

미사일 형상 설계 효율화를 위한 변이형 오토인코더 기반 설계 공간 재설정

신중현^{1,2}, 유강국³, 강유업¹, 정신규², 최종원⁴, 이상아^{1*}¹한국생산기술연구원 제조AI연구센터, ²경희대학교 기계공학과, ³서울대학교 항공우주공학과 ⁴중앙대학교 첨단영상대학원

VARIATIONAL AUTOENCODER BASED REDESIGNING DESIGN SPACES FOR EFFICIENT MISSILE GEOMETRY DESIGN

J. Shin^{1,2}, K. You³, Y. Kang¹, S. Jeong², J. Choi⁴ and S. Lee^{1*}¹Manufacturing AI Research Center, Korea Institute of Industrial Technology²Dept. of Mechanical Engineering, Kyung Hee Univ.³Dept. of Aerospace Engineering, Seoul National Univ.⁴Graduate School of Advanced Imaging Sciences, Multimedia and Film(GSAIM), Chung-Ang Univ.

*Corresponding author, E-mail: ivory@kitech.re.kr

Keywords:

공력 최적설계
(Aerodynamic design optimization),
변이형 오토인코더
(Variational autoencoder),
생성형 모델(Generative model),
차원 축소 모델(Reduced-order modeling)

ABSTRACT

Aerodynamic shape optimization is often hindered by high-dimensional design spaces containing large infeasible regions, which complicates the search for optimal solutions. This study proposes a methodology to redesign the design space for 3D missile geometry using a variational autoencoder (VAE) to overcome these challenges. A continuous, low-dimensional latent space that implicitly embeds the complex feasibility constraints is learned by training a VAE exclusively on a dataset of feasible shapes. The results demonstrate that this redesigned space significantly improves the generation rate of feasible designs compared to the original space. This study concludes that redesigning the design space with a VAE is a promising strategy to enhance the efficiency and stability of 3D shape optimization by transforming a complex, constrained problem into a more tractable, unconstrained alternative.

Received | 18 August, 2025

Revised | 30 September, 2025

Accepted | 30 September, 2025



This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0>) which permits unrestricted noncommercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

© KSCFE 2025

1. 서론

미사일과 같은 비행체의 경우 설계 단계에서 설정된 공력 성능이 비행시간, 속도, 안정성과 같은 주요 성능에 직결되기에 공력 성능을 극대화하는 공력 형상 최적 설계를 진행하는 것이 중요하다[1]. 일반적인 공력 형상 최적 설계 과정은 다음과 같다[2]. 먼저 설계변수(design variables)와 제약조건(constraint)을 고려하여 설계공간을 정의한다. 그리고 정의된 설계공간 안에서 전산유체역학(CFD) 시뮬레이션과 같은 고비용의 계산을 통해 최적화 알고리즘으로 선별된 실험점에 대한 목적 성능을 평가하게

된다. 하지만 이 과정은 많은 시간과 계산 비용을 요구하므로, 실험계획법을 통해 선정된 형상에 대한 해석 결과를 바탕으로 설계공간 전체의 성능을 예측하는 대리 모델(surrogate model)을 생성한다. 그 후, 대리 모델과 최적화 알고리즘을 통해 최적해를 탐색하고, 탐색한 최적해가 목적 성능에 도달할 때까지 이 과정을 반복하게 된다.

이 중 설계 공간 정의 단계는 탐색할 해의 범위를 결정하므로 최적 설계에서 매우 중요하다[3]. 그러나 설계 공간을 정의할 때, 설계 변수가 늘어날수록 차원의 저주(curse of dimensionality) 문제로 인해 탐색해야 하는 설계공간의 부피가 기하급수적으로 커지게 된다. 이 과정에서 변수 간의 관계는 비선형성이 높아져 해석이 어려워지고, 결국 실현 불가능한(infeasible) 영역도 함께 급격히 커지게 되며, 다수의 제약 조건 하에서 전체 설계 공간 내 실현 가능한 영역이 매우 복잡한 형태를 띠게 된다. 결과적으로 방대한 설계공간을 한정된 데이터만으로 탐색하여 최적해를 찾는 것은 최적화 과정을 비효율적으로 만들며, 실현 불가능한 영역까지 포함해 샘플링하면 대리 모델 구축에 또 다른 계산 비용 문제를 발생시킨다[4]. 그러므로 실현 가능한 영역은 충분히 포함하면서 필요하지 않은 실현 불가능한 영역은 최소화하는 설계 공간을 설정할 필요가 있다[5].

이러한 설계 공간의 근본적인 문제들을 해결하기 위해, 최근 딥러닝 기반의 생성형 모델(generative model)이 새로운 해법으로 주목받고 있다[6]. 생성형 모델은 주어진 데이터의 기저 분포를 학습하여 기존에 없던 새로운 데이터를 생성하는 인공지능 모델이다. Variational Autoencoder(VAE)와 Generative Adversarial Networks(GAN), Diffusion model과 같은 다양한 생성형 모델들이 활발히 적용되고 있고, 생성형 모델을 사용하여 다양한 디자인을 생성하여 초기 개념설계 단계에서 사용하고 있다. 생성형 모델을 활용한 접근법의 핵심은, 기존의 방대한 설계 공간 전체를 탐색하는 대신 오직 실현 가능한 설계 데이터만을 학습하여 설계 공간 자체를 재구성하는 것이다. 즉, 물리적 또는 기하학적 제약 조건을 만족하는 실현 가능한 설계안들로 구성된 데이터셋으로부터, 생성형 모델은 타당한 설계의 규칙을 암묵적으로 학습한다. 이를 통해 모델은 실현 가능한 설계안들이 존재하는 저차원의 연속적인 잠재 공간(latent space)을 구축하게 된다.

