

전개형 우주 데이터센터 방열판용 냉각 유로 형상 설계를 위한 생성형 AI

안동균^{*†}, 하형진^{**}, 양선웅^{**}

^{*}한양대학교 ERICA 로봇공학과, ^{**}한양대학교 ERICA 기계공학과

Generative AI for Cooling Channel Design of Deployable Space Data Center Radiators

Donggyun An^{*†}, Hyeong-Jin Ha^{**}, Sunwoong Yang^{**}

^{*}Dept. of Robotics, Hanyang Univ. ERICA, ^{**} Dept. of Mechanical Engineering, Hanyang Univ. ERICA

Key Words: 생성형 AI(Generative AI), 확산 모델(Diffusion Model), 냉각 유로(Cooling Channel), 전개형 방열판(Deployable Radiator), 우주 데이터센터(Orbital Data Center), Signed Distance Function(SDF)

Abstract

This work presents a diffusion model that generates cooling channel geometries for deployable radiator panels of orbital data centers. Rejecting megawatts of heat requires radiators too large to launch flat, so the panel is folded, and each point where a channel crosses a fold line becomes a leak-prone hinge penetration. Channel layouts are represented as signed distance functions, and the model generates whole flow paths instead of tuning a fixed layout. With v-prediction in place of noise prediction, the validity gate pass rate rises from 29.9% to 90.5%. Generated tiles are joined by flipping every second tile, so the channel crosses each fold line only once, the minimum possible, without violating any gate at the joint. All 6,186 assembled panels pass, while generating whole panels directly yields 57.9% (1x2) and 44.3% (1x4). The geometries are intended for subsequent thermal-fluid evaluation.

1. 서 론

지상 데이터센터는 AI 연산 수요의 폭증으로 전력·용수·부지 확보의 한계에 직면하고 있으며, 태양광 전력을 상시 확보할 수 있고 입지 제약이 없는 우주 데이터센터가 대안으로 부상하고 있다. 우주 데이터센터는 MW급 전력을 소비하는 만큼 같은 규모의 폐열을 우주로 방출해야 한다. 진공에서 방열은 복사에만 의존하며, MW급 방열판의 면적은 약 2,500 m²에 이른다⁽¹⁾. 유로의 열저항을 낮춰 방열면 온도를 높이면 필요 면적은 온도의 4 제곱에 반비례해 줄지만, 압력강하가 커지면 펌프 동력과 시스템 질량이 다시 증가한다. 나아가 수 천 m²의 방열판은 접어서 발사하고 궤도에서 펼치는 전개형(deployable) 구조가 불가피한데, 유로가 접힘선을 가로지르는 관통부는 누설 경로이자 응력 집중 지점이 되고, 미소운석 관통에 대비한 구획화도 요구된다⁽¹⁾. 즉 전개형 방열판의 유로는 열저항·압력강하의 고전적 상충에 접힘 구조라는 기하학적 제약을 더해 만족해야 한다.

기존 유로 설계는 serpentine, parallel 등 정해진 배치를 고정된 채널 폭·간격 같은 치수만 최적화하므로, 배치 자체가 다른 형상은 탐색하지 못한다. 최근 HeatGen⁽²⁾은 히트싱크 핀 형상을 diffusion model⁽³⁾로 생성하였으나, 위상이 고정된 파라메트릭 표현에 머물며 전개 구조나 관통 강건성은 다루지 않는다.

본 연구는 전개형 방열판의 냉각 유로를 생성하는 diffusion 모델 기반 프레임워크를 제안한다. 첫

째, 유로를 signed distance function(SDF) 이미지로 표현하여 배치 자체를 생성 대상으로 삼는다. 둘째, 고노이즈 구간의 오차 증폭을 제거하는 v-예측 파라미터화⁽⁴⁾를 채택한다. 셋째, 생성된 단위 타일을 접힘선 관통이 접합부당 하나가 되도록 전개형 패널로 조립한다. 생성물은 연결성, 최소 채널 폭, 최소 벽 두께, 체적분율, 굴곡도, 고립 유체의 여섯 가지 기하학적 유효성 게이트로 걸러내며, 탈락 형상은 수정 없이 폐기하여 통과율이 생성 능력을 그대로 반영하도록 하였다. 프레임워크는 serpentine 계열에서 시연되었으며, 생성 형상은 후속 대리모델 기반 열유체 평가의 후보군을 이룬다.

