

이화여자대학교 대학원

2024학년도

석사학위 청구논문

양팔 로봇을 이용한 주성분 분석 및  
그래프 학습 기반의 옷감 조작 알고리즘

인공지능·소프트웨어학부

유효정

2025

양팔 로봇을 이용한 주성분 분석 및  
그래프 학습 기반의 옷감 조작 알고리즘

이 논문을 석사학위 논문으로 제출함

2024 년 12 월

이화여자대학교 대학원

인공 지능 · 소프트웨어 학부 유효정

# 유 효 정의 석사학위 논문을 인준함

지도교수 김영준 \_\_\_\_\_

심사위원 박상수 \_\_\_\_\_

오유란 \_\_\_\_\_

김영준 \_\_\_\_\_

이화여자대학교 대학원

# 목 차

<b>I.</b>	<b>서론</b> .....	<b>1</b>
	A. 연구의 필요성 및 목적 .....	1
	B. 문제 정의 .....	2
	C. 도전 과제 .....	6
	D. 연구 기여 .....	7
	E. 논문의 구성 .....	8
<b>II.</b>	<b>관련 연구</b> .....	<b>9</b>
	A. 로봇을 이용한 옷 조작 연구 .....	9
	B. 그래프 기반 인공 신경망 .....	13
	C. 물리 기반 시뮬레이터를 사용한 학습 데이터 생성 .....	15
<b>III.</b>	<b>옷감 조작 알고리즘</b> .....	<b>18</b>
	A. 주성분 분석 기반 알고리즘 .....	18
	1. 파지점 위치 계획 알고리즘 .....	18
	2. 회전 정보 계획 알고리즘 .....	22
	B. 그래프 인공신경망 학습 기반 알고리즘 .....	24
<b>IV.</b>	<b>합성 데이터</b> .....	<b>27</b>
	A. 블렌더 시뮬레이터 .....	27
	B. 학습 데이터 증강 .....	30
	C. 어노테이션과 정답 레이블 .....	32
	1. 파지점 위치 레이블 .....	32
	2. 그리퍼의 접근 방향 레이블 .....	36
	3. 그리퍼의 두 손가락 사이 방향 레이블 .....	37
<b>V.</b>	<b>실험 및 결과</b> .....	<b>40</b>



A. 정성적 평가 .....	40
B. 정량적 평가 .....	44
1. 그래프 인공신경망 학습 평가 .....	44
2. 시뮬레이션 평가 .....	45
<b>VI. 결론 .....</b>	<b>50</b>
<b>Bibliography .....</b>	<b>50</b>
<b>ABSTRACT .....</b>	<b>55</b>

## 표 목 차

표 5.1. PCA 기반 알고리즘의 그리퍼의 포즈 품질 평가.....	46
표 5.2. GNN 학습 기반 알고리즘의 그리퍼의 포즈 품질 평가 .....	47
표 5.3. PCA 기반 알고리즘과 GNN 학습 기반 알고리즘 비교 .....	47

## 그림 목 차

그림 1.1.	다양한 형태의 그리퍼 .....	1
그림 1.2.	문제 정의.....	2
그림 1.3.	그리퍼의 파지 자세 예시 .....	3
그림 1.4.	그리퍼와 로컬 프레임(local frame) .....	4
그림 1.5.	그리퍼의 이동 과정.....	5
그림 1.6.	파지 후 옷을 펼치는 과정 .....	5
그림 2.1.	FlingBot[8] 연구 .....	10
그림 2.2.	로봇을 활용한 옷 조작 작업 벤치마크 연구[9].....	10
그림 2.3.	자연어를 사용한 옷 조작 연구[10].....	11
그림 2.4.	Zhu의 연구[11] .....	12
그림 2.5.	Qian의 연구[12] .....	12
그림 2.6.	GNN의 기본 동작 원리[13].....	13
그림 2.7.	Grigorev의 연구[14] .....	14
그림 2.8.	B-spline 기반의 컨볼루션 연산 예시[16].....	14
그림 2.9.	Pfaff의 MeshGraphNets[17].....	16
그림 2.10.	Blanco의 시뮬레이션 데이터와 실세계 데이터간의 거리 비교 연구[21] .....	16
그림 2.11.	Lips의 연구[26].....	17
그림 3.1.	$k$ 값의 변화에 따른 추출된 점들의 변화 (threshold는 0.2로 고정).....	20
그림 3.2.	threshold값의 변화에 따른 추출된 점들의 변화 ( $k$ 는 32로 고정).....	21
그림 3.3.	그리퍼의 접근 방향.....	22
그림 3.4.	PCA 기반 방식을 사용한 그리퍼의 포즈 계산 과정 .....	23

그림 3.5.	GNN 학습 기반 방식을 사용한 그리퍼의 포즈 계획 과정	24
그림 3.6.	GNN 기반의 모델 아키텍처	25
그림 4.1.	블렌더의 옷 시뮬레이션에 사용되는 스프링의 종류	29
그림 4.2.	블렌더에서 모델링한 티셔츠와 수건의 모습	29
그림 4.3.	허공에 걸려있는 옷 메쉬	30
그림 4.4.	회전과 스케일 값을 변경한 옷감 형상	31
그림 4.5.	옷의 주요 지점 클러스터링	32
그림 4.6.	중간 $\text{score}(v_i)$ 값	33
그림 4.7.	최종 $\text{score}(v_i)$ 값	34
그림 4.8.	깊이에 따른 노드 클러스터링	36
그림 4.9.	그리퍼의 접근 방향 레이블, 빨간노드는 $v_i$ , 주황색 노드들은 $N$ , 파란색 화살표는 $\mathbf{r}_z$ 를 나타낸다	37
그림 4.10.	같은 깊이 클러스터 내 인접 노드	38
그림 4.11.	그리퍼의 포즈 레이블	39
그림 5.1.	PCA 분석 결과의 정성적 비교	42
그림 5.2.	GNN 학습 기반 결과의 정성적 비교	43
그림 5.3.	수건 데이터셋을 사용한 학습의 손실 함수 그래프	44
그림 5.4.	티셔츠 데이터셋을 사용한 학습의 손실 함수 그래프	44
그림 5.5.	파지 성공 여부 판단	45
그림 5.6.	수건을 펼친 모습	49
그림 5.7.	티셔츠를 펼친 모습	49

## 논문개요

발전된 센서 기술, 모션 플래닝 및 로봇 제어 알고리즘과 인공지능 기술을 갖춘 로봇의 등장으로 인해 사람들이 단순 반복 작업이나 위험한 작업을 직접 하지 않고도 로봇을 활용해 편리하게 처리할 수 있게 되었다. 예를 들어, 산업용 로봇은 조립 라인에서 부품을 정확하게 조작하고 이동시키는 데 사용되며, 자율 주행 차량의 연구의 경우 로봇이 도로 위의 장애물을 인식하고 회피하는 기술이 개발되어, 안전하고 효율적인 운영을 가능하게 한다.

그러나 얇고 유연한 소재인 옷과 같은 소프트 바디를 조작하는 것은 여전히 중요한 연구 과제이다. 원하는 작업에 맞춰 로봇이 옷을 조작하기 위해서는 옷의 형상을 정확하게 파악하고 그리퍼가 옷의 어느 부분을 잡아야 하는지를 고려해야 한다. 지금까지 많은 연구에서는 옷이 잘 펼쳐져 있는 상태를 가정하여 로봇의 인식 시스템이 형상을 쉽게 파악하였으나, 실제 환경에서는 옷이 구겨져 있는 경우가 대부분이다. 따라서 옷을 잘 펼치는 작업이 선행되어야 하며, 이를 통해 로봇이 옷의 형상을 정확하게 인식하고 조작할 수 있다.

본 논문에서는 그리퍼를 장착한 양팔 로봇이 옷을 잘 조작하기 위해서는 옷이 구김 없이 펼쳐진 상태가 선행되어야 한다는 점에 주목하여, 양팔 그리퍼가 최적의 포즈로 옷감을 잡을 수 있는 알고리즘을 제안한다. 이를 위해 두 가지 방법을 사용하였는데, 첫 번째는 옷감의 점군(point cloud) 데이터를 주성분 분석(PCA) 기반 방식으로, 두 번째는 옷의 메쉬 데이터를 그래프 기반(GNN) 학습 기반 방식으로 조작하는 방법이다.

첫 번째 방법인 PCA 분석 기반 방식에서는 옷의 가장자리나 돌출된 지점이 잡는데 성공할 가능성이 높다고 보고, 점군 좌표값의 주성분 분석을 통해 이러한 뾰족한 성질을 가진 특징점들을 찾아낸다. 두 번째 방법인 GNN 학습 기반 방식에서는 물리 시뮬레이터를 이용해 옷의 변형 정도가 현실의 옷감의 움직임과 유사한 학습

데이터를 생성하고, 이를 GNN에 학습시켜 파지 자세를 계획한다.


계획된 파지 자세의 성능은 그리퍼가 계획된 포즈로 이동 시, 두께가 얇은 옷의 파지점이 그리퍼의 손가락 사이에 위치하는지를 통해 파지 성공 여부를 평가하고, 파지점을 잡아 펼쳤을 때 옷의 면적이 얼마나 넓어지는지를 측정하여 평가한다. 그 결과, PCA 기반 알고리즘은 옷감의 초기 형상에 크게 의존하여 그리퍼가 옷을 잡지 못하는 경우가 자주 발생하지만, GNN 기반 알고리즘은 지도 학습 방식으로 다양한 형상의 옷에 유연하게 적응하여 옷을 잡는데 성공한 경우가 더 많았다.

이러한 연구를 통해 로봇을 활용한 옷감 조작 작업의 선행학습인 옷을 펼치는 알고리즘을 제시함으로써, 실제 환경에서의 옷감 조작 기술 발전에 기여할 수 있을 것으로 기대된다.

# I. 서론

## A. 연구의 필요성 및 목적

현대의 로봇 기술은 일상생활에서 사람이 수행하던 단순 반복 작업이나 위험한 작업을 대신할 만큼 발전해왔다. 산업용 로봇은 조립, 용접, 포장 등에서 빠르고 정확한 작업을 수행하고 있으며, 협동 로봇은 사람과 협력하여 공장 내에서 다양한 작업을 동시에 처리할 수 있다. 또한, 자율 주행 차량 기술의 발전으로 로봇이 도로 위에서 장애물을 인식하고 회피하는 능력을 가지게 되었다. 강체에 비해 자유도가 높은 특성을 지닌 옷과 같은 소프트 바디 또한 가정 뿐만 아니라 의료 및 서비스 산업 등 다양한 분야에서 그 필요성이 증가하고 있다. 특히 여러 관절로 이루어진 로봇(redundant robot)은 각 관절을 다양한 각도로 움직일 수 있어 특정 방향으로의 움직임이 제한되는 상태(singularity)를 피하기 쉽다. 또한, 인간의 손과 비슷한 작업을 수행할 수 있도록 그리퍼를 부착한 로봇은 그림 1.1와 같이 다양한 형태의 그리퍼를 적용할 수 있으며, 이를 통해 물체를 집거나 다른 위치로 옮기는 작업에 효과적으로 활용될 수 있다. 이러한 특성 덕분에 그리퍼를 장착한 다관절 로봇은 옷감 조작 분야에서도 유용하게 사용할 수 있다.



(a) 두 손가락 형태[1] (b) 세 손가락 형태[2] (c) 수중 그리퍼[3] (d) 소프트 바디 재질[4]

그림 1.1. 다양한 형태의 그리퍼

옷을 조작하기 위해서는 로봇의 인식 시스템이 주어진 이미지 등의 데이터에서 옷을 인식하고, 어떤 포즈로 옷감을 파지할 지 결정해야 한다. 하지만 일상생활에서 옷감은 구겨져 있는 상태로 놓여 있을 수 있으며, 매니폴레이션 플래닝 시스템 (manipulation planning system)이 옷의 어느 부분을 잡아야 할지 계획하기는 쉽지 않다. 여태까지의 연구들은 주로 옷이 펼쳐져 있는 상태를 가정하고 옷감을 조작하는 방법에 집중해 왔지만, 구겨진 옷을 펼쳐 준비하는 방법에 관해서는 많은 연구가 이루어지지 않았다. 본 연구는 이러한 문제를 해결하고자, 로봇이 임의의 상태에 놓인 옷을 최대 면적으로 파지하고 펼칠 수 있도록 최적의 그리퍼 포즈를 계획하는 방법을 제안한다. 이를 통해 로봇이 이후 수행될 옷감 조작 작업의 성공률을 높이고, 일상생활에서 로봇을 사용한 옷감 조작 작업을 자동화하고자 한다.

## B. 문제 정의





그림 1.2. 문제 정의

본 연구는 그림 1.3와 같이 그리퍼를 장착한 양 팔 로봇을 사용하여 한 쪽 로봇팔이 옷을 허공에 쥐고 있을 때 반대편 로봇팔을 사용하여 옷을 파지할 자세를 추정하는 알고리즘을 연구하는 것이 목표이다.