특히 VAE는 이러한 목적에 매우 적합한 모델로 평가받는다. VAE는 인코더(encoder)와 디코더(decoder)로 이루어진 구조를 통해 고차원의 설계 데이터를 저차원의 잠재 공간으로 압축하고 다시 복원하는 과정에서, 잠재 공간이 통계적으로 정규화 되고 연속적인 특성을 갖도록 학습한다. 이렇게 학습된 잠재 공간은 실현 가능한 설계들로만 채워진 새로운 설계 공간 역할을 하며, 이 공간 내에서 샘플링 된 점들은 높은 확률로 실현 가능한 설계안을 생성한다. 결과적으로, 복잡한 제약 조건이 포함된 고차원 최적화 문제를 다루기 쉬운 저차원의 비제약(unconstrained) 최적화 문제로 변환하여 탐색 효율성을 극대화할 수 있다.

지금까지 VAE 모델을 다양한 형상에 적용한 연구들이 있었지만, 대부분 에어포일과 같은 2차원 설계 문제에 집중되었으며[2], 미사일에 관한 연구 또한 2차원에 한정된 것을 확인할 수 있다[7]. 본 연구에서는 이러한 VAE 기반 방법론을 3차원 미사일 형상 설계 문제에 적용하였으며, 특히 실현 가능한 영역에 속하는 미사일 설계 변수 데이터만을 학습에 사용하여 설계 공간을 재설정 가능성을 확인하였다.

2. 배경

2.1 공학 설계에 적용된 생성형 모델

공학 설계 분야에서 생성형 모델은 설계 공간 탐색의 효율성을 높이고 혁신적인 설계를 생성하기 위한 강력한 도구로 부상하고 있다. 특히 GAN, VAE, Diffusion model은 고차원의 복잡한 설계 데이터를 학습하여 새로운 설계안을 생성하는 데 활발히 적용되고 있다[6].

2.1.1 GAN 적용 사례

GAN[8]은 생성자(generator)와 판별자(discriminator)의 적대적 학습을 통해 매우 사실적인 데이터를 생성하는 능력으로 주목받았다. 공학 설계 분야에서는 에어포일이나 3차원 형상 생성에 GAN을 적용하려는 시도가 있었다. Chen 등[9]은 다중 목표 최적화를 위해 성능과 다양성을 동시에 고려하는 MO-PaDGAN을 제안하여 에어포일 설계에 적용했다. Nobari 등[10]은 RANGE-GAN을 통해 기존의 2차원 형상 생성 문제를 3차원으로 확장하여, ShapeNet 데이터셋을 이용해 다양한 3차원 항공기 형상을 생성하는 연구를 수행했다. Shu 등[11]은 GAN이 생성한 3차원 항공기 형상을 해석을 통해 자동 필터링함으로써 물리적으로 검증된 형상 생성 프레임워크를 제안하였다. 하지만 GAN을 사용하면 학습 과정이 불안정하고, 학습 데이터의 일부 모드만 학습하고 나머지 다양성을 놓치는 모드 붕괴(mode collapse) 현상이 발생하기 쉽다. 이를 해결하기 위해 앞선 연구들은 손실 함수에 성능, 다양성, 또는 설계 제약조건과 관련된 항을 추가하는 기법을 사용한다.

2.1.2 Diffusion model 적용 사례

Diffusion model[12]은 순수한 노이즈에서 점진적으로 노이즈를 제거하여 데이터를 복원하는 방식으로 작동하며, 이미 생성 분야에서 GAN보다 높은 품질과 다양성을 가진다. Bagazinski 등[13]은 C-shipGen 연구에서 실현 가능한 선박 형상 데이터만을 이용하여 그 분포를 Diffusion model에 학습시켰고, 그 결과 기존의 무작위 샘플링 방식보다 훨씬 높은 비율로 실현 가능한 설계안을 생성할 수 있었다. Graves 등[14]은 에어포일 데이터셋을 기반으로 원하는 성능을 갖는 2차원 고품질 에어포일을 생성하며, 유효하지 않은 설계 생성 비율을 감소시켰다. 그러나 Diffusion model은 점진적인 노이즈 제거 과정을 여러 번 반복해야 하므로, 다른 생성 모델에 비해 학습과 데이터 생성에 많은 계산 비용이 드는 단점이 있다 [15].

2.1.3 VAE 적용 사례

VAE[16]는 GAN의 학습 불안정성이나 Diffusion model의 높은 계산 비용과 같은 문제에서 비교적 자유로워, 설계 공간 분석을 위한 차원 축소 모델(reduced-order modeling)로 널리 채택되어 왔다. VAE는 데이터를 저차원의 잠재 공간으로 압축하고 다시 복원하는 과정에서 데이터의 비선형적 특징을 효과적으로 학습한다.

