

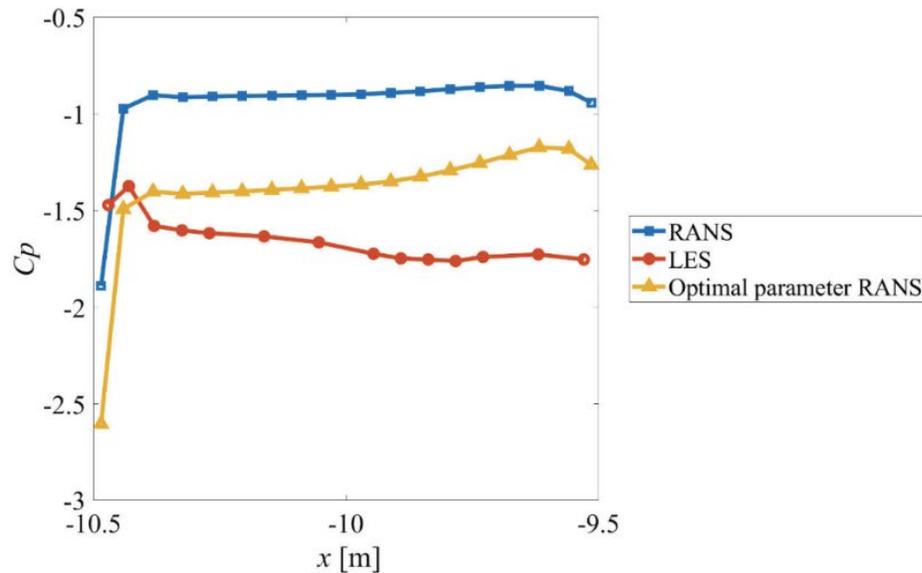
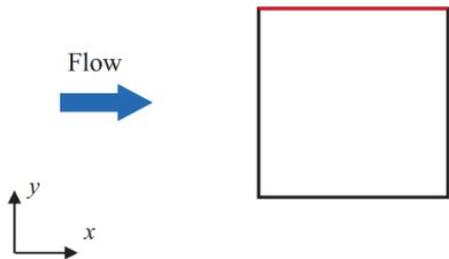


RANSによるx方向流速

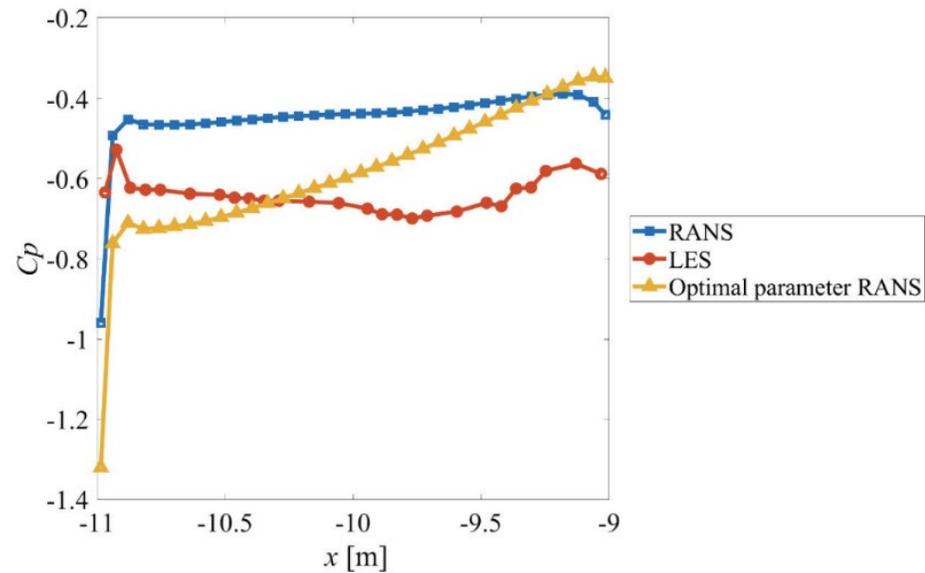
$$\frac{|C_{D_LES} - C_{D_RANS}| - |C_{D_LES} - C_{D_DA}|}{C_{D_LES}} \times 100 = 1.81\%$$

- 主流方向に断面長さが4倍になると流れ場の再現性ととも抵抗係数の再現性も向上する。
- 必ずしも断面長さが増加すると再現性が低下するわけではない。

主流に平行な壁面上での圧力分布の比較



データ同化した断面形状



主流方向長さが2倍の断面形状

- 同化した断面形状では同化により圧力分布が下流側で上昇している。
- 主流長さが2倍のケースではLESも下流側で圧力分布が上昇する。
- 同化では圧力の上昇を過大評価してしまう。

