



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

석사학위논문

실시간 물리 변형을 위한 NeRF
기반 변형체 가시화 시스템



한 성 대 학 교 대 학 원

컴 퓨 터 공 학 과

컴 퓨 터 공 학 전 공

구 현 우

석사학위논문
지도교수 계희원

실시간 물리 변형을 위한 NeRF 기반 변형체 가시화 시스템

NeRF-based Deformable Object Visualization
System for Real-time Physical Simulation



HANSUNG
UNIVERSITY

2025년 6월 일

한 성 대 학 교 대 학 원

컴 퓨 터 공 학 과

컴 퓨 터 공 학 전 공

구 현 우

석사학위논문
지도교수 계희원

실시간 물리 변형을 위한 NeRF 기반 변형체 가시화 시스템

NeRF-based Deformable Object Visualization
System for Real-time Physical Simulation

위 논문을 공학 석사학위 논문으로 제출함

2025년 6월 일

한 성 대 학 교 대 학 원

컴 퓨 터 공 학 과

컴 퓨 터 공 학 전 공

구 현 우

구현우의 공학 석사학위 논문을 인준함

2025년 6월 일



HANSONG
UNIVERSITY

심사위원장 이 지 은 (인)

심 사 위 원 계 희 원 (인)

심 사 위 원 송 미 화 (인)

국 문 초 록

실시간 물리 변형을 위한 NeRF 기반 변형체 가시화 시스템

한 성 대 학 교 대 학 원
컴 퓨 터 공 학 과
컴 퓨 터 공 학 전 공
구 현 우

의료 시뮬레이션에서 정밀하고 현실감 있는 변형 시뮬레이션은 교육과 수술 계획 수립에서 핵심적인 역할을 한다. 기존의 CT 기반 시스템은 내부 조직 구조를 정량적으로 표현하는 데에는 효과적이지만, 표면 구조의 시각적 실사성이 부족한 한계를 가진다. 본 연구에서는 이를 해결하기 위해, NeRF 기법을 이용하여 실제 모습을 촬영한 다시점 영상 집합으로부터 볼륨 데이터를 생성하고, 이 데이터를 물리 엔진으로 변형한 뒤, 변형 정보를 이용하여 고화질 볼륨 가시화를 수행하는 볼륨 기반의 통합 시스템을 제안한다.

특히, INGP를 사용하여 직접 촬영한 동영상으로부터 빠르게 암시적 신경 표현을 학습하고, 이를 삼차원 정규격자 형태인 명시적 볼륨 데이터로 변환하여 물리 시뮬레이션에 적용할 수 있도록 구성한다. 물리 변형은 GPU 병렬화된 체인메일 알고리즘을 통해 수행되며, INGP를 통해 학습된 밀도 값을 이용한 새로운 강성 기준 제약을 적용하여 실제 물리 변형과 유사한 시뮬레이션을 구현한다. 또한, 기존 체인메일 알고리즘에 후처리 안정화 단계를 적용

하여 더욱 안정된 수렴 결과를 얻는다. 마지막으로, 병렬 리샘플링을 이용해 변형된 볼륨 데이터를 생성하고, 이를 통해 실시간 볼륨 가시화를 수행한다. 본 시스템은 기존의 단편화된 학습, 변형, 가시화 모듈들을 하나의 통합 파이프라인으로 구성함으로써, 구조적 정합성과 시각적 사실성을 동시에 확보하고자 한다.

【주요어】 의료 시뮬레이션, NeRF, 3차원 체인메일 알고리즘, 병렬 리샘플링, GPU 병렬처리, 시스템



목 차

I. 서 론	1
1.1 연구 배경 및 목적	1
1.2 논문의 구성	5
II. 관련 연구	6
2.1 NeRF	6
2.2 체인메일 알고리즘	8
2.3 병렬 리샘플링	10
2.4 암시적 신경 표현	11
III. 시스템 설계	13
3.1 시스템 환경	13
3.2 시스템 구조	13
IV. 시스템 구현	16
4.1 데이터 생성	16
4.1.1 개요	16
4.1.2 데이터 초기화	17
4.1.3 암시적 볼륨의 이산화	17
4.2 데이터 변형	21
4.2.1 개요	21

4.2.2 암시적 표현 기반 체인메일 입력 데이터 재구성	22
4.2.3 후처리 안정화 단계	24
4.3 데이터 가시화	26
V. 실험 및 결과	28
VI. 결 론	40
참 고 문 헌	41
ABSTRACT	48



표 목 차

[표 4-1] INGP의 암시적 볼륨의 이산화 알고리즘	19
[표 4-2] 시점 변경에 따른 이산화 알고리즘	20
[표 4-3] CPU 영역에서의 후처리 안정화 알고리즘	25
[표 5-1] 해상도별로 명시적 볼륨 데이터를 변환하기 위한 시간	32
[표 5-2] 후처리 안정화 단계 수렴 결과 비교	37
[표 5-3] 볼륨 해상도 크기에 따른 변형 및 가시화 속도 비교	38



그림 목 차

[그림 2-1] NeRF 개요	6
[그림 2-2] 이차원으로 보는 체인메일 알고리즘	9
[그림 3-1] 시스템 구조	13
[그림 4-1] 암시적 신경 표현과 명시적 볼륨 데이터	18
[그림 5-1] Wheel 데이터셋의 학습 횟수 비교. (a) 100, (b) 250, (c) 500, (d) 1000	29
[그림 5-2] 카메라 촬영을 통해 생성된 다시점 입력 집합 학습 횟수 비교. (a) 200, (b) 500, (c) 1000, (d) 2000	30
[그림 5-3] 시점 의존적 특성을 반영하지 않은 영상 (a), 시점 의존적 특성을 반영한 영상 (b)	31
[그림 5-4] 사용자 마우스 드래그로 수행된 변형 결과. (a) 마우스로 선택된 변형 위치, (b) 약한 변형, (c) 강한 변형	33
[그림 5-5] INGP의 밀도 값 기반 체인메일 변형 결과 (a) 변형 전 영상, (b) 변형 후 영상	34
[그림 5-6] 안정화 횟수에 따른 변형 결과. (a) 원본 데이터 영상, (b) 2회 적용된 영상, (c) 3회 적용된 영상	35
[그림 5-7] 후처리 안정화 횟수에 따른 수렴 결과. (a) 5회, (b) 10회, (c) 25회	36
[그림 5-8] 카메라 촬영을 통해 획득한 다시점 영상 집합으로 생성한 데이터의 변형 및 가시화 결과. (a) 원본 데이터 영상, (b) 외력이 가해진 영상, (c) 후처리 단계로 수렴된 결과	39

I. 서론

1.1 연구 배경 및 목적

의료 시뮬레이션은 생체 조직의 물리적 특성을 재현하고, 시술 계획 및 교육을 지원하기 위한 중요한 도구로 활용된다. 특히, 실제 인체 구조의 복잡성과 물리적 특성을 반영한 정밀한 변형 시뮬레이션은 고품질의 교육 및 치료 효과를 보장하기 위한 핵심 요소로 자리 잡고 있다. 이러한 시뮬레이션은 보통 컴퓨터 단층촬영(CT, Computed Tomography) 또는 자기공명영상(MRI, Magnetic Resonance Imaging)으로부터 획득한 고해상도 데이터를 기반으로 한다. 획득한 데이터를 통해 볼륨 데이터를 생성한 후, 물리 기반 변형 시뮬레이션을 수행하고 결과를 실시간으로 가시화하는 일련의 절차로 구성된다. 그러나 CT 촬영은 내부 밀도 정보를 중심으로 데이터를 구성하기 때문에, 변형 이후 표면을 사실적으로 표현하는 데 한계를 가진다.

CT 영상은 조직의 형태나 밀도 분포를 정밀하게 제공할 수 있으나, 재질의 색상, 반사, 투과 등과 같은 광학적 특성을 포함하지 않기 때문에 단독으로는 재질의 외형을 시각적으로 재현하는 것은 불가능하다. 이에 따라, CT 데이터가 제공하지 못하는 광학적 속성을 보완하기 위해 외부 시각 정보(예: 실제 촬영된 영상)를 활용하여 재질의 광학적 특성까지 반영할 수 있는 접근 방식이 필요하다. 실제로 Zhao는 재료의 외부 사진을 별도로 촬영하여, CT 데이터가 제공하지 못하는 재질의 광학적 속성을 획득하여 활용하였다(Zhao, S., 2014). 그러나 이 방식은 단일 시점의 정적인 영상만을 활용하므로, 다시점 일관성(multi-view consistency)이 보장되지 않는다는 한계를 갖는다.

한편, NeRF(Neural Radiance Fields)는 다양한 시점에서 관찰한 이차원 영상으로부터 삼차원 장면을 고해상도로 재구성할 수 있으며, 표면 형상과 조명 반응을 실사적(photorealistic)으로 표현하는 데 강점을 가진다(Mildenhall, B., 2021). 이러한 특징은 시각적 사실성에 초점을 맞춘 그래픽스 분야에서

주로 활용됐으나, 최근에는 적은 수의 영상만으로도 삼차원 장면을 복원할 수 있는 효율성이 두드러지며, 의료 영상 분야에도 적용되고 있다(Wang, X., 2024). 예를 들어, MedNeRF와 UMedNeRF는 단일 X-ray 영상 또는 DRR(Digitally Reconstructed Radiograph)을 입력으로 사용하여 CT에 가까운 삼차원 단층 정보를 추정하는 방식을 제안하였다(Corona-Figueroa, A., 2022)(Hu, J., 2024). 이들은 환자의 방사선 노출을 최소화하면서도 진단에 필요한 구조적 정보를 효과적으로 복원할 가능성을 보여주고 있다.

또한, 기존 NeRF 기반 시각 표현 기법이 주로 정적인 시점 기반 복원에 초점을 두었다면, 최근에는 이를 시간적 변형이나 물리적 상호작용까지 포함하는 방향으로 확장하려는 시도도 나타나고 있다. 예를 들어, D-NeRF는 시간에 따른 변화를 반영하기 위해 기존 위치와 시점으로 구성된 5차원 입력에 일차원 시간 축을 추가한 6차원 입력을 처리하고, 신경망 자체에서 변형 상태를 내재적으로 모델링한다(Pumarola, A., 2021). PAC-NeRF는 물리적 일관성을 더욱 엄격하게 보장하기 위해 연속체 역학 기반의 보존 법칙을 NeRF 구조에 통합하고, 시뮬레이션의 정합성과 예측 가능성을 높이는 방식을 제안하였다(Li, X., 2023). PIE-NeRF는 NeRF 구조에 물리 기반 연조직 모델을 결합하여, 시점 변화뿐만 아니라 외부 힘에 따른 실시간 연조직 변형을 표현하는 것을 목표로 하였다(Feng, Y., 2024).

그러나 이들 접근은 모두 신경망이 학습한 변형 범위 내에서만 표현할 수 있다. 즉, 학습 외부의 새로운 물리적 조건이나 사용자가 정의한 가상의 변형 상태에 대하여, 실시간으로 새로운 결과를 생성하거나 일반화하는 데에는 구조적인 한계가 존재한다. 특히, 의료 시뮬레이션과 같이 실제 해부 구조를 기반으로 다양한 시술 시나리오를 가정하고, 반복적 및 정밀한 변형 시각화를 수행해야 하는 응용 분야에서는 이러한 제약이 더욱 두드러진다.

앞서 살펴본 NeRF 기반의 변형 확장 모델들은 신경망이 학습한 범위 밖의 변형 상태를 처리하기 어렵고, 외부 물리 시뮬레이션과의 연동에도 한계를 가진다. 이에 본 연구에서는 NeRF의 암시적 신경 표현(INR, Implicit Neural Representation)을 기반으로, 삼차원 공간을 정해진 격자로 나눈 명시적 볼륨 데이터로 변환한 뒤, 이를 외부 물리 시뮬레이션 알고리즘과 결합하는 방식을

채택하였다.

본 연구가 제안하는 시스템은 실제로 촬영한 다양한 입력 데이터를 빠르게 학습하고, 이에 대한 변형 시뮬레이션 결과를 실시간으로 가시화한다. 이는 학습 속도와 실험 반복 효율을 중시해야 함을 의미한다. 이를 위해 본 시스템은 INGP(Instant neural graphics primitives)(Muller, T., 2022)를 기반으로 실사 표면 모델을 생성하였다. INGP는 다중 해상도 해시 인코딩(multiresolution hash encoding)과 경량 신경망을 결합하여, NeRF에 비해 훨씬 빠른 학습 속도를 제공하고 학습 중간 결과에 대한 시각적 확인도 간편하다.

그리하여 본 시스템은 INGP로 학습된 MLP로부터 특정 시점이 주어질 때마다 밀도와 색상을 계산하고, 이를 통해 명시적 볼륨 데이터를 생성한다. 이후 단계에서 이 데이터를 기반으로 변형 시뮬레이션과 가시화를 수행한다. 이와 같은 방식은 반복 실험과 구조 간 비교, 성능 검증을 위한 초기 연구 단계에 적합한 단순성과 확장성을 제공한다.

본 시스템에서는 명시적 볼륨 데이터를 변형하기 위한 방식으로 체인메일 알고리즘 기반의 물리 변형 기법을 채택하였다(Rodríguez, A., 2016). 체인메일 알고리즘은 고해상도 볼륨 데이터에 직접 적용이 가능하고, 비교적 단순한 제약 조건 기반의 경량 연산 구조를 통해 빠르고 안정적인 변형 전파 시뮬레이션을 수행할 수 있다는 장점을 지닌다. 특히 HP(Heterogeneous Parallel)-Chainmail과 같은 확장 기법은 이질적인 물성 모델링에도 유연하게 적용될 수 있어, 더욱 정교하고 다양한 재질 기반의 변형을 유도할 수 있다.