2. 이론 및 실험

2.1 확산 모델 기반 유로 생성

확산 모델(denoising diffusion probabilistic model, DDPM)⁽³⁾은 데이터에 가우시안 노이즈를 점진적으로 더해 순수 노이즈로 만드는 forward 과정과, 그 역을 신경망으로 학습해 노이즈로부터 데이터를 복원하는 inverse 과정으로 구성된다. Forward과정은 원본 x_0 에 대해 시각 t 에서 다음과 같이 정의된다.

$$x_t = \sqrt{\alpha_t}x_0 + \sqrt{1 - \alpha_t}\epsilon \quad (1)$$

여기서 $\epsilon \sim N(0, I)$ 는 가우시안 노이즈이고 α_t 는 누적 신호 비율로 $t = 0$ 에서 1, $t = T$ 에서 0에 가까워지며, 본 연구는 $T = 1000$ 과 cosine 스케줄을 사용하였다.

[†] Presenting Author, chdrbs123450@hanyang.ac.kr

전체 흐름은 Fig. 1과 같다. 확산 모델은 연속값 데이터를 전체하므로 이진 마스크를 부호거리장 (SDF) Φ 로 바꾼다. 각 화소에 가장 가까운 경계까지의 유클리드 거리를 유체 쪽은 양수, 고체 쪽은 음수로 부여하고, 절단 거리 14 px에서 잘라 $[-1, 1]$ 로 정규화한다. 생성된 SDF는 $\Phi > 0$ 으로 마스크로 되돌리며, 전 데이터셋에서 이 왕복 변환의 IoU가 1.000으로 정보 손실이 없다.




Fig. 1 Pipeline for generating cooling channel geometries.

학습 데이터는 serpentine 계열 설계 68종에서 유효성 게이트를 통과한 5,893장(256×256 화소, 1 px = 1 mm)이며, 모델은 시간 조건부 U-Net이다. 생성물에도 같은 게이트를 적용하고 탈락분은 폐기한다(Fig. 2).




Fig. 2 Generated samples. (a)–(d) accepted; (e)–(h) rejected by the connectivity, wall-thickness, isolated-fluid, and volume-fraction gates.

2.2 v-예측 파라미터화

표준 DDPM은 신경망이 노이즈 ϵ 을 예측하며, 원본은 $\hat{x}_0 = (x_t - \sqrt{1 - \bar{\alpha}_t}\epsilon)/\sqrt{\bar{\alpha}_t}$ 로 복원된다. 분모의 $\sqrt{\bar{\alpha}_t}$ 는 $t=999$ 에서 4.93×10^{-5} 까지 감소하므로 예측 오차가 약 2만 배로 증폭된다. 이 오차 중 모든 화소가 같은 방향으로 밀리는 성분은 스텝을 거치며 상쇄되지 않고 쌓이는데, SDF가 전체적으로 밀리면 $\Phi = 0$ 경계가 함께 움직여 유체 체적분율이 바뀐다. 실제로 ϵ -예측의 생성물은 체적분율이 0.365에서 0.481로 증가하여 통과율이 29.9%에 그쳤다.

v-예측⁽⁴⁾은 신경망이 다음 양을 예측하게 한다.

$$v = \sqrt{\bar{\alpha}_t}\epsilon - \sqrt{1 - \bar{\alpha}_t}x_0 \quad (2)$$

이때 복원식 $\hat{x}_0 = \sqrt{\bar{\alpha}_t}x_t - \sqrt{1 - \bar{\alpha}_t}v$ 에는 나눗셈이 없어 오차가 증폭되지 않는다. 동일 조건에서 8시드 1,024장으로 평가한 결과, v-예측의 통과율은 90.5%[95% 신뢰구간 88.6~92.2%]로 ϵ -예측을 크게 앞섰고 체적분율도 학습 데이터와 일치하였다(0.354 vs 0.365). 샘플링은 DDIM⁽⁵⁾($\eta = 1$, 100 스텝)으로 수행하였으며, DDPM 1000 스텝과 통과율 차이 없이(McNemar $p = 0.683$) 9.9배 빨랐다.