今回の同化ではRANSにおける再現性を向上するために再付着の影響を過大評価している

- 主流方向の長さが2倍の断面形状では別途同化したパラメータの使用により精度向上が可能
- 乱流モデルの変更により今回の条件でも精度が向上する可能性
- 流れ場全体の再現性は向上しており、複雑な形状においては精度が向上する可能性



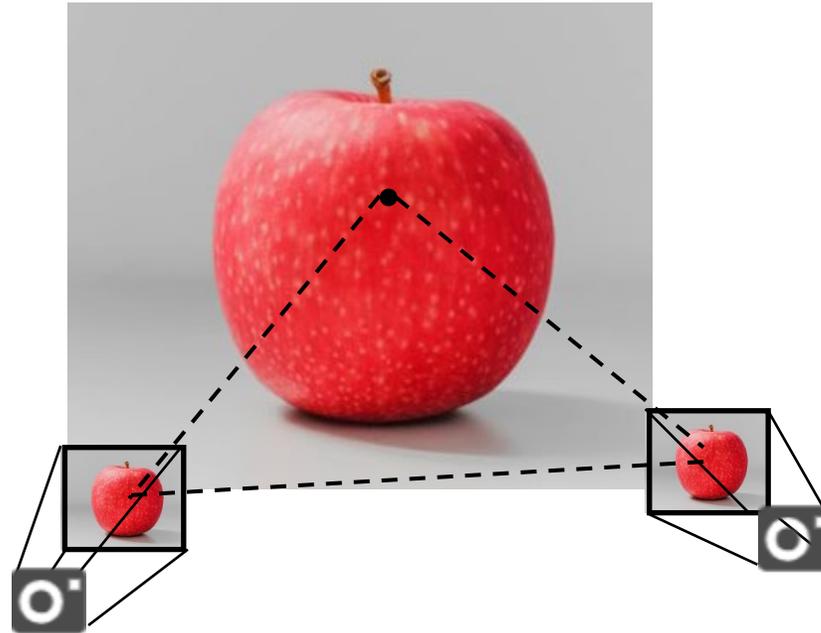
表面形状の自動生成に関する研究

02



画像データからの3次元モデルの生成

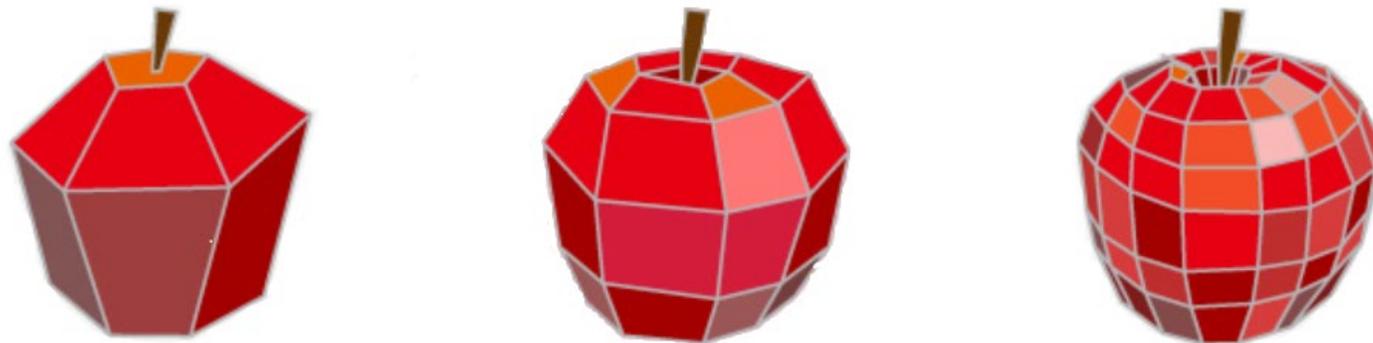
フォトグラメトリ (Structure from motion) のコンセプト



- 3次元物体のワールド座標系とカメラ座標系および画像座標系を定義
- 物体上に特徴点を定義
- カメラ座標から物体までの距離を余弦定理などで推定
- 複数の写真から距離を推定して対象の物体を3次元化