또한, 체인메일 알고리즘을 통해 변형된 데이터를 효율적으로 처리 및 가시화하기 위해 병렬 리샘플링 기법을 함께 활용한다. 이 기법은 변형된 데이터를 정규격자 형태로 신속하게 재구성할 수 있으며, 이는 가시화 단계로의 효율적인 데이터 전달을 가능하게 한다.

본 연구는 NeRF 기반의 암시적 신경 표현을 INGP 구조를 통해 학습한 뒤, 이를 명시적 볼륨 데이터로 변환하고, 체인메일 기반 물리 변형 및 병렬 리샘플링을 통합하여 가시화까지 연결하는 전체 파이프라인을 통합한 볼륨 기반의 시스템을 제안한다. 이와 관련하여 기존 연구 중에서는 학습된 데이터

를 기반으로 변형 시뮬레이션과 가시화를 수행한 사례가 일부 존재한다. 그러나 이들은 학습, 변형, 가시화 과정을 단편적으로 수행하며, 실시간 상호작용을 포함한 통합 시스템 구조를 갖춘 본 연구와는 차별성을 가진다.

예를 들어, Ter horst는 의료 시술 전후의 촬영된 실제 얼굴 사진과 CBCT 영상 데이터를 활용하여, 시술에 따라 변화한 인체의 부위별 위치 변화를 예측하는 딥러닝 기반 모델을 제안하였다(Ter Horst, R., 2021). 그러나 이 시스템은 데이터 정렬, 학습을 통한 변형 예측, 그리고 결과 출력이 각각 분리된 절차로 이루어지며, 단계 간 결과를 파일로 전달하는 방식이다. 예측 결과는 최종적으로 STL(STereoLithography) 형식으로 저장되며, 외부 소프트웨어를 통해 가시화를 수행해야 하므로 실시간성과 상호작용성에는 제약이 있다.

삼차원 안모 수술 시뮬레이션 분야에서도 유사한 방향의 연구가 제안된 바 있다. Lampen은 FEM(Finite Element Method) 기반의 고정밀 연조직 변형 데이터를 이용해 학습한 PointNet++(Qi, C. R., 2017) 기반의 딥러닝 모델을 통해, 수술 전 CT로부터 생성된 안면 메시(mesh)와 하악골 이동 정보, 경계 조건을 입력으로 받아 연조직의 변형을 예측하는 방식을 제안하였다(Lampen, N., 2022). 이는 실제 환자의 데이터를 기반으로 모델을 학습 및 검증하였으며, FEM과 유사한 수준의 예측 정확도를 유지하면서도 계산 시간을 단축할 수 있음을 보였다. 그러나 해당 연구 또한 시뮬레이션을 구성하는 각 단계가 통합되어 있지 않으며, 외부 자극에 따른 반복적 변형 시뮬레이션에 유연하게 대응하지 못한다.

본 연구는 이처럼 단편적으로 수행되었던 학습, 변형, 가시화 과정을 하나의 통합 시스템으로 구현하고, 이를 통해 의료 시뮬레이션에서 요구되는 실시간성, 시각적 사실성, 외부 상호작용 가능성을 동시에 만족시키는 새로운 프레임워크를 제안한다. 본 시스템은 기존의 CT 기반 구조가 제공하는 내부 밀도 정보와 NeRF 기반 구조가 제공하는 고품질 외곽 형상 표현의 장점을 결합하고, 이를 물리 기반 변형 및 실시간 가시화 단계로 자연스럽게 연계함으로써, 정밀 의료 시뮬레이션 환경에 유용한 기반 기술로 확장될 가능성을 보인다.

1.2 논문의 구성

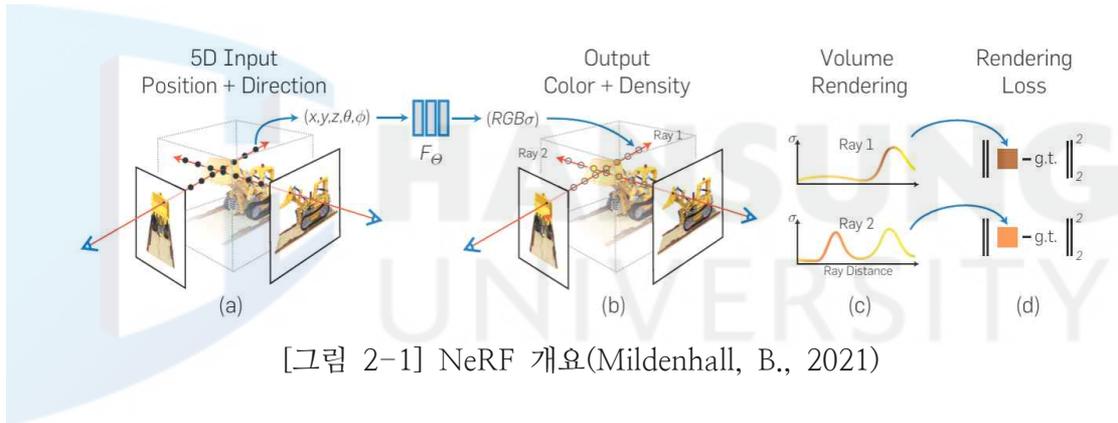
본 연구의 구성은 다음과 같다. 2장에서는 본 연구가 제안하는 시스템에서 적용하는 핵심 기술들을 소개한다. 데이터 생성을 위한 딥러닝 기법인 NeRF, 데이터 변형을 위해 사용되는 3D 체인메일 알고리즘, 그리고 데이터 가시화에 사용되는 병렬 리샘플링 기법을 설명한다. 3장에서는 전체적인 시스템 아키텍처를 소개한다. 4장에서는 시스템 파이프라인의 각 단계를 상세히 기술한다. 5장에서는 시스템 작동 결과를 보이며, 마지막으로 6장에서 결론을 맺는다.



II. 관련 연구

2.1 NeRF

NeRF는 여러 시점에서 촬영한 불연속적인 이차원 영상들을 입력으로 하여, 임의의 시점에서 관찰할 수 있는 삼차원 장면을 재구성하는 학습 모델이다. NeRF의 MLP는 위치 정보(x, y, z)와 방향 정보(θ, ϕ)로 구성된 오차원 입력을 사용하여 공간상의 밀도(density, σ)와 시점 방향에 따른 색상 정보(r, g, b)를 출력으로 가진다.



그러나 NeRF는 MLP 기반의 복잡한 모델 구조와 광선 투사에 대한 대량의 연산을 요구하여, 긴 학습 시간과 실시간 상호작용에는 적합하지 않다는 한계를 가진다. 이러한 문제를 극복하기 위해 다양한 경량화 및 최적화 시도가 이루어졌으며(Reiser, C., 2021)(Deng, K., 2022)(Wang, Y., 2024), 각 기법은 연산 병렬화, 복셀 격자 기반 표현, 하이브리드 인코딩 등 다양한 접근을 통해 성능 개선을 시도해 왔다. 예를 들어, KiloNeRF는 장면을 수천 개의 셀(cell)로 분할하고 각각을 작은 MLP가 담당하도록 구성함으로써, 병렬 처리를 통해 렌더링 속도를 향상시켰다. DS(Depth-Supervised)-NeRF는 광선 종결 분포(ray termination distribution)를 깊이 정합성에 맞게 조절함으로써, 적은 수의 시점에서 빠르고 안정적인 학습과 복잡한 장면에 대한 구조적

정합성을 동시에 확보할 수 있도록 하였다. 또한 Hyb-NeRF는 해상도에 따라 복셀 기반 인코딩과 해시 인코딩을 병합한 하이브리드 구조를 도입하여, 표현력과 효율성 간의 균형을 맞추었다. 이러한 기법들은 일반적으로 PyTorch와 같은 고수준 프레임워크 기반으로 구현되며, 실험 유연성과 표현력 측면에서 강점을 가진다.

이와 같은 다양한 NeRF 확장 기법들은 학습 대상 장면의 공간적 범위에 따라 크게 경계가 있는(bounded) 형태와 경계가 없는(unbounded) 형태로 구분된다. NeRF++, Mip-NeRF 360, TensorRF 등은 360도 전역 장면이나 외부(outdoor) 환경과 같이 넓은 공간을 재구성하기 위한 구조로, 자유로운 카메라 궤적에 대응할 수 있는 표현력을 갖추도록 설계되었다(Zhang, K., 2020)(Barron, J. T., 2022)(Chen, A., 2022). 반면, INGP를 비롯하여 KiloNeRF, MF-NeRF, Hyb-NeRF 등은 학습 공간이 미리 정의된 제한된 삼차원 범위 내(bounded volume)에 존재한다고 가정하는 구조를 채택하고 있으며, 이를 통해 연산 최적화, 메모리 절감, 빠른 학습이 가능하도록 구성되었다.

본 연구에서 다루는 의료 시뮬레이션은 해부학적으로 정의된 인체 내부 또는 특정 부위를 대상으로 하며, 이는 일반적인 넓은 장면이 아닌 공간적으로 제한된 범위 내에서의 변형과 시각화를 요구한다. 이러한 특성상 전역적 표현을 다루는 경계 없는 형태보다는, 계산 효율과 학습 속도 측면에서 유리한 경계 있는 형태가 더 적합하다.

이러한 경계 있는 형태 기반 접근 중 INGP는 NeRF 구조의 경량화와 고속화를 동시에 달성하기 위한 대안으로 주목받았다. INGP는 입력 좌표를 효과적으로 인코딩하기 위한 다중 해상도 해시 인코딩 기법을 제안하였다. 이는 연속적인 공간을 여러 해상도의 격자로 나눈 뒤, 해당 좌표를 해시 함수를 통해 고차원 특징(feature) 공간으로 매핑함으로써, 복잡한 신경망을 사용하지 않고도 축소된 신경망으로 공간 정보를 효율적으로 표현한다. 이 인코딩 방식은 전체 모델을 경량화하면서도 정밀한 표현을 유지할 수 있으며, 장면 크기에 따라 수 초에서 수 분 이내의 빠른 학습을 가능하게 한다.

특히, INGP는 이러한 구조적 간결성 외에도 학습 및 추론 과정 전반을

Fully Fused CUDA 커널로 구성하여 GPU 연산의 효율성을 극대화한다는 점에서 차별성을 갖는다(Muller, T., 2021). 이 방식은 다양한 연산 단계를 단일 커널로 통합함으로써 커널 간 메모리 접근을 줄이고, 병목현상을 최소화하는 데 효과적이다. 이와 같이 INGP는 fully fused 커널 통합을 가능하게 하도록 C++ 및 CUDA 중심의 저수준 구현 방식을 기반으로 설계되었다. 이러한 접근은 연산 흐름에 대한 정밀한 제어와 메모리 최적화를 위한 구현 유연성을 제공하는 방식으로 해석될 수 있다.

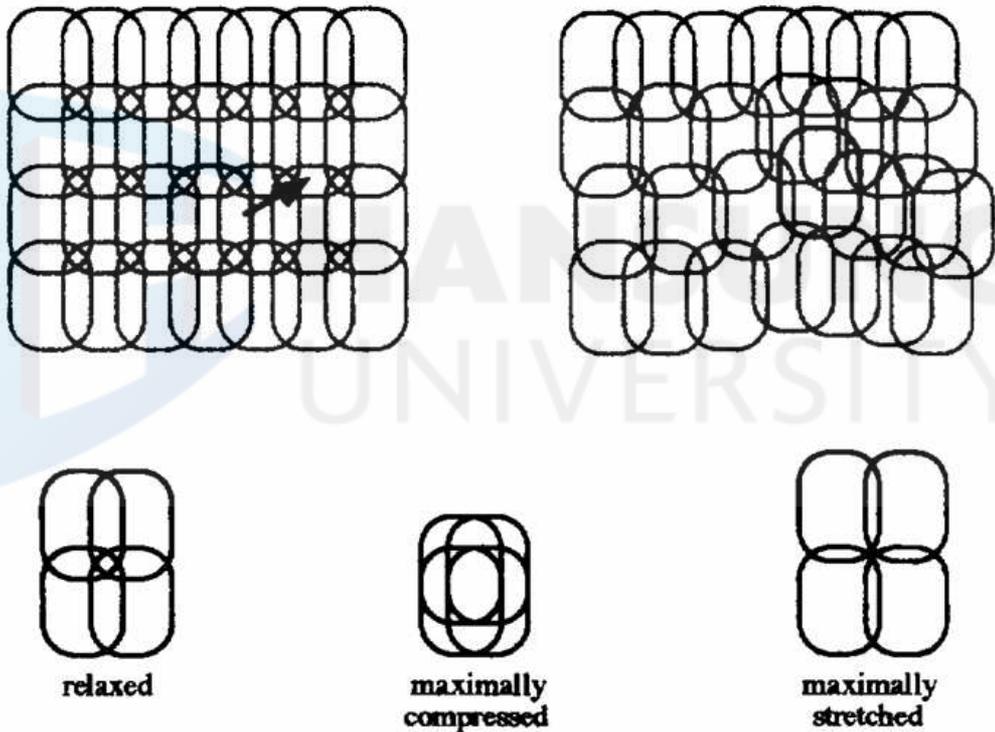
반면, NeRF++, Mip-NeRF 360, TensoRF 등과 같은 대표적인 NeRF 확장 기법들은 주로 PyTorch 기반 환경에서 개발되었으며, 실험 유연성과 기능 확장 측면에서 강점을 보였다. 그러나 일반적으로 Python 인터페이스 기반의 모듈 구조를 따르기 때문에, CUDA 연산을 부분적으로 호출하는 방식으로 구현되어 시스템 수준의 연산 통합이나 병렬 최적화 환경에서 일정한 제약이 따를 수 있다.

본 연구는 실시간 물리 변형 시뮬레이션과의 통합, 연산 흐름의 구조적 일관성 확보, 그리고 하드웨어 자원의 직접 제어 가능성을 중요한 고려 요소로 삼고 있다. 이러한 요구 조건에 비추어볼 때, INGP는 제한된 영역 내에서의 빠른 학습과 정밀한 표현이 가능하고, C++ 및 CUDA 기반의 저수준 구현을 통해 물리 기반 알고리즘과의 통합에도 적절한 구조를 제공한다. 따라서 본 연구는 INGP를 기반으로 소스 코드를 일부 수정하여 본 시스템에 적용하였다.

