

## Development of Joint-Based Motion Prediction Model for Home Co-Robot Using SVM

Sungyeob Yoo<sup>†</sup> · Dong-Yeon Yoo<sup>††</sup> · Ye-Seul Park<sup>†††</sup> · Jung-Won Lee<sup>††††</sup>

### ABSTRACT

Digital twin is a technology that virtualizes physical objects of the real world on a computer. It is used by collecting sensor data through IoT, and using the collected data to connect physical objects and virtual objects in both directions. It has an advantage of minimizing risk by tuning an operation of virtual model through simulation and responding to varying environment by exploiting experiments in advance. Recently, artificial intelligence and machine learning technologies have been attracting attention, so that tendency to virtualize a behavior of physical objects, observe virtual models, and apply various scenarios is increasing. In particular, recognition of each robot's motion is needed to build digital twin for co-robot which is a heart of industry 4.0 factory automation. Compared with modeling based research for recognizing motion of co-robot, there are few attempts to predict motion based on sensor data. Therefore, in this paper, an experimental environment for collecting current and inertia data in co-robot to detect the motion of the robot is built, and a motion prediction model based on the collected sensor data is proposed. The proposed method classifies the co-robot's motion commands into 9 types based on joint position and uses current and inertial sensor values to predict them by accumulated learning. The data used for accumulating learning is the sensor values that are collected when the co-robot operates with margin in input parameters of the motion commands. Through this, the model is constructed to predict not only the nine movements along the same path but also the movements along the similar path. As a result of learning using SVM, the accuracy, precision, and recall factors of the model were evaluated as 97% on average.

Keywords : Machine Learning, IoT, Digital Twin, Big Data, Co-Robot

## SVM을 이용한 가정용 협력 로봇의 조인트 위치 기반 실행동작 예측 모델 개발

유 성 엽<sup>†</sup> · 유 동 연<sup>††</sup> · 박 예 슬<sup>†††</sup> · 이 정 원<sup>††††</sup>

### 요 약

디지털 트윈은 현실 세계의 물리적인 사물을 컴퓨터상에 동일하게 가상화시키는 기술로써, IoT를 통해 센서 데이터를 수집하고, 수집한 데이터를 활용하여 물리적인 사물과 가상 사물을 양방향으로 연결을 할 수 있게 한다. 디지털 트윈 기술은 가상 모델의 시뮬레이션을 통해 동작을 조정하고 환경변화에 대한 대응을 미리 실험하여 위험성을 최소화할 수 있는 장점을 지닌다. 최근 인공지능이나 기계학습에 관련된 기술들이 주목받기 시작하면서, 물리적인 사물의 동작을 가상화하여 가상 모델을 관찰하고 다양한 시나리오를 적용하려는 시도가 증가하고 있다. 특히, 인더스트리 4.0에서 공장자동화의 핵심인 협력 로봇의 디지털 트윈을 구축하기 위해서는 로봇의 동작을 인지하는 과정이 필수적으로 요구된다. 로봇의 동작을 인지하기 위한 모델링 기반의 연구에 비해 센서 데이터 기반으로 동작을 예측하는 연구는 미비한 상황이다. 따라서 본 논문에서는 로봇의 동작을 인지하기 위해 가정용 협력 로봇에서 전류 및 관성 센서 데이터를 수집하기 위한 실험 환경을 구축하고, 수집한 센서 데이터를 기반으로 한 동작 예측 모델을 제안하고자 한다. 제안하는 방식은 조인트 위치 기반으로 로봇의 동작 명령어를 9가지로 분류하고 전류와 관성 센서값을 사용하여 학습을 통해 예측하는 방식이다. 이때, 학습에 사용되는 데이터는 협력 로봇이 동작 명령어의 입력 파라미터에 마진을 가지고 작동할 때 수집되는 센서값이다. 이를 통해, 동일한 경로를 따라 이동하는 9가지 동작뿐만 아니라 각 동작과 비슷한 경로를 따라 이동하는 동작에 대해서도 예측하는 모델을 구축하였다. SVM을 이용하여 학습한 결과, 모델의 성능은 평균적으로 정확도, 정밀도, 및 재현율이 모두 97%로 평가되었다.

키워드 : 기계학습, IoT, 디지털 트윈, 빅데이터, 협력로봇

※ 이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2019R1H1A2101112).

※ 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터 지원사업의 연구결과로 수행되었음(IITP-2019-2016-0-00309).

※ 이 논문은 2019년도 한국정보처리학회 춘계학술발표대회에서 '가정용 협력 로봇의 센서 데이터 기반 실행동작 예측 모델 개발'의 제목으로 발표된 논문을 확장한 것임.