幾何学的な演算の繰り返しで3次元モデルを生成

従来手法でメッシュを生成する際の課題

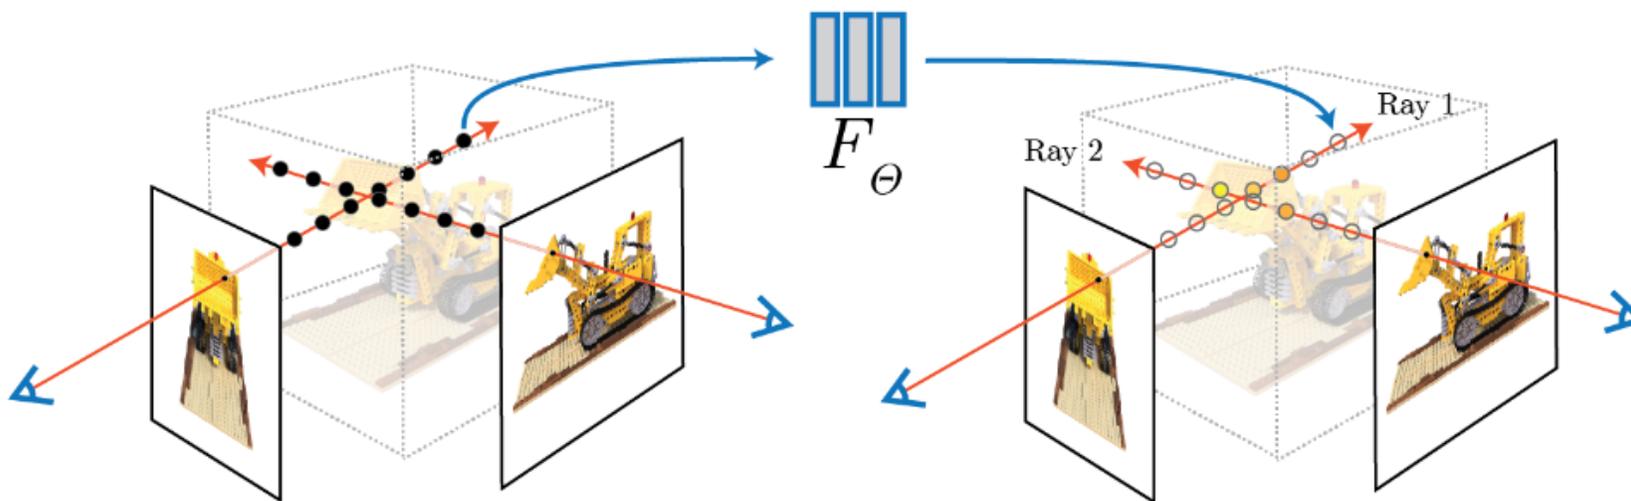


画像参照元 <https://mynavi-creator.jp/blog/article/the-role-of-3dcg-designer>

精度の高いモデル生成には正確な特徴点が多く必要
→多くの画像データが必要
→演算回数が増加してモデル化に多くの時間が必要

物体表面を表す関数 $F(x, y, z, \theta, \phi)$ の非線形性が問題