Yonekura 등[17]은 조건부 VAE(Conditional VAE)를 사용하여 원하는 공력 성능을 만족하는 에어포일을 생성하는 연구를 수행했으며, Kang 등[18]은 VAE를 통해 에어포일의 물리적 지표를 직접 조절하여 직관적으로 형상을 생성하는 방법을 제안했다. 이처럼 VAE는 설계 변수들 간의 복잡한 관계와 특징을 학습하여 데이터를 의미 있는 저차원 잠재 공간으로 매개변수화할 수 있다. 이렇게 학습된 잠재 공간은 기존의 복잡한 설계 공간을 대체하며, 연속적이고 잘 구조화된 새로운 설계 공간으로 사용될 수 있다.

2.2 VAE

VAE는 AE(Autoencoder) 구조와 동일하게, 입력 데이터를 저차원의 잠재 공간으로 매핑하는 인코더와 잠재 공간의 벡터로부터 원본 데이터를 재구성하는 디코더로 구성된다. 다만 Fig. 1에서 볼 수 있듯이 AE는 인코더가 단일 잠재 변수 z 를 바로 출력하지만, VAE는 인코더가 잠재 분포의 평균 μ 와 표준편차 σ 를 예측하고, 이 두 파라미터로부터 확률적 난수 ϵ 을 이용해 잠재 변수 z 를 샘플링한다는 차이가 있다.




Fig. 1. Architectures of (a)AE and (b)VAE

VAE 인코더는 고차원 입력데이터 $\mathbf{x}$ 를 저차원 잠재 변수 $\mathbf{z}$ 로 압축하는 것이 목적이며, 수식 $q_\phi(\mathbf{z}|\mathbf{x})$ 로 표현된다. 이때 $\mathbf{z}$ 는 특정 값이 아닌 평균 μ 와 표준편차 σ 를 갖는 정규분포로 출력되며, ϕ 는 인코더 신경망의 파라미터이다. 디코더는 잠재 변수 $\mathbf{z}$ 를 받아 원본데이터 $\mathbf{x}$ 와 유사한 결과물 $\mathbf{x}'$ 으로 복원하는 것이며, 수식 $p_\theta(\mathbf{x}|\mathbf{z})$ 로 표현된다. 여기서 θ 는 디코더 신경망의 파라미터이다.

VAE의 손실 함수는 식(1)과 같이 재구성 손실(reconstruction loss) $E_{q_\phi(\mathbf{z}|\mathbf{x})}[\log p_\theta(\mathbf{x}|\mathbf{z})]$ 과 정규화 손실(regularization loss) $D_{KL}(q_\phi(\mathbf{z}|\mathbf{x})||p(\mathbf{z}))$ 두 가지 항의 합으로 이루어진다. 재구성 손실은 잠재변수 $\mathbf{z}$ 로부터 원본데이터 $\mathbf{x}$ 가 생성될 가능성도(likelihood)를 이용하여, 입력 데이터와 디코더가 재구성한 데이터 간의 차이를 최소화하여 정보의 압축 및 복원 능력을 높이도록 한다. 정규화 손실은 두 확률 분포의 유사도를 측정하는 KL(Kullback-Leibler) divergence를 사용하여, 인코더가 만든 잠재 공간의 확률 분포 $q_\phi(\mathbf{z}|\mathbf{x})$ 가 표준 정규 분포와 같이 사전에 정의된 분포 $p(\mathbf{z})$ 와 유사해지도록 강제한다. 표준 VAE에서는 두 손실의 가중치가 동일하지만, β -VAE[19]는 식(2)과 같이 정규화 손실 항에 하이퍼파라미터 β 를 도입하여 재구성 손실과 정규화 손실 간의 균형을 직접 제어할 수 있다.

$$\mathcal{L}_{VAE}(\theta, \phi; \mathbf{x}, \mathbf{z}) = E_{q_\phi(\mathbf{z}|\mathbf{x})}[\log p_\theta(\mathbf{x}|\mathbf{z})] - D_{KL}(q_\phi(\mathbf{z}|\mathbf{x})||p(\mathbf{z})) \quad (1)$$

$$\mathcal{L}_{\beta-VAE} = \mathcal{L}_{reconstruction} + \beta \cdot \mathcal{L}_{KL-divergence} \quad (2)$$

이러한 구조를 통해 VAE는 다음과 같은 두 가지 중요한 특징을 갖는다. 먼저 생성 모델로서의 특징이다. VAE는 데이터에 내재된 복잡한 비선형 관계를 학습하여, 이를 통계적으로 정규화된 연속적인 잠재 공간으로 변환할 수 있다. 이렇게 구조화된 잠재 공간을 기반으로 확률적 모델링이 가능해져, 잠재 공간에서 새로운 벡터를 샘플링하여 기존 학습 데이터와 유사하면서도 새로운 형상을 생성할 수 있다. 특히 실현 가능한 설계 데이터만을 학습에 사용하면, 생성된 형상 역시 높은 확률로 실현 가능성을 보장받게 된다. 따라서 VAE로 학습된 잠재 공간은 실현 가능한 설계들로 채워진 새로운 설계 공간으로 정의될 수 있으며, 이를 통해 효율적으로 다양한 형상을 탐색할 수 있다.