Gabas는[5] 우선 바닥에 구겨진 상태로 놓인 옷의 윗부분을 한쪽 로봇 팔로 쥐어서 들어 올린 후, 반대쪽 팔로 허공에 늘어져 있는 부분 중 가장 아랫쪽을 잡고 이전에 잡고 있던 윗부분은 놓는 방식으로 옷을 초기화하였다. 이 방식은, 그리퍼에 잡혀 있는 옷의 부피가 최소화할 수 있기 때문이다.

따라서 본 연구에서는 위와 같은 방식으로 그리퍼가 최소한의 부피의 옷을 쥐고 있을 때의 옷감 형상을 점군과 메쉬 데이터를 확보하여 입력 데이터로 사용한다. 그리퍼의 자세 추정시에는 어느 지점을 잡아야 하는지와 그리퍼의 회전(orientation) 정보 두 가지를 결정해야 한다. 점군 데이터를 입력 데이터로 사용하는 경우는 점군상의 특정 점을, 메쉬를 사용하는 경우에는 메쉬상의 특정 노드를 파지 지점으로 선택한다.



(a) 점군 데이터



(b) 메쉬 데이터

그림 1.3. 그리퍼의 파지 자세 예시

점군 데이터는 3차원 공간의 좌표값으로 이루어진 점들의 집합으로, 식 1.1과 같이 표현된다.

$$P = \{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_n\}, \quad \mathbf{p}_i = \begin{bmatrix} x_i \\ y_i \\ z_i \end{bmatrix} \in \mathbb{R}^3 \quad (1.1)$$

점군은 3차원 좌표값 외에도 RGB 색상값을 포함할 수 있지만, 각 점들 간의 연결 정보를 포함하지 않는다는 특징이 있다.

메쉬 데이터는 식 1.2으로 정의되며, 식 1.3은 노드집합, 식 1.4는 엣지 집합, 식 1.5는 평면 집합을 나타낸다. 엣지 집합은 두 노드  $v_i$ 와  $v_j$ 간의 연결성을, 평면 집합은 메쉬를 구성하는 삼각형 면을 나타낸다.

$$M = (V, E, F) \quad (1.2)$$

$$V = \{v_1, v_2, \dots, v_n\} \quad (1.3)$$

$$E = \{e_{i,j} \mid e_{i,j} = (v_i, v_j), \quad 1 \leq i < j \leq n\} \quad (1.4)$$

$$F = \{f_{i,j,k} \mid f_{i,j,k} = (v_i, v_j, v_k), \quad \{e_{i,j}, e_{j,k}, e_{k,i}\} \subseteq E, \quad 1 \leq i < j < k \leq n\} \quad (1.5)$$




그림 1.4. 그리퍼와 로컬 프레임(local frame)

그리퍼의 종류를 고려하여 그리퍼의 회전 상태를 결정해야 한다. 본 연구에서는 그림 1.6과 같이 두 손가락 그리퍼를 사용한다. 그리퍼의 로컬 프레임에서  $\mathbf{r}_z$ 는

그리퍼의 접근 방향,  $\mathbf{r}_y$ 는 그리퍼 두 손가락 사이의 방향을 의미한다. 그리퍼의 회전값은 행렬 1.6과 같이 표현된다. 이 때 얇은 두께를 가진 옷감이 그리퍼의 두 손가락 사이에 놓일 수 있도록 그리퍼의 회전 상태를 결정해야 한다.

$$\mathbf{R} = \begin{bmatrix} \mathbf{r}_x & \mathbf{r}_y & \mathbf{r}_z \end{bmatrix} \in SO(3), \quad \mathbf{r}_x, \mathbf{r}_y, \mathbf{r}_z \in \mathbb{R}^3 \quad (1.6)$$




그림 1.5. 그리퍼의 이동 과정

로봇을 결정된 위치로 곧장 이동 시키면, 옷의 주름 때문에 잡으려는 지점을 가려고 있는 다른 부분과 충돌이 발생할 수 있다. 이를 방지하기 위해, 그림 1.5과 같이 그리퍼는 파지 지점에서 접근 방향의 반대편으로 일정 거리 떨어진 위치로 이동하며, 계획된 그리퍼의 회전값에 맞춰 자세를 조정한다. 이후 그리퍼의 접근 방향을 따라 파지 지점으로 팔을 이동시킨다.




그림 1.6. 파지 후 옷을 펼치는 과정

그리퍼가 옷을 낀 후 펼치는 과정은 그림 1.6과 같다. 옷은 힘을 가해 늘리면

탄성력에 의해 늘어나기 때문에, 늘리는 방법에 따라 측정된 옷의 면적이 달라질 수 있다. 따라서 옷을 펼치는 동안 양쪽 그리퍼가 잡고 있는 파지점 간의 거리를 제한하는 것이 중요하다. 양 팔의 그리퍼가 잡을 두 파지점간의 거리가 옷을 편평한 바닥에 펼쳐 놓았을 때를 기준으로  $L$ 이라고 할 때, 옷을 펼치는 내내 두 파지점 간의 거리는  $L$ 보다 멀어지지 않도록 한다. 파지 지점을 잡아서 기존에 로봇 팔에 잡혀있던 높이까지 들어올린 후  $L$ 만큼 떨어져 있도록 펼친다. 펼친 후의 옷 면적은 옷을 임의의 2D 평면에 투영했을 때 가질 수 있는 최대 면적으로 측정한다.

정리하자면, 본 연구는 점군 또는 메쉬 상의 특정한 점이나 노드를 파지점으로 계획하고, 그 위치가 두 손가락 사이에 들어올 수 있도록 하는 그리퍼의 회전 정보를 계획하여 옷을 펼쳤을 때 면적이 최대가 되도록 하는 그리퍼의 최적의 포즈  $\mathbf{T} \in SE(3)$ 를 결정하는 것을 목표로 한다.

### C. 도전 과제

강체를 대상으로 한 그리퍼 파지 자세 연구는 기존에도 많이 이루어졌지만, 옷감은 강체와 달리 변형이 자유로워 높은 자유도를 가지므로 다양한 형태로 구부러지거나 늘어날 수 있다는 점 때문에 강체에 비해 많이 연구되지 못했다. 이러한 옷감의 특징을 고려하여 그리퍼의 파지 자세를 결정하는 것은 어려운 문제이다. 본 연구의 주요 도전 과제는 이러한 변형 가능한 옷감과 같은 물체를 최대한 넓은 면적을 확보하도록 파지하는 포즈를 계획하는 데 있다.

또한, 옷감의 형상은 매우 다양하고 복잡하여 이를 대상으로 로봇이 유연하게 파지 자세를 계획할 수 있도록 하는 인공지능망을 학습시키기 위해서는 옷 형상을 잘 학습할 수 있는 인공 신경망 모델을 선택하는 것이 중요하다. 또한, 이와 같은 복잡한 물체를 대상으로 학습하는 과정에서 데이터의 양과 질을 확보하는 것이

중요한 문제로 데이터셋을 마련하는데 어려움이 있다.

변형체를 파지하는 기존 연구[6], [7]에서는 주로 강체나 소프트 바디를 대상으로 파지 품질을 평가하며 픽업 성공률, 변형 에너지, 변형 정도, 응력 등을 기준으로 삼았다. 하지만 옷은 부피가 있는 소프트 바디와 달리 얇은 두께를 가진 물체로, 파지 자세의 품질을 단순히 변형의 정도로 평가하는 것은 적절하지 않다. 따라서 옷감을 잡고 펼치는 작업에 적합한 그리퍼의 포즈를 평가할 수 있는 새로운 기준과 정량적인 평가 기준이 필요하다.

## D. 연구 기여

본 연구가 기여하는 바는 다음과 같다.

- PCA 분석 기반 방식과 GNN 학습 기반 방식이라는 두 가지 접근 방식을 사용하여 옷감을 잡기 위한 그리퍼의 파지 자세를 계획한다. PCA 분석 기반 방식은 학습 데이터 없이도 사용할 수 있다는 점에서 유리하며, 학습 기반 방식은 시뮬레이터로 생성된 데이터를 활용하여 더욱 복잡하고 다양한 옷의 형상에 대해서도 유연하게 파지 자세를 계획할 수 있다는 장점이 있다.
- 물리 기반 시뮬레이터를 활용하여 다양한 형상의 옷감 데이터를 대량으로 생성함으로써 학습 과정에 필요한 데이터셋을 제공한다. 물리 시뮬레이터로 데이터셋을 생성하는 방식은 실제 환경에서 얻기 어려운 데이터를 확보하며, 로봇의 옷감 파지 성능을 강화하는 데 필요한 중요한 데이터를 더욱 쉽게 확보할 수 있다.
- 두께가 얇은 2차원적인 특성을 가진 옷감을 파지하는 작업의 성능을 비교하기 위한 적합한 파지 품질 지표를 제안한다. 그리퍼의 회전 정보 품질 평가로는

양 손가락 사이에 계획한 파지 지점이 위치하는지 여부로 평가하며, 파지 후 옷감을 펼쳤을 때 옷의 최대 면적을 지표로 계획된 파지점의 위치를 평가한다.

## E. 논문의 구성

본 논문의 구성은 다음과 같다. II. 장에서는 본 연구와 관련된 선행 연구를 다룬다. 이 장에서는 로봇을 활용해 옷 조작 연구, 그래프 기반 인공 신경망, 물리 기반 시뮬레이터를 활용해 합성 데이터를 생성한 선행 연구들을 소개한다. III. 장에서는 그리퍼의 파지 자세를 계획하는 PCA 기반 분석 방식과 GNN 학습 기반 방식의 두 가지 알고리즘을 제시한다. IV. 장에서는 블렌더(Blender) 시뮬레이터를 사용하여 본 연구에서 사용한 옷 데이터를 확보하는 방법을 설명한다. 마지막으로 V. 장에서는 두 알고리즘을 평가하기 위한 시뮬레이션 시나리오를 설명하고, 정성적, 정량적 방법으로 두 알고리즘을 평가한다.

## II. 관련 연구

본 장에서는 관련된 선행 연구를 살펴본다. A절에서는 로봇을 활용한 옷감 조작 연구에 대해 다루며 다양한 작업에서 로봇이 옷 조작에 활용될 수 있음을 소개한다. B절에서는 본 연구에 사용된 그래프 기반 인공 신경망(GNN)에 대해 설명하고, GNN의 기본 원리, 구조, 장점 및 이를 통해 옷감의 파지 자세를 계획하는 방법을 소개한다. 마지막으로 C절에서는 물리 기반 시뮬레이터를 사용해 학습 데이터를 생성하는 연구를 다루며 실제 데이터 수집이 어려운 환경에서도 합성 데이터를 학습에 사용할 수 있음을 소개한다.

### A. 로봇을 이용한 옷 조작 연구

다관절 로봇은 복잡한 움직임을 구현할 수 있어, 옷을 펼치는 작업에서도 높은 성능을 기대할 수 있다. Ha[8]는 그림 2.1과 같이 다관절 로봇을 사용하여 구겨진 옷을 단계적으로 조작하며 옷을 펼치는 방법에 대해 연구하였다. 로봇의 동작을 여러 기본 동작(action primitives)으로 나누어 수행하며 각 단계마다 어떤 동작을 수행할지를 인공 신경망 FlingBot 모델을 통해 예측했다. 그림 2.1과 같이 잡기, 늘리기, 튕기기와 같은 다양한 동작을 조합하여 옷을 펼치며, 자기 지도 학습(self-supervised learning)을 통해 최적의 동작을 계획했다.





그림 2.1. FlingBot[8] 연구

Garcia[9]는 로봇을 활용한 다양한 옷감 조작 작업에 관한 벤치마크 연구를 진행하였다. 그림 2.2과 같이 테이블보를 펼치거나 수건을 접고, 티셔츠를 사람에게 입히는 작업을 대상으로 평가한다. 이 연구에서는 각 작업에 따라 로봇의 조작 성능을 체계적으로 평가할 수 있는 구체적인 지표들을 제시하여, 추후에 로봇을 활용한 옷 조작 연구가 더욱 발전할 수 있는 기틀을 마련했다.



(a) 테이블보 펼치기

(b) 수건 접기

(c) 티셔츠 입히기

그림 2.2. 로봇을 활용한 옷 조작 작업 벤치마크 연구[9]

Deng[10]은 기존의 로봇을 활용한 옷 조작 연구가 특정 단일 작업에만 집중하고



있어 조작 작업이 유연하지 못하다는 점을 문제로 보았다, 이를 극복하기 위해 그림 2.3와 같이 트랜스포머 기반 아키텍처를 활용해 자연어를 사용함으로써 일반성 (generality)을 높였다. 이러한 일반성이 높은 인공지능망은 다중 작업 학습(multi-task learning)에도 높은 성능을 보인다. 텍스트 및 이미지로 이루어진 멀티 모달(multi-modal) 데이터를 입력 받아 로봇이 잡아야 하는 옷의 위치와 잡은 후 놓아야 하는 위치, 해당 작업의 성공 여부를 예측한다. 이 연구를 통해 Deng은 자연어를 사용해서 조금 더 유연하고 일반적인 상황에서도 로봇이 옷을 조작할 수 있는데 활용될 수 있다는 것을 제안하였다.