ニューラルネットワークによる関数の推定



<https://github.com/bmild/nerf>

Neural Radiance Field(NeRF)

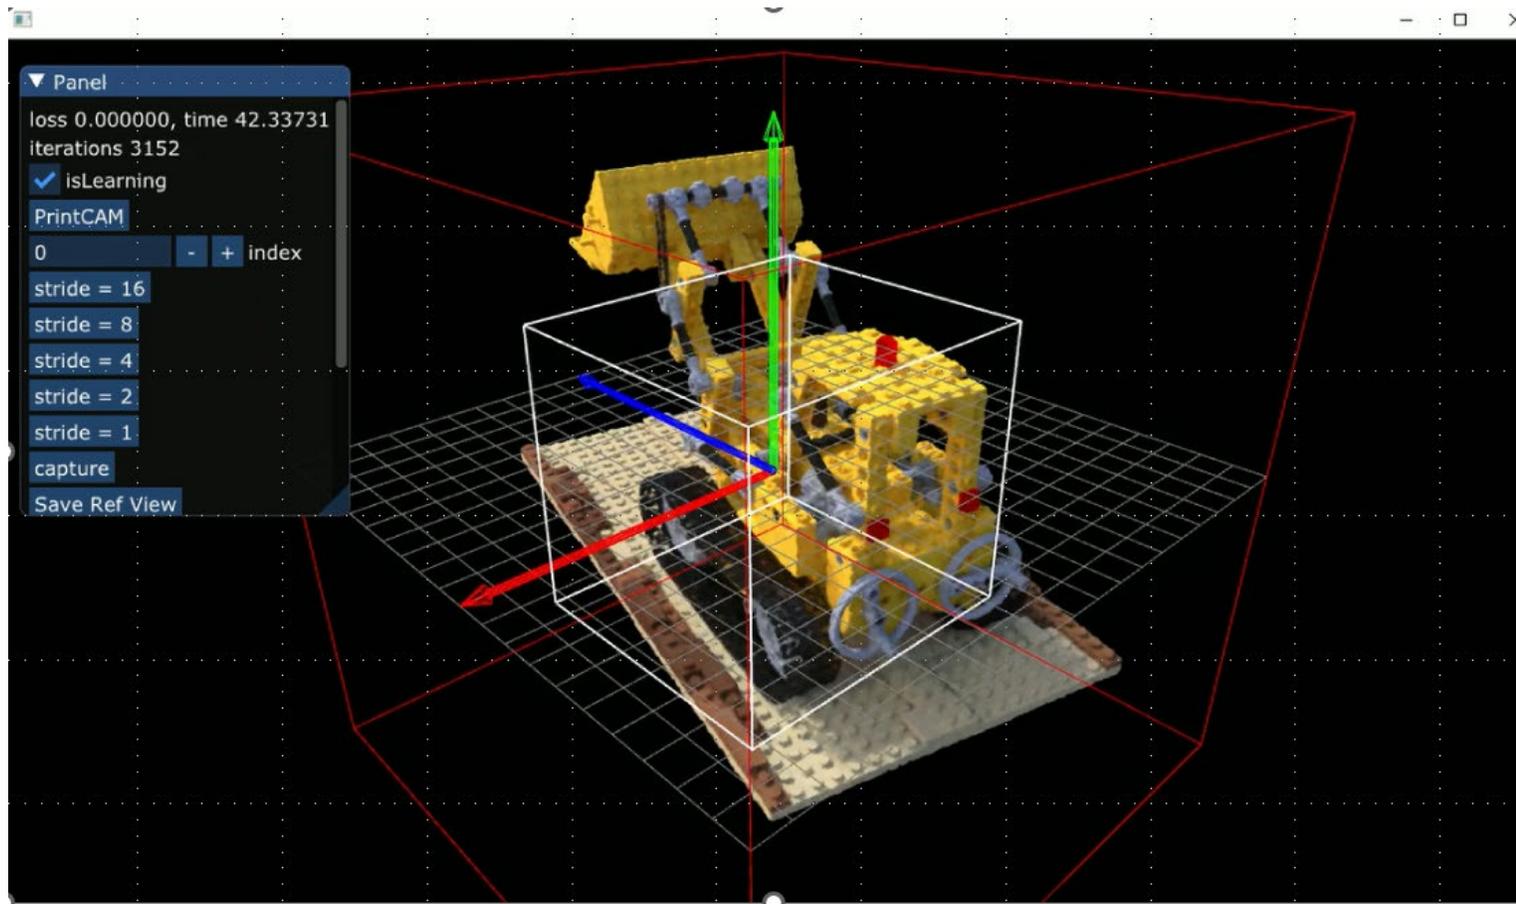
- ・カメラの位置(視点)を入力として写真中のある点の色と密度(ピクセル等)を出力と考える
- ・すべての入力と出力が成立する非線形な方程式が存在すれば物体を3次的に描画可能
- ・ニューラルネットワークを利用して非線形な方程式を導出