† 준 회원 : 아주대학교 전자공학과 학사과정

†† 준 회원 : 아주대학교 전자공학과 석사과정

††† 준 회원 : 아주대학교 전자공학과 박사과정

†††† 종신회원 : 아주대학교 전자공학과 교수

Manuscript Received : July 25, 2019

Accepted : August 24, 2019

\* Corresponding Author : Jung-Won Lee(jungwony@ajou.ac.kr)

### 1. 서 론

디지털 트윈(Digital Twin)은 현실 세계의 물리적인 사물을 컴퓨터상에 동일하게 가상화하는 기술을 말한다. 이 기술은 IoT (Internet of Things)을 통해 센서 데이터를 수집하고, 수집한 데이터를 활용하여 물리적인 사물과 가상 사물을 양방향으로 연결을 할 수 있게 한다[1]. 최근에는 가상화한 모델에 빅데이터 기반의 인공지능 모델을 탑재함으로써, 분석 혹은 진단의 성능을 향상시키고 물리적 사물을 유지보수하는 것은 물론, 전체 시스템에 대한 최적화를 가능케 하고 있다[2].

디지털 트윈을 구축하기 위해서는 로봇의 동작을 인지하는 과정이 필수적으로 요구된다. 일반적으로 동작을 인지하여 행동을 수행하기 위해, 수집한 데이터를 분석하여 로봇의 상태나 동작에 대해 표준화된 모델링 과정을 거친다[3]. 그러나 물리적인 사물이나 시스템을 가상화하기 위해 사용된 수식 기반의 모델링은 실제로 수집된 데이터와 모델의 시뮬레이션 결과가 일치하지 않는 문제가 발생한다[4]. 달리 말하면, 수식을 이용한 모델링 기법은 도메인에 대한 전문 지식과 사전 지식을 요구하고, 기계 시스템의 변화에 민감하다는 문제를 가지고 있다[5].

최근에는 인공지능이나 기계학습에 관련된 기술들이 주목받기 시작하면서, 물리적인 사물의 동작을 가상화하여 가상 모델을 관찰하고 다양한 시나리오를 적용하려는 시도가 증가하고 있다[6]. 적용되는 분야는 대부분 기계 시스템으로, 대표적인 예는 협력 로봇이다. 협력 로봇은 4차 산업혁명 관련 산업 중 인더스트리 4.0에서 주목받고 있는 기기이다. 협력 로봇의 디지털 트윈을 구현하기 위해서는 로봇의 동작을 인지하는 과정이 필수적으로 요구된다[1]. 로봇의 동작을 인지하기 위한 수식 모델링 기반의 연구[6]에 비해 센서 데이터 기반의 연구는 데이터 자체를 학습하여 기계 시스템에 대한 전문지식이 덜 요구되는 이점이 있지만, 연구는 미비한 상황이다.

따라서 본 논문에서는 협력 로봇의 물리적 특성에 종속적이고 복잡한 모델링 작업 대신 실행환경에서의 로봇이 생성

한 센서 빅데이터를 이용해서 가정용 협력 로봇의 동작 예측 모델을 구현하고자 한다. 제안하는 방식은 로봇의 동작 명령어를 조인트 위치 기반으로 분류하고 전류와 위치 센서 값을 사용하여 SVM(Support Vector Machine)을 통해 학습하여 예측하는 방식이다. Fig. 1은 제안하는 방식을 나타낸 그림이다. 그림에서 확인할 수 있듯이, 로봇의 동작 명령어는 로봇을 구성하고 있는 6개의 조인트 각도에 따라 결정될 수 있다. 이때, 입력되는 파라미터의 값에 따라 동작 명령어의 종류(move\_pose, move\_joints, shift\_pose)가 결정될 수 있다. 본 논문에서는 이와 같은 동작 명령어를 동작의 시점과 종점이 같은 조건 내에서 9가지 경로로 분류하였으며, 이로부터 전류 및 관성 센서에 대한 데이터를 수집하여 실험하였다. 실험 환경은 가정용 협력 로봇을 기반으로 구축되었으며, 수집된 데이터는 앞서 언급한 바와 같이 SVM을 이용하여 9가지 동작을 구분하기 위해 학습되었다. 실험 결과, 학습 성능은 평균 정확도, 정밀도, 및 재현율 모두 97%로 높게 평가되었다. 제안한 모델은 디지털 트윈을 구축하기 위해, 실행환경에서 동적으로 대응하는 협력 로봇의 동작을 인지하는 과정에 활용할 수 있다.