2.2 체인메일 알고리즘

체인메일 알고리즘은 S. F. Gibson에 의해 최초로 제안된 3D 체인메일 알고리즘으로부터 출발한다(Gibson, S. F., 1997). 3D 체인메일 알고리즘은 볼륨 데이터를 빠르게 변형하기 위한 기하학적 접근 방식을 채택한다. 이는 볼륨 데이터 상의 각 원소를 위쪽과 아래쪽, 좌우, 그리고 앞뒤 방향에 있는 인접 이웃들과 연결하고, 이들 사이에 정의된 거리 제약 조건을 만족시키도록 변형을 전파한다. 사용자가 하나의 노드를 특정 위치로 움직이면, 해당 노드

의 이웃들은 사전에 설정된 거리 제한을 위반하지 않도록 따라 움직인다. 이러한 방식으로 변형이 연쇄적으로 퍼져나가 사슬 갑옷이 움직이는 모습을 본떠 체인메일 알고리즘이라 칭한다. 이 과정은 물리 법칙에 따른 힘이나 질량 계산 없이, 순수하게 기하학적 규칙을 기반으로 작동하기 때문에 계산이 단순하고 빠르며, 시각적 피드백이 중요한 가상 수술 시뮬레이션 등에서 유용하게 활용된다. 그러나 복잡한 변형 시 정확한 물리적 표현은 어려우며, 계산은 CPU 중심으로 수행되어 고해상도 데이터에 적용하기에는 성능이 부족한 제약이 있다.



[그림 2-2] 이차원으로 보는 체인메일 알고리즘(Gibson. S. F., 1997)

이러한 한계를 극복하기 위해 Rodríguez가 제안한 SP-체인메일(Sparse Parallel-Chainmail)은 3D 체인메일의 기본 구조는 유지하면서도, GPU 기반 병렬 처리를 적용하여 변형 계산의 성능을 비약적으로 향상시켰다(Rodríguez, A., 2015). 기존 3D 체인메일은 격자 내 원소를 순차적으로 갱신 방식에 의

존한다. 반면, SP-체인메일은 이러한 삼차원 격자 데이터를 인접한 이웃 정보에 기반을 두어, 각 원소의 상태를 동시에 갱신하는 방식으로 해석하며, 이러한 처리 방식은 전체 연산을 병렬적으로 수행할 수 있도록 한다. 또한, 실제로 영상 데이터는 한정된 영역에서만 변형이 일어나고 나머지 영역 대부분은 정적인 점을 고려하여, 계산이 필요한 블록만 선택적으로 처리할 수 있도록 블록 단위 처리 방식과 이진 활성화 맵(boolean map) 기반의 활성화 영역 관리 전략을 도입하였다.

그러나 SP-체인메일은 여전히 균질(homogeneous)한 물성만을 고려하였고, 다양한 조직의 비균질한 물성을 표현하기에는 한계가 있었다. 이에 따라, HP-체인메일 알고리즘은 전파 속도에 재료 물성이 반영되도록 타임스탬프(timestamp) 기반의 파동 전파(wavefront propagation) 기법을 도입하였다. 또한, 안정화 단계에서는 링크의 강성(stiffness)을 기반으로 한 가중 평균을 통해 비균질한 변형을 안정적으로 처리할 수 있도록 하였다(Rodríguez, A., 2016). 본 연구에서는 HP-체인메일을 기반으로 GPU에 더욱 최적화된 변형 방법을 적용한다.

2.3 병렬 리샘플링

병렬 리샘플링(parallel resampling)은 변형된 좌표 정보를 입력으로 받아, 변형된 새로운 볼륨 데이터를 생성하는 기법이다. 이는 기존의 볼륨 데이터를 여러 개의 사면체(tetrahedron)로 분해한 뒤, 각 사면체를 새로운 볼륨 데이터에 매핑하여 변형된 볼륨 데이터를 격자 형태로 재구성한다. 이 기법은 GPU 병렬화를 활용하여 수많은 사면체를 동시에 처리하여, 변형된 데이터를 빠르게 계산하고 실시간으로 변형체 볼륨을 시각화할 수 있게 한다.

대표적인 기존 연구 중 하나로, Aguilera는 고해상도 볼륨 데이터의 실시간 가시화를 위해, 다양한 변형 시뮬레이션 알고리즘과의 호환성을 높인 병렬 리샘플링 기반 구조를 제안하였다(Aguilera, A. R., 2016). 이 기법은 물리적으로 변형된 비정형 메시 데이터를 격자(grid)로 재구성할 수 있어, 정해진 격자 구조 없이 불규칙한 표면 또는 볼륨 데이터를 효율적으로 처리할 수 있다.

이를 통해 기존의 DVR(Direct Volume Rendering) 파이프라인과 자연스럽게 연결되어, 변형된 데이터를 시각화할 수 있다. 또한, 물리 변형 알고리즘의 방식이나 데이터 해상도와 관계없이 일관된 형식의 데이터가 전달되므로, 가시화 과정에서의 일관성과 실용성을 제공한다.

비슷한 목적을 가진 Gascon의 연구는 사면체 메시를 사용하여 변형된 볼륨을 처리하는 래스터화(rasterization) 기반 방법을 제안하였다. 이 방법은 변형된 사면체 메시를 기반으로 삼차원 텍스처 매핑을 활용하여 정규격자에 볼륨 값을 재투영함으로써, 대규모 의료 데이터에 대한 실시간 시각화를 가능하게 한다(Gascon, J., 2013). 그러나 Gascon의 방식은 변형 메시가 명시적으로 제공되어야 하며, 비정형 메시의 구조와 연계된 데이터 구조의 복잡성으로 인해 특정 변형 기법에 종속될 수 있다.

반면에, Aguilera의 방식은 암시적 샘플링 메시 기반의 정형화된 데이터 흐름을 통해 다양한 변형 방식과의 유연한 통합이 가능하며, 위상적인(topological) 구조 변화 처리에도 강인하게 대응할 수 있어, 높은 호환성과 일반성을 제공한다. 따라서 병렬 리샘플링은 고해상도 시각화가 요구되는 의료 영상이나 과학적 시뮬레이션 환경에서, 다양한 형태의 물리 기반 변형 결과를 동일한 가시화 경로로 통합 처리할 수 있는 유연한 시스템을 제공한다. 이에 따라, 본 연구에서는 두 선행 연구인 Gascon과 Aguilera가 제안한 각 방법들의 장점을 결합한 Park의 방법을 적용하여 병렬 리샘플링 가시화를 수행한다(Park, C., 2022).

2.4 암시적 신경 표현

암시적 신경 표현(INR, Implicit Neural Representation)은 좌표 기반 표현으로도 알려진 방식으로서, 연속적인 좌표 기반 신경망 함수로 신호를 표현하는 접근법이다. 이 방식은 명시적인 격자나 메시를 사용하지 않고, 공간상의 좌표를 입력으로 하여 각 위치에 대한 신호 값(색상, 밀도 등)을 출력하는 신경망 기반의 함수를 학습한다. 이는 신호 값을 신경망을 통해 직접 근사함으로써, 메모리 효율성과 해상도 독립성을 동시에 확보할 수 있다는 장점이

있다.

이러한 표현 방식은 DeepSDF(Park, J. J., 2019)와 Occupancy Networks(Mescheder, L., 2019)를 통해 본격적으로 응용되기 시작하였다. DeepSDF는 연속적인 SDF(Signed Distance Function)를 학습하여 물체 표면을 부드럽게 표현할 수 있었으며, Occupancy Networks는 주어진 점이 물체 내부에 포함되는지를 예측하는 확률적 점유 함수(occupancy field)를 학습하였다. 이러한 방법들은 물체 수준(object-level)의 기하학적 형상을 효과적으로 재현하는 데 강점을 보였으나, 시점에 따른 색상 변화나 조명 효과와 같은 시점 의존적 시각 정보를 반영하지 못한다는 한계가 있었다.

이후 INR의 표현력을 확장하려는 시도로 제안된 Convolutional Occupancy Networks(Peng, S., 2020)는 전결합(FC, fully connected) 네트워크 대신 CNN(Convolutional Neural Network) 기반의 인코더를 도입하여, 입력 데이터의 지역적 특성과 전역 구조를 동시에 반영할 수 있도록 설계되었다. 이를 통해 노이즈(noise)가 포함된 점 구름(point cloud)이나 저해상도 입력으로도 복잡한 실내 장면까지도 재구성할 수 있는 유연한 구조를 제안하였으나, 여전히 시점 기반의 사실적 시각 표현(view synthesis)까지는 도달하지 못했다는 점에서 한계를 가진다.

이러한 한계를 극복한 것이 바로 NeRF이다. NeRF는 INR을 통해 시점에 따른 방사값(radiance)을 예측하고, 이를 볼륨 가시화 기법으로 광선 적분하여 새로운 시점의 영상을 사실적으로 합성할 수 있었다. 이를 통해 NeRF는 형상 중심의 INR을 시점 의존적인 광학적 장면 표현으로 확장하였으며, 장면 수준에서의 실사적 시점 합성을 가능하게 한 주요 사례로 평가된다.

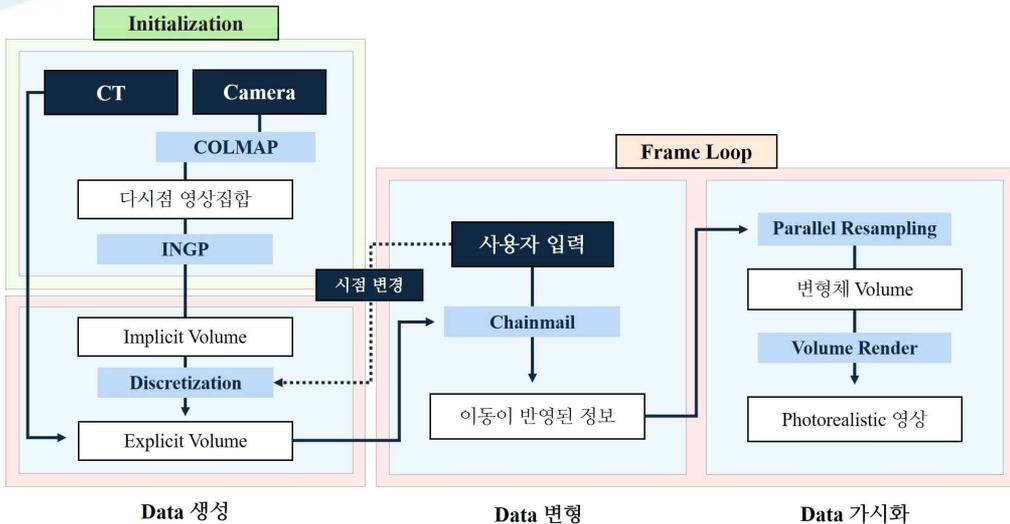
III. 시스템 설계

3.1 시스템 환경

본 연구는 INGP를 통해 학습된 INR을 명시적 볼륨 데이터로 변환한 후, 체인메일 알고리즘 기반의 물리 변형을 적용하고, 병렬 리샘플링을 통해 효율적인 볼륨 가시화를 수행하는 볼륨 기반의 통합 시스템을 제안한다. 본 시스템은 C/C++과 CUDA 12.6을 기반으로 구현된다. 체인메일 알고리즘의 전파 및 안정화 단계와 변형된 볼륨 데이터를 재구성하는 병렬 리샘플링은 CUDA를 활용해 고속으로 처리된다. GUI 구성 및 사용자 입력을 통한 시점 변경과 변형 제어는 Qt 6을 사용하여 구현된다. 전체 프로젝트의 모듈 관리와 플랫폼 간 빌드 자동화를 위해 CMake 3.31로 빌드 시스템을 구성한다.

3.2 시스템 구조

본 연구에서 제안하는 시스템 구조는 크게 세 가지 주요 단계로 구성된다.



[그림 3-1] 시스템 구조

첫 번째 단계는 데이터 생성으로, 이 단계에서는 기존의 NeRF 모델을 활용한 데이터셋(dataset)을 사용하거나, 직접 촬영한 동영상을 기반으로 COLMAP(Schonberger, J. L., 2016)을 이용하여 다시점 영상 집합을 생성한다. 이렇게 획득된 영상 집합을 입력으로 INGP가 학습을 수행하여, 연속적인 공간상에서 정의된 암시적 신경 표현인 INR이 생성된다(4.1.2절). 이후, 구조적 일관성을 확보하고 변형 및 가시화를 효율적으로 할 수 있도록 해당 표현은 명시적 볼륨 데이터로 변환된다(4.1.3절).

INGP의 INR은 위치 정보뿐만이 아니라 시점 방향도 입력으로 사용하여, 동일한 물체가 관찰 각도에 따라 다른 색상으로 표현되므로 실사적인 고화질 가시화가 가능하다. 그러나 INR을 명시적 볼륨 데이터로 변환하는 과정에서 각 복셀은 하나의 색상 값(r, g, b)만 저장하게 된다. 이 색상 값은 입력으로 전달된 특정 시점 방향에 대해 고정된 상태로 계산된 단일 결과를 의미한다. 다시 말해, INR에서는 위치 정보와 시점 방향을 실시간으로 조합하여 색상을 추정할 수 있었으나, 명시적 볼륨 데이터에서는 위치 정보와 대응되는 정규격자 인덱스만 사용하게 된다. 이로 인해 시점 방향에 대한 정보를 내재하지 않아 시점 의존성(view-dependency)을 상실하게 된다.