또 다른 특징은 특성 분리(disentanglement)이다. 일반적으로 β 를 크게 설정하면 정규화 손실이 강화되어 잠재 분포가 표준 정규분포에 더 밀착되며, 잠재 공간의 각 잠재 변수들이 데이터의 독립적인 특징을 뚜렷하게 학습하도록 유도할 수 있다. 예를 들어, 사람 얼굴 이미지를 학습할 때 특정 잠재 변수가 얼굴 방향, 표정, 또는 머리 스타일 등을 독립적으로 제어하도록 학습할 수 있다[20]. 이 특성 분리 특징을 공학 설계에 적용하면, 미사일의 설계 변수 관계를 각 잠재 변수에 독립적으로 학습시켜, 설계자가 원하는 성능을 가진 형상을 직관적으로 생성할 수 있다.

3. 방법론

3.1 데이터 준비

본 연구에서 제안하는 VAE 기반 설계 공간 재설계 방법론을 구현하기 위해, Fig. 2의 3차원 미사일 형상[21]을 기준으로 하는 데이터를 준비하고, VAE 모델을 학습시키는 과정을 수행하였다. 데이터 준비 단계에서는 기준 형상을 정의하고, 설계 변수 샘플링 및 실현 가능한 형상만을 사용하기 위한 제약조건 필터링을 통해 VAE 모델 학습 데이터셋을 구축하였다.



Fig. 2. NASA TP-2157 3D geometry

3.1.1 Baseline model

본 연구의 기준 형상은 NASA의 공개 기술 보고서(TP-2157)[22]에 명시된 카나드 제어 미사일로 선정하였다. 이 미사일은 크게 body, canard, tail 세 가지 주요 구성 요소로 이루어져 있다. 미사일의 3차원 형상을 정의하기 위해, 반실험적 기법을 이용한 공력 해석 프로그램인 Missile DATCOM[23] 미사일 변수 정의에 따라 Fig. 3와 같이 총 16개의 설계 변수를 선정하였다.




Fig. 3. Missile design variables

각 설계 변수는 Table 1과 같이 공력 특성에 미치는 민감도에 따라 기준 형상의 설계변수 값을 중심으로 차등적인 범위를 갖도록 설정하였다. 공력 성능에 큰 영향을 끼치는 설계변수는 비교적 좁은 범위로 제한해서 비현실적인 형상이 생성

되는 것을 방지했으며, 공력 성능에 적은 영향을 끼치는 설계변수의 범위는 크게 설정하여 새로운 설계를 가능하도록 한다. 이렇게 정의된 초기 설계 공간 내에서, 실험계획법 Latin Hypercube Sampling(LHS)을 사용하여 총 10,000개의 설계 변수 조합을 생성하였다.

Table 1. Missile design variable definition and range

Variables	Description	Lower limit	Baseline	Upper limit
L_{Nose}	Nose length	0.0857	0.0953	0.1048
D_{Nose}	Nose diameter	0.0381	0.0424	0.0464
L_{Center}	Centerbody length	0.8350	0.9278	1.0205
XLE_{root}^1	Canard root leading edge position	0.120	0.158	0.200
$Chord_{root}^1$	Canard root chord length	0.090	0.111	0.130
$Chord_{tip}^1$	Canard tip chord length	0.0250	0.0333	0.0400
$SSPAN^1$	Canard fin span	0.0630	0.0724	0.0820
Z_{upper}^1	Canard airfoil thickness	0.0206	0.0229	0.0252
$LMax_{root}^1$	Canard root max thickness position	0.5134	0.5705	0.6275
$LMax_{tip}^1$	Canard tip max thickness position	0.5081	0.5645	0.6210
XLE_{root}^2	Tail root leading edge position	0.6700	0.8072	0.8200
$Chord_{root}^2$	Tail root chord length	0.1800	0.2159	0.2300
$Chord_{tip}^2$	Tail tip chord length	0.1000	0.1255	0.1500
$SSPAN^2$	Tail fin span	0.0700	0.0904	0.1100
Z_{upper}^2	Tail airfoil thickness	0.005002	0.005558	0.006113
$LMax_{root}^2$	Tail root max thickness position	0.06712	0.07458	0.08203

Unit: m

3.1.2 제약조건

초기 LHS로 생성된 10,000개의 설계 변수 조합에는 실현 불가능한 형상들이 다수 포함되어 있다. 따라서 유효한 학습 데이터셋을 구축하기 위해, 본 연구에서는 기하학적 제약조건과 공력 제약조건을 순차적으로 적용하여 데이터를 필터링하였다.

먼저, 물리적으로 성립할 수 없거나 비현실적인 형상들을 학습 데이터에서 배제하기 위해, 기하학적 제약조건을 정의하고 이를 만족하지 않는 샘플들을 필터링하였다. Tail이 body에 부착되지 않거나 각 구성 요소의 크기가 비정상적으로 커지거나 작아지는 경우가 이에 해당하며, Table 2에 3개의 기하학적 제약조건을 나타내었고, 이때 X 는 설계변수 벡터이며, α_n 과 c_n 은 제약조건을 위한 양의 상수이다.