본 논문의 구성은 다음과 같다. 1장의 서론에 이어 2장에서는 관련 연구를 소개한다. 3장에서는 센서 빅데이터 기반 동작 예측 모델을 설계하기 위해, 로봇 암의 동작 명령어에 대해 정의하고, 이를 위치 기반으로 분류하는 방법과 예측 모델을 소개한다. 이어 4장에서는 설계된 동작 예측 모델을 실제로 구현하고 평가하며, 5장의 결론으로 마무리 짓는다.

### 2. 관련 연구

현재 협력 로봇의 물리적 모델 가상화를 위해 수식 모델 등을 기반으로 시뮬레이션 모델을 설계 및 개발하고 있지만 [6], 아직 디지털 트윈을 적용하기 위해 데이터 기반 시뮬레이션을 이용한 가상화 연구는 미비하다. 하지만, 인더스트리 4.0의 핵심인 디지털 트윈을 협력 로봇 이외의 다른 산업 분야에 적용하고 있는 사례는 증가하고 있다[7, 8]. [7]은 항공기 구조 수명 예측 프로세스에 관해 수행된 연구로, 디지털

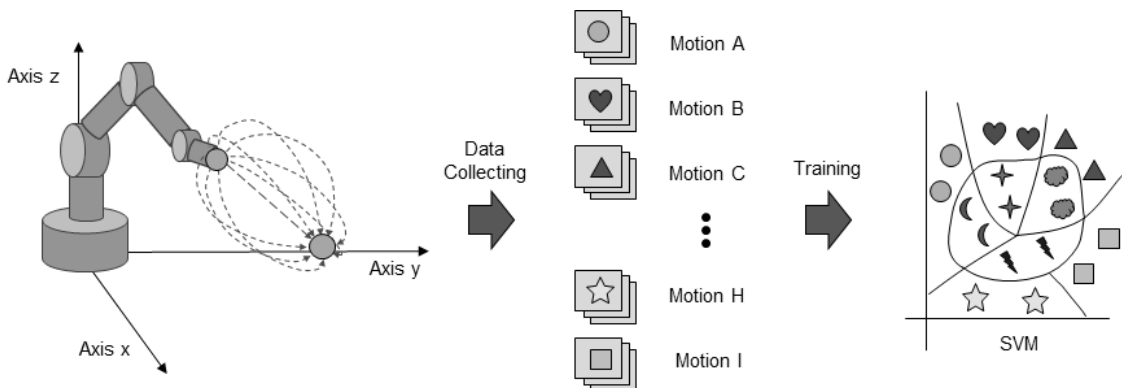


Fig. 1. Development Structure Diagram of Motion Prediction Model for Home Co-robot using SVM

트윈을 사용하여 비행 조건에 따른 온도와 구조적인 변형의 계산을 통합하여 항공기 구조물의 수명을 예측하고 구조적 무결성을 보장하는 모델을 제안했다. 또한, [8]은 중공 유리 생산 라인의 다목적 최적화에 관해 수행한 연구로, 디지털 트윈을 적용하여 정적 설계와 동적 실행 간의 반복 최적화를 위한 신속한 개별 생산 라인 설계를 제안했다.

디지털 트윈은 IoT를 통해 센서 데이터를 수집하고, 수집한 데이터를 활용하여 물리적 사물과 가상 사물을 양방향으로 연결할 수 있게 한다[1]. 이때, 양방향으로 연결하기 위해 운영 데이터를 수집하고 시뮬레이션하는 과정이 필요하게 된다[2]. 전통적으로 시뮬레이션을 구현하는 방식은 수식 기반의 모델링 방식이 있다. [6]은 시뮬레이션 기반 시스템 엔지니어링 프로세스인 실험적 디지털 트윈(Experimentable Digital Twins)을 제안하여 하이브리드 시나리오 가운데 물리적 사물과 가상 모델을 연결한다. 그러나 이 방식에서는 모델링을 할 때 사용되는 수식이 복잡해질수록 시뮬레이션 결과와 물리적인 사물이 일치하지 않는다는 문제가 발생한다 [4]. 또한, 디지털 트윈을 적용하는 분야에 대한 전문적인 지식을 요구하고, 기계 시스템의 변화에 민감하다는 문제를 가지고 있다[5]. 따라서 본 논문에서는 복잡한 수식을 통한 모델링 방식 대신 실행환경에서의 로봇이 생성한 센서 빅데이터를 이용해서 가정용 협력 로봇의 동작 예측 모델을 제안하고자 한다.