이에 따라, 본 시스템에서는 NeRF의 시점 의존성을 보존하기 위해 사용자 입력으로 시점이 변경될 때마다 학습된 암시적 신경 표현으로부터 명시적 볼륨 데이터를 다시 생성한다. 반면에, CT 데이터와 같은 의료용 볼륨 데이터는 별도의 변환 없이 바로 명시적 볼륨 데이터로 사용이 가능하며, 추가적인 처리 과정 없이 바로 데이터 변형 단계로 진입한다. 이러한 입력 데이터를 모두 활용한 방법은 본 시스템이 추후 목표로 하는 실사적인 표현과 내부 물리 시뮬레이션 정확도를 동시에 확보하기 위함이다.

두 번째 단계인 데이터 변형에서는 사용자 입력 이벤트를 처리하여 체인메일 알고리즘을 통해 물리적 변형을 수행한다. 이때, 앞서 생성된 명시적 볼륨 데이터의 밀도 값을 강성 값으로 활용하여 변형을 수행한다(4.2.2절). 또한, 본 연구는 기존 GPU 병렬처리 기반 체인메일 알고리즘에 후처리 안정화 단계를 추가하여, 다양한 변형 입력과 복잡한 데이터 구조에서도 안정적인 변형 전파를 가능하게 한다(4.2.3절).

마지막으로, 데이터 가시화 단계에서는 병렬 리샘플링 기법을 사용하여 이 동이 반영된 체인메일 볼륨 데이터로부터 새로운 샘플링 메시지를 생성하고, 이를 기반으로 변형된 볼륨 데이터를 재구성한다(Park, C. 2022). 이후 변형된 볼륨 데이터를 볼륨 가시화 기법으로 시각화하여 사실적인 영상을 생성한다.

이와 같은 세 가지 단계는 [그림 3-1]에 제시된 시스템 구조에 따라 결합된다. 본 시스템은 암시적 신경 표현을 명시적 볼륨 데이터로 변환하고, 이를 변형 및 가시화하는 일련의 과정을 수행한다. 이를 통해 본 연구에서는 의료 시뮬레이션에서 요구되는 시각적 해상도와 사실성을 동시에 확보할 수 있는 통합된 초기 시스템 프레임워크를 제안한다. 각 단계에서의 세부 구현은 4장에서 보다 상세히 다루게 된다.



IV. 시스템 구현

이번 장에서는 시스템의 각 파이프라인 단계를 세부적으로 설명한다. 이는 데이터 생성, 데이터 변형, 그리고 데이터 가시화 각 단계의 입력과 출력을 비롯하여, 사용된 모듈의 구현 및 결합 방법을 설명한다.

4.1 데이터 생성

4.1.1 개요

데이터 생성 단계는 세부적인 두 단계로 나뉜다. 첫 번째 단계는 초기화 (Initialization) 단계로, COLMAP을 이용하여 카메라로 촬영한 동영상으로부터 다시점 영상 집합을 생성하고, 이를 INGP에 학습시켜 암시적 신경 표현인 INR을 구축하기까지의 과정을 포함한다. INGP는 기본적으로 학습과 가시화 기능을 통합한 환경에서 동작한다. 그러나 본 시스템은 물리적 변형이 반영된 별도의 가시화 과정을 포함하므로, 기존 구조와의 분리가 요구된다.

이에 따라, 본 연구에서는 INGP의 학습 기능만을 수행한 후, 구축된 INR 데이터를 시스템의 실행 루프(Frame Loop) 내로 전달하여 재사용될 수 있도록 한다. 이 구현을 통해, 사용자 입력으로 시점이 변경될 때마다 INR에 즉시 접근하여 새로운 명시적 볼륨 데이터를 생성할 수 있는 구조를 설계하였다.

두 번째 단계에서는 앞선 초기화 단계에서 구축된 INR을 명시적 볼륨 데이터로 변환한다. 앞서 서술한 바와 같이, 시점 의존성을 보존하기 위해 변환 과정은 사용자 입력으로 시점이 변경될 때마다 수행된다. 본 연구에서 생성하는 명시적 볼륨 데이터는 $256 \times 256 \times 256$ 크기의 해상도를 가진다. 각 복셀은 위치에 대응되는 INR의 출력 값인 float4 형으로 색상 값(r, g, b)은 그대로 사용하며, 밀도 값(σ)은 불투명도(α)로 변환하여 저장한다. 이는 $16,777,216 \times 16B = 268,435,456B$ 로 약 256MB의 크기를 가지며, 이후 데이

터 변형 및 데이터 가시화 단계에서 입력 데이터로 활용된다.

4.1.2 데이터 초기화

NeRF 모델은 고품질의 삼차원 장면 복원을 위해 입력 데이터로서 다시점 영상 집합과 이에 대응하는 카메라 포즈 정보(자세와 방향)를 요구한다. 실제 환경에서 직접 촬영한 동영상을 입력 데이터로 사용할 때는 추가적인 전처리 과정이 필요하다.

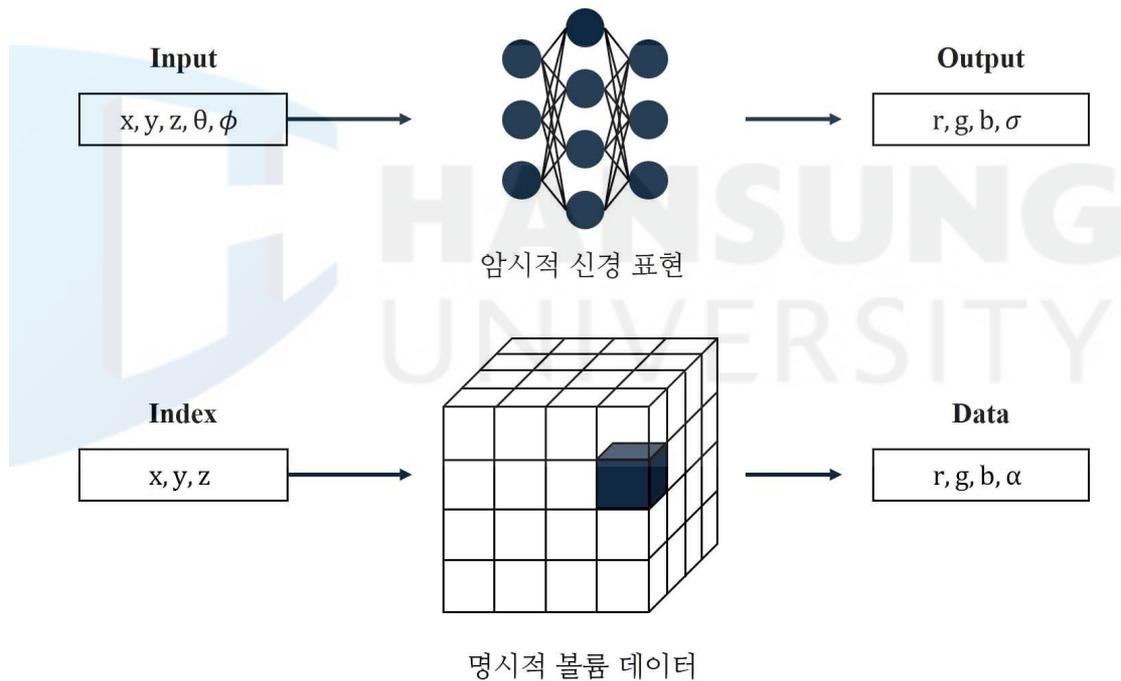
먼저, 동영상을 촬영한 후 FFmpeg(FFmpeg developers) 오픈소스 툴킷을 이용해 동영상에서 각 프레임을 추출하여 연속된 이미지를 생성한다. FFmpeg는 고속으로 동영상 파일을 처리할 수 있어, 대량의 이미지 프레임을 효율적으로 추출할 수 있다.

이후, COLMAP을 사용하여 각 영상에 대응하는 카메라 포즈 정보를 추출한다(Schonberger, J. L., 2016). COLMAP은 SfM(Structure-from-Motion) 및 MVS(Multi-View-Stereo)를 기반으로 한 대표적인 삼차원 장면을 재구성하는 도구로, 연속된 이미지에서 카메라의 포즈 정보를 추정하는 데 사용된다. 이 과정은 크게 특징 추출, 특징 매칭, 에피폴라 기하학(epipolar geometry)을 통한 초기 카메라 포즈 추정, 그리고 bundle adjustment 기법을 사용한 카메라 포즈 최적화 단계로 이루어진다. COLMAP은 이러한 단계를 자동으로 처리하여 삼차원 공간에서의 카메라 위치와 방향을 추정한다.

다음으로, COLMAP에서 출력된 카메라 포즈 정보는 NeRF 모델에서 요구하는 형식으로 변환해야 한다. 이는 COLMAP의 출력 데이터를 JSON 형식으로 변환하여, 각 이미지에 해당하는 카메라 위치와 방향 정보를 저장한다. 이 일련의 과정은 INGP에서 제공하는 Python 스크립트를 통해 수행되며, 실제 환경에서 촬영한 동영상을 INGP의 입력 데이터로 사용함으로써 학습을 통해 암시적 신경 표현을 구축한다.

4.1.3 암시적 볼륨의 이산화

암시적 신경 표현인 INR은 장면의 기하학적 정보와 시각적 정보를 연속적인 함수 형태로 압축적으로 내포하고 있어, 메모리 효율성과 해상도 유연성 측면에서 강점을 지닌다. 그러나 이와 같은 표현 방식은 일반적으로 격자 기반의 자료구조나 명시적 필드 데이터를 입력으로 사용하는 물리 기반 변형 알고리즘에 직접 적용하기 어렵다는 한계를 지닌다. 그리하여 본 연구에서는 이산화를 통해 INR의 INR을 명시적인 정규격자 형태의 볼륨 데이터로 변환하여 이후 단계에서 사용한다. 이는 INR이 제공하는 고해상도 표면 정보를 활용하면서도, 물리 기반 연산의 구조적 안정성과 구현상의 일관성을 확보하기 위함이다.



[그림 4-1] 암시적 신경 표현과 명시적 볼륨 데이터

INGP로부터 생성된 암시적 볼륨 데이터를 명시적 볼륨 데이터로 획득하기 위한 기존의 방법은 [표 4-1]에서 제시된다. 먼저, INGP에 의해 학습된 INR은 GPU 전용 메모리에 저장되며(줄 3), 입력 해상도(res)에 따라 격자 내 각 복셀의 중심 위치 또는 정점에서의 색상 및 밀도 값을 균일(uniform)한

간격으로 샘플링한다(줄 6). 이때 각 위치는 고정된 시점으로 투사된 광선 방향(dir)을 입력으로 한 INR의 추론 과정을 통해 색상 및 밀도 값을 계산한다(줄 8). 마지막으로 추론된 결과를 다시 명시적 색상 필드(rgba)로 변환한다(줄 10). 이 과정은 CUDA 기반 병렬 연산으로 최적화되어, 수백만 개의 복셀에 대해 INR 추론과 후처리 연산이 일괄 수행된다. 결과적으로 이산화된 출력은 각 복셀이 vec4 형으로 색상 값(r, g, b)과 밀도 값(σ)을 가진 입력 해상도 크기의 명시적 볼륨 데이터이다.

Algorithm 1 : INGP의 암시적 볼륨의 이산화 알고리즘

```

1  Function get_rgba_on_grid(res, dir):
2       $N \leftarrow res.x \times res.y \times res.z$ 
3      GPUmemory<vec4> rgba[N]
4      GPUmemory<float> pos[N × floats_per_coord]
5      batch_size ← min(N, max_batch_size)
6      generate_grid_samples <<< GRID, BLOCK >>> (res, dir, pos)
7      For N in steps of batch_size Do
8          rgbsigma ← network_inference(pos)
9          rgbsigma ← occupancy_filter(rgbsigma)
10         rgba ← convert_to_rgba(rgbsigma)
11     Return rgba

```

[표 4-1] INGP의 암시적 볼륨의 이산화 알고리즘

본 연구에서 제안하는 시스템은 시점 의존적 특성을 재현하고자, [표 4-1]에서 제시된 알고리즘을 활용하여 시점 방향이 변경될 때마다 해당 시점에 대한 명시적 볼륨 데이터를 다시 생성한다.

명시적 볼륨 데이터가 한 번 생성되면, 각 복셀의 위치와 법선(normal)

정보를 추출하고 새로운 시점에서의 시각 정보를 역으로 계산하여, 고해상도 볼륨 데이터를 다시 생성하는 비용을 절약하는 방식도 고려할 수 있다. 그러나 이러한 방식은 각 픽셀에 대한 광선 교차 판단, 법선 기반 조명 계산, 그리고 시점 반영 재투영 등의 복잡한 연산이 요구된다. 이에 따라, 본 시스템에서는 시점 변경 시마다 새로운 볼륨 데이터를 매번 생성하는 방식을 채택하였다. 이는 고해상도 볼륨 데이터로 변환 시 일정 수준의 계산 비용을 요구하지만, NeRF 기반의 학습 표현을 물리 변형 시뮬레이션에 적용하고 그 결과를 확인하기 위한 초기 시스템 구성에 적합하다.

Algorithm 2 : 시점 변경에 따른 이산화 알고리즘

```

1  Function get_view_volume(dir):
2      GPUMemory<float4> rgba = get_rgba_on_grid(res, dir, depth)
3      If 생성된 텍스처가 없다면 Do
4          create_cuda_texture(rgba.data())
5      Else
6          update_cuda_texture(rgba.data())

```

[표 4-2] 시점 변경에 따른 이산화 알고리즘

INGP는 실시간 광선 기반 가시화를 위한 INR 학습에 최적화되어 설계되었기 때문에, 학습된 데이터를 명시적 볼륨 형태로 외부에 전달하거나 직접 가시화하는 기능을 본래의 시스템 목적상 요구되지 않았다. 따라서 INGP는 [표 4-1]을 활용하여 명시적 볼륨 데이터를 파일로 출력하여 외부 시각화 도구에서 활용하는 방식만을 제공한다. 이 과정에서 GPU 메모리상의 데이터를 CPU 메모리로 복사하고 파일로 저장하는 비용이 발생하게 된다.