Table 2. Definition of geometric constraints

Geometric constraints
$g_1(X) : XLE_{root}^2 + Chord_{root}^2 - L_{Nose} - L_{Center} \leq 0$
$g_2(X) : Chord_{root}^1 - \alpha_1 Chord_{tip}^1 < c_1$
$g_3(X) : Chord_{root}^2 - \alpha_2 Chord_{tip}^2 < c_2$

Fig. 4에서 기하학적 제약조건에 따라 표현된 샘플들을 시각화하였고, 실현 가능한 영역과 실현 불가능한 영역의 관계를 볼 수 있다. 각 축은 기하학적 제약조건 $g_1(X)$ 과 직접적으로 관련된 4개의 설계변수 중 L_{Center} 와 XLE_{root}^2 이며, 개별 샘플들이 2차원 설계 공간에 점으로 표현된다. 기하학적으로 실현 가능한 데이터(파란색)와 실현 불가능한 데이터(회색)의 경계가 불분명한 것을 볼 수 있으며, 이는 두 영역 간의 경계가 비선형적임을 보여준다. 또한 각 영역에서 추출된 대표적인 미사일 형상을 함께 도시하여 제약조건의 물리적 의미를 직관적으로 볼 수 있다. 좌측 미사일 형상은 실현 불가능한 영역의 랜덤 형상 예시이며, 꼬리날개가 동체에 정확히 부착되지 않는 반면, 우측 미사일 형상은 기하학적으로 온전한 것을 확인할 수 있다. 이러한 기하학적 제약조건 필터링 과정을 통해 초기 10,000개의 샘플 중 4,702개의 샘플만이 최종적으로 선별되었다.




Fig. 4. Design map and representative missile shapes illustrating geometric feasibility filtering

다음으로, 기하학적으로는 유효하지만 공력 성능 요구조건을 만족하지 못하는 데이터를 추가로 필터링했다. 미사일 공력 해석 프로그램 Missile DATCOM을 이용하여 Table 3의 비행 조건에서 공력 해석을 진행했다. 비행조건은 [22]를 참고하였다. 미사일의 운용 특성을 고려하여 양력은 크고 항력은 작은 성능을 목적 성능으로 했고, 양력계수 $C_L > C_L^*$, 항력계수 $C_D < C_D^*$ 로 공력 제약조건을 적용하였다[24]. 이때 C_L^* , C_D^* 는 설계 요구 성능을 기준으로 설정한 설정 값이다. 이렇게 얻은 실현 가능한 데이터만을 사용해 VAE를 학습함으로써, 잠재 공간이 실현 가능한 설계 범위에 집중되어 표현 학습이 더욱 효율적으로 이루어질 수 있게 하였다.

Table 3. Missile DATCOM flight condition

Flight condition	
Mach	1.75
Angle of attack	$\alpha = 2^\circ$
Sideslip angle	$\beta = 2^\circ$
Altitude	Sea level

최종적으로 공력 제약조건 필터링 과정을 통해 4,702개의 샘플 중 3,405개의 샘플만이 실현 가능한 데이터로 선별되었다. Fig. 5는 필터링을 통해 선별된 3,405개의 실현 가능한 설계 샘플들과 기준 형상을 2차원으로 중첩하여 시각화한 그림이다. 회색으로 표시된 영역은 실현 가능한 설계안들이 갖는 기하학적 형상의 전체 범위를 나타내며, 이를 통해 body, canard, tail의 크기와 위치가 어느 정도의 변화 폭을 갖는지 직관적으로 확인할 수 있다.




Fig. 5. 2D missile geometry of baseline model and feasible samples

Fig. 6은 16차원의 실현 가능한 설계변수 데이터와 실현 불가능한 설계변수 데이터를 주성분 분석(Principal Component Analysis, PCA)을 통해 2차원의 설계공간으로 시각화한 그림이다. 그림에서 볼 수 있듯, 실현 가능한 데이터와 불가능한 데이터가 명확한 경계 없이 복잡하게 얹혀 있어, 두 데이터를 함께 사용할 경우 이 경계를 구분하는 모델을 학습시키는 것은 어렵다. 따라서 본 연구에서는 VAE가 이 복잡한 경계를 학습하는 부담에서 벗어나 오직 실현 가능한 데이터의 내재적 분포와 특징 학습에만 집중할 수 있도록 했으며, 이를 통해 더 안정적이고 효율적으로 실현 가능한 설계 공간을 구축할 수 있을 것이라 기대했다.




Fig. 6. Design space map with feasible and infeasible data (a) Feasible and infeasible data with C_L using PCA, (b) Feasible and infeasible data with C_D using PCA

3.2 학습

학습에 사용된 VAE 구조는 Fig.7과 같다. 먼저 scaler를 이용하여 정규화한 16개의 설계변수 값을 입력으로 받으며, 인

코더와 디코더를 통해 다시 설계변수 값을 재구성하게 된다. 인코더와 디코더는 3개의 층(layer)으로 구성되며, 각 층의 크기는 32, 4096, 32이고, 잠재공간의 분포는 표준 정규분포를 따르도록 하였으며 잠재공간의 차원은 14차원으로 설정하였다. 잠재공간의 차원은 설계공간을 효과적으로 압축하면서 재구성 성능을 보존하는 14차원으로 설정하였다. VAE 학습에는 Optimizer로 Adam을, 학습률은 초기 학습률을 0.001로 하고 500 epoch마다 0.5비율로 학습률을 감소시키는 학습률 스케줄러(learning rate scheduler)를 이용하였고, 활성화 함수는 LeakyRelu(Leaky Rectified Linear Unit)를, β 는 하이퍼파라미터 튜닝을 통해 0.07으로 설정하였다. 학습은 50,000 epoch을 진행했으며, 배치 크기는 500으로 하였다.




