

Conditional variational auto-encoder を用いた翼形状生成

Generating airfoil shape using conditional variational auto-encoder

米倉一男^{*1} 服部均^{*1} 西津卓史^{*1}
 Kazuo Yonekura Hitoshi Hattori Takafumi Nishizu

^{*1}株式会社 I H I
 IHI Corporation

We train an inference model for airfoil shape in application of mechanical design. It is important to obtain a reasonable shape that shows a specific performance that designers need. We use conditional variational auto-encoder to train inference model. We use NACA airfoil to evaluate the proposed method, and show the method outputs reasonable shapes. However, when we use naive discretization method of shapes, generated shape involves small perturbation which leads self-intersection. Since such perturbation is not desired in view of mechanical desing, we use Gaussian process to smooth the shape.

1. はじめに

航空用エンジンや車両用過給機などをはじめとする機械の設計では、要求仕様を満足したうえでなるべく性能の良い形状を見つけ出すことが重要である。さらに、コスト削減のために、設計にかかる時間をなるべく短縮することが求められる。また機械設計ではそれまでの設計実績や文献等を参考にして行われることがあるため、その場合においても、設計時間の短縮が求められる。

機械設計では設計実績や検討段階の形状および性能値の情報が蓄積されている。[Yonekura 2014] は、形状を複数集めて主成分分析を用いて分析することで形状の特徴量を抽出して形状最適化を行う手法を構築した。[Nita 2014] はその手法を文献で公開された多くの形状を集めて適用することで、高性能なタービン翼の冷却孔を創出した。しかしこの手法は特徴量を抽出するだけで性能値を指定して形状を創出することはできないという特徴があったため、短時間で所望の性能の形状を見つけ出すことが難しかった。

主成分分析と同様に特徴量抽出を行う手法の一つとして、auto-encoder (AE) や variational auto-encoder (VAE) [Kingma 2015] などがある。これらはニューラルネットワークを利用してデータの特徴量抽出と再構成に使用される。例えば文献[佐藤 2018]では VAE を材料の欠陥判定に用いている。VAE にラベルを処理するノードを付加して、条件付きの特徴量抽出を行う手法が conditional VAE (CVAE) [Sohn 2014] である。本報告では CVAE を用いて前述の課題を解決し、指定した性能の翼を生成する手法を提案する。CVAE を用いれば短時間で所望の性能の翼が得られ、設計作業が行いやすくなる。さらに性能値と関係づけた特徴抽出ができるため、物理現象に対するより深い洞察を得られることが期待される。本稿では翼形状を用いて数値実験を行い、提案した CVAE の有効性を検証する。

2. 形状生成手法

本稿では形状を点列を用いて表現する。したがって曲線を折れ線近似することになる。機械設計における性能計算で広く使用される CFD (Computational Fluid Dynamics) 計算では、

形状に沿うように計算格子を設定して微分方程式を数値的に解く。このとき、形状は計算格子に沿った線分で近似されるため、形状を線分の集合として表現すること自体には問題はない。しかし一方で、線分の集合はジグザグになったり交差する可能性がある。これは前述の数値計算の観点からも許容できず、滑らかな線分近似になる必要がある。

本稿では扱う形状は二次元形状とし、二通りの方法で点列を扱う。一つ目は図 1 に示すように、等間隔の X 座標に対する Y 座標を変数とする方法である。これは [Yonekura 2014] と同じ手法である。これを手法 A と呼ぶ。手法 A を用いれば線分同士の交差が発生しにくいという特徴があるが、 X 方向の軸長さが一定である必要があり、使用できる形状が限定される。二つ目は形状を任意の方法で離散化し、その X, Y 座標を変数とする方法である。これを手法 B と呼ぶ。この方法では線分同士の交差が起こりやすくなるが、任意の形状を扱えるため自由度が高い。




図 1: 形状の離散化手法 A [Yonekura 2014].