본 시스템은 이러한 목적과 달리, 구축된 INR을 명시적 볼륨 데이터로 변환한 후, 이를 후속 체인메일 기반 변형 및 병렬 리샘플링, 그리고 최종 가시화까지 하나의 파이프라인 내에서 처리하는 것을 목표로 한다. 이를 위해, 변

환된 명시적 볼륨 데이터는 GPU 메모리상에서 후속 단계로 직접 전달되어 처리되며(줄 4, 6), 기존에 요구되었던 별도의 CPU 메모리 복사나 디스크 저장 과정 없이 연산이 연속적으로 수행된다. 이러한 구조는 전체 파이프라인의 일관성을 유지하는 데 중요한 역할을 한다.

이처럼 GPU 메모리상에서 전달된 명시적 볼륨 데이터는 각각 데이터 변형 단계와 데이터 가시화 단계의 입력으로 사용된다. 데이터 변형 단계에서는 시점과 무관한 내부 밀도 값만을 활용하므로, 이산화는 초기 한 번만 수행하여 입력 데이터를 초기화한다. 다시 말해, 시점이 변경되더라도 INGP의 암시적 신경 표현인 INR로부터 명시적 볼륨 데이터를 다시 이산화할 필요가 없음을 의미한다. 이때, 데이터 변형 단계의 입력 데이터는 체인메일 원소 볼륨이라 정의한다.

데이터 가시화 단계에서 병렬 리샘플링을 이용하여 변형된 볼륨 데이터를 생성하기 위해 두 가지 주요 입력이 사용된다. 첫 번째는 변형되지 않은 명시적 볼륨 데이터로, [표 4-2]를 통해 생성된 CUDA 텍스처를 사용한다. 두 번째 입력은 체인메일 알고리즘을 통해 생성된 이동이 반영된 정보로, 이는 데이터 변형 단계의 출력 결과로부터 획득한다.

4.2 데이터 변형

4.2.1 개요

데이터 변형 단계에서는 체인메일 알고리즘을 사용하여 물리 변형을 수행하고, 이를 통해 이동이 반영된 정보를 생성한다. 이때 사용되는 입력은 앞선 데이터 생성 단계에서 생성된 체인메일 원소 볼륨으로, 색상 값과 밀도 값(r , g , b , α)을 가진다. 하지만 체인메일 알고리즘은 인접 복셀 간의 거리 제약 기반 연산을 수행하기 때문에 색상 정보는 필요로 하지 않으며, 각 위치에 대응되는 복셀의 강성을 표현할 수 있는 밀도 값만을 활용한다. 앞서 서술하였듯이, 본 연구에서는 초기 시점 방향을 기준으로 한 번만 생성된 명시적 볼륨 데이터로부터 색상 값을 제외한 밀도 정보만을 추출하고, 각 복셀의 위치 좌

표와 함께 저장한 새로운 볼륨 데이터인 체인메일 원소 볼륨을 구성하였다.

또한, 이렇게 구성된 볼륨 데이터를 실제 체인메일 연산에 적용할 때는 해상도에 따른 연산 복잡도를 고려해야 한다. 체인메일 알고리즘은 각 격자 원소 간의 물리적 제약 조건을 기반으로 전파와 안정화를 반복적으로 적용하는 방식으로, 고해상도의 볼륨 데이터일수록 연산량이 급격히 증가한다. 이를 방지하고 처리 효율을 높이기 위해, 본 시스템에서는 원본 데이터인 명시적 볼륨 데이터를 각 x, y, z 축에 대하여 1/4로 축소하여 $64 \times 64 \times 64$ 크기로 다운 샘플링 된 체인메일 원소 볼륨을 생성한다. 이 과정에서 해상도 축소로 인해 시뮬레이션 정밀도가 다소 저하될 수 있으나, 1/4로 축소된 해상도에서도 원본 결과에 근접한 품질과 빠른 수행 속도를 동시에 확보할 수 있어, 1/4 해상도가 효과적인 대안임을 기존 연구의 실험을 통해 검증된 바 있다(이상은, 2024).

더불어, 본 시스템은 메모리 활용 방식에서 기존 체인메일 기반 시스템과 차별성을 갖는다. 기존 체인메일 기반 시스템에서는 CPU 메모리상에서 입력 볼륨 데이터를 생성한 뒤, 이를 GPU로 복사하는 과정이 필요했으나, 본 시스템에서는 명시적 볼륨 데이터가 이미 GPU 상에 저장되어, 체인메일 원소 볼륨을 생성하기 위해 별도의 메모리 복사 없이 곧바로 GPU에서 초기화가 가능하다. 이와 같은 구조는 체인메일 알고리즘의 초기 입력 과정을 간소화하며, 연산 흐름의 일관성과 효율성을 향상시킨다.

본 단계에서는 사용자 입력에 따라 체인메일 알고리즘이 전파를 수행하고, 그 결과로 물리적 변형이 반영된 데이터가 출력된다. 이 출력 데이터는 앞서 명시적 볼륨 데이터로부터 색상 정보를 제외하고 강성 값을 추출하여 구성된 체인메일 원소 볼륨과 동일한 구조를 가진다. 이때, 각 복셀은 float4 형으로 위치 값(x, y, z)과 강성 값(a)을 저장한다. 그리하여 생성되는 체인메일 원소 볼륨은 $262,144 \times 16B = 4,194,304B$ 로 약 4MB의 크기를 가진다.

4.2.2 암시적 표현 기반 체인메일 입력 데이터 재구성

암시적 신경 표현으로부터 획득되는 밀도 값은 $[0, \infty)$ 의 값을 가진다. 이

는 NeRF 계열 모델이 장면의 표면 구조와 투명도를 정밀하게 표현하기 위함이다. 그러나 체인메일 알고리즘에서는 각 복셀의 물리적 강성을 수치로 표현해야 한다. 이때, 사용되는 값은 일반적으로 명확한 범위를 갖는 고정된 값 내에서 정의되어야, 복셀 간 상대적인 강성 차이를 안정적으로 해석하고 제어할 수 있다. 예를 들어, CT 데이터는 각 복셀의 조직 밀도를 HU(Hounsfield Unit)라는 물리 단위로 표현하며, 일반적으로 -1000 의 공기부터 $+1000$ 이상의 뼈 조직까지 일정한 해석 범위 내에서 사용된다.

반면, 상한선이 없는 밀도 값을 강성 값으로 사용할 경우, 각각의 값이 어느 정도의 강성을 나타내는지 정량적으로 해석하기 어렵다. 이에 따라, 본 연구에서는 변형 연산에 사용할 수 있는 일관된 강성 척도를 제공하기 위해 밀도 값을 $0 \sim 1$ 사이의 α 값으로 정규화하여 사용한다.

$$\alpha = 1 - \exp(-\sigma \cdot \delta) \quad \text{수식 1}$$

σ 는 밀도 값이고, δ 는 샘플 간 거리 또는 복셀이 차지하는 단위 공간의 크기를 의미한다. 이 거리 δ 는 작을수록 α 값이 작아져 복셀이 투명하게, 클수록 α 값이 커져 복셀이 더 불투명하게 표현된다. INGP는 학습 과정에서 연산량을 줄이기 위해, 정보가 작은 영역에서는 δ 를 넓게, 표면처럼 중요한 영역에서는 조밀하게 설정하여 효율적으로 샘플링을 수행한다. 그러나 본 시스템은 이처럼 가변적인 샘플 간격을 그대로 유지하지 않고, 명시적 볼륨 데이터로 이산화하여 사용한다. 이때, 복셀 간 간격과 샘플 간 거리가 일치하지 않으며, 같은 밀도 값을 사용하더라도 α 값 계산 시 왜곡이 발생할 수 있다.

따라서 본 연구에서는 일정한 복셀 간 간격을 전제로, 고정된 샘플 간 거리로 α 를 계산하며, 이 과정은 INGP로부터 생성된 불필요한 노이즈도 일정 부분 제거하는 기능을 수행한다. 또한, 일정 임계값(threshold) 이하의 매우 작은 밀도 값을 가진 복셀은 완전히 투명하게 처리함으로써, 잔여 노이즈를 추가로 제거한다.

변환된 α 값은 CT 데이터가 가지는 물체의 강성과는 성질이 다르게 빛의 투과율을 표현하는 밀도 값을 가진다. 따라서 이를 그대로 사용할 경우, 실제

재질의 강성을 반영하는 데는 한계가 있다. 그럼에도 불구하고, INGP는 공기와 연조직, 뼈 등과 같은 구조적 경계에서 밀도 값의 차이가 상대적으로 크게 나타나는 경향이 있다. 이러한 특성을 활용하면 변환된 α 값을 적절히 조정하고 전이함수를 설계함으로써, 기존 CT 데이터에서 정의된 조직 간 상대적 강성 분포와 유사한 수준의 변형을 구성할 수 있다. 본 시스템은 이를 바탕으로 체인메일 알고리즘에 적용하여 공기는 0.1, 피부는 0.2, 그리고 뼈는 0.5의 기준 강성 값으로 변형을 수행한다.

4.2.3 후처리 안정화 단계

실시간 체인메일 기반 물리 시뮬레이션에서 수렴 품질과 형태 안정성은 중요하다. 특히, GPU 병렬 구조를 기반으로 하는 SP-체인메일 및 HP-체인메일 알고리즘에서는, 전파와 안정화를 고정된 횟수만큼 교차 반복(interleaved)하는 구조를 채택함으로써 일정한 프레임 단위 실행 시간을 확보하였다. 그리고 효율적인 전파 연산을 위해, 전체 영역을 블록 단위로 나누고, 변형이 실제로 확산하는 블록을 활성화 블록으로 지정한다. 이를 통해 전파가 필요한 원소들에 대해서만 변형 연산을 수행할 수 있다. 그러나 이러한 방식은 안정화 횟수가 고정되어 있어, 입력 변형의 크기나 분포, 물성의 이방성 등 다양한 요인에 따라 수렴 품질이 달라질 수 있는 한계를 내포한다. 또한, 변형이 전파된 원소에 대해서만 안정화를 수행하기 때문에, 변형이 직접적으로 전달되지 않은 주변 영역과의 위치 변화가 부자연스러운 결과가 나타날 수 있다.

이러한 배경에서 전파 이후에도 일부 복셀 간에 위치나 강성 값이 완벽히 일치하지 않는 오차나 불안정성을 보완하기 위한 후처리 안정화 단계(post-propagation relaxation stage)의 필요성이 제기된다. 후처리 안정화는 전파 단계에서 확산한 변형 필드를 추가로 정렬하고 부드럽게 안정화함으로써, 자연스러운 시뮬레이션 결과를 얻을 수 있다. 특히, 외력이 크거나 위치 변화가 급격하게 일어나는 상황에서는, 모델의 형태가 크게 변형되기 때문에 단일 전파와 안정화 반복만으로는 충분한 수렴 상태에 도달하기 어려울 수

있다. 이와 같은 상황에서는 변형 후 전체 구조의 물리적 일관성을 확보하기 위한 후처리 안정화 단계가 더욱 중요하게 작용한다.

후처리 안정화는 Gibson이 제안한 체인메일 구조에서 이미 제시된 바 있으며, 해당 연구에서는 3D 체인메일과 탄성 안정화(elastic relaxation) 두 단계를 조합하여 변형을 처리하는 구조를 제안하였다(Gibson, S., 1998). 이때 탄성 안정화는 3D 체인메일이 적용된 이후나 시스템이 유휴(idle) 상태일 때 반복적으로 적용된다고 서술되어 있다. 이는 전파 후의 에너지 오차를 줄이기 위한 후속 안정화 과정으로 해석할 수 있으며, 연속적인 변형과 그에 따른 수렴을 부드럽게 조율하는 역할을 한다. 다만, 해당 구조는 단일 스레드 기반의 CPU 환경을 전제로 하였기 때문에, GPU 병렬 환경에서 그대로 적용하기에는 구조적 제약이 존재한다.

본 연구에서는 이를 GPU 병렬 구조에 적합하도록 재구성하여, 전파 및 안정화 반복이 종료된 후, 별도로 전체 체인메일 원소를 대상으로 한 번 더 안정화를 수행되는 후처리 안정화 단계를 제안한다. 이는 [표 4-3]과 같이 구현되며, 고정되지 않은 원소에 대해 인접 노드와의 상대 거리 기반 위치 보정을 병렬로 수행한다.

Algorithm 3 : CPU 영역에서의 후처리 안정화 알고리즘

```

1  For 체인메일 블록 크기 Do
2       $rBlockIdxArr \leftarrow blockIdx$ 
3  End For
4   $relax \lll GRID, BLOCK \ggg (elements)$ 
5   $cudaDeviceSynchronize()$ 

```

[표 4-3] CPU 영역에서의 후처리 안정화 알고리즘

[표 4-3]에서 (줄 4)의 안정화 커널은 수식 2에서 제시된 기존 HP-체인 메일에서 사용한 안정화 수식을 이용한다. p_e^* 는 원소 e 의 갱신된 이상적인 위

치로 이웃하는 원소들이 제시하는 위치 p_i 들을 기반으로 정의된다. 이 과정에서 이웃하는 원소들과의 강성에 따른 가중치 w_i 가 부여되며, 강성이 높을 이웃일수록 더 큰 영향력을 가지며, 단단한 구조일수록 높은 우선순위를 갖도록 한다.

$$p_e^* = \frac{\sum_{i=1}^m (p_i w_i)}{\sum_{i=1}^m w_i} \quad \text{수식 2}$$

결과적으로 후처리 안정화 단계를 통해 변형 세기나 물성 구조와 관계없이 일정한 품질의 수렴을 유도함으로써, 반복 횟수에 대한 수동 조정 부담을 줄이고 시뮬레이션 결과의 일관성을 확보할 수 있다. 이는 고정되지 않은 원소에 대해 인접 노드와의 거리 제약을 기반으로 위치를 보정하며, 비교적 낮은 계산 복잡도로 병렬 환경에서도 효율적으로 수행될 수 있다.