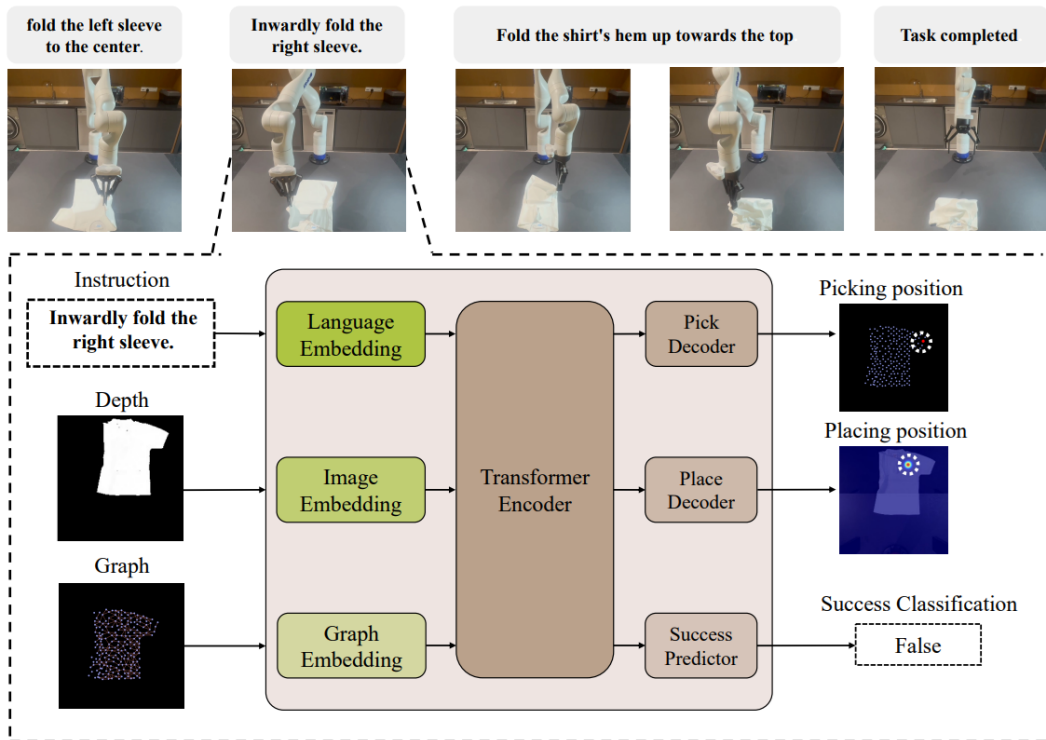


그림 2.3. 자연어를 사용한 옷 조작 연구[10]

Zhu[11]와 Qian[12]은 세그멘테이션(segmentation) 기법을 사용하여 로봇의 그리퍼가

옷을 잡아서 펼칠 수 있는 방법에 대한 연구를 진행하였다. Zhu의 경우 옷이 주름에 의해 가려지는 부분은 그리퍼로 접근하기 어렵다고 보고 이를 고려한 잡기 좋은 영역을 세그멘테이션을 통해 추출하였다. Qian은 옷을 바깥쪽 엣지부분과 안쪽 엣지부분으로 세그멘테이션 하는 방법을 통해 바깥쪽 엣지에서 안쪽 엣지 방향으로 그리퍼의 포즈를 계획하였다.




그림 2.4. Zhu의 연구[11]

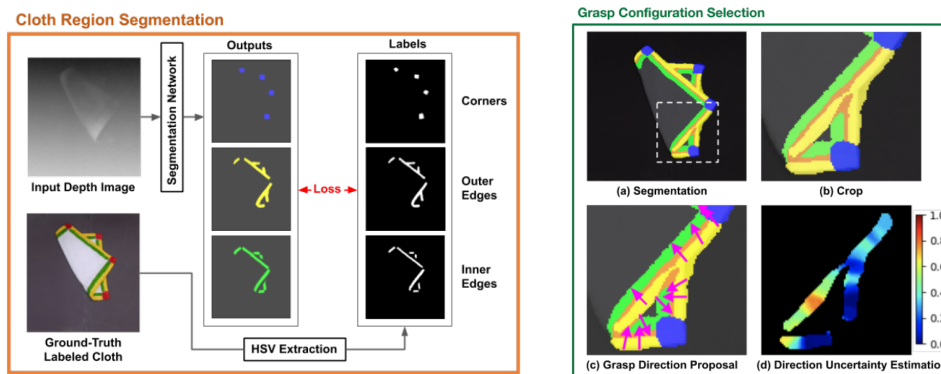


그림 2.5. Qian의 연구[12]

## B. 그래프 기반 인공 신경망

인공 신경망은 입력 데이터의 특성과 해결하고자 하는 문제의 특징에 따라 적합한 모델을 선택해야 한다. 본 논문에서는 그래프 기반 인공 신경망을 활용하여 그리퍼의 적합한 포즈를 학습한다. 그래프 기반 인공 신경망은 단순한 배열이 아닌 복잡하게 상호 연결된 데이터 간의 관계를 그래프로 표현하므로, 옷감과 같이 자유도가 높은 물체의 특성을 잘 반영할 수 있다. 특히 비 유클리드(Non-euclidean) 데이터인 메쉬의 경우 그래프로 인코딩이 쉬워 시뮬레이터로 생성한 메쉬 데이터를 사용하여 GNN을 효과적으로 학습하고 활용할 수 있다.




그림 2.6. GNN의 기본 동작 원리[13]

GNN은 그림 2.6과 같은 방법으로 그래프 내 인접한 노드(node)와 엣지(edge)가 가진 특징들을 학습하여 그래프의 특징 및 관계성을 학습한다. 각 노드는 GNN의 레이어를 통과하면서 자신과 일정 거리 이내에 연결된 인접 노드의 데이터를 집계(aggregation)하여 자신의 노드들의 특징값을 업데이트하는 과정을 반복한다. 이를 메시지 패싱(message passing)단계라고 하며 이를 통해 각 노드는 그래프에 내재된 복잡한 관계성을 효과적으로 학습할 수 있다. 또한 GNN의 입력 데이터로 사용되는 그래프는 노드나 엣지의 개수에 제한이 없기 때문에, 적은 노드를 가진 메쉬부터

복잡한 형태를 띤 메쉬까지 입력 데이터로 사용할 수 있다는 점에서 유연하게 옷의 파지 자세를 계획할 수 있다.

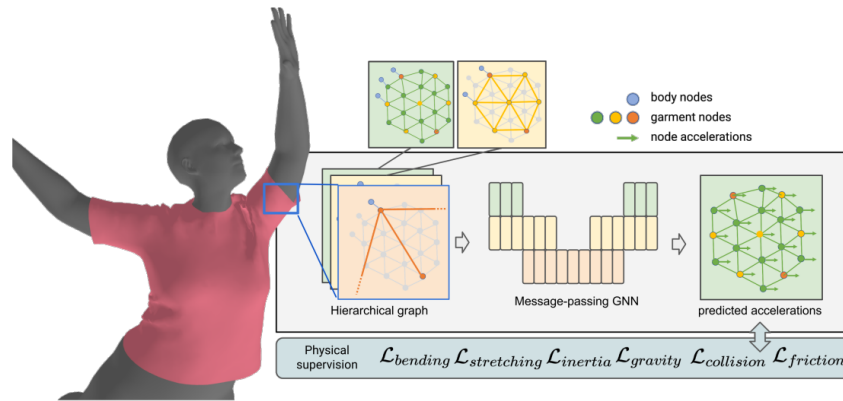


그림 2.7. Grigorev의 연구[14]

Grigorev[14]는 계층적 구조를 가진 그래프로 이루어진 GNN 을 학습시키는 방법으로 마네킹의 움직임에 따라 옷의 움직임을 예측하는 모델을 연구하였다. AMASS 데이터셋[15]을 사용해 학습시켰으며, 자기 지도 학습을 위해 물리 방정식을 사용한 손실함수를 추가하였다.

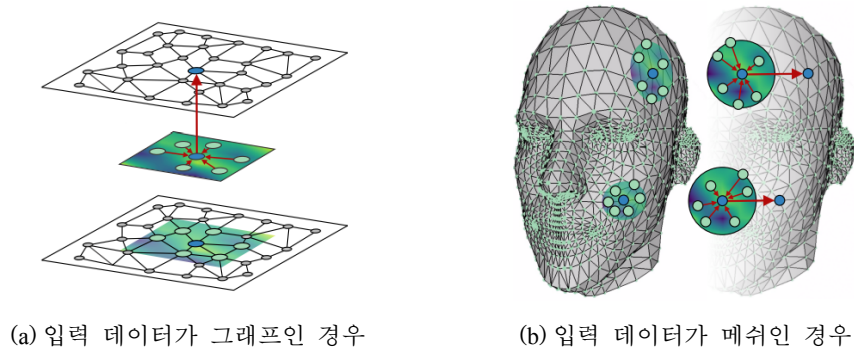


그림 2.8. B-spline 기반의 컨볼루션 연산 예시[16]

본 연구에서는 그림 2.8의 SplineCNN[16]으로 구성된 그래프 기반의 인공 신경망을 사용한다. SplineCNN은 기존의 격자 형태의 데이터에만 사용된 컨볼루션 연산을 그래프와 같은 비구조적 데이터에서도 사용할 수 있도록 B-spline을 기반으로 한 컨볼루션 연산을 수행한다. 이를 통해 기하학적 구조를 가진 비 유클리디안 데이터가 입력으로 주어졌을 때도 컨볼루션 신경망과 같이 고정된 수의 가중치 파라미터 값을 사용하여 효율적으로 연산을 수행한다. 이러한 가중치 파라미터 공유는 모델의 복잡성을 줄이고 계산의 효율성을 높이는데 기여한다. 결과적으로 SplineCNN은 다양한 형태의 불규칙 구조 데이터에서도 높은 성능을 발휘할 수 있어 복잡한 형태의 옷감 형태가 주어졌을 때도 효과적으로 사용할 수 있다.

### C. 물리 기반 시뮬레이터를 사용한 학습 데이터 생성

물리 기반 시뮬레이터의 발전으로 인해, 현실과 유사한 시뮬레이션 데이터를 쉽게 확보할 수 있게 되었다. Pfaff[17]는 물리 시뮬레이터로 생성한 데이터를 통해 물체의 운동 역학(dynamics)을 예측하는 MeshGraphNets을 연구하였다. 그림 2.9과 같이 시뮬레이터에서 메쉬 데이터를 비롯해 각 노드의 위치와 속도에 관련된 시간열 데이터를 추출한다. 이 데이터를 그래프의 노드 특성 데이터로 인코딩 하였으며 시뮬레이터에서 계산된 가속도와 모델이 예측한 가속도와와의 차이로 손실 함수를 정의하여 운동 역학에 관한 시간열 데이터를 예측하였다. 이 연구는 물리 기반 시뮬레이터가 정교한 계산을 수행할 수 있지만 연산 비용이 매우 비싸다는 한계점을 극복하며 시뮬레이션 진행에 오랜 시간이 소요되는 문제를 미리 학습 시킨 인공 신경망을 활용하여 해결하고자 하였다. MeshGraphNets는 학습 데이터를 생성하기 위해 ArcSim[18], COMSOL[19], SU2[20] 시뮬레이터를 사용하여 옷감 뿐 아니라 유체 시뮬레이션 등 다양한 분야에서 물리 기반 시뮬레이터와 비슷한 정확도를 가진 시간열 데이터를 보다 빠른 속도로 예측할 수 있다.

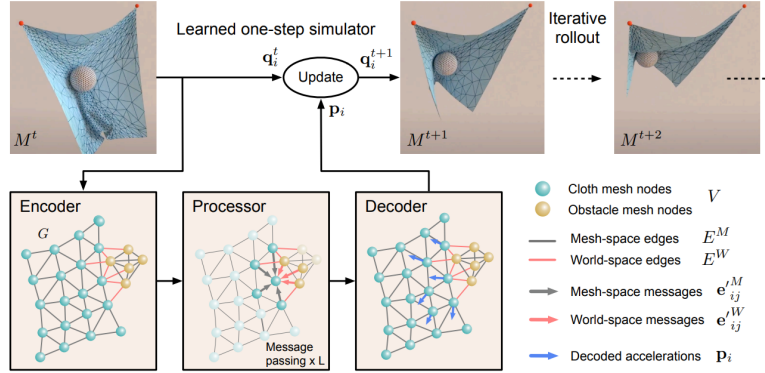


그림 2.9. Pfaff의 MeshGraphNets[17]

Blanco[21]는 물리 시뮬레이터를 활용하여 얻은 옷의 시뮬레이션 데이터와 실제 데이터 간의 차이를 비교 평가하는 연구를 진행하였다. 이를 통해 시뮬레이션을 통해 얻은 데이터와 실세계에서 물체의 운동간의 간격을 줄일 수 있는 기반을 마련하였다. 이 연구는 그림 2.10과 같이 오픈소스로 알려진 Mujoco[22], Bullet[23], Flex[24], SOFA[25] 시뮬레이터를 사용하여 로봇이 천을 조작하는 시뮬레이션 데이터를 확보하고, Azure Kinect 센서를 이용해 얻은 실제 RGB-D 이미지 데이터와의 차이를 비교 분석함으로써 현재 널리 사용되는 물리 엔진들의 성능과 한계를 평가한다. 이러한 연구는 추후 시뮬레이션 기술을 개선하고 실제 환경에서의 로봇 제어 성능을 향상시키기 위한 연구의 기틀을 제공한다.