NeRFによる3Dモデル生成

Input

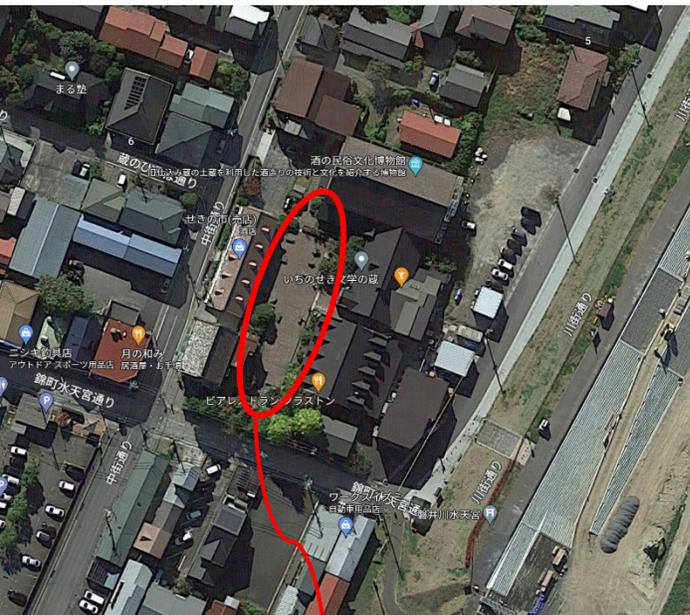


Neural Radiance Field

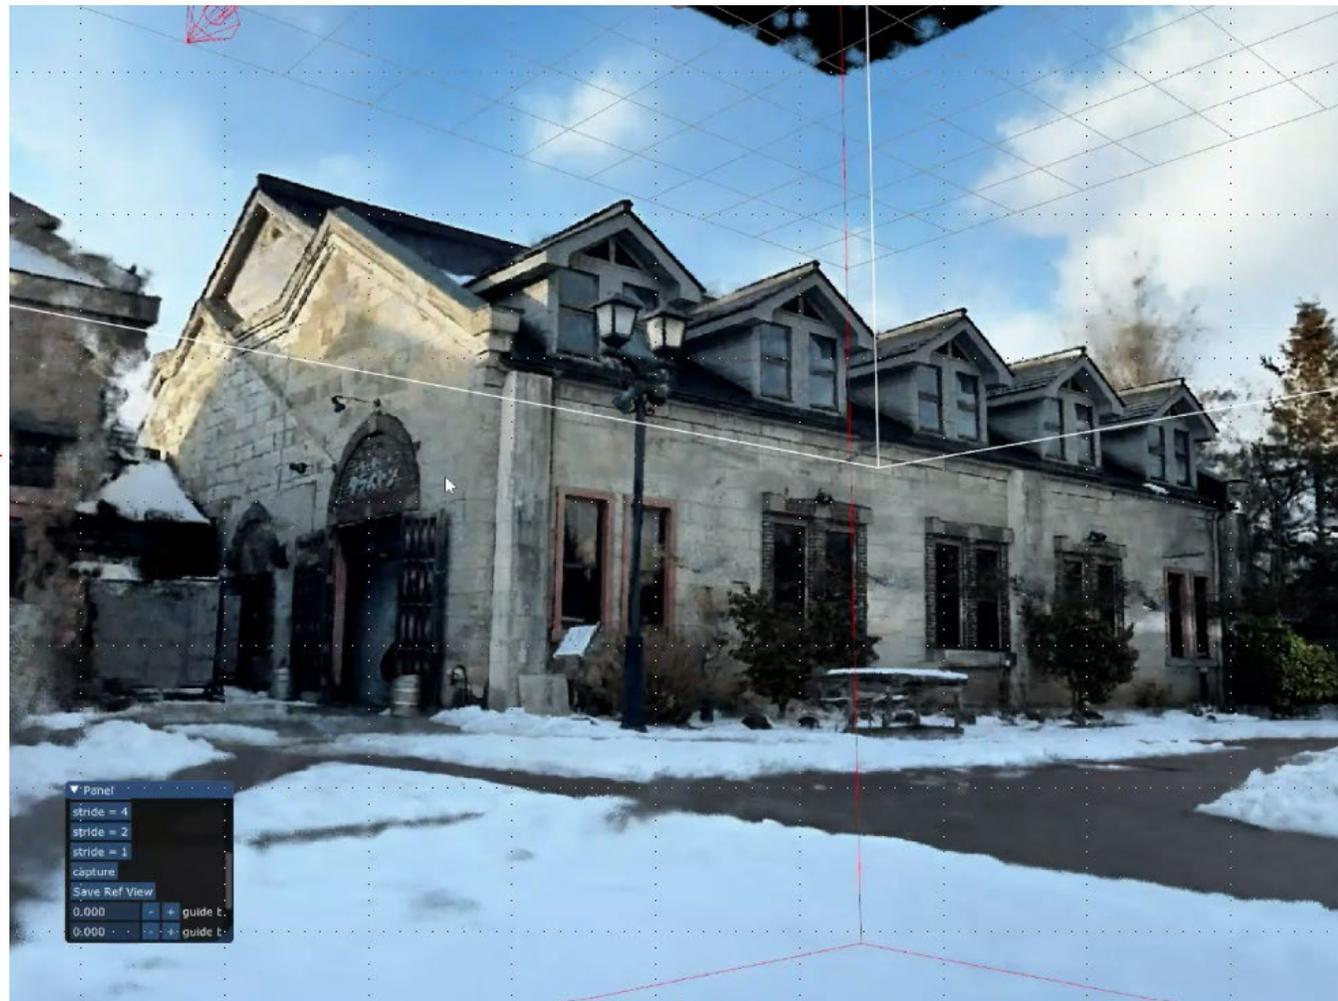
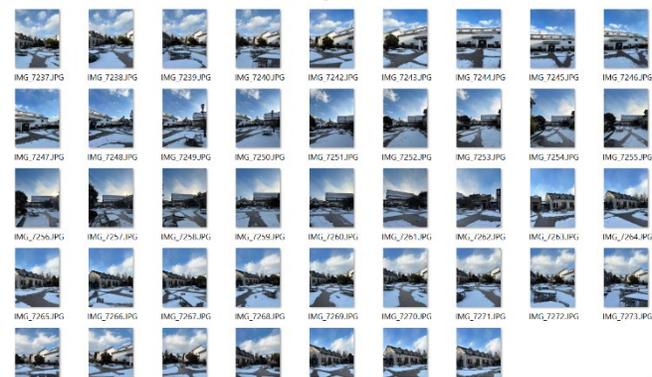