본 연구는 다양한 입력 조건에서 일정한 안정화 효과를 제공하며, 기존 체인메일 구조와도 자연스럽게 통합될 수 있다. 이는 GPU 기반 체인메일 알고리즘의 시뮬레이션 품질을 보완하는 단순하면서도 실용적인 방안으로 적용할 수 있음을 보인다.

4.3 데이터 가시화

시스템 파이프라인의 마지막 단계는 데이터 가시화이다. 먼저, 본 연구에서는 Park이 제안한 병렬 리샘플링 기반의 방법을 활용하여 변형된 볼륨 데이터를 생성한다(Park, C., 2022). 이는 앞선 단계로부터 획득한 변형되지 않은 원본 데이터의 CUDA 텍스처와 데이터 변형 단계의 출력인 이동이 반영된 정보를 입력으로 사용한다. 병렬 리샘플링은 이 두 입력을 기반으로, 변형된 샘플링 메시지를 정규격자 상에 다시 매핑함으로써 변형된 볼륨 데이터를 구성한다. 이때, 사용되는 변형 정보는 앞선 체인메일 기반 변형 알고리즘의

출력 결과인 이동이 반영된 정보로부터 계산된 각 격자의 이동 좌표이며, 해당 좌표를 기준으로 CUDA 텍스처에 저장된 원본 볼륨 데이터의 밀도 값과 색상 값을 획득한다. 이 과정은 CUDA 텍스처를 사용함으로써, 보간을 포함한 샘플링 방식으로 GPU 상에서 고속으로 수행된다. 마지막으로, 병렬 리샘플링으로부터 생성된 정규격자 기반의 변형된 볼륨 데이터는 전통적인 볼륨 가시화 기법을 통해 실시간으로 시각화된다.



V. 실험 및 결과

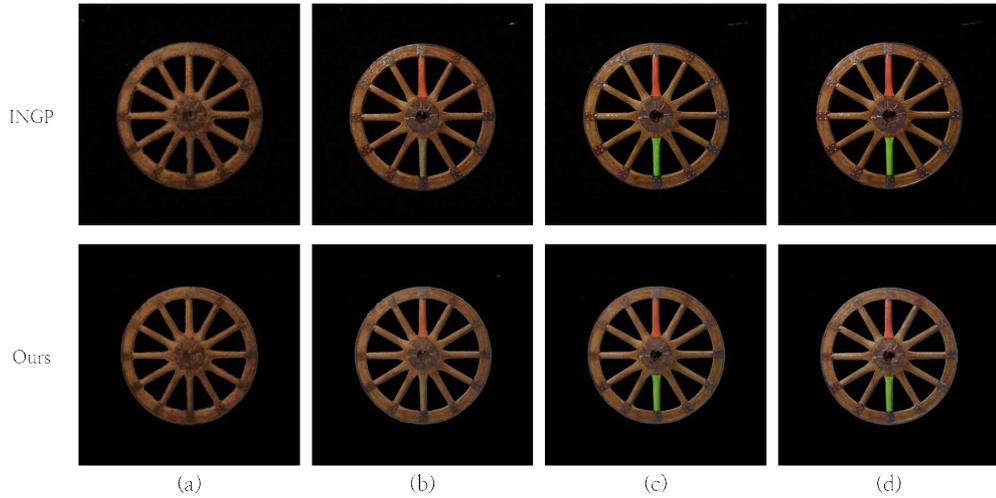
5.1 실험 환경

본 실험은 Intel i7-14700F CPU, 64GB RAM, NVIDIA GeForce RTX 4070 SUPER 환경에서 수행되었다. 실험은 512x512x300 크기의 복부 CT 데이터와 Galaxy Z Flip 6의 핸드폰 카메라로 약 30초 촬영한 동영상을 입력 데이터로 사용한다. 해당 동영상으로부터 초당 두 장의 이미지를 생성하여 총 60개의 다시점 영상으로 학습을 수행한다. 추가로 기존 NeRF 데이터셋의 학습 및 변형 결과를 확인하기 위해 ParticleNeRF(Abou-Chakra, J., 2024)의 Wheel 데이터셋과 synthetic NeRF scenes(Mildenhall, B., 2021)의 Lego 데이터셋을 사용한다. 각 데이터셋은 24,000개와 100개의 다시점 영상을 가진다.

5.2 이산화된 데이터 가시화 결과

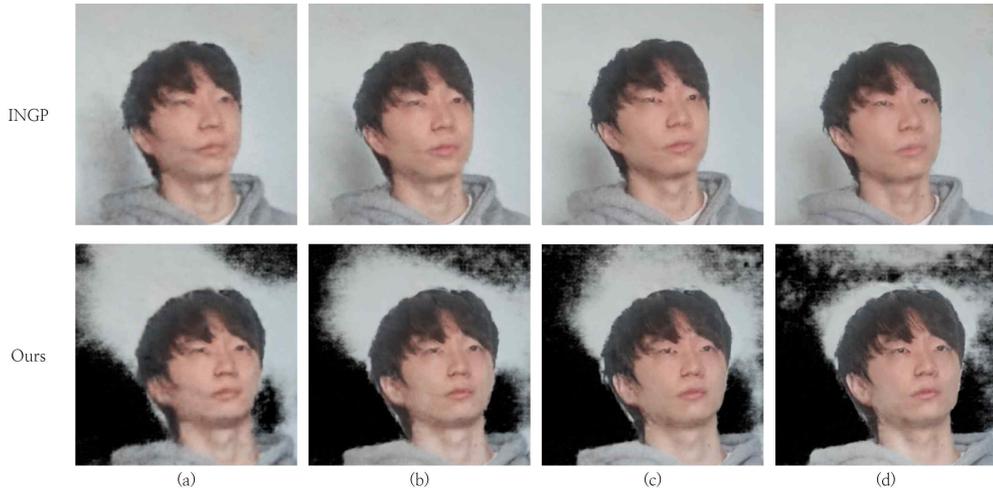
본 연구가 제안하는 시스템은 INGP로 학습된 암시적 신경 표현인 INR을 명시적 볼륨 데이터로 변환하여 실험을 진행한다. INGP에서는 학습 횟수(iteration)가 모델의 수렴도와 표현력에 직접적인 영향을 미치며, 이는 결과 영상 품질을 결정짓는 주요 요인 중 하나로 여겨진다. INGP는 주어진 다시점 영상 집합을 기반으로 INR을 학습하며, 학습이 충분하지 않으면 공간 구조나 색상 정보의 표현력이 부족하여 결과 영상 품질이 저하된다.

이에 따라, 본 연구에서는 INGP로 학습된 INR을 명시적 볼륨 데이터로 변환한 후, 그 품질이 실제로 학습의 진행 정도에 따라 어떤 영향을 받는지 검증하고자 한다. 이를 위해 학습 횟수를 100, 250, 500, 그리고 1000으로 조절하며, 각 단계에서 생성된 암시적 표현을 256x256x256 크기의 명시적 볼륨 데이터로 변환하고, 변환된 결과 영상과 원본 영상 간의 품질 차이를 비교한다.



[그림 5-1] Wheel 데이터셋의 학습 횟수 비교.
 (a) 100, (b) 250, (c) 500, (d) 1000

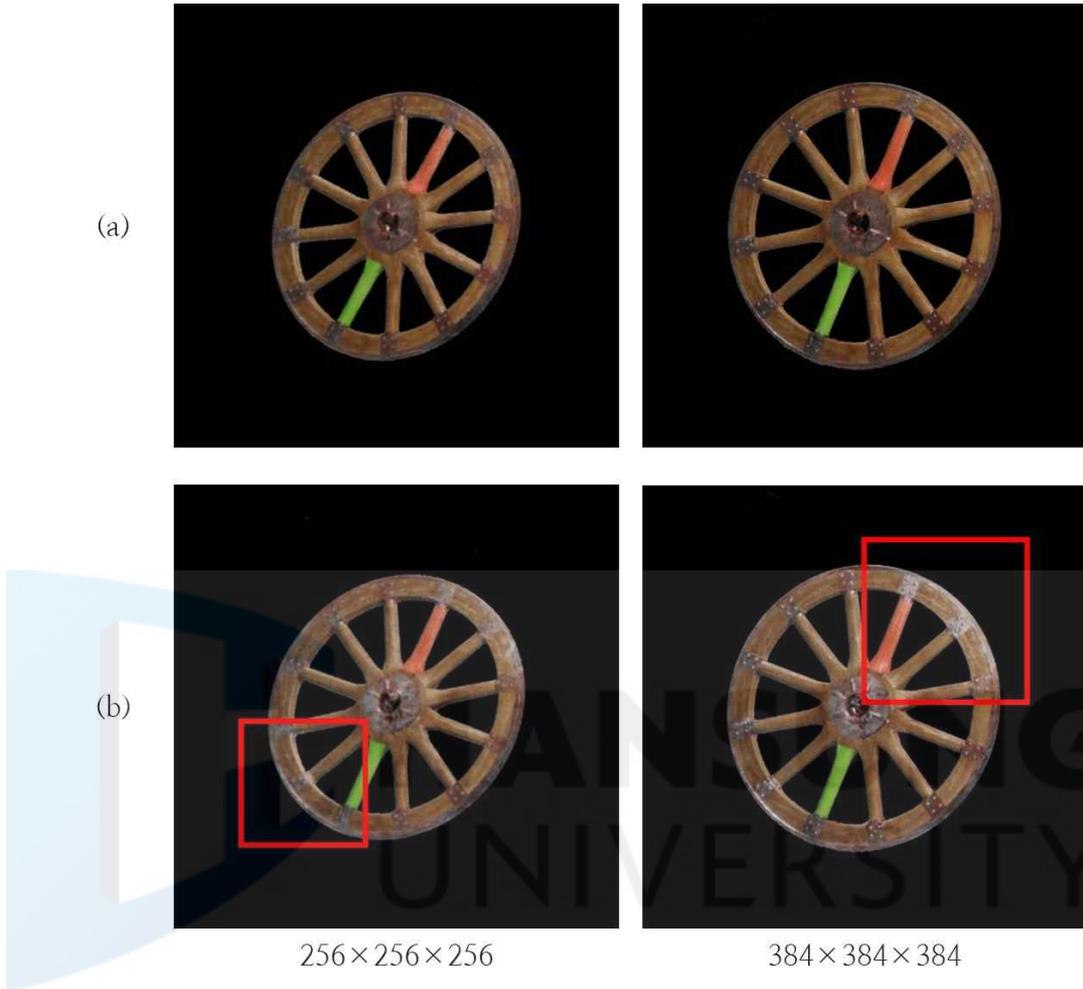
[그림 5-1]를 통해 명시적 볼륨 데이터로 변환된 결과는 INGP의 학습 횟수에 따라 큰 품질 변화 없이 비교적 안정적인 모습을 보인다. 이는 품질 차이가 학습 부족이 아니라, INGP가 내부적으로 $\sqrt{3}/1024$ 의 고정된 간격으로 샘플링한 고정밀 표현을 $256 \times 256 \times 256$ 크기의 명시적 볼륨 데이터로 다운 샘플링하는 과정에서 발생한 손실로부터 비롯된 것임을 확인할 수 있다.



[그림 5-2] 카메라 촬영을 통해 생성된 다시점 입력 집합 학습 횟수 비교.
(a) 200, (b) 500, (c) 1000, (d) 2000

[그림 5-2]는 카메라 촬영을 통해 생성된 다시점 입력 집합을 학습한 결과를 나타낸다. 이 경우 사용된 입력 영상 수가 Wheel 데이터셋보다 적은 60장에 불과하므로, 실험에서는 학습 횟수를 두 배로 설정하여 비교하였다. 직접 촬영한 동영상 기반의 학습은 상대적으로 노이즈가 많이 발생하는 경향이 있다. 이에 따라, 본 연구에서는 명시적 볼륨 데이터를 생성하는 과정에서 특정 임계값 이하의 밀도 값을 가진 복셀을 완전히 투명하게 처리하여, 상대적으로 중요도가 낮은 배경 영역에 존재하는 노이즈를 효과적으로 제거할 수 있었다.

또한, 본 연구에서는 사용자 입력으로 시점이 변경될 때마다 명시적 볼륨 데이터를 다시 생성하여 시점 의존적 특성을 재현한다. [그림 5-3]은 학습된 INR을 명시적 볼륨 데이터로 변환하는 과정에서 재현되는 시점 의존성 특성을 보인다. 시점 의존성이 반영된 모습을 뚜렷하게 비교하기 위해, 가장 입력 영상 수가 많은 Wheel 데이터셋을 사용하여 실험을 진행하였다.



[그림 5-3] 시점 의존적 특성을 반영하지 않은 영상 (a), 시점 의존적 특성을 반영한 영상 (b)

(a)는 시점 의존성을 적용하지 않은 결과로, 초기에 고정된 시점으로 변환된 명시적 볼륨 데이터를 사용한다. 반면, (b)는 변경된 시점 방향에 맞추어 INR로부터 명시적 볼륨 데이터를 다시 생성한 후 가시화를 수행한 결과를 보여준다. 특히, 고해상도 볼륨 데이터에서는 시점 의존적 특성이 더욱 정밀하게 반영된 모습을 더욱 뚜렷하게 확인할 수 있다.

INGP는 이산화를 수행하는 과정에서, 한 번에 처리되는 샘플 수를 백만 개 또는 해상도에 따라 필요한 전체 샘플 수 중 더 작은 값으로 제한하였다. 그러나 고해상도의 볼륨 데이터를 입력으로 사용하는 경우, 지나치게 많은 샘

플을 한 번에 처리하는 경우 GPU 메모리 사용량이 급격히 증가하고, 캐시 미스(cache miss)나 스레드 간 자원 경쟁 등으로 전체 처리 속도가 오히려 저하될 수 있다. 이때, 한 번에 처리되는 샘플 수(Batch Size)를 조절하여 GPU의 메모리 대역폭과 연산 자원을 효과적으로 활용할 수 있는 적절한 균형점을 확인하고자 한다.