Fig. 7. VAE Model Architecture

4. 결과

학습된 VAE 모델의 성능을 평가하고, 재설계된 설계 공간의 유효성을 검증하기 위해 전체 데이터셋을 8:1:1의 비율로 나누어 학습(train), 검증(validation), 테스트(test) 세트로 사용하여, 학습된 모델의 재구성 성능, 잠재 공간의 학습 결과, 그리고 재설계된 공간에서의 형상 생성 성능을 분석하였다.

4.1 재구성

학습된 VAE 모델이 원본 설계 변수들을 얼마나 정확하게 복원하는지 평가하기 위해 재구성 성능을 분석하였다. Fig. 8은 16개의 설계 변수별 원본 데이터(x축)와 VAE 디코더를 통해 재구성된 데이터(y축)를 비교한 산점도이다. 모델의 학습 데이터를 회색, 테스트 데이터를 빨간색 점으로 표현하였고, 점들이 $y=x$ 직선 주위에 밀집하여 분포하는 것을 통해, 모델이 원본 설계 변수들을 높은 정확도로 재구성함을 확인할 수 있다. 결정계수 R^2 를 분석하면, 학습 세트에서 0.963 테스트 세트에서 0.8643으로 나타났다. 테스트 세트에서 오차가 상승한 것은 학습 데이터와 테스트 데이터 간의 제한된 유사성으로 인해 발생하였다. 특히, R^2 가 상대적으로 낮게 나타난 설계변수 $Chord_{root}^1$ 과 $Chord_{tip}^1$ 과 $Chord_{root}^2$, $Chord_{tip}^2$ 는 기하학적 제약조건에 의해 서로 강한 상호 의존성을 갖는 변수들이다. 해당 변수들이 독립적으로 존재하기보다 특정 비율이나 관계를 유지해야 하므로, 학습 데이터에 내재된 이러한 관계를 벗어나는 테스트 데이터를 마주했을 때 재구성 오차가 증가한 것으로 분석하였다.




Fig. 8. Reconstruction performance of train and test data for each design variable

Fig. 9는 테스트 데이터에 대한 VAE의 재구성 성능을 시각적으로 보여주는 그림이다. 테스트 데이터에서 무작위로 추출한 여러 원본 형상(회색 실선)과, 이를 VAE가 재구성한 결과(빨간색 점선)를 중첩하여 나타낸다. 대부분의 경우 두 형상이 거의 일치하는 것을 볼 수 있다. 다만 일부 형상에서 관찰되는 차이는 VAE의 정규화 손실의 영향이며, 학습 데이터를 완벽하게 암기하기보다 새로운 설계안을 생성하기 좋은 일반화되고 연속적인 잠재 공간을 학습하는 것을 우선하기 때문에 발생하였다.




Fig. 9. Visual comparison of original and reconstructed shapes for the test set

4.2 잠재공간

VAE는 비지도 방식으로 데이터의 내재적인 특징을 스스로 학습할 수 있다. 본 연구에서는 이렇게 학습된 모델이 의미 있는 저차원 잠재 공간으로 학습되었는지 확인하기 위해 학습된 14차원의 잠재 공간과 원본 16차원 설계 변수 간의 상관 관계를 분석하고, 잠재 변수의 변화에 따른 형상 변화를 관찰하였다.

Table 4는 제약조건에 종속된 설계변수와 이 특징을 학습한 특정 잠재 변수 간의 상관관계를 보여준다. Tail의 $Chord_{root}^2$ 또는 $Chord_{tip}^2$ 가 상대적으로 커지거나 작아지는 경우를 대비하기 위해 설정한 기하학적 제약조건에 의해 두 설계변수는 비례관계를 가지며, 잠재변수 z_1 은 tail의 설계 변수와 강한 음의 상관관계를 맺고 있음을 확인할 수 있다. 또한 canard의 $Chord_{root}^1$ 및 $Chord_{tip}^1$ 도 같은 이유로 비례관계를 가지며, 잠재변수 z_2 는 canard의 설계변수와 강한 양의 상관 관계를 맺고 있음을 확인할 수 있다. 이는 VAE가 단순히 데이터를 압축하는 것을 넘어, 설계 변수들 간의 관계를 포착하여 의미적으로 분리된 특징들을 잠재 공간의 각 축에 투영했음을 알 수 있다.

Table 4. Correlation between design variables and latent variables for train data

	$Chord_{root}^1$	$Chord_{tip}^1$	$Chord_{root}^2$	$Chord_{tip}^2$
z_1	0.11	0.06	-0.57	-0.61
z_2	0.41	0.47	0.29	0.07

Fig. 10는 다른 잠재 변수들은 평균값으로 고정한 채, 특정 잠재 변수를 $\mu - 2\sigma$ 에서 $\mu + 2\sigma$ 까지 1σ 단위로 변화시켰을 때 생성되는 미사일 형상의 변화를 보여준다. Fig. 10(a)에서 잠재변수 z_2 는 canard의 $Chord_{root}^1$ 및 $Chord_{tip}^1$ 와 양의 상관

관계를 가지므로, 잠재 변수의 값이 커짐에 따라 설계 변수 $Chord_{root}^1$ 과 $Chord_{tip}^1$ 이 증가하며, 미사일의 canard 부분의 각 설계변수가 점진적으로 변하는 것을 관찰할 수 있다. Fig. 10(b)에서 잠재변수 z_1 은 tail의 $Chord_{root}^2$ 및 $Chord_{tip}^2$ 와 음의 상관관계를 가지므로, 잠재 변수의 값이 $\mu - 2\sigma$ 에서 $\mu + 2\sigma$ 으로 커짐에 따라 설계 변수 $Chord_{root}^2$ 와 $Chord_{tip}^2$ 이 감소하며 미사일 tail이 점진적으로 변하는 것을 관찰할 수 있고, 학습된 잠재 공간의 잠재변수를 이용해서 직관적인 미사일 형상 제어가 가능한 것을 확인할 수 있다.