그림 2.10. Blanco의 시뮬레이션 데이터와 실세계 데이터간의 거리 비교 연구[21]

Lips의 연구[26]는 Nvidia Flex 시뮬레이터를 사용해 펼쳐진 옷에서 주요 키 포인트를 예측하는 연구를 진행하였다. 그림 2.11은 이를 통해 예측된 티셔츠, 수건, 바지의 키 포인트를 보여준다.



그림 2.11. Lips의 연구[26]

본 연구는 이러한 선행 연구들의 노력을 기반으로, 물리 기반 시뮬레이터를 사용하여 옷감 데이터를 확보하고 이를 통해 그리퍼의 포즈를 계획하였다. 이를 통해 로봇을 사용한 옷감 조작 작업에 앞서 필요한 선행 작업을 보다 잘 수행할 수 있도록 기여한다.

### III. 옷감 조작 알고리즘

본 장에서는 두 가지 기반의 알고리즘을 제안한다. 먼저, A절에서는 점군 데이터를 활용하여 옷의 형상을 주성분 분석(Principal Component Analysis)으로 분석하고, 이를 통해 그리퍼의 최적 포즈를 계획하는 방법을 설명한다. B절에서는 옷의 메쉬 데이터를 그래프 기반 인공신경망에 학습시켜 파지 자세를 계획하는 방식을 다루며, 이를 통해 보다 정교한 파지 자세 계획이 가능함을 소개한다.

#### A. 주성분 분석 기반 알고리즘

##### 1. 파지점 위치 계획 알고리즘

이 절에서는 옷의 형상이 점군 데이터로 주어졌을 때 그리퍼의 파지 자세를 계획하는 알고리즘에 대해 설명한다. 어떤 물체를 잡을 때, 일반적으로 뾰족하게 튀어나와 있는 특이 지점을 잡는 것이 더 효과적이다. 이러한 지점은 물체를 안정적으로 잡는 데 유리하며, 로봇의 그리퍼가 목표 지점에 잘 맞춰 파지할 수 있도록 돕는다. Bazazian[27]가 제안한 방법을 사용하면, 점군 데이터를 주성분 분석(PCA)을 통해 각각의 점이 얼마나 평평한지 또는 뾰족한지를 표면 변동(surface variation) 값을 통해 예측할 수 있다.

옷의 점군 데이터가 식 1.1과 같이 주어졌을 때 점  $\mathbf{p}$ 의 표면 변동값은 다음과 같이 정의된다. 우선 최근접- $k$  알고리즘을 통해 점  $\mathbf{p}$ 로부터 유클리디안 거리를 기준으로 가까운  $k$ 개의 점을 뽑는다. 이 점들은 식 3.1과 같이 점군  $P'(\mathbf{p})$ 로 정의할 수 있다.



$$P'(\mathbf{p}) = \{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_k\} \quad (3.1)$$

점군  $P'(\mathbf{p})$ 의 공분산 행렬을 통해 점군이 특정 방향으로 얼마나 퍼져 있는지를 파악할 수 있다. 고유값 분해(eigen decomposition)를 수행하여 고유값(eigen value)과 고유벡터(eigen vector)를 계산할 수 있으며, 이를 통해 데이터의 주된 방향과 구조적 특징을 파악할 수 있기 때문이다. 고유값이 큰 순서대로 나열했을 때, 이에 대응하는 고유벡터들은 점의 분포가 가장 많이 분산된 축의 방향을 순서대로 나타낸다. 이 축을 주성분이라고 하며 해당 고유값은 그 축으로 퍼져 있는 정도를 나타낸다.

이때, 표면 변동  $\sigma_k(\mathbf{p})$ 는 고유값  $\lambda$ 을 사용하여 식 3.2과 같이 정의한다.

$$\sigma_k(\mathbf{p}) = \frac{\lambda_0}{\lambda_0 + \lambda_1 + \lambda_2} \quad \lambda_0 < \lambda_1 < \lambda_2 \quad (3.2)$$

$\lambda_0$ 가 0에 가까워 지는 경우, 표면 변동은 0에 가까운 값을 가지며 이 경우 점  $p$  주위의 점들은 편평한 점 분포를 가진다는 의미이다.

$\lambda_0, \lambda_1, \lambda_2$  값이 모두 비슷할 경우 표면 변동 값은 최대값  $\frac{1}{3}$ 에 가까워지며, 이 경우 점이 뾰족하다고 예측할 수 있다.

따라서 표면 변동  $\sigma_k(\mathbf{p})$  값이 작으면 해당 점이 편평하다는 의미를 가지며, 값이 클수록 뾰족한 점에 해당한다. 옷의 점군 데이터에서 각 점의 표면 변동 값을 계산한 뒤, 이 값이 일정 기준보다 높은 점들을 필터링함으로써 뾰족한 점들을 추출해낼 수 있다.




그림 3.1.  $k$  값의 변화에 따른 추출된 점들의 변화 (threshold는 0.2로 고정)

그림 3.1과 같이 작은  $k$  값은 각 점의 가까운 이웃을 고려하여 국소적인 특징을 추출하고 곡률이나 불규칙성을 민감하게 탐지할 수 있지만, 이상값(outlier)나 노이즈(noise)에 취약할 수 있다. 반면  $k$  값이 커질수록 더 멀리 있는 점들을 포함하게 되어, 개별 구조보다는 전체적인 형태를 반영하는 데 적합하다. 그러나 계산 복잡도가 증가한다는 한계가 있다. 본 연구의 실험에서 다루는 옷감 점군은 옷마다 약 50,000 개의 점으로 이루어져 있으므로 이를 고려하여  $k = 32$ 로 설정한다.

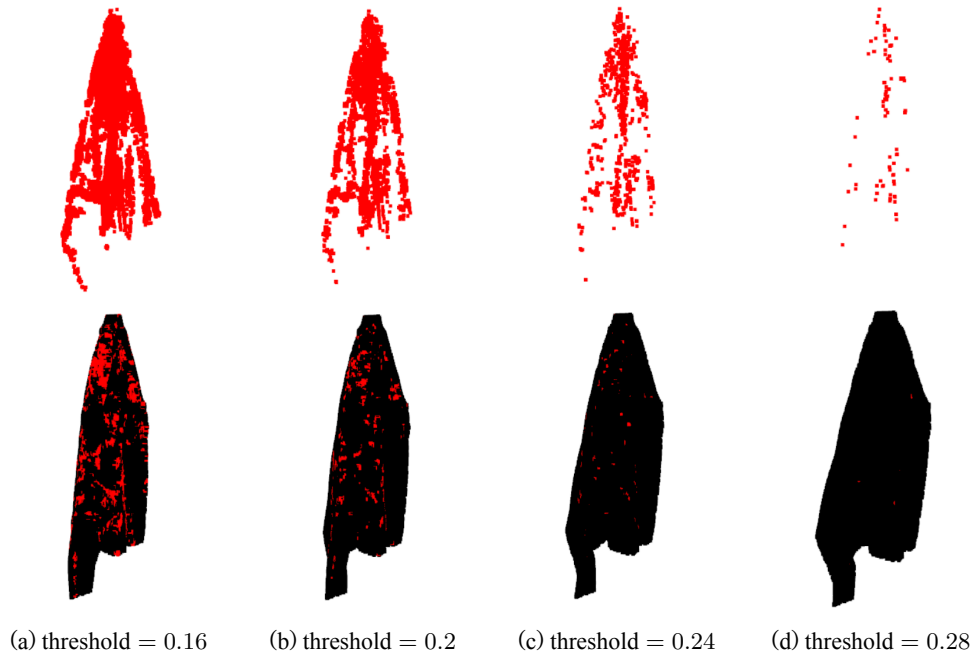


그림 3.2. threshold 값의 변화에 따른 추출된 점들의 변화 ( $k$ 는 32로 고정)

그림 3.2과 같이 임계값(threshold)을 조절하면 필터링되는 점의 개수가 달라진다. 본 연구에서는 표면 변동값의 임계값으로 0.2를 사용한다.

추출된 뾰족한 점들 중에서도 다른 천에 가려져 있지 않은 점들 중에 반대편 로봇 팔과의 충돌 방지를 위해 가장 아래쪽에 놓인 점을 선별한다. 즉 카메라와의 거리 기준으로 가까운 외곽의 100개의 점들 중에서 중력 방향으로 가장 아래쪽에 있는 점  $\mathbf{p}_{\text{grasp}}$ 을 선택함으로써 안정적으로 그리퍼가 접근하고 파지를 수행할 수 있는 최적의 지점을 결정한다.

## 2. 회전 정보 계획 알고리즘

본 절에서는 점군이 주어질 때, 그리퍼의 포즈에서 회전 정보를 계획하는 알고리즘에 대해 소개한다. 그리퍼가 두 개의 손가락을 사용하므로 그리퍼의 접근 방향은, 두 손가락 사이에 옷이 안정적으로 잡히기 위해 바깥쪽 외곽선인 끝단 쪽에서 안쪽을 향한 방향으로 접근하는 것이 좋다. 이렇게 파지하면 두 손가락 사이에 옷의 끝 외곽선이 놓이게 되어 그리퍼로 쥐었을 때 고정되어 옷이 균형 있게 잡히게 될 가능성이 높다. 반대로, 바깥쪽에서 안쪽으로 접근하지 않고 옷을 잡으려는 경우 접근하는 그리퍼에 의해 옷이 밀리면서 파지점으로 계획한 지점이 두 손가락 사이에 들어오지 않고 오히려 밀려날 위험이 있다.

$\mathbf{p}_{grasp}$  를 카메라의 거리가 가까운 점들 중에서 선별하므로 주로 옷의 끝단에 위치하게 되는데, 이 때 점  $\mathbf{p}_{grasp}$  을 기준으로 최근접- $k$  알고리즘으로 선별된 점들의 평균 위치를  $\mathbf{p}_{mean}$  이라고 하면 이 점은  $\mathbf{p}_{grasp}$  보다 안쪽을 향한다. 따라서 그리퍼의 접근 방향은 식 3.3와 같이 계산한다.

$$\mathbf{r}_z = \frac{\mathbf{p}_{mean} - \mathbf{p}_{grasp}}{\|\mathbf{p}_{mean} - \mathbf{p}_{grasp}\|} \quad (3.3)$$

이 과정을 시각화하면 그림 3.3과 같다.




그림 3.3. 그리퍼의 접근 방향

$\mathbf{r}_x$ 는 임의의 기준 축인  $\mathbf{v} = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}$ 와 유사하면서도  $\mathbf{r}_z$ 와 수직일 수 있도록 식 3.4과 같이  $\mathbf{v}$ 를  $\mathbf{r}_z$ 에 수직인 평면에 투영한 방향 벡터를 구하고 이를 정규화 한다.

$$\mathbf{r}_x = \frac{(\mathbf{v} - (\mathbf{v} \cdot \mathbf{r}_z)\mathbf{r}_z)}{\|\mathbf{v} - (\mathbf{v} \cdot \mathbf{r}_z)\mathbf{r}_z\|} \quad (3.4)$$

$\mathbf{r}_y$ 는  $\mathbf{r}_z$ 와  $\mathbf{r}_x$ 에 모두 수직일 수 있도록 외적을 통해 식 3.5과 같이 계산한다.

$$\mathbf{r}_y = \mathbf{r}_z \times \mathbf{r}_x \quad (3.5)$$

파지점을 비롯해 그리퍼의 회전 정보를 포함한 포즈를 계획하는 과정을 시각화하면 그림 3.4과 같다.