- 100枚程度の写真を入力。
- Instant ngp methodを使用すれば数分で学習が完了。
- Interactiveなviewの生成が可能。

NeRFによる開放空間の3Dモデル生成



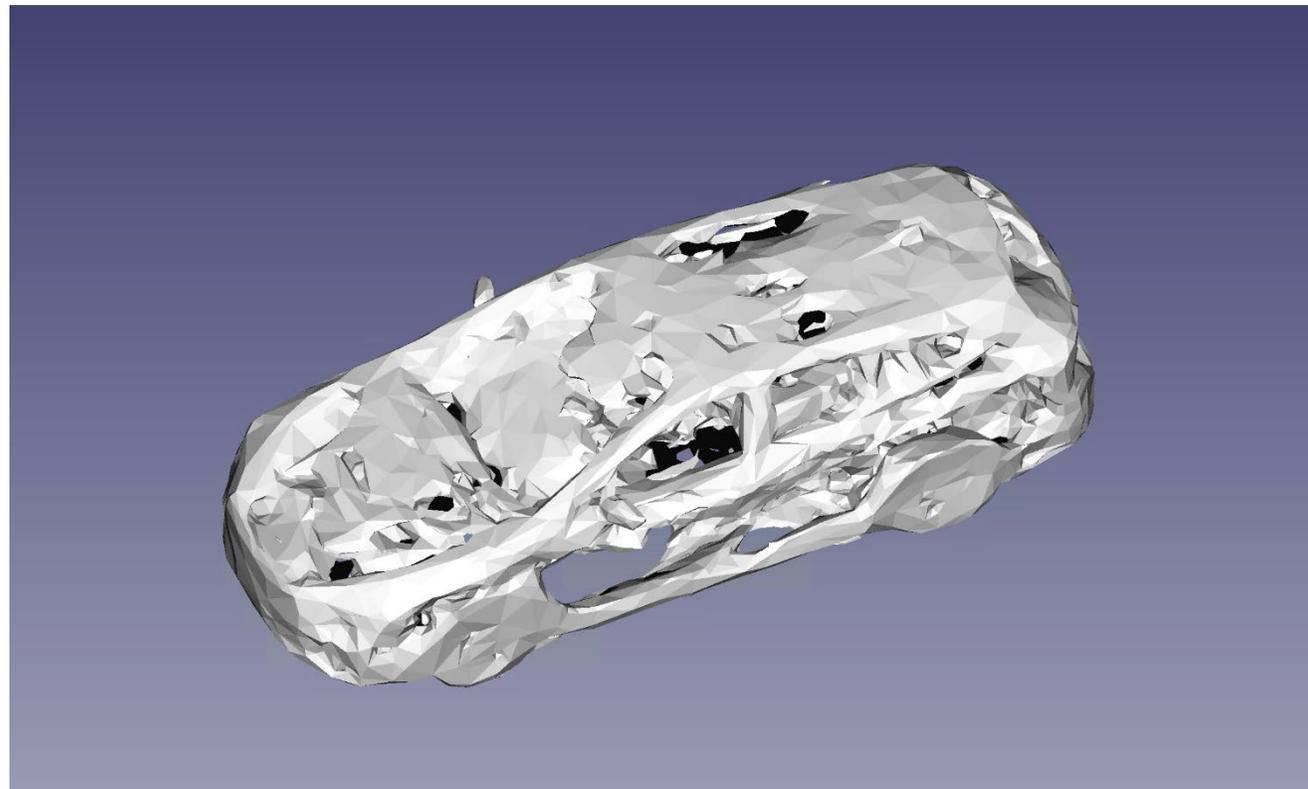
Neural
Radiance Field



NeRFからメッシュ生成する際の課題



Luma AI : <https://lumalabs.ai/>



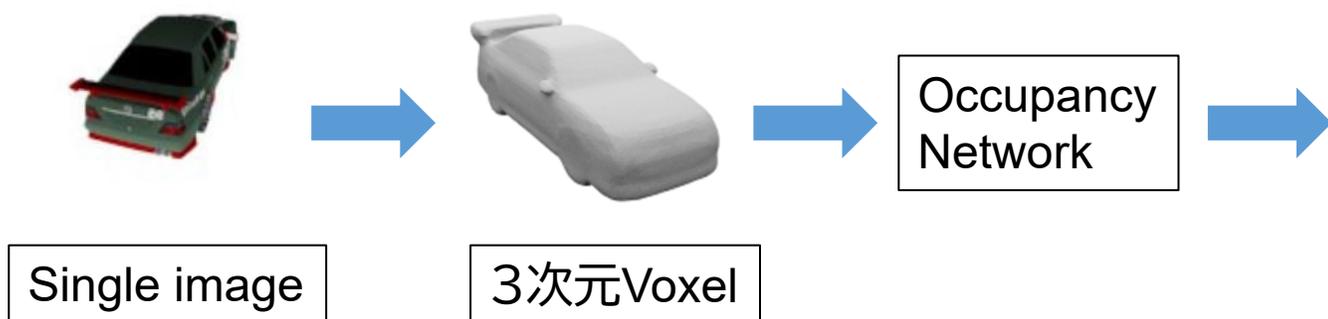
- NeRFは表面の形状をメッシュや点群として出力することに向いていない
- 表面の色でなくメッシュなどの形状を直接学習するネットワークが必要