Fig. 10. Shifts in generated geometries due to latent variable traversal

4.3 데이터 생성

기존의 실현 가능한 학습 데이터의 설계공간을 학습한 VAE가 실현 가능한 새로운 설계안을 효율적으로 생성하는 능력을 검증하기 위해, Fig. 11과 같이 표준 정규 분포를 따르는 14차원 잠재 공간 내에서 새로운 잠재 벡터를 샘플링하고, 이를 디코더에 통과시켜 새로운 미사일 설계 변수들을 생성하였다. 이때, 표준 정규 분포의 99.7% 신뢰구간에 해당하는 -3σ 에서 3σ 까지의 범위를 사용했으며, -3σ 과 3σ 에서 정규 분포의 누적 분포 함수(cumulative distribution function)값을 최솟값과 최댓값으로 하는 범위 내에서 LHS을 이용해 5,000개의 14차원 잠재 벡터를 샘플링하는 방법을 사용하였다.

이 방법을 통해, LHS을 이용하여 샘플링한 학습 데이터의 특징을 보전하며, VAE가 정규 분포에 따르도록 학습한 잠재 공간을 체계적으로 탐색하고 생성 능력의 전반적인 성능을 검증하고자 하였다.




Fig. 11. Data generation architecture

Fig. 12는 원본 설계 공간(회색)과 VAE의 디코더를 통해 새롭게 생성된 샘플 중 실현 가능한 샘플들의 분포(빨간색)를 PCA를 통해 2차원으로 시각화한 그림이다. 생성된 샘플들이 원본 데이터의 분포를 효과적으로 커버하고 있음을 통해, VAE가 원본 설계 공간의 특징을 성공적으로 학습했음을 알 수 있다. 그리고 초기 설계 공간에서 무작위 LHS로 샘플링했을 때의 실현 가능률은 34.05% (3405/10000)였던 반면, VAE의 잠재 공간에서 샘플링하여 생성된 설계안들의 실현 가능률은 58.74% (2937/5000)로 현저히 높게 나타났다. 이는 VAE가 실현 가능한 설계들의 매니폴드를 학습하여, 재설계된 공간이 실현 불가능한 영역을 상당 부분 배제하고 있음을 의미한다. 이 결과는 본 연구에서 제안한 방법론이 최적화 과정에서 불필요한 탐색을 줄이고 설계 효율을 크게 향상시킬 수 있음을 직접적으로 증명한다.




Fig. 12. Design space of generated data using PCA

Fig. 13은 학습된 VAE의 잠재 공간에서 새로운 잠재 벡터를 샘플링한 후, 디코더를 통해 복원한 3차원 미사일 형상의 다양한 예시이다. 생성된 형상은 각 구성요소가 올바르게 연결된 기하학적으로 실현 가능한 모습이며, 이는 VAE가 실현 가능한 설계 공간의 특징을 성공적으로 학습하여 새로운 설계안을 생성할 수 있음을 시각적으로 보여준다.




Fig. 13. Examples of 3D missile geometries generated by the VAE

5. 결론

본 연구는 VAE가 3차원 미사일 설계를 표현하는 설계공간을 압축되고 연속적인 잠재 공간으로 학습할 수 있음을 확인했다. 특히, 실현 가능한 데이터만을 선별하여 학습함으로써, VAE는 복잡한 제약 조건이 내재된 새로운 설계 공간을 구축하였다. 그리고 학습된 잠재 공간의 각 축이 특정 기하학적 형상과 유의미한 상관관계를 가지며 잠재 변수 조작을 통한 직관적인 형상 제어의 가능성을 제시했고, 설계자가 저차원 공간에서 원하는 형상을 수정하고 탐색할 수 있음을 의미한다. 또한 새로운 설계 공간에서 샘플링하여 생성된 새로운 설계 후보들은 기존의 무작위 샘플링 방식보다 현저히 높은 실현 가능성을 보였다. 따라서 본 연구가 제안하는 모델은 최적화 과정을 지원하는 기반 기술로서의 의미를 가지며, 전체 최적 설계 과정의 계산 비용을 줄이고 효율성을 향상시키는 기반을 마련하였다.

후 기

본 연구는 한국생산기술연구원 Key-Tech사업(KITECH-EH-250001)과 산업통산자원부 로봇산업핵심기술개발사업(RS-2024-00507383)의 지원을 받아 수행된 연구임

References

- [1] 2006, Fleeman, E.L., "Tactical Missile Design (Vol. 468)," *AIAA. J.*, Reston, VA.