3. 数値実験

本章では、二次元層流翼形である NACA 翼 [Abbott 1949] を用いた形状生成を行う。機械学習ライブラリとして Chainer [Tokui 2015] を使用した。NACA 翼は NACA が体系的に調査した翼のデータベースで、パラメータを指定すれば一意に翼形状が定まる。今回は 4 桁系列と呼ばれる翼を対象とし、ラベルとして揚力係数 (CL; Lift Coefficient) を用いる。あらかじめ

連絡先: 米倉一男, 株式会社 I H I, 神奈川県横浜市磯子区新中原町 1, kazuo.yonekura@ihi.co.jp

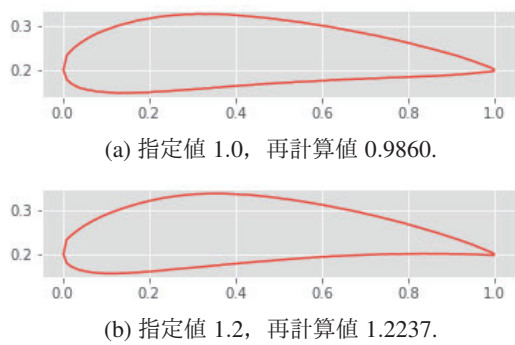


図 2: 手法 A で生成した形状の例




図 3: 手法 B で生成した形状とその平滑化の例.

手法 A は 189 個, 手法 B は 4560 個の形状を作成して揚力係数を計算し, それぞれ CVAE で学習した. ただし揚力係数は正規化した. 手法 A を用いて生成した形状を図 2 に示す. CL を指定して点列を生成し, その点列を用いて再度 CFD 計算によって揚力係数を計算した. 手法 B を用いた場合, 生成された点列がいびつな形をしているため, ガウス過程を用いて平滑化した. 図 3 に点列と平滑化された曲線を示す. ただし座標は翼弦長を単位長さとしている. いびつな形をしている理由は, 収束の過程における残差が残っているためと考えられる. 点列と平滑曲線との距離は翼長さに対して約 0.5% 程度と小さいが, このようにいびつな点列では CFD 計算ができない場合がある. 平滑な曲線を用いて揚力係数を再計算した結果を図 4 に示す. 滑らかな翼形状が得られ, 指定値に近い性能値が得られた.

最後に, 指定した性能値に対する実際の性能値を比較する. 揚力係数を 0.8 から 1.2 まで 0.05 刻みで変更して手法 A, B それぞれで形状を生成し, 再度性能値を計算した. その性能値の平均相対誤差を表 1 に示す. 手法 A と B のどちらも 2.3% 以下の誤差で大きな差は無く, 離散化手法による差は小さいと考えられる. ただし, 手法 A では例えば翼長さが一定でなければならないなどの制限があり, 一般的な形状に対して使用できる手法ではない.

4. 結論

本稿では CVAE を用いた翼形状生成手法を提案した. 本手法を用いることで, 指定した性能の形状を短時間に得ることができる. NACA 翼を使用した数値実験では, 生成した形状の性能値の誤差は 3% 以内と小さく, 本手法は有効であると考えられる. しかし形状の離散化手法によっては形状に凹凸があったり線分同士が交差して形状として成立しない場合があるため, 後処理として滑らかにすることが必要である.




図 4: 手法 B で生成した形状の例

表 1: 指定値との平均相対誤差.

	手法 A	手法 B
平均相対誤差	2.16%	2.25%

参考文献

[Yonekura 2014] Yonekura, K. and Watanabe, O.: A Shape Parameterization Method Using Principal Component Analysis in Applications to Parametric Shape Optimization, Journal of Mechanical Design, Vol. 136 (12), 121401, (2014).

[Nita 2014] Nita, K., Okita, Y., Nakamata, C., Kubo, S., Yonekura, K., and Watanabe, O.: Film Cooling Hole Shape Optimization Using Proper Orthogonal Decomposition, ASME Turbo Expo 2014, GT2014-27239, (2014).

[Kingma 2015] Kingma, D.P., Rezende, D.J., Mohamed, S., Welling, M.:Semi-supervised learning with deep generative models, Advances in Neural Information Processing Systems 27, pp. 3581–3589, (2014).

[Sohn 2014] Sohn, K., Lee, H., and Yan, X.: Learning Structured Output Representation using Deep Conditional Generative Models, Advances in Neural Information Processing Systems 28, pp. 3483–3491, (2015).

[佐藤 2018] 佐藤玄, 前田宗彦, 鈴木一将, 大島誉寿, 内田雄太, 米倉一男: 形状特徴項を用いた VAE の復元性能の向上, 第 21 回情報論的学習理論ワークショップ, D1-36, (2018).

[Abbott 1949] Abbott, I.H. and Von Doenhoff, A.E.: Theory of Wing Sections Including a Summary of Airfoil Data, Dover, (1949).

[Tokui 2015] Tokui, S., Oono, K., Hido, S. and Clayton, J., Chainer: a Next-Generation Open Source Framework for Deep Learning, Proceedings of Workshop on Machine Learning Systems(LearningSys) in The Twenty-ninth Annual Conference on Neural Information Processing Systems (NIPS), (2015).