Occupancy Networkによるメッシュ生成

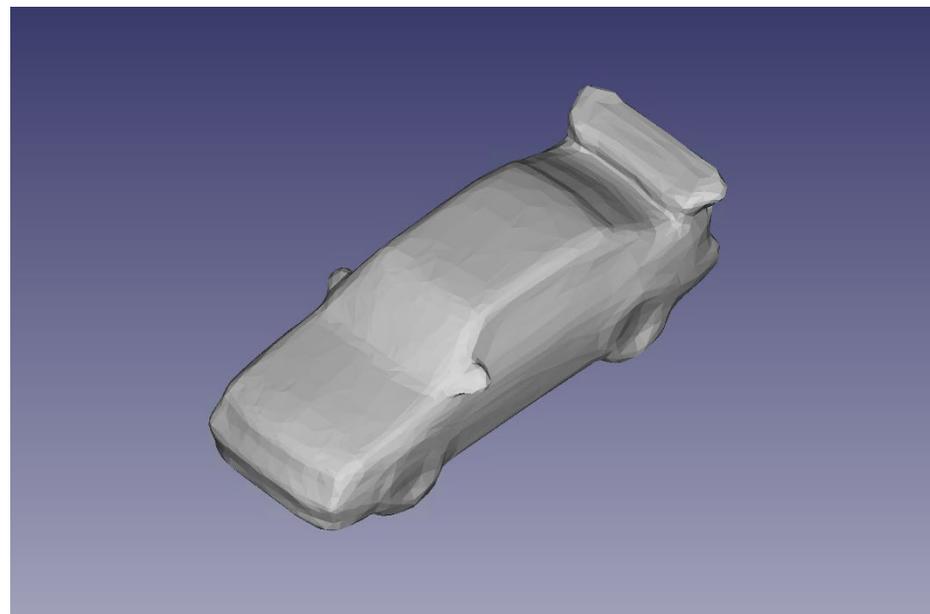
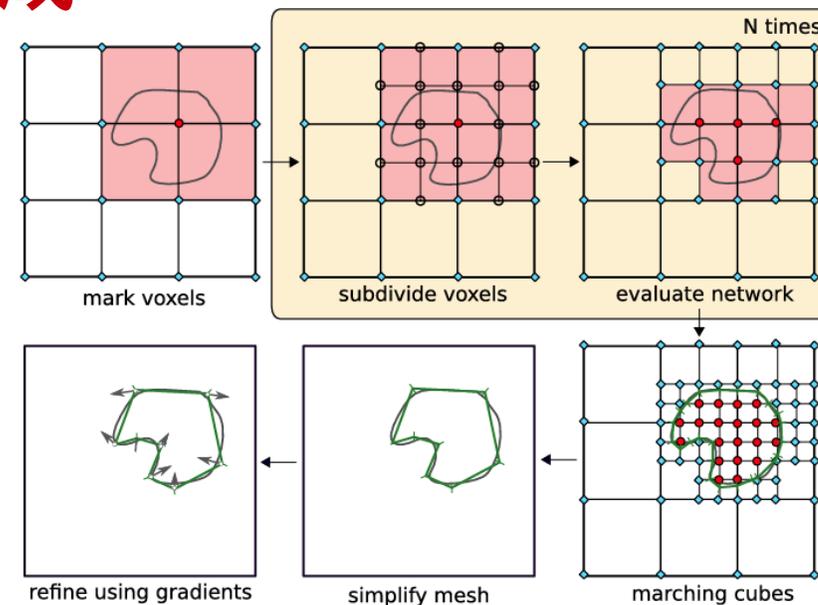
Voxel内の占有率 : $o: \mathbf{R}^3 \rightarrow \{0,1\}$

$$L_B(\theta) = \frac{1}{|B|} \sum_{i=1}^{|B|} \sum_{j=1}^K L(f_{\theta}(p_{ij}, x_i), o_{ij})$$