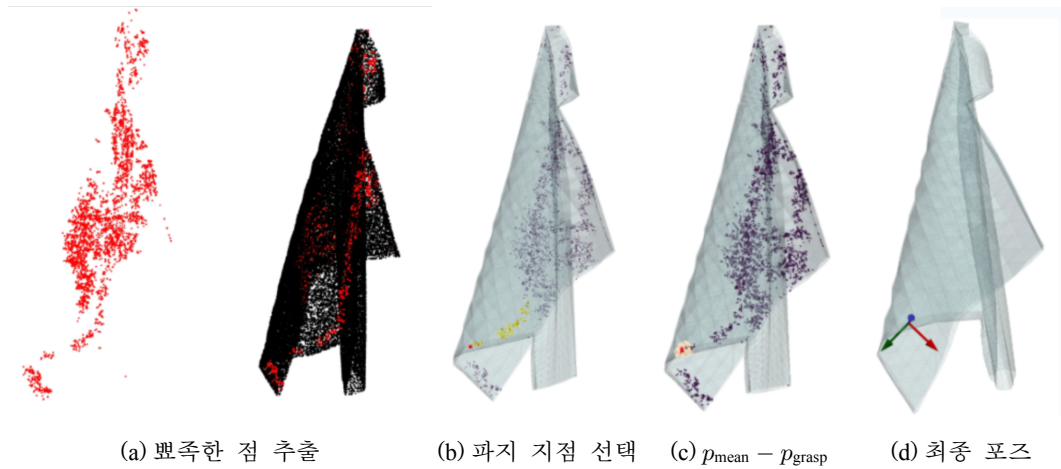


그림 3.4. PCA 기반 방식을 사용한 그리퍼의 포즈 계산 과정

## B. 그래프 인공지능망 학습 기반 알고리즘




그림 3.5. GNN 학습 기반 방식을 사용한 그리퍼의 포즈 계획 과정

본 절에서는 GNN 기반의 인공지능망을 활용하여 그리퍼의 포즈를 계획하는 방법을 소개한다. 메쉬 데이터를 그래프로 인코딩 한 후, GNN 기반의 모델인 위치 계획 모델과 회전 정보 계획 모델을 통해 그리퍼가 파지할 위치와 그리퍼의 회전 정보를 계획한다. 이상적인 파지점일 확률값이 높은 지점을 추출하고, 해당 노드의 그리퍼의 회전 정보 값을 결합하여 최종 그리퍼의 포즈  $\mathbf{T}$  를 계획한다.

메쉬 데이터  $M = (V, E)$ 를 그래프  $G = (\mathcal{V}, \mathcal{E})$ 로 인코딩 하는 과정에서, 메쉬의 노드  $V$ 는 그래프의 노드  $\mathcal{V}$ 로 메쉬의 엣지  $E$ 는 그래프의 엣지  $\mathcal{E}$ 로 변환된다.

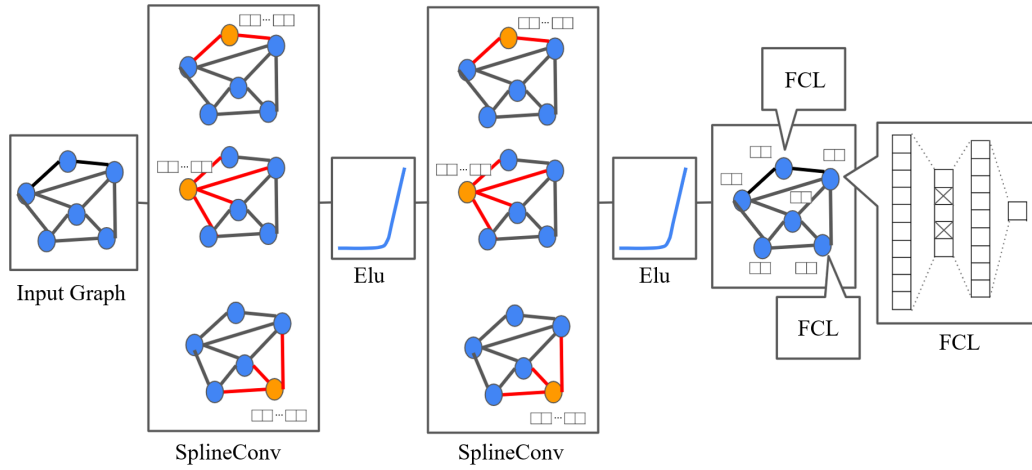


그림 3.6. GNN 기반의 모델 아키텍처

위치 계획 모델과 회전 정보 계획 모델의 구조는 그림 3.6과 같다. 두 모델은 공통적으로 그래프의 노드에  $x_v = 1$  와 같은 특성값을, 엣지에  $\mathbf{x}_{uv} = \|\mathbf{p}_u - \mathbf{p}_v\|$  와 같은 특성값을 할당한다. 모든 노드의 특성값을 1로 설정함으로써 메쉬의 각 노드가 서로 구분되지 않도록 하여 개별적인 속성 없이 모델이 단순히 그래프의 구조적 관계를 학습하도록 하며 엣지 특성값은 두 노드간의 유클리디안 거리로 정의하여 그래프의 특징을 학습할 수 있게 한다.

노드 특성값은 SplineCNN 과 Elu 활성화 함수(activation function)를 2번 거치면서 주위의 노드 특성값과 엣지 특성값을 반영하여 그래프의 관계성을 학습한다. 메시지 패싱 과정에서 집계함수(aggregation function)으로는 *add* 연산자를 사용한다.

이후 각각의 노드는 완전 연결층(Fully connected layer, FCL)과 ELU 활성화 함수를 통과한다. 이후 드롭 아웃(drop out) 기법을 적용하여 과적합(overfitting) 을 방지한다. 마지막으로 FCL을 한번 더 거쳐서 최종적인 노드 임베딩을 계산한다.

노드 임베딩과 IV. C에서 소개한 방법으로 생성한 정답 레이블과의 차이를 손실

함수로 정의하며 최적화 방법으로는 Adam optimizer 를 사용한다.

전체 300번의 에포크(epoch)을 반복하며 1번째 에포크부터 100번째 에포크까지는 learning rate = 0.01 를 사용하며 100번째 에포크부터는 learning rate = 0.001로 줄이는 방법을 통해 모델 파라미터값이 최적화된 값으로 수렴하도록 하여 모델의 안정성을 높였다.



## IV. 합성 데이터

본 연구는 다양한 형태로 변형되는 수건과 티셔츠를 대상으로 하며, 이를 위해 메쉬나 점군 데이터와 같은 기하학적 데이터를 수집해야 한다. 특히 학습 기반 알고리즘에서는 지도 학습(supervised learning) 방식을 사용하므로, 다량의 학습 데이터와 정답 레이블(ground truth)이 필요하다. 하지만 실제 환경에서 옷감의 다양한 형태를 확보하고 수작업으로 어노테이션(annotation) 데이터를 만드는 작업은 상당히 많은 시간과 노력을 요구한다. 이를 해결하기 위해 블렌더 시뮬레이터를 이용하여 현실과 유사한 옷의 변형 데이터를 대규모로 생성하여 사용한다. A절에서 블렌더 시뮬레이터에서 옷을 시뮬레이션 하는 방법을 설명하며, B절에서 시뮬레이터를 통해 자동적으로 어노테이션 데이터를 확보하여 학습 데이터의 정답 레이블을 손쉽게 만드는 방법을 다룬다.

### A. 블렌더 시뮬레이터

본 연구에서는 블렌더 시뮬레이터를 통해 옷감이 그리퍼와 충돌하고 펼쳐지는 과정의 형상 변형 데이터를 생성한다. 블렌더는 모델링(modeling), 렌더링(rendering), 애니메이션(animation) 및 리깅(rigging) 작업에 자주 활용되는 오픈소스 프로그램이다 [28]. 강체, 유체, 파티클, 옷감 등 다양한 물리 시뮬레이션을 지원하며 Python API를 통해 데이터를 생성하는 작업을 자동화 할 수 있어 대규모 학습 데이터를 효율적으로 확보할 수 있다.

블렌더에서는 질량-스프링 시스템을 사용해서 옷의 움직임을 모델링한다. 각 노드는 질량을 가진 점으로 모델링되며, 이 점들은 스프링으로 연결된다. 이 시스템은 식 4.1과 같이 훅의 법칙을 따라서 시뮬레이션 된다.

$$m \cdot \mathbf{a} = -k \cdot (\mathbf{x} - \mathbf{x}_0) \quad (4.1)$$

식 4.1에서  $m$ 은 노드의 질량,  $\mathbf{a}$ 는 노드의 가속도,  $k$ 는 스프링의 탄성 계수,  $\mathbf{x}$ 는 노드의 현재 위치,  $\mathbf{x}_0$ 는 평형 상태에서의 노드의 위치를 나타낸다. 따라서 노드 간 거리가 늘어나면 줄어드는 방향으로, 줄어들면 늘어나는 방향으로 힘이 작용하여 현실에 가깝게 시뮬레이션한다.

이를 시간 적분법(time integration)을 사용하면 각 프레임의 위치와 속도를 구할 수 있다. 오일러 시간 적분법을 사용하는 경우 옷감이 물리적으로 이상하게 변형되거나 폭발하는 형상으로 시뮬레이션이 진행되어 불안정한 모습을 보일 수 있다. 특히 옷감의 경우는 자유도가 높기 때문에 이러한 불안정한 시뮬레이션 형상이 두드러진다. 따라서 암시적 시간 적분법을 사용하며 이는 식 4.2과 식 4.3과 같이 시뮬레이션 된다.

$$\mathbf{v}_{n+1} = \mathbf{v}_n + \mathbf{a}_{n+1} \cdot \Delta t \quad (4.2)$$

$$\mathbf{x}_{n+1} = \mathbf{x}_n + \mathbf{v}_{n+1} \cdot \Delta t \quad (4.3)$$

$\mathbf{x}_n, \mathbf{x}_{n+1}$ 는 현재 프레임과 다음 프레임에서의 노드 위치,  $\mathbf{v}_n, \mathbf{v}_{n+1}$ 는 현재 프레임과 다음 프레임에서의 노드 속도,  $\Delta t$ 은 현재 프레임과 다음 프레임 사이의 시간,  $\mathbf{a}_{n+1}$ 은 다음 프레임에서 노드에 작용하는 가속도를 나타낸다.

따라서 시뮬레이션 시작 시 프레임 간의 시간 간격과 각 노드의 초기 위치가 주어지면 후의 법칙과 암시적 시간 적분법에 따라 다음 프레임의 각 노드의 위치와 속도값을 계산할 수 있고, 이를 시간열 데이터로 확보하여 시뮬레이션이 진행된다.




그림 4.1. 블렌더의 옷 시뮬레이션에 사용되는 스프링의 종류

블렌더에서는 이러한 운동 방정식에 영향을 받는 4종류의 스프링을 사용한다 그림 4.1는 이러한 다양한 종류의 스프링을 나타낸다. 하늘색 엣지(edge)는 장력 스프링(tension spring)과 압축 스프링(compression spring)을 나타내며 인접한 상하좌우의 노드를 연결한다. 노란색 엣지는 전단력 스프링(shear spring)을 나타내며 대각선에 있는 노드를 연결한다. 주황색 엣지는 각 굽힘 스프링(angular bending spring)을 나타내며 인접한 면 사이의 각도를 기준으로 작용하여 두 면 사이의 각도가 너무 커지거나 작아지지 않도록 작용한다. 블렌더에서는 각 스프링의 탄성 계수 파라미터를 조절할 수 있어 옷의 장력, 압축성, 전단력, 굽힘 특성을 미세하게 조절할 수 있다.




그림 4.2. 블렌더에서 모델링한 티셔츠와 수건의 모습

본 연구에서는 수건과 티셔츠를 그림 4.2과 같이 모델링하였으며, 이는 앞서 설명한 블렌더의 질량-스프링 모델을 활용하여 시뮬레이션 되어 데이터로 추출된다.

## B. 학습 데이터 증강

인공 신경망 학습을 위해서는 다양한 옷 형태를 포함한 학습 데이터가 필요하다. 특히 옷감과 같이 자유도가 높은 물체는 다양한 형상을 가질 수 있기 때문에, 옷의 형상을 학습시키기 위해선 데이터의 규모가 인공신경망의 성능에 큰 영향을 끼친다. 본 절에서는 블렌더를 활용하여 대량의 옷 데이터를 생성한 방법과, 그리퍼의 포즈 계획을 위한 어노테이션 데이터를 효율적으로 확보한 방법을 설명한다.




그림 4.3. 허공에 걸려있는 옷 메쉬

본 연구에서는 양팔 로봇을 사용하여 옷을 펼치는 시나리오를 설정한다. 따라서 그림 4.3과 같이 옷의 일부가 허공에 고정되어 있고 나머지는 중력에 의해 펼쳐진 모습의 옷감 데이터가 필요하다. 허공에 고정되어 있는 점의 위치에 따라 시뮬레이션 이후의 모습이 달라지므로 고정점의 개수만큼의 옷 데이터를 확보할 수 있다.




그림 4.4. 회전과 스케일 값을 변경한 옷감 형상

그러나 고정점을 달리 하는 것만으로는 학습에 충분한 데이터셋을 마련하기 어렵다. 따라서 그림 4.4와 같이  $x, y$  방향으로 스케일 값과 회전 값에 변화를 주어 데이터의 개수를 증가시켰다.

옷의 특성상 얇은 형태여야 하므로  $z$  방향의 스케일 값은 적용하지 않으며,  $z$  방향의 중력을 적용하고 있어  $z$  축 회전 또한 시뮬레이션이 진행되면서 의미가 사라지므로  $z$  방향의 회전은 적용하지 않았다. 회전 값  $\theta_x, \theta_y$ 은 오일러 각도(Euler angles)로서  $x$ 축과  $y$ 축을 기준으로 한 회전 각도를 의미한다. 무작위의 스케일 값과 회전 값을 얻기 위해, 스케일의 경우 평균이 1, 표준편차가 0.1인 가우시안 정규분포(Gaussian normal distribution)에서, 회전 값은 평균이 0, 표준편차가 1인 가우시안 정규분포에서 샘플링하여 약 100개의  $(scale_x, scale_y, \theta_x, \theta_y)$  쌍을 뽑는다.