2.3 전개형 패널 생성

MW급 방열판은 면적이 수천 m^2 에 달해 발사체에 실을 수 없으므로, 단위 판을 접어서 발사하고 궤도에서 펼치는 전개형 구조가 필요하다. 이때 유로가 접합선을 가로지르는 관통부는 누설 경로이자 응력 집중 지점이 되므로, 접합선당 관통 횟수는 적을수록 좋다. 그러나 냉각수가 다음 판으로 넘어가려면 접합선을 최소 한 번 건너야 하므로, 접합부당 관통 한 번이 달성 가능한 하한이다. 본 연구는 이를 설계 요구조건으로 두고, 앞판의 출구와 뒤판의 입구가 같은 높이에서 한 번 만나도록 유로를 구성한다. 넓은 판을 통째로 생성하는 방법도 있으나, 입구에서 출구까지 경로가 길어질수록 연결 굵기가 급증해 통과율이 1x1: 90.5%, 1x2: 57.9%, 1x4: 44.3%로 떨어진다. 또한 통째로 생성한 판은 접합선을 몇 번 건너는지 제어할 수 없다.

본 연구는 대신 1x1 타일을 조립한다. 입구를 좌측 하단, 출구를 우측 상단에 둔 타일을 짝수 번째마다 상하 반전해 이어 붙이면, Fig. 3과 같이 앞 타일의 출구와 뒤 타일의 입구가 같은 높이에서 만나 별도의 연결관 없이 유로가 이어진다. 각 타일의 유로가 자기 영역 안에 완결되므로 접합선 통과는 접합부당 정확히 한 번이며, 힌지 관통 최소화가 조립 방식 자체에서 보장된다.




Fig. 3 Foldable assembly. Mirroring alternate tiles connects the outlet of one tile to the inlet of the next; dashed lines mark fold lines, each crossed exactly once.

게이트를 통과한 타일 1,062장으로 1x2~1x4 판 6,186장을 조립한 결과 전량(100%)이 게이트 6종을 통과하였고, 접합부 12,372곳 모두에서 유로 통과 횟수가 1이었다. 1x1 모델 하나로 재학습 없이 임의 길이의 판을 구성할 수 있다. 생성물과 학습

데이터의 중복률($\text{IoU} \geq 0.95$)은 0.8%로 학습 데이터 내부의 0.7%와 같은 수준이어서 단순암기가 아님을 확인하였다.

3. 결 론

본 연구는 전개형 우주 데이터센터 방열판의 냉각 유로를 확산 모델로 생성하는 프레임워크를 제안하고 *serpentine* 계열에서 검증하였다. 유로를 SDF로 표현하고 v -예측을 채택함으로써 고노이즈 구간의 오차 증폭을 제거하였고, 그 결과 유효성 게이트 통과율이 ε -예측의 29.9%에서 90.5%로 향상되었다. 넓은 판을 통째로 생성하면 연결 끊김으로 통과율이 1x4에서 44.3%까지 떨어지는 반면, 짝수 번째 타일을 반전해 조립하는 방식은 6,186 판 전량이 게이트를 통과하였고 집합부 12,372곳 모두에서 접힘선 관통이 정확히 한 번으로 보장되었다. 조립 방식은 재학습 없이 1x1 모델 하나로 임의 길이의 판을 구성할 수 있다는 이점도 갖는다. 생성된 형상은 후속 대리모델 기반 열유체 평가의 후보군으로 활용될 예정이다.

후 기

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임. (No. RS-2024-00355857)

참고문헌

- (1) Starcloud Inc., 2025, “Starcloud White Paper,” *Starcloud Inc.*, <https://starcloudinc.github.io/wp.pdf>.
- (2) Keramati, H., Sadeghi, M. and Jaiman, R. K., 2025, “HeatGen: A Guided Diffusion Framework for Multiphysics Heat Sink Design Optimization,” *arXiv preprint*, arXiv:2511.09578.
- (3) Ho, J., Jain, A. and Abbeel, P., 2020, “Denoising Diffusion Probabilistic Models,” *Advances in Neural Information Processing Systems*, Vol. 33, pp. 6840~6851.
- (4) Salimans, T. and Ho, J., 2022, “Progressive Distillation for Fast Sampling of Diffusion Models,” *International Conference on Learning Representations*.
- (5) Song, J., Meng, C. and Ermon, S., 2021, “Denoising Diffusion Implicit Models,” *International Conference on Learning Representations*.