[표 5-1] 해상도별로 명시적 볼륨 데이터를 변환하기 위한 시간

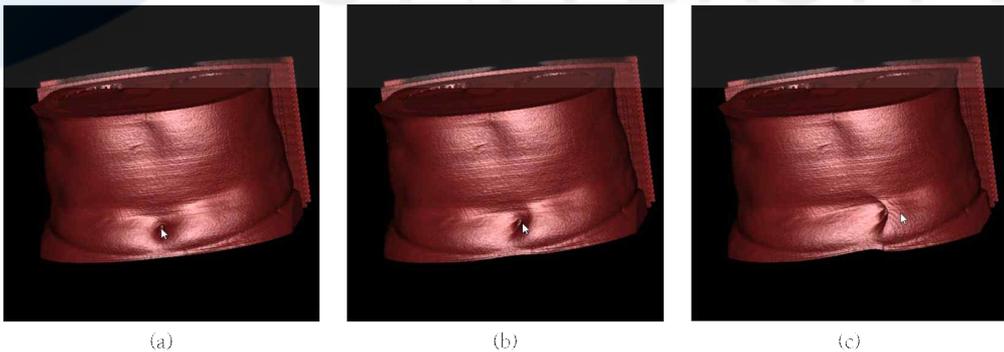
		Volume Size		
		128×128×128	256×256×256	384×384×384
Batch Size (2^n)	16	7.03	41.37	123.68
	17	6.70	35.63	113.03
	18	6.92	35.29	114.36
	19	7.49	40.44	129.01
	20	8.91	45.11	147.31
	21	9.87	50.27	185.92
	22	9.86	51.50	168.49

[표 5-1]은 사용되는 볼륨 데이터 해상도에 따라 암시적 신경 표현을 명시적 볼륨 데이터로 변환한 데까지 걸리는 시간을 ms단위로 나타낸다. 이는 시점 변경을 100회 수행하였을 때 걸린 평균 시간을 나타낸다. 실험 결과에 따르면, 처리 단위를 2^{17} 로 설정하였을 때, 가장 빠른 처리 성능을 보인다. 이

보다 큰 단위로 갈수록 메모리 대역폭을 초과하거나 캐시 구조를 비효율적으로 사용하여 처리 속도가 오히려 저하되는 모습이 관찰되며, 반대로 더 작은 단위는 개별 처리량이 부족하여 GPU의 연산 유닛이 충분히 활용되지 않는 문제가 발생한다.

5.3 사용자 입력에 따른 체인메일 변형 결과

물리 변형은 사용자가 마우스를 드래그하여 원하는 방향으로 직접 가할 수 있다. 사용자가 마우스로 클릭한 화면상의 위치는 삼차원 공간상의 광선으로 변환되며, 이 광선은 카메라를 기준으로 볼륨 데이터 내부를 따라 투사된다. 이때, 광선이 지나가는 경로 상에서 미리 설정된 임계값보다 큰 강성을 가지는 복셀 중 가장 먼저 광선과 교차하는 복셀을 변형의 기준점으로 선택한다. 또한, 변형의 강도는 사용자가 마우스로 드래그한 거리의 크기에 비례하여 조절할 수 있다. [그림 5-4]는 복부 CT 데이터를 대상으로 변형을 수행한 결과를 보인다. 제시된 결과를 통해, (c)에서는 사용자가 더 넓은 범위를 드래그하여 더 강한 물리 변형이 적용되었음을 확인할 수 있다.



[그림 5-4] 사용자 마우스 드래그로 수행된 변형 결과.
(a) 마우스로 선택된 변형 위치, (b) 약한 변형, (c) 강한 변형

INGP를 통해 학습된 INR을 변환하여 생성된 명시적 볼륨 데이터를 대상으로 체인메일 알고리즘을 적용한 결과를 [그림 5-5]에 제시한다. 사용된

NeRF 데이터셋은 Lego와 Wheel이며, (a)는 변형 전 원본 영상을, (b)는 변형을 가한 이후의 결과를 나타낸다. Lego에서는 굴삭기 중심부에 물리적 전파를 가하여 전면이 앞으로 쏠리는 변형이 발생하며, 전파가 물체를 따라 이동하여 하단의 구조물도 함께 앞으로 변형되는 모습을 확인할 수 있다. Wheel의 경우, 정면에서 충격을 가한 모습을 유사하게 표현하여 좌측 상단의 바퀴가 뒤로 밀리며 찌그러진 결과를 보인다.

Lego



Wheel



(a)

(b)

[그림 5-5] INGP의 밀도 값 기반 체인메일 변형 결과.

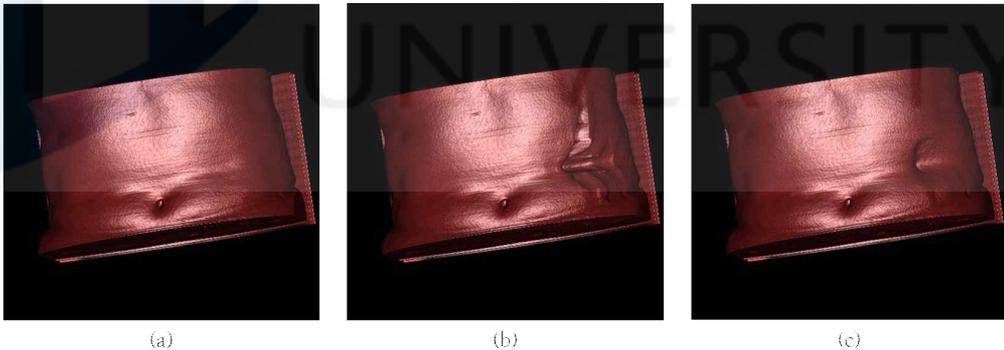
(a) 변형 전 영상, (b) 변형 후 영상

두 데이터셋 모두 학습을 통해 추론된 밀도 값을 사용하여 체인메일 알고

리즘을 적용한다. 이 밀도 값은 CT 데이터와 달리 물체 내부의 물리적 강성을 표현하지 않지만, 정규화된 불투명도 α 값의 기준을 적절하게 설정할 경우, 물체가 물리적으로 자연스럽게 변형될 수 있으며, 일정 수준 이상의 강성 값을 가지고 있어 원래의 형태로 수렴하는 특성을 관찰할 수 있다.

5.4 후처리 안정화 단계 적용 결과

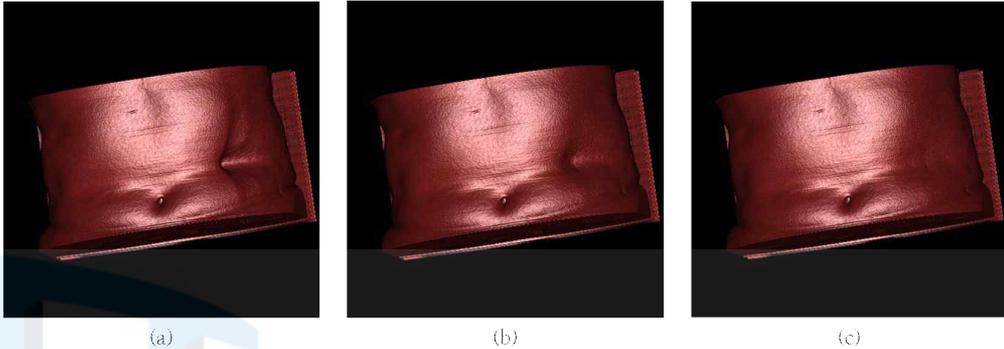
본 연구는 체인메일 알고리즘 기반의 물리 변형을 사용하며, 후처리 안정화 단계를 추가로 구현하여 더욱 안정된 수렴 품질을 달성하고자 한다. 기존의 HP-체인메일은 매 프레임 고정된 횟수의 안정화 단계만 수행하였고, 활성화 블록에 대한 모든 전파가 완료되면 더 이상 안정화를 수행하지 않는다. 이는 입력 데이터가 바뀌게 될 경우, 해당 데이터에 적합한 안정화 횟수를 다시 찾아야 함을 의미한다. [그림 5-6]은 에 제시된 결과를 통해 안정화 횟수를 조정함으로써, 더욱 안정된 수렴 결과를 얻을 수 있음을 증명한다.



[그림 5-6] 안정화 횟수에 따른 변형 결과.
(a) 원본 데이터 영상, (b) 2회 적용된 영상,
(c) 3회 적용된 영상

본 연구에서는 입력 데이터와 무관하게 임의의 횟수의 안정화를 수행한 후, 후처리 안정화 단계를 추가하여 일관된 수렴 결과를 얻을 수 있도록 한다. [그림 5-7]은 매 프레임 한 번의 안정화 단계를 추가로 수행하는 후처리

안정화 단계를 [그림 5-6]의 (b)영상을 대상으로 적용한 결과를 보인다. 이는 전체 체인메일 원소 볼륨을 대상으로 수행되므로, (a)에서 활성화 블록에 대해서만 수행된 안정화로 인해 불안정했던 경계를 완화한 모습을 확인할 수 있다. 또한, (c)에서 25회만 적용해도 [그림 5-6]의 (a) 원본 데이터 영상과 거의 동일한 모습으로 수렴되었음을 확인할 수 있다.



[그림 5-7] 후처리 안정화 횟수에 따른 수렴 결과.
(a) 5회, (b) 10회, (c) 25회

[표 5-2]는 데이터 변형 단계의 입력인 원본 데이터와 출력인 체인메일 전파를 통해 이동이 반영된 데이터의 위치 정보를 비교하여 오차를 소수점 아래 넷째 자리까지 반올림한 결과를 나타낸다. 수식 3에서 제시한 오차 값 e_i 은 원소 i 가 주변의 6개 이웃 원소 $N(i)$ 들과 이루는 상대 위치 구조의 변화량을 측정함으로써, 구조 전체의 형태가 잘 유지되고 있는지 평가한다. 이때, p_i 는 원본 데이터에서의 원소 위치를, p'_i 는 이동이 반영된 데이터에서의 위치를 각각 나타낸다.

$$e_i = \left\| \sum_{j \in N(i)} (p'_j - p'_i) - \sum_{j \in N(i)} (p_j - p_i) \right\| \quad \text{수식 3}$$

즉, 전체 구조가 이동하거나 전체적으로 조금씩 변형되더라도, 이웃 간의 상대적인 배치가 그대로 유지된다면 오차 값은 작게 유지된다. 이는 형상의

안정성에 초점을 두어, 전체 데이터를 대상으로 적용되는 후처리 안정화 단계가 변형된 부분에 오차를 최소화하는 결과를 강조하기 위함이다.

[표 5-2] 후처리 안정화 단계 수렴 결과 비교

		No Post Relaxation	# of Post Relaxations			
			5	10	25	50
Deform Intensity (distance)	20	0.0023	0.0012	0.0009	0.0007	0.0005
	40	0.0054	0.0031	0.0026	0.0015	0.0010
	60	0.0080	0.0047	0.0035	0.0021	0.0015
	80	0.0111	0.0060	0.0047	0.0029	0.0021
	100	0.0133	0.0073	0.0057	0.0039	0.0027

변형의 강도(Deform Intensity)가 강해질수록 많은 전파가 이루어져 오차 값이 크게 나타나는 결과를 확인할 수 있다. 또한, 전체 데이터를 대상으로 안정화 단계를 5회만 수행해도 오차가 약 50%로 줄어드는 결과를 보인다. 이는 활성화된 블록에 대해서만 안정화를 수행하지 않고, 전체 체인메일 원소에 대해서 안정화를 수행함으로써 더욱 자연스러운 수렴 결과를 얻게 됨을 증명한다.

5.5 제안 시스템을 통한 물리 변형 후 가시화 결과

본 시스템의 최종 출력은 이산화된 데이터를 사용하여 체인메일 변형을 수행한 뒤, 후처리 안정화 단계까지 적용한 가시화 결과이다. [표 5-3]은 체

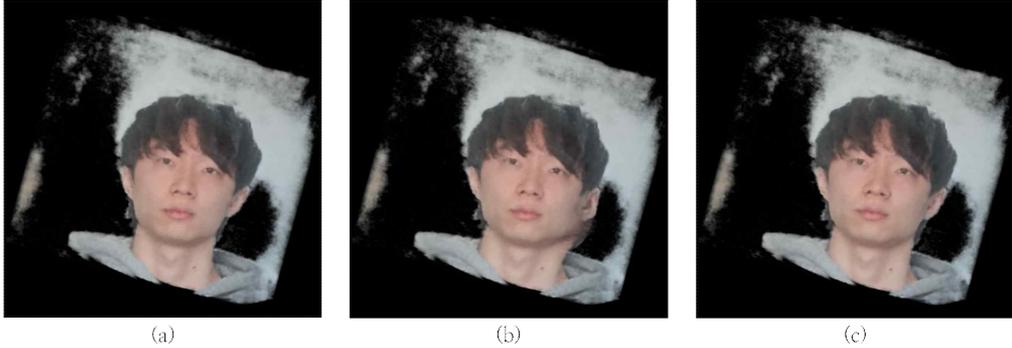
인메일 변형, 후처리 안정화, 그리고 가시화 단계의 소요 시간을 사용하는 데이터 해상도 크기에 따라 비교한 결과를 보인다. 이때, 변형과 후처리 안정화는 체인메일 원소 볼륨을 대상으로 수행되므로, 1/4 크기로 다운샘플링된 해상도를 가진다.