- [2] 2022, Li, J., Du, X. and Martins, J.R., “Machine Learning in Aerodynamic Shape Optimization,” *Prog. Aerosp. Sci.*, Vol.134, 100849.
- [3] 2023, Wang, K., Han, Z., Zhang, K. and Song, W., “Efficient Global Aerodynamic Shape Optimization of a Full Aircraft Configuration Considering Trimming,” *Aerosp.*, Vol.10, No.8, p.734.
- [4] 2024, Tian, Y., Zuniga, A., Zhang, X., Dürholt, J.P., Das, P., Chen, J., Matusik, W. and Konaković-Luković, M., “Boundary exploration for Bayesian optimization with unknown physical constraints,” arXiv preprint arXiv:2402.07692.
- [5] 2025, Serani, A. and Diez, M., “A Survey on Design-Space Dimensionality Reduction Methods for Shape Optimization,” *Arch. Comput. Methods Eng.* (in press), arXiv:2405.13944.
- [6] 2022, Regenwetter, L., Nobari, A.H. and Ahmed, F., “Deep Generative Models in Engineering Design: A Review,” *J. Mech. Des.*, Vol.144, No.7, 071704.
- [7] 2022, Wu, P., Yuan, W., Ji, L., Zhou, L., Zhou, Z., Feng, W. and Guo, Y., “Missile Aerodynamic Shape Optimization Design Using Deep Neural Networks,” *Aerosp. Sci. Technol.*, Vol.126, 107640.
- [8] 2020, Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. and Bengio, Y., “Generative Adversarial Networks,” *Commun. ACM*, Vol.63, No.11, pp.139-144.
- [9] 2021, Chen, W. and Ahmed, F., “MO-PaDGAN: Reparameterizing Engineering Designs for Augmented Multi-Objective Optimization,” *Appl. Soft Comput.*, Vol.113, 107909.
- [10] 2021, Nobari, A.H., Chen, W. and Ahmed, F., “Range-GAN: Range-Constrained Generative Adversarial Network for Conditioned Design Synthesis,” *Proc. ASME IDETC-CIE*, Paper.V03BT03A039.
- [11] 2020, Shu, D., Cunningham, J., Stump, G., Miller, S.W., Yukish, M.A., Simpson, T.W. and Tucker, C.S., “3-D Design Using Generative Adversarial Networks and Physics-Based Validation,” *J. Mech. Des.*, Vol.142, No.7, 071701.
- [12] 2020, Ho, J., Jain, A. and Abbeel, P., “Denoising Diffusion Probabilistic Models,” *Adv. Neural Inf. Process. Syst.*, Vol.33, pp.6840-6851.
- [13] 2024, Bagazinski, N.J. and Ahmed, F., “C-ShipGen: a conditional guided diffusion model for parametric ship hull design,” *Proc. International Marine Design Conference*, Paper.841.
- [14] 2024, Graves, R. and Farimani, A.B., “Airfoil Diffusion: Denoising Diffusion Model for Conditional Airfoil Generation,” arXiv preprint arXiv:2408.15898.
- [15] 2021, Dhariwal, P. and Nichol, A., “Diffusion Models Beat GANs on Image Synthesis,” *Adv. Neural Inf. Process. Syst.*, Vol.34(NeurIPS 2021), pp.8780-8794.
- [16] 2013, Kingma, D.P. and Welling, M., “Auto-Encoding Variational Bayes,” *Proc. Int. Conf. Learn. Representations*.
- [17] 2022, Yonekura, K., Wada, K. and Suzuki, K., “Generating Various Airfoil Shapes with Required Lift Coefficient Using Conditional Variational Autoencoders,” *Eng. Appl. Artif. Intell.*, Vol.108, 104560.
- [18] 2025, Kang, Y.E., Lee, D. and Yee, K., “Intuitive and Feasible Geometric Representation of Airfoil Using Variational Autoencoder,” *J. Comput. Des. Eng.*, Vol.12, No.2, pp.27-48.
- [19] 2017, Higgins, I., Matthey, L., Pal, A., Burgess, C., Glorot, X., Botvinick, M., Mohamed, S. and Lerchner, A., “ β -VAE: Learning Basic Visual Concepts with a Constrained Variational Framework,” *Proc. Int. Conf. Learn. Representations*.
- [20] 2020, Ding, Z., Xu, Y., Xu, W., Parmar, G., Yang, Y., Welling, M. and Tu, Z., “Guided Variational Autoencoder for Disentanglement Learning,” *Proc. IEEE/CVF Conf. on Computer Vision and Pattern Recognition (CVPR 2020)*, pp. 7923-7932.
- [21] 2023, You, K.K., Ha, J.H. and Lee, S.C., “An Automated Aerodynamic Analysis System in Missile Based on Open-Source Software,” *Int. J. Aeronaut. Space Sci.*, Vol.24, pp.592-605.
- [22] 1983, Blair, A.B., Jr., Allen, J.M. and Hernandez, G., “Effect of Tail-Fin Span on Stability and Control Characteristics of a Canard-Controlled Missile at Supersonic Mach Numbers,” *NASA Tech.*, Paper.2157.
- [23] 2014, United States Air Force, “Missile Data Compendium (DATCOM) User Manual – 2014 Revision,” USAF, USA.
- [24] 2014, Arslan, K., “Aerodynamic Optimization of Missile External Configurations,” M.S. thesis, Middle East Technical University, Turkey.