https://github.com/autonomousvision/occupancy_networks



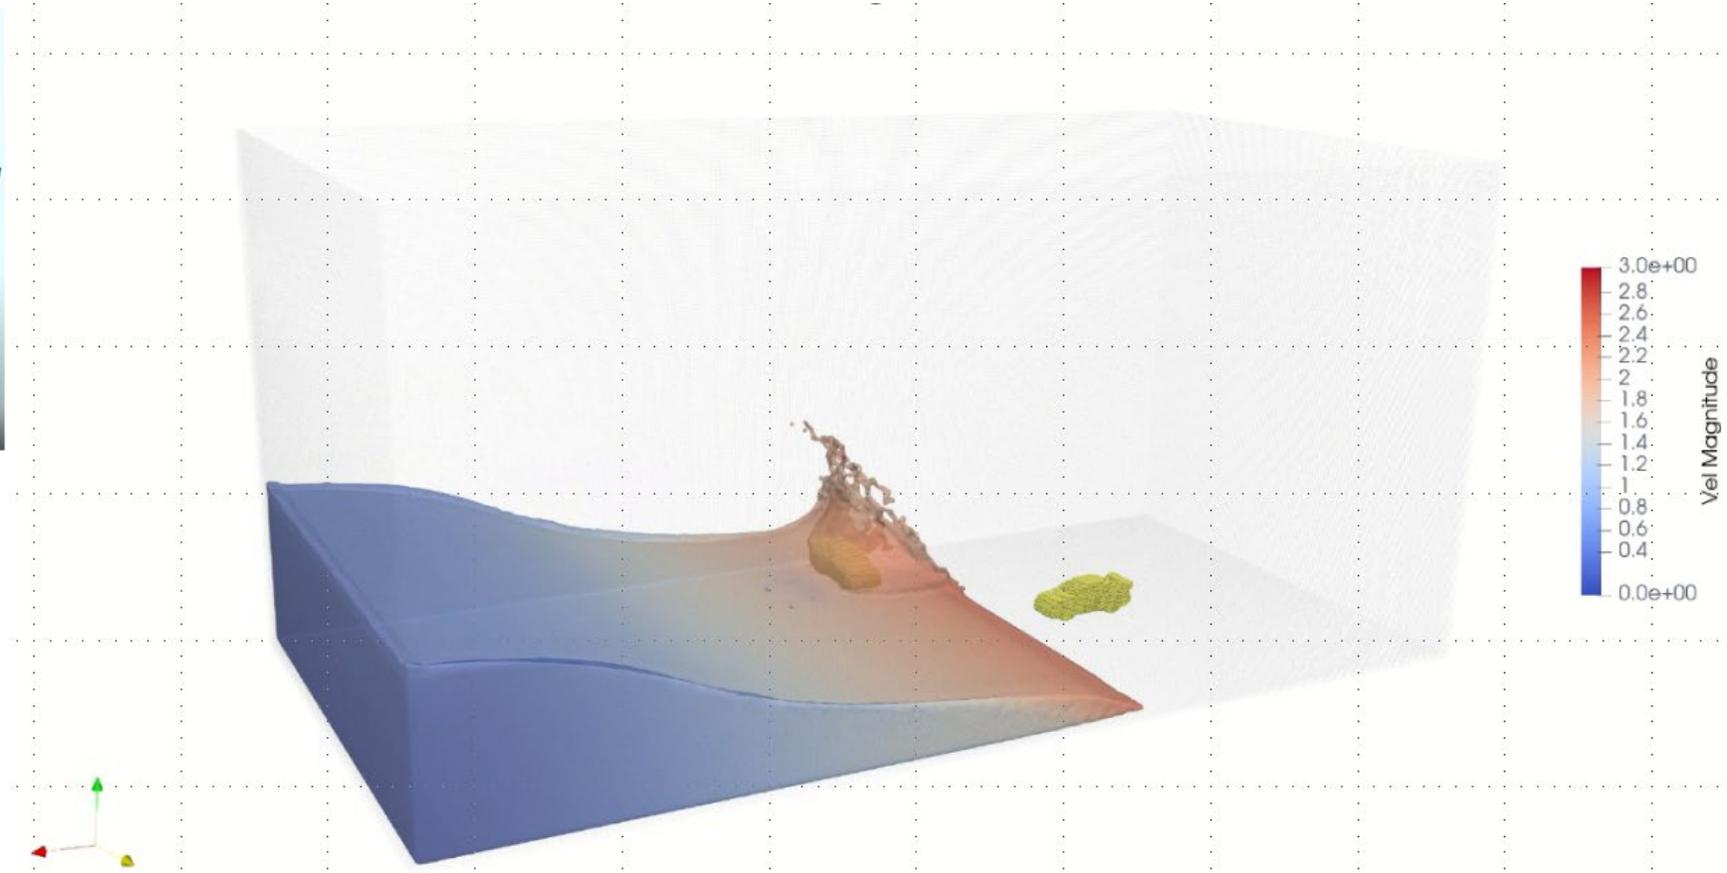
- 概形をとらえたメッシュ生成は可能
- 角の精度はまだ不十分



生成したメッシュを利用した粒子法での解析テスト



DualSPHysics : Urban flooding
<https://dual.sphysics.org/animations/>



- 形状が精度におよぼす影響が比較的小さい条件なら解析が可能。
- 空力性能の推定にはさらに高精度なメッシュの生成が必要。

まとめ

データ同化によるパラメータ最適化

- アンサンブルカルマンフィルタによりLESの結果をRANSに同化
- 最適化された乱流モデルパラメータによりRANSのLESに対する再現性が向上
- 断面形状を変化させたケースでも流れ場の再現性が向上
- 抵抗係数に関しては必ずしも再現性が向上するとは限らない

表面形状の自動生成

- 2次元の画像データからニューラルネットワークにより3次元モデルの生成を検討
- NeRFは良好なシーンを再現可能だがメッシュの生成には適していない
- メッシュ生成手法は様々なものが研究されているが、
解析に十分な精度のメッシュを生成することは今後の課題。