고정점을 달리 한 옷의 형상마다 샘플링 된 스케일 값과 회전 값을 적용하여서 옷 데이터를 다량으로 생성하여 약 6,400개의 수건 데이터와 약 6,300개의 옷 데이터를 확보한다.

## C. 어노테이션과 정답 레이블

본 연구에서는 지도 학습 방법으로 학습한 인공신경망을 통해 그리퍼의 포즈를 계획한다. 따라서 각각의 학습 데이터에는 그리퍼의 포즈를 나타내는 정답 레이블 (ground truth)이 필요하다.

### 1. 파지점 위치 레이블

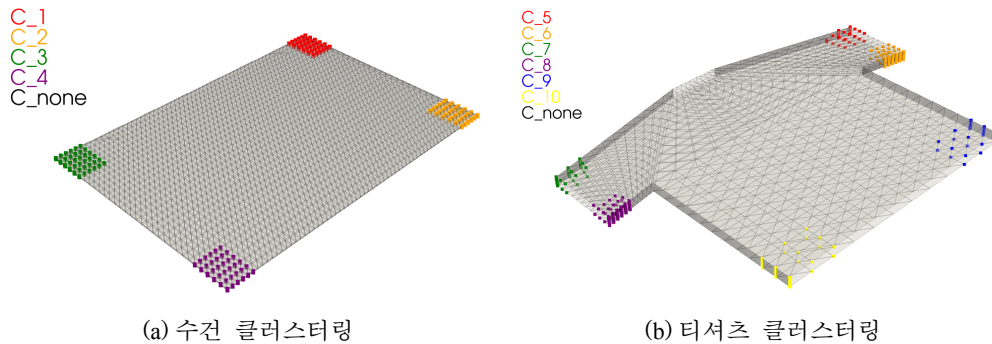


그림 4.5. 옷의 주요 지점 클러스터링

옷을 한 팔로 잡고 있을 때, 다른 팔이 잡아야 할 위치를 고려하면, 옷감을 그리퍼로 파지하는 연구들[29], [30], [31]과 같이 수건의 네 코너와 티셔츠의 소매의 양 끝, 밑단을 주요 파지 지점으로 선별할 수 있다. 수건의 코너 부분은 물리적으로 쉽게 잡을 수 있어 파지하기 용이하며, 이 지점들을 잡으면 변형을 최소화하면서 안정적인 파지가 가능하다. 또한, 티셔츠는 소매, 목 부분, 밑단 등 명확한 경계를 가지며, 옷감 조작 시 안정적인 파지 지점으로 고려된다. 그림 4.5는 이러한 주요

파지 지점들을 나타낸다.

노드  $v_i$  마다  $score(v_i)$  을 부여하여 수건의 네 코너와 옷의 소매 양 끝, 밑단의 양끝에 노드  $v_i$  가 속하는 경우는  $score(v_i) = 1$  으로, 그렇지 않은 경우  $score(v_i) = 0$  으로 정의한다.

각 노드의 score 값을 시각화한 결과는 그림 4.6과 같다. 파란색의 경우 score 값이 0인 노드를 나타내며 붉은색의 경우 score 값이 1인 노드를 나타낸다.




그림 4.6. 중간  $score(v_i)$  값

그러나 이미 공중에서 잡고 있는 부분과 가까운 노드를 파지점으로 선정할 경우, 로봇의 두 팔 간의 충돌 가능성이 있다. 또한 다른 천이 가리고 있는 노드를 잡으려고 하는 경우, 그리퍼가 이동 중에 다른 부분의 천에 충돌해 밀리며 계획된 파지점을 잡지 못할 가능성이 있으므로 이 지점들의 score 값을 낮게 설정되어야 한다.

로봇의 양팔 사이의 충돌을 피하기 위해서 이미 잡혀 있는 옷의 위치로부터 일정 거리 이내에 위치하는 클러스터에 속한 노드의 경우 score 값을 0으로 수정한다.

또한 다른 천에 가려져 있는 정도를 고려하여 클러스터마다 score 값을 수정한다.

가려진 정도는 각 노드에서 쏜 광선(ray)과 옷감 메쉬간 교점의 개수로 계산한다. 교점의 개수가 많을수록 해당 부분이 다른 천에 가려져 있다고 본다.  $C_{none}$  클러스터를 제외한 각 클러스터의 score 값을 설정하는 알고리즘은 아래의 Algorithm 1에 설명되어 있다. 각 클러스터에 속한 노드  $v$ 의 위치  $\mathbf{p}_{ray}$ 에서 법선 벡터(normal vector)  $\mathbf{n}_{ray}$ 를 따라 광선을 생성한다. 노드의 법선 벡터는 해당 노드가 포함된 평면들의 법선 벡터 평균으로 계산한다. 이후 옷감 메쉬를 구성하는 삼각형과 광선의 교점을 계산하고, 교점이 삼각형 내부에 있는지는 무게 중심 좌표(Barycentric coordinate)를 사용해 판별한다. 이를 클러스터 내의 모든 노드에 대해 반복해 교점의 개수를 구하고 이를 클러스터의 노드 수로 나누어 평균값을 구한다. 이후 교점 개수를 최소값과 최대값으로 정규화하여 score 값을 0.6과 1 사이로 변환한다. 교점 개수가 최대인 클러스터의 경우 score는 0.6으로, 교점의 개수가 최소인 클러스터의 경우는 score가 1이 된다.




그림 4.7. 최종  $score(v_i)$  값



---

**Algorithm 1:** Cluster Scoring Algorithm

---

```
1 Input: Mesh  $M = (V, E, F)$ , Clusters  $C_{\text{key}} = \{C_1, C_2, C_3, C_4\}$  (for towel) or  
    $C_{\text{key}} = \{C_5, C_6, \dots, C_{10}\}$  (for t-shirt)  
2 Output: Scores  $S$   
3 for each cluster  $C \in C_{\text{key}}$  do  
4   IntersectionCount = 0  
5   for each node  $v \in C$  do  
6      $\mathbf{p}_{\text{ray}} \leftarrow$  position of  $v$  as ray origin  
7      $\mathbf{n}_{\text{ray}} \leftarrow$  normalized average of normal vectors of faces containing  $v$  as ray direction  
8     for each triangle  $f_{i,j,k} \in F$  do  
9       is_intersected  $\leftarrow$  The ray intersects  $f_{i,j,k}$  and the intersection lies inside the triangle  
10      if is_intersected then IntersectionCount++  
11    $S.append(\text{IntersectionCount}/|C|)$   
12 for each score  $s \in S$  do  
13    $s = 1 - \frac{s - s_{\min}}{s_{\max} - s_{\min}} \times 0.6$   
14 return  $S$  // Normalized cluster scores
```

---

최종 score 값을 시각화하면 그림 4.7과 같다. 주요 파지 지점 클러스터에 속하지만 이미 다른 로봇팔에 잡혀져 있는 부분과 가까운 노드는 score 값을 0으로 수정하여 이상적인 파지점으로 선택될 확률이 낮게끔 수정하였다. 또한 광선과의 교점의 개수를 사용하여 그리퍼가 접근 시 옷과 충돌이 적은 노드일수록 score 값을 높게 설정하여 이상적인 파지점으로 선택될 확률이 높아지도록 수정하였다.

이렇게 계산한 score 값을 파지점을 계획하는 GNN의 정답 레이블로 사용함으로써 GNN이 이상적인 파지점을 계획할 수 있도록 한다.

## 2. 그리퍼의 접근 방향 레이블

그리퍼의 접근 방향을 학습하기 위해, 옷의 노드들 중 어떤 노드가 다른 노드에 비해 상대적으로 안쪽에 위치하는지, 혹은 바깥쪽에 위치하는지를 구분하는 정보가 필요하다. 이는 Qian의 논문[12]과 같이, 옷을 집는 경우 바깥쪽에서 안쪽으로 잡는 것이 일반적으로 더 잡기 쉽다는 점을 참고한 것이다. 따라서 그리퍼의 접근 방향을 바깥쪽 테두리에서 안쪽 테두리 쪽으로 향하도록 설정한다.

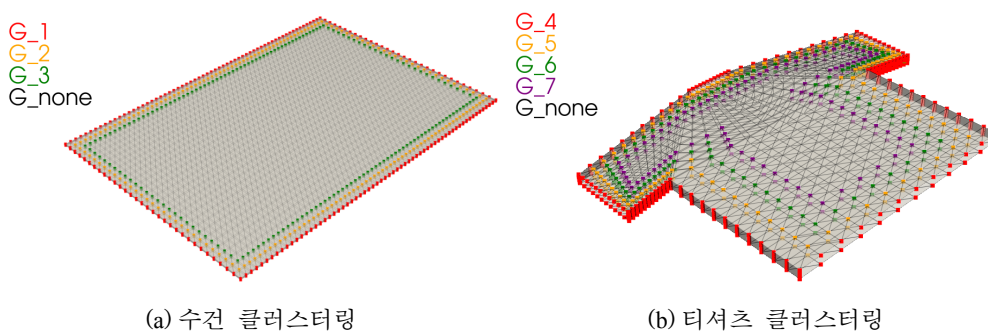


그림 4.8. 깊이에 따른 노드 클러스터링

본 연구에서는 그림 4.8와 같이 바닥에 펼친 옷을 위에서 내려다 볼 때 외곽 선으로부터 깊이를 기준으로 바깥쪽 노드와 안쪽에 놓인 노드를 구분한다. 수건의 경우  $\mathcal{G}_{towel} = \{G_1, G_2, G_3, G_{none}\}$ 으로 클러스터링 하며,  $G_1$ 은 가장 외곽의 노드 클러스터,  $G_3$ 은 가장 안쪽의 노드 클러스터를 나타낸다. 티셔츠의 경우  $\mathcal{G}_{t-shirt} = \{G_4, G_5, G_6, G_7, G_{none}\}$ 로 클러스터링하여  $G_4$ 가 가장 외곽의 노드 클러스터를  $G_7$ 은 가장 안쪽의 노드 클러스터를 나타낸다.

노드  $v_i$ 가 파지점으로 선택되었을 때 그리퍼의 접근 방향  $\mathbf{r}_z$ 은 그림 4.9와 같이 계산한다. 노드  $v_i$ 가  $G_k$ 에 속해 있을 때,  $G_{k+1}$ 에 속한 노드 중  $v_i$ 와 일정 거리 이내에 있는 점들의 집합을  $N$ 으로 정의한다.  $N$ 에 속한 점들의 평균 위치를 계산하여 노드  $v_i$ 에서 그 평균위치를 향하는 벡터를 정규화하여  $\mathbf{r}_z$ 로 사용한다.




그림 4.9. 그리퍼의 접근 방향 레이블, 빨간노드는  $v_i$ , 주황색 노드들은  $N$ , 파란색 화살표는  $\mathbf{r}_z$  를 나타낸다

### 3. 그리퍼의 두 손가락 사이 방향 레이블

본 연구에서 두 개의 손가락을 가진 그리퍼를 가정하고 있다. 따라서 깊이에 따른 노드 클러스터링을 기반으로 같은 클러스터에 속한 노드들이 놓인 방향을  $\mathbf{r}_x$ 로

정의하고  $\mathbf{r}_z$  과  $\mathbf{r}_x$  을 외적하는 방법으로 그리퍼의 손가락 방향  $\mathbf{r}_y$  을 계산한다. 깊이 클러스터 데이터를 사용해 같은 깊이의 노드를 향하는 벡터  $\mathbf{r}_x$  를 정의함으로써 두 손가락 사이로 얇은 천이 들어올 수 있도록 그리퍼의 두 손가락이 오프리는 방향  $\mathbf{r}_y$  을 계산하는것이 용이하기 때문이다.




그림 4.10. 같은 깊이 클러스터 내 인접 노드

$\mathbf{r}_x$  는 그림 4.10과 같이 계산한다. 노드  $v_i$  와 같은 깊이의 클러스터에 속한 노드 중 인접한 노드들을 선별하고 그 노드들의 위치를  $\mathbf{adj}_1, \mathbf{adj}_2$  으로 정의한다.  $\mathbf{adj}_1 - \mathbf{adj}_2$  를  $\mathbf{v}$  라고 할 때, 식 4.4 과 같이  $\mathbf{v}$  에서  $\mathbf{r}_z$  와 수직인 방향의 벡터만 남기고 정규화하는 방식으로  $\mathbf{r}_x$  로 정의한다.

$$\mathbf{r}_x = \frac{(\mathbf{v} - (\mathbf{v} \cdot \mathbf{r}_z)\mathbf{r}_z)}{|\mathbf{v} - (\mathbf{v} \cdot \mathbf{r}_z)\mathbf{r}_z|} \quad (4.4)$$

이후 회전형렬  $\mathbf{R} = [\mathbf{r}_x \ \mathbf{r}_y \ \mathbf{r}_z]$  의 각 열벡터가 서로 수직이 되도록  $\mathbf{r}_y = \mathbf{r}_z \times \mathbf{r}_x$  를 계산한다.