[표 5-3] 볼륨 해상도 크기에 따른 변형 및 가시화 속도 비교

		Volume Size		
		128×128×128	256×256×256	384×384×384
Frame Time (ms)	Deform	1.9449	3.1923	5.9422
	Post Relax	0.3021	0.3898	0.5192
	Render	2.0912	6.5966	20.5681
	Total	4.3382	10.1787	27.0295

실험 결과는 100프레임 동안 변형 및 가시화를 수행한 평균 시간을 ms단위로 측정한 결과이다. 이는 384×384×384 크기의 고해상도 볼륨 데이터에서도 약 27ms의 속도를 보임으로써, 사용자 입력으로 시점이 변경되어 수행되는 이산화 과정을 제외하면, 최소한의 오버헤드로 실시간 성능을 보일 수 있음을 증명한다.

[그림 5-8]은 카메라 촬영을 통해 획득한 다시점 영상 집합으로 INGP가 학습하여 생성한 데이터를 대상으로 체인메일 변형 이후 후처리 안정화 단계까지 적용된 최종 출력 결과를 보인다.



[그림 5-8] 카메라 촬영을 통해 획득한 다시점 영상 집합으로 생성한 데이터의 변형 및 가시화 결과.
 (a) 원본 데이터 영상, (b) 외력이 가해진 영상,
 (c) 후처리 단계로 수렴된 결과

(b)에서는 관찰자 시점 기준으로, 사용자 입력에 의한 변형으로 오른쪽 볼이 늘어나는 모습을 확인할 수 있으며, 이와 함께 주위 피부 조직도 함께 자연스럽게 끌려오는 모습을 관찰할 수 있다. 이후 (c)에서는 후처리 안정화 단계를 거쳐 수렴된 모습으로, 원본 데이터 (a)와 비교하였을 때 시각적으로 식별하기 힘들 정도로 형태가 복원되는 것을 확인할 수 있다.

VI. 결론

본 연구에서는 INGP를 기반으로 학습을 수행한 데이터를 획득하고 이를 명시적 볼륨 데이터로 변환한 뒤, 체인메일 알고리즘으로 변형 및 병렬 리샘플링을 수행하고 이를 가시화하는 볼륨 기반의 통합 시스템을 구현하였다. 이 시스템은 시점 방향이 변경될 때마다 해당 시점에 맞춰 명시적 볼륨 데이터를 생성하여 시점 의존적인 시각적 특성을 재현한다. 또한, INGP의 밀도 값을 기반으로 체인메일 요소의 상대적인 강성 제약 기준을 정의하여, 실제 물리 변형과 유사한 결과를 얻을 수 있었다. 이 과정에서 기존 체인메일 알고리즘에 후처리 안정화 단계를 추가함으로써, 보다 안정적으로 수렴하는 변형 결과를 제공한다. 이는 향후 의료 시뮬레이션의 발전을 위한 기반이 되는 시스템으로, 파이프라인의 각 단계에 사용되는 모듈들을 유연하게 사용할 수 있는 틀을 제공한다.

그러나 본 연구는 의료 영상 데이터를 활용한 실시간 가상 수술 시뮬레이션을 목표로 하였으나, 제시된 실험 결과는 인체 외부를 대상으로 표면 데이터와 기존 NeRF 실험용 데이터셋을 중심으로 구성되었다. 실제 CT 영상은 체인메일 알고리즘을 통한 물리적 변형 시뮬레이션에만 활용되었으며, 다시점 실사 영상과의 정합을 포함한 통합 시각화까지는 구현하지 못하였다. 이는 의료용 CT 데이터와 다시점 실사 영상 간의 정밀한 정합(registration) 기술이 요구되며, 해당 부분은 향후 연구를 통해 보완되어야 할 과제로 남아 있다.

참 고 문 헌

1. 국내문헌

이상은, 계획원. (2023a). 3D 체인메일을 이용한 변형체의 GPU 최적화 연구. 『멀티미디어학회논문지』, 26(2), 131-139.

이상은, 계획원. (2023b). 3D 체인메일을 이용한 변형체의 가시화 효율성 연구. 『한국HCI학회 학술대회』, 921-923.

이상은, (2024), “병렬적 3차원 체인메일 알고리즘의 최적화 연구” 대학원 석사 학위논문



2. 국외문헌

- Abou-Chakra, J., Dayoub, F., & Stünderhauf, N. (2024). Particlenerf: A particle-based encoding for online neural radiance fields. In Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (pp. 5975–5984).
- Aguilera, A. R., Salas, A. L., Perandrés, D. M., & Otaduy, M. A. (2015). A parallel resampling method for interactive deformation of volumetric models. *Computers & Graphics*, 53, 147–155.
- Chen, A., Xu, Z., Geiger, A., Yu, J., & Su, H. (2022, October). Tensorf: Tensorial radiance fields. In European conference on computer vision (pp. 333–350). Cham: Springer Nature Switzerland.
- Barron, J. T., Mildenhall, B., Verbin, D., Srinivasan, P. P., & Hedman, P. (2022). Mip-nerf 360: Unbounded anti-aliased neural radiance fields. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 5470–5479).
- Corona-Figueroa, A., Frawley, J., Bond-Taylor, S., Bethapudi, S., Shum, H. P., & Willcocks, C. G. (2022, July). Mednerf: Medical neural radiance fields for reconstructing 3d-aware ct-projections from a single x-ray. In 2022 44th annual international conference of the IEEE engineering in medicine & Biology society (EMBC) (pp. 3843–3848). IEEE.
- Deng, K., Liu, A., Zhu, J. Y., & Ramanan, D. (2022). Depth-supervised nerf: Fewer views and faster training for free. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 12882–12891).
- Feng, Y., Shang, Y., Li, X., Shao, T., Jiang, C., & Yang, Y. (2024). Pie-nerf: Physics-based interactive elastodynamics with nerf. In Proceedings of the IEEE/CVF Conference on Computer Vision

and Pattern Recognition (pp. 4450–4461).

- Gascon, J., Espadero, J. M., Perez, A. G., Torres, R., & Otaduy, M. A. (2013, July). Fast deformation of volume data using tetrahedral mesh rasterization. In Proceedings of the 12th ACM SIGGRAPH/Eurographics Symposium on Computer Animation (pp. 181–185).
- Gibson, S. F. (1997, April). 3D chainmail: a fast algorithm for deforming volumetric objects. In Proceedings of the 1997 symposium on Interactive 3D graphics (pp. 149–ff).
- Gibson, S., Fyock, C., Grimson, E., Kanade, T., Kikinis, R., Lauer, H., ... & Sawada, A. (1998). Volumetric object modeling for surgical simulation. *Medical Image Analysis*, 2(2), 121–132.
- Hu, J., Fan, Q., Hu, S., Lyu, S., Wu, X., & Wang, X. (2024, May). UMedNeRF: Uncertainty-aware single view volumetric rendering for medical neural radiance fields. In 2024 IEEE International Symposium on Biomedical Imaging (ISBI) (pp. 1–4). IEEE.
- Lampen, N., Kim, D., Fang, X., Xu, X., Kuang, T., Deng, H. H., ... & Yan, P. (2022). Deep learning for biomechanical modeling of facial tissue deformation in orthognathic surgical planning. *International journal of computer assisted radiology and surgery*, 17(5), 945–952.
- Li, X., Qiao, Y. L., Chen, P. Y., Jatavallabhula, K. M., Lin, M., Jiang, C., & Gan, C. (2023). Pac-nerf: Physics augmented continuum neural radiance fields for geometry-agnostic system identification. arXiv preprint arXiv:2303.05512.
- Mescheder, L., Oechsle, M., Niemeyer, M., Nowozin, S., & Geiger, A. (2019). Occupancy networks: Learning 3d reconstruction in function space. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 4460–4470).

- Mildenhall, B., Srinivasan, P. P., Tancik, M., Barron, J. T., Ramamoorthi, R., & Ng, R. (2021). Nerf: Representing scenes as neural radiance fields for view synthesis. *Communications of the ACM*, 65(1), 99–106.
- Müller, T., Rousselle, F., Novák, J., & Keller, A. (2021). Real-time neural radiance caching for path tracing. *arXiv preprint arXiv:2106.12372*.
- Müller, T., Evans, A., Schied, C., & Keller, A. (2022). Instant neural graphics primitives with a multiresolution hash encoding. *ACM transactions on graphics (TOG)*, 41(4), 1–15.
- Park, C., & Kye, H. (2022). Efficient Massive Computing for Deformable Volume Data Using Revised Parallel Resampling. *Sensors*, 22(16), 6276.
- Park, J. J., Florence, P., Straub, J., Newcombe, R., & Lovegrove, S. (2019). Deepsdf: Learning continuous signed distance functions for shape representation. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 165–174).
- Peng, S., Niemeyer, M., Mescheder, L., Pollefeys, M., & Geiger, A. (2020). Convolutional occupancy networks. In *Computer Vision – ECCV 2020: 16th European Conference, Glasgow, UK, August 23 – 28, 2020, Proceedings, Part III 16* (pp. 523–540). Springer International Publishing.
- Pumarola, A., Corona, E., Pons-Moll, G., & Moreno-Noguer, F. (2021). D-nerf: Neural radiance fields for dynamic scenes. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 10318–10327).
- Qi, C. R., Yi, L., Su, H., & Guibas, L. J. (2017). Pointnet++: Deep hierarchical feature learning on point sets in a metric space.

Advances in neural information processing systems, 30.

- Reiser, C., Peng, S., Liao, Y., & Geiger, A. (2021). Kilonerf: Speeding up neural radiance fields with thousands of tiny mlps. In Proceedings of the IEEE/CVF international conference on computer vision (pp. 14335–14345).
- Rodríguez, A., León, A., Arroyo, G., & Mantas, J. M. (2015). SP-ChainMail: a GPU-based sparse parallel ChainMail algorithm for deforming medical volumes. *The Journal of Supercomputing*, 71, 3482–3499.
- Rodríguez, A., León, A., & Arroyo, G. (2016). Parallel deformation of heterogeneous ChainMail models: Application to interactive deformation of large medical volumes. *Computers in Biology and Medicine*, 79, 222–232.
- Schonberger, J. L., & Frahm, J. M. (2016). Structure-from-motion revisited. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4104–4113).
- Sun, C., Sun, M., & Chen, H. T. (2022). Direct voxel grid optimization: Super-fast convergence for radiance fields reconstruction. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 5459–5469).
- Ter Horst, R., van Weert, H., Loonen, T., Bergé, S., Vinayahalingam, S., Baan, F., ... & Xi, T. (2021). Three-dimensional virtual planning in mandibular advancement surgery: Soft tissue prediction based on deep learning. *Journal of Cranio-Maxillofacial Surgery*, 49(9), 775–782.
- Wang, Y., Gong, Y., & Zeng, Y. (2024). Hyb-NeRF: a multiresolution hybrid encoding for neural radiance fields. In 2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV) (pp. 3677–3686). IEEE.

- Wang, X., Hu, S., Fan, H., Zhu, H., & Li, X. (2024). Neural radiance fields in medical imaging: Challenges and next steps. arXiv preprint arXiv:2402.17797.
- Zhang, K., Riegler, G., Snavely, N., & Koltun, V. (2020). Nerf++: Analyzing and improving neural radiance fields. arXiv preprint arXiv:2010.07492.
- Zhao, S., Jakob, W., Marschner, S., & Bala, K. (2014). Building volumetric appearance models of fabric using micro CT imaging. *Communications of the ACM*, 57(11), 98–105.



3. 기타 자료

FFmpeg. <https://ffmpeg.org/> (accessed May 29, 2025)



ABSTRACT

NeRF-based Deformable Object Visualization System for Real-time Physical Simulation

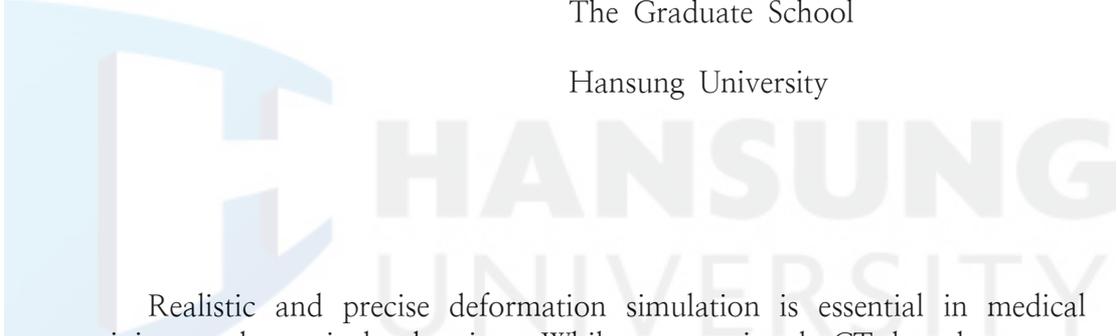
Ku, Hyunwoo

Major in Computer Engineering

Dept. of Computer Engineering

The Graduate School

Hansung University



Realistic and precise deformation simulation is essential in medical training and surgical planning. While conventional CT-based systems effectively represent internal anatomical structures quantitatively, they often lack photorealism in visualizing surface details. To overcome this limitation, we propose a unified, volume-based framework that reconstructs volumetric data from multi-view video captures using Neural Radiance Fields (NeRF), simulates physical deformations, and visualizes the results in high resolution.

Our approach leverages Instant Neural Graphics Primitives (INGP) to rapidly learn an implicit neural representation from raw videos, which is then converted into an explicit volumetric grid suitable for physical simulation. The deformation process is driven by a GPU-parallelized chainmail algorithm, enhanced with a novel stiffness constraint derived from the density values obtained via INGP. This allows for physically plausible deformation using only a single parameter. Additionally, we

introduce a post-processing relaxation stage to improve convergence and realism of the results. The final deformed volume is reconstructed through parallel resampling, enabling real-time rendering with high visual fidelity. By integrating data acquisition, deformation, and visualization into a single pipeline, our system ensures structural coherence and delivers a visually realistic simulation environment for interactive medical applications.

【Keyword】 Medical Simulation, NeRF, 3D Chainmail Algorithm, Parallel Resampling, GPU Parallel Computing, System



HANSUNG
UNIVERSITY