옷의 각 노드가 파지점으로 선택될 경우의 그리퍼의 포즈 레이블을 각 파지점의 위치에 표현하면 그림 4.11와 같다. 그림에서 파란색 화살표는 그리퍼의 접근 방향, 초록색 화살표는 그리퍼의 두 손가락 사이의 방향을 나타낸다.




그림 4.11. 그리퍼의 포즈 레이블

이와 같이 블렌더를 사용하여 데이터를 확보하고 어노테이션 데이터를 추가하여 다량의 데이터를 자동화하여 손쉽게 얻음으로써 GNN의 학습 데이터로 사용한다.

## V. 실험 및 결과

본 장에서는 본 연구에서 제안한 알고리즘으로 계획한 그리퍼의 파지 품질을 평가하는 방법과 그 평가 결과를 소개한다. 본 연구의 목표는 옷을 펼치기 위한 파지 지점을 탐색하고 이를 잡기 위한 그리퍼의 회전 상태를 계획하는 알고리즘을 개발하는 것이다. 이를 위해 두 가지 기반의 알고리즘을 연구하였으며, 각 알고리즘의 성능을 객관적으로 비교하기 위해 동일한 조건에서 실험을 진행하는 것이 필수적이다. 특히, 옷의 초기 형상이 동일하게 유지되어야 정확한 비교가 가능하다. 그러나 실제 로봇을 사용한 실험에서는 외부 요인으로 인해 동일한 초기 형상을 반복적으로 재현하기 어렵다. 반면, 시뮬레이션 환경은 외부 변수를 통제하여 초기 형상을 일관되게 재현할 수 있으므로 두 알고리즘의 성능 비교에 적합하다. 이에 따라 본 연구는 시뮬레이션 환경에서만 실험을 진행하였으며 PyTorch Geometric 라이브러리와 Nvidia GeForce RTX 3090 GPU를 사용하였다.

### A. 정성적 평가

PCA 기반 알고리즘을 통해 계획한 그리퍼의 파지 자세 결과는 그림 5.1과 같다. 왼쪽 그림에서 보라색 점들은 점군 데이터에서 뾰족한 지점으로 계획된 점들을 의미하며, 노란색 점은 계획된 최적의 파지점을 나타낸다. 가운데 그림에서는 주황색 점들이 파지 지점 주변의 최근접- $k$  점들을 나타내며, 파란색 화살표는 그리퍼의 접근 방향을 의미한다. 오른쪽 그림은 최종적으로 계산된 그리퍼의 포즈를 보여준다.

GNN 기반 알고리즘을 사용하여 계획한 그리퍼의 파지 자세 결과는 그림 5.2과 같다. 왼쪽 그림에서는 각 노드가 주요 파지 지점일 확률을 색상으로 표현하였으며, 붉은 색이 주요 지점일 가능성이 높은 점을 나타낸다. 가운데 그림은 계획된 그리퍼의 회전 정보를, 오른쪽 그림은 파지 지점일 확률이 높은 4개의 지점에서의

그리퍼의 포즈를 보여준다.




그림 5.1. PCA 분석 결과의 정성적 비교






그림 5.2. GNN 학습 기반 결과의 정성적 비교

## B. 정량적 평가

### 1. 그래프 인공신경망 학습 평가

그림 5.3과 그림 5.4는 에포크를 진행하면서 측정된 손실 함수의 그래프를 나타낸다. 학습이 진행됨에 따라 손실 함수값은 점진적으로 감소하며 수렴하면서 모델이 안정적으로 최적화되는 모습을 확인할 수 있다. 이러한 경향은 모델이 학습을 통해 점차 일반화되고 있음을 나타낸다.

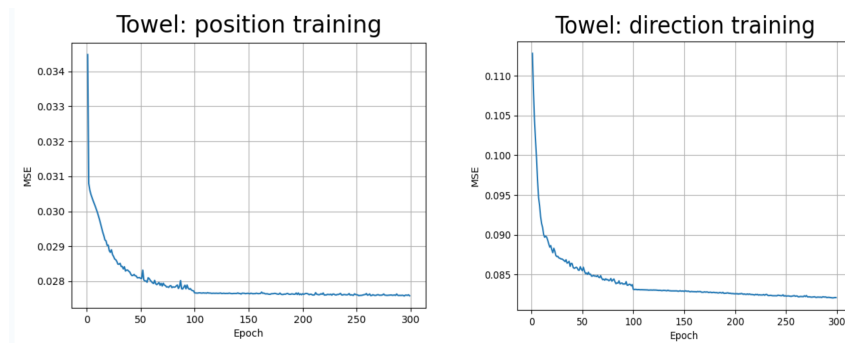


그림 5.3. 수건 데이터셋을 사용한 학습의 손실 함수 그래프

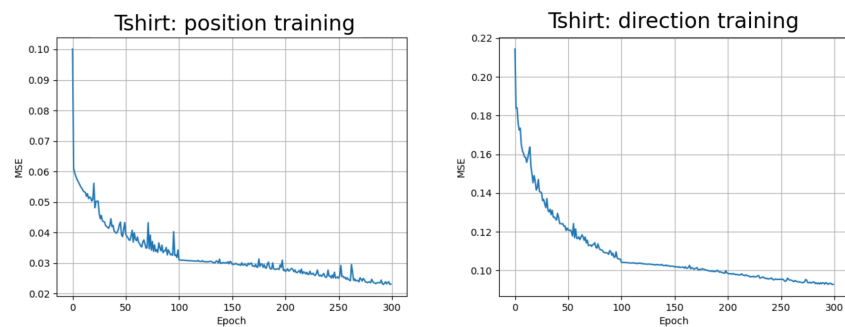


그림 5.4. 티셔츠 데이터셋을 사용한 학습의 손실 함수 그래프

## 2. 시뮬레이션 평가

본 절에서는 시뮬레이션에서 그리퍼의 포즈를 평가한 방법과 그 결과를 소개한다. 수건과 티셔츠를 사용했으며 수건은 정사각형 수건과 가로로 넓은 수건 두 종류를 사용했다.




그림 5.5. 파지 성공 여부 판단

파지 성공 여부는 그림 5.5과 같이 판단한다. 총 세 개의 웨이 포인트(way point)로 그리퍼를 움직이며, 세번째 웨이 포인트때 계획한 옷의 파지 노드가 그리퍼의 양 손가락 사이에 놓이는지를 기준으로 판단하였다.

첫 번째 웨이 포인트에서, 그리퍼는 각 실험에서 동일한 지점과 각도로 설정한다. 두 번째 웨이 포인트에서는 계획된 파지점 근처에 위치시키고, 계획된 회전 정보와 나란해지도록 회전시킨다. 그 후, 세 번째 웨이 포인트에서는 계획된 그리퍼의 포즈와 일치하도록 설정한다. 이 과정에서 그리퍼와 옷의 충돌로 인해 옷이 밀리게 되면, 파지하려는 노드도 함께 밀려나게 되어 그리퍼의 이동 후에 계획된 노드가 두 손가락 사이에 놓이지 않을 수도 있다.

파지 성공시 그리퍼의 정가운데 위치와 잡으려고 했던 옷의 노드와의 거리를 측정한다. 이 거리가 가까울수록 계획한 옷의 노드가 손가락 사이에 놓이도록 그리퍼의 회전정보를 잘 계획하였다고 평가한다.

이에 따른 평가 결과는 표 5.1, 표 5.2와 같다. 정규화된 거리는 계획한 옷의

파지 노드가 두 손가락 사이에 들어오는 경우 중 최대 거리를 기준으로 거리값을 계산하여 1에서 뺀 값을 사용한다. 정규화된 투영 면적의 경우 옷의 최대 면적 대비 투영 면적을 나타낸다. 옷의 최대 면적은 옷을 늘리지 않고 바닥에 편평하게 펼쳤을 때 위에서 내려다 본 넓이를 기준으로 한다. 정규화된 거리값이 1에 가까울수록, 정규화된 투영 면적이 1에 가까울수록 옷을 파지할 그리퍼의 포즈를 잘 계획했다고 평가할 수 있다.

표 5.1. PCA 기반 알고리즘의 그리퍼의 포즈 품질 평가

데이터		파지 성공 여부	정규화된 거리	정규화된 투영 면적
정사각형 수건 (0.7m x 0.7m)	#1	실패	-	0.37
	#2	실패	-	0.31
	#3	성공	0.79	0.77
가로로 넓은 수건 (0.7m x 1m)	#1	실패	-	0.41
	#2	실패	-	0.48
	#3	실패	-	0.27
티셔츠	#1	성공	0.73	0.37
	#2	실패	-	0.38
	#3	성공	0.46	0.64
	#4	실패	-	0.34

표 5.2. GNN 학습 기반 알고리즘의 그리퍼의 포즈 품질 평가

데이터		파지 성공 여부	정규화된 거리	정규화된 투영 면적
정사각형 수건 (0.7m x 0.7m)	#1	성공	0.75	0.62
	#2	성공	0.78	0.41
	#3	성공	0.61	0.77
가로로 넓은 수건 (0.7m x 1m)	#1	성공	0.67	0.65
	#2	성공	0.60	0.81
	#3	성공	0.99	0.47
티셔츠	#1	실패	-	0.30
	#2	성공	0.73	0.74
	#3	실패	-	0.36
	#4	성공	1	0.71

표 5.3은 PCA 기반 알고리즘과 GNN 학습 기반 알고리즘을 통해 계획한 그리퍼의 포즈 품질 평가 비교를 나타낸다.

표 5.3. PCA 기반 알고리즘과 GNN 학습 기반 알고리즘 비교

방법	파지 성공 횟수	파지 실패 횟수	정규화된 거리의 평균	정규화된 투영 면적의 평균
PCA	3	7	0.66	0.43
GNN	8	2	0.77	0.58


실험 결과, GNN 기반 알고리즘은 PCA 기반 알고리즘보다 파지 성공 횟수가 더 많고, 실패 횟수는 적었으며 정규화된 거리의 평균과 정규화된 투영 면적의 값 또한

더 높아 파지 포즈를 더 잘 계획한 것으로 평가할 수 있다. 또한, ICRA 2024 학회 (IEEE International Conference on Robotics and Automation)에서 PCA 기반 알고리즘을 사용한 결과 최대 면적 대비 펼친 면적의 평균이 0.55로 3위의 결과를 보였고, 1 위 팀은 0.60을 기록하였다. 본 연구에서 실험한 PCA 기반 알고리즘은 0.43, GNN 기반 알고리즘은 0.58로 볼 때, 이는 본 연구에서 제안한 GNN 기반 알고리즘이 PCA 기반 알고리즘에 비해 상대적으로 더 나은 성능을 보이며, 학술대회에서의 결과와 비교했을 때도 경쟁력 있는 성능을 보임을 시사한다.


이는 PCA 기반 알고리즘의 경우 그리퍼의 접근 방향을 올바르게 계산하지 못하여 그리퍼로 옷을 쥐지 못한 것이 주된 원인이라고 볼 수 있다. 이는 뾰족한 점을 선별하여 그 중 최적의 파지점을 선택하는 과정에서 데이터의 전체적인 분포를 고려하기 보다는 카메라 방향으로 가까운 점들을 선택하는 지역적인 선별 과정을 거치기 때문이다. 이러한 방식은 입력 데이터의 관측 방향이 조금만 달라져도 결과가 크게 변할 수 있는 한계를 가진다. 따라서 PCA 기반 알고리즘은 특정 데이터의 입력에만 최적의 결과를 보이는 경우가 많았다.

반면, GNN 기반 알고리즘은 파지점을 선택할 때 옷의 주름에 의해 가려지는 영역 (occlusion) 등을 고려하고, 노드 간의 상대적인 거리를 엣지 특성으로 활용하는 등 데이터의 전역적 특성과 공간적 구조를 학습하여 보다 포괄적인 특성들을 고려한다. 또한 학습 과정에서 다양한 회전과 스케일을 적용한 데이터를 미리 학습시킴으로써 입력 데이터가 달라져도 특징을 안정적으로 추출할 수 있다. 결과적으로 GNN 기반 알고리즘은 입력 데이터에 따라서 성능이 크게 달라지지 않고 더 일관되고 유연한 성능을 낼 수 있다는 점을 시사한다.

파지점을 펼친 후의 옷의 모습은 그림 5.6, 그림 5.7과 같다.




(a) 초기 수건 형상




(b) 펼쳐진 후의 수건 형상

그림 5.6. 수건을 펼친 모습



(a) 초기 티셔츠 형상



(b) 펼쳐진 후의 티셔츠 형상

그림 5.7. 티셔츠를 펼친 모습

## VI. 결론

본 연구에서는 로봇이 옷을 효과적으로 조작할 수 있도록, 옷을 최대한 펼칠 수 있는 그리퍼의 최적 파지 자세를 계획하는 알고리즘을 제안한다. 이를 위해 PCA 기반 알고리즘과 GNN 학습 기반 알고리즘을 사용하여 그리퍼의 파지 자세를 계획하고, 두 알고리즘의 성능을 비교하여 각각의 장단점을 분석한다.

PCA 기반 알고리즘은 주어진 점군의 형상에 크게 의존하며, 그에 따라 성능이 크게 달라지는 경향이 있다. 반면, GNN 기반 알고리즘은 지도 학습 방식으로, 미리 다량의 데이터셋을 확보해야 하는 단점이 있지만, 한 번 학습한 후에는 다양한 형상의 옷에 대해서도 유연하게 파지 지점을 추출할 수 있는 장점이 있다. 또한 PCA는 입력을 받은 후 실시간으로 정해진 방식에 따라 계산을 시작하지만, GNN은 학습 과정에서 다량의 데이터를 오프라인으로 미리 학습하여 데이터의 패턴과 구조를 파악한 후, 이를 추론 과정에서 활용하기 때문에 속도 면에서 더욱 효율적일 수 있다. 이러한 차이는 점군이나 메쉬 데이터의 규모가 커질수록 더욱 뚜렷하게 두드러진다고 볼 수 있다.

그러나 본 연구에서는 모션 플래닝(motion planning)을 고려하지 않았기 때문에 알고리즘의 실제 적용에서는 한계가 존재할 수 있다. 또한 시뮬레이션에서만 평가된 수치로는 실제 환경에서의 정확성을 보장하지 않는다는 문제가 있다. 이는 향후 실제 로봇 환경에서의 실험을 진행함으로써, 알고리즘의 정확성과 효율성을 더욱 향상시킬 수 있을 것이다.



## 참고 문헌

- [1] N. Rojas, R. R. Ma, and A. M. Dollar, “The gr2 gripper: An underactuated hand for open-loop in-hand planar manipulation,” *IEEE Transactions on Robotics*, vol. 32, no. 3, pp. 763–770, 2016.
- [2] S. B. Backus and A. M. Dollar, “An adaptive three-fingered prismatic gripper with passive rotational joints,” *IEEE Robotics and Automation Letters*, vol. 1, no. 2, pp. 668–675, 2016.
- [3] J. Bemfica, C. Melchiorri, L. Moriello, G. Palli, and U. Scarcia, “A three-fingered cable-driven gripper for underwater applications,” in *2014 IEEE international conference on robotics and automation (ICRA)*. IEEE, 2014, pp. 2469–2474.
- [4] M. Zhu, Z. Wang, S. Hirai, and S. Kawamura, “Design and fabrication of a soft-bodied gripper with integrated curvature sensors,” in *2017 24th International Conference on Mechatronics and Machine Vision in Practice (M2VIP)*. IEEE, 2017, pp. 1–6.
- [5] A. Gabas, Y. Kita, and E. Yoshida, “Dual edge classifier for robust cloth unfolding,” *ROBOMECH Journal*, vol. 8, no. 1, p. 15, 2021.
- [6] I. Huang, Y. Narang, C. Eppner, B. Sundaralingam, M. Macklin, R. Bajcsy, T. Hermans, and D. Fox, “Defgraspsim: Physics-based simulation of grasp outcomes for 3d deformable objects,” *IEEE Robotics and Automation Letters*, vol. 7, no. 3, pp. 6274–6281, 2022.
- [7] Z. Pan, X. Gao, and D. Manocha, “Grasping fragile objects using a stress-minimization metric,” in *2020 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, 2020, pp. 517–523.
- [8] H. Ha and S. Song, “Flingbot: The unreasonable effectiveness of dynamic manipulation for cloth unfolding,” in *Conference on Robot Learning*. PMLR, 2022, pp. 24–33.

- [9] I. Garcia-Camacho, M. Lippi, M. C. Welle, H. Yin, R. Antonova, A. Varava, J. Borras, C. Torras, A. Marino, G. Alenya *et al.*, “Benchmarking bimanual cloth manipulation,” *IEEE Robotics and Automation Letters*, vol. 5, no. 2, pp. 1111–1118, 2020.
- [10] Y. Deng, K. Mo, C. Xia, and X. Wang, in *2024 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, 2024, pp. 7508–7514.
- [11] X. Zhu, X. Wang, J. Freer, H. J. Chang, and Y. Gao, “Clothes grasping and unfolding based on rgb-d semantic segmentation,” in *2023 IEEE International conference on robotics and automation (ICRA)*. IEEE, 2023, pp. 9471–9477.
- [12] J. Qian, T. Weng, L. Zhang, B. Okorn, and D. Held, “Cloth region segmentation for robust grasp selection,” in *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 2020, pp. 9553–9560.
- [13] W. Hamilton, Z. Ying, and J. Leskovec, “Inductive representation learning on large graphs,” *Advances in neural information processing systems*, vol. 30, 2017.
- [14] A. Grigorev, M. J. Black, and O. Hilliges, “Hood: Hierarchical graphs for generalized modelling of clothing dynamics,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2023, pp. 16 965–16 974.
- [15] N. Mahmood, N. Ghorbani, N. F. Troje, G. Pons-Moll, and M. J. Black, “Amass: Archive of motion capture as surface shapes,” in *Proceedings of the IEEE/CVF international conference on computer vision*, 2019, pp. 5442–5451.
- [16] M. Fey, J. E. Lenssen, F. Weichert, and H. Müller, “Splinecnn: Fast geometric deep learning with continuous b-spline kernels,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 869–877.
- [17] T. Pfaff, M. Fortunato, A. Sanchez-Gonzalez, and P. W. Battaglia, “Learning mesh-based simulation with graph networks,” *arXiv preprint arXiv:2010.03409*, 2020.

- [18] R. Narain, A. Samii, T. Pfaff, and J. O’Brien, “Arcsim: Adaptive refining and coarsening simulator,” *University of California–Berkeley, Berkeley, CA, accessed Oct*, vol. 1, p. 2016, 2014.
- [19] C. Multiphysics, “Introduction to comsol multiphysics®,” *COMSOL Multiphysics, Burlington, MA, accessed Feb*, vol. 9, no. 2018, p. 32, 1998.
- [20] T. D. Economon, F. Palacios, S. R. Copeland, T. W. Lukaczyk, and J. J. Alonso, “Su2: An open-source suite for multiphysics simulation and design,” *Aiaa Journal*, vol. 54, no. 3, pp. 828–846, 2016.
- [21] D. Blanco-Mulero, O. Barbany, G. Alcan, A. Colomé, C. Torras, and V. Kyrki, “Benchmarking the sim-to-real gap in cloth manipulation,” *IEEE Robotics and Automation Letters*, 2024.
- [22] E. Todorov, T. Erez, and Y. Tassa, “Mujoco: A physics engine for model-based control,” in *2012 IEEE/RSJ international conference on intelligent robots and systems*. IEEE, 2012, pp. 5026–5033.
- [23] E. Coumans, “Bullet physics simulation,” in *ACM SIGGRAPH 2015 Courses*, 2015, p. 1.
- [24] M. Macklin, M. Müller, N. Chentanez, and T.-Y. Kim, “Unified particle physics for real-time applications,” *ACM Transactions on Graphics (TOG)*, vol. 33, no. 4, pp. 1–12, 2014.
- [25] F. Faure, C. Duriez, H. Delingette, J. Allard, B. Gilles, S. Marchesseau, H. Talbot, H. Courtecuisse, G. Bousquet, I. Peterlik *et al.*, “Sofa: A multi-model framework for interactive physical simulation,” *Soft tissue biomechanical modeling for computer assisted surgery*, pp. 283–321, 2012.

- [26] T. Lips, V.-L. De Gusseme *et al.*, “Learning keypoints for robotic cloth manipulation using synthetic data,” *IEEE Robotics and Automation Letters*, 2024.
- [27] D. Bazazian, J. R. Casas, and J. Ruiz-Hidalgo, “Fast and robust edge extraction in unorganized point clouds,” in *2015 international conference on digital image computing: techniques and applications (DICTA)*. IEEE, 2015, pp. 1–8.
- [28] R. Hess, *Blender foundations: The essential guide to learning blender 2.5*. Routledge, 2013.
- [29] J. Maitin-Shepard, M. Cusumano-Towner, J. Lei, and P. Abbeel, “Cloth grasp point detection based on multiple-view geometric cues with application to robotic towel folding,” in *2010 IEEE International Conference on Robotics and Automation*. IEEE, 2010, pp. 2308–2315.
- [30] Y. Li, Y. Yue, D. Xu, E. Grinspun, and P. K. Allen, “Folding deformable objects using predictive simulation and trajectory optimization,” in *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 2015, pp. 6000–6006.
- [31] K. Yamazaki, “Grasping point selection on an item of crumpled clothing based on relational shape description,” in *2014 IEEE/RSJ International Conference on Intelligent Robots and Systems*. IEEE, 2014, pp. 3123–3128.

## **ABSTRACT**

# **Cloth Manipulation Algorithm Based on PCA and GNN Learning Using a Dual-Arm Robot**

Hyojeong Yu

Artificial Intelligence and Software

The Graduate School

Ewha Womans University

With the advancement of robotics, tasks such as handling simple repetitive chores or performing dangerous activities can now be efficiently carried out by robots, freeing humans from these duties. Among these tasks, manipulating soft bodies, such as clothes, remains a challenging research problem due to the excessive degrees of freedom. For a robot to effectively manipulate clothing, its recognition system must accurately identify the cloth's position, and the gripper must determine the optimal grasping pose. Most existing research assumes that the cloth is already stretched out and laid flat, simplifying the task for the robot's recognition system. However, in the real world, clothes are often wrinkled or crumpled, posing a significant challenge.

This dissertation proposes two algorithms to estimate the gripper's pose for effective grasping and unfolding of clothing. The first method is based on Principal Component Analysis (PCA) applied to the point cloud data of the cloth, while the second method uses mesh data in a Graph Neural Network (GNN)-based approach to predict the optimal grasping poses.

The PCA-based method analyzes the principal components of the point cloud and calculates surface variation, filtering out sharp points. Grasping directions are predicted based on the density distribution of the points. In contrast, the GNN-based method generates realistic training data through a physics simulator and uses this data to train the model.

The cloth data is generated through Blender simulation, and the evaluation is conducted within the simulator. The physics simulator generates a large amount of data that closely approximates real-world scenarios, enabling more accurate evaluations.

The performance of the predicted grasping poses is evaluated by checking if the gripper's two fingers successfully capture the estimated cloth vertex. The quality of the grasp pose is influenced by potential collisions, which may cause the predicted vertex to not always lie between the two fingers. Additionally, the evaluation includes a metric based on the area of the cloth unfolded after grasping the predicted vertex and stretching it. For the GNN-based approach, the evaluation also shows that as the model was trained, the Mean Squared Error (MSE) gradually decreased and eventually converged, indicating that the model had stabilized.

The results show that the PCA-based algorithm is highly dependent on the shape of the initial point cloud, while the GNN-based approach, though requiring a large dataset for training, can generalize across various cloth shapes. Additionally, the GPU-accelerated GNN algorithm offers faster predictions for larger cloth data compared to PCA. However, the study does not incorporate motion planning, and therefore, real-world testing using a robot and ROS is essential to enhance the algorithm's accuracy and efficiency.

## 감사의 글

직장을 정리하고 대학원 생활을 시작한 후 많은 일들이 있었던 것 같습니다. 힘든 순간도 있었지만, 후회 없는 대학원 생활을 위해 노력했던 시간들이 지금 돌아보면 오히려 즐겁게 느껴지기도 합니다. 부족했던 저를 성장시켜 주고, 새로운 미래로 나아갈 수 있는 기회를 주신 많은 분들께 감사의 인사를 전하고자 합니다.

먼저 제 연구를 지도해 주신 김영준 교수님께 깊이 감사드립니다. 학부 시절 그래픽스 수업을 통해 생긴 흥미와 호기심이 저를 다시 그래픽스 분야로 이끌었습니다. 명확한 연구 방향과 연구에 전념할 수 있는 환경을 마련해 주신 덕분에 이 논문을 완성할 수 있었습니다. 교수님의 가르침에 다시 한번 진심으로 감사드립니다.

논문 심사위원으로 참여해 주신 박상수 교수님과 오유란 교수님께 진심으로 감사드립니다. 두 분의 소중한 조언 덕분에 연구가 한층 더 발전할 수 있었습니다.

함께해 준 소중한 선후배들, 혜정 언니, 지민, 보경, 의정, 주이, 민서, 하진에게 감사의 마음을 전합니다. 연구가 잘 풀리지 않을 때 함께 고민을 나누고 서로 위로하며 힘이 되었던 순간들 덕분에 끝까지 연구를 마칠 수 있었습니다. 여러분과 함께한 시간들이 정말 소중하게 느껴집니다. 또한, 한경민 박사님과 유지연 선생님께서도 깊이 감사드립니다.

항상 가장 큰 힘이 되어 주신 부모님과 언니에게 진심으로 감사드립니다. 평소 무뚝뚝함을 핑계로 이런 이야기를 전할 기회가 없었지만, 부모님의 변함없는 사랑과 응원이 없었다면 오늘의 저는 없었을 것입니다. 가족의 따뜻한 응원 덕분에 힘든 순간들도 잘 이겨낼 수 있었습니다.

많은 분들께서 저에게 주셨던 관심과 응원, 그리고 사랑을 밑바탕으로 앞으로도 최선을 다하겠습니다. 감사합니다.