### 3. 센서 빅데이터 기반 동작 예측 모델 설계

#### 3.1 로봇 암 동작 명령어 정의

3.1절에서는 로봇 암의 동작 명령어에 대해 정의하도록 한다. 본 논문에서 사용한 가정용 협력 로봇은 Fig. 2와 같다. 가정용 협력 로봇은 그림과 같이 6개의 조인트로 구성되었으며, 각 조인트는 명령어에 따라 독립적으로 동작할 수 있다. 다음은 기능과 입력 파라미터에 따라 정의한 세 가지 동작 명령어이다.

- `move_pose`: 로봇의 끝단을 원하는 위치로 움직일 때 사용한다. 3차원 유한 회전군의 한 좌표인  $x, y, z, roll, pitch, yaw$ 를 입력 파라미터로 받는다.
- `move_joints`: 각 조인트의 각도를 지정하여 원하는 동작을 수행할 때 사용하며 각 조인트의 각도를 입력 파라미터로 받는다.
- `shift_pose`: 로봇 암의 끝단을 현재 위치 기준으로 특정 값만큼 움직이고 싶을 때 사용한다. 움직이고 싶은 축과 그 변화량을 입력 파라미터로 받는다.

`move_pose` 명령어와 `shift_pose` 명령어는 로봇 암의 끝단을 원하는 위치로 움직인다는 점에서 비슷하다. 하지만 `move_pose` 명령어는 입력 파라미터를 절대 위치로 사용하

지만, `shift_pose` 명령어는 입력 파라미터를 상대 위치로 사용한다. 다음 Table 1, Table 2, Table 3은 동작 명령어 각각의 입력 파라미터와 기능 설명을 나타낸다.




Fig. 2. Joints of Home Co-Robot

Table 1. Robot Arm Motion Command(Move\_pose)

Command Type	<code>move_pose</code>
Parameters	$x, y, z, roll, pitch, yaw$
Description	Move the end of the robot arm from the current position to $(x, y, z, roll, pitch, yaw)$ .

Table 2. Robot Arm Motion Command(Move\_joints)

Command Type	<code>move_joints</code>
Parameters	<code>joints</code>
Description	Move the end of the robot arm from the current position to the input joint position.

Table 3. Robot Arm Motion Command(Shift\_pose)

Command Type	<code>shift_pose</code>
Parameters	<code>axis, value</code>
Description	Move the end of the robot arm by the input value on the input axis from the current position.

#### 3.2. 조인트 위치 기반 동작 분류

3.2절은 3.1절에서 정의한 동작 명령어 중에서 `move_pose`를 활용하여 조인트 위치 기반 동작을 분류한다. 본 논문에서 제안하는 동작 예측 모델은 동작의 시점과 종점이 같더라도 경로가 다르다면 다른 동작으로 인식해야 한다. 이를 고려하여 시점과 종점이 같은 9가지 동작을 구분하였다. 해당 동작은 기존 5가지의 동작에서 3차원 평면에서의 경로 4가지를 추가한 것이다[9]. Fig. 3는 동작마다 로봇 암 끝단이 지나는 경로를 나타낸 그림이다. Fig. 3(a)는 각 경로를 높은 곳에서 내려다본 그림이고, Fig. 3(b)는 각 경로를 정면에서 바라본 그림이다. Fig. 3(b)에서의 경로 A~I는 시점과 종점

이 같은 동작들의 궤적을 나타낸다. 경로 A는 시점에서 종점까지 직선으로 가는 경로로써, 최단 경로를 지난다.

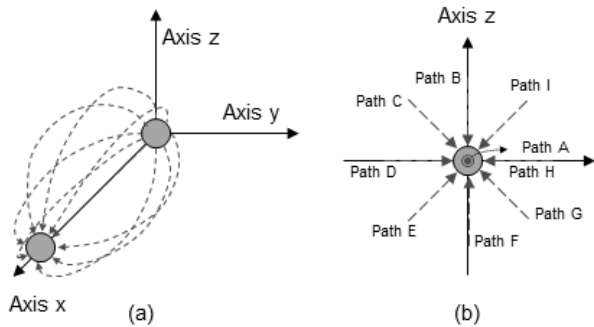


Fig. 3. Joint Position based Motion Classification Method  
(a) Aero View (b) Front View

경로 B와 F는 경로 A에서 각각 +z방향, -z방향으로 휘어져서 가는 경로이다. 두 경로는 xy 평면에 대해 대칭적이다. 경로 D와 H는 경로 A에서 각각 -y방향, +y방향으로 휘어져서 가는 경로이다. 두 경로는 xz 평면에 대해 대칭적이다. 경로 C와 I는 경로 B에서 각각 -y방향, +y방향으로 45도 기울어져서 가는 경로이다. 두 경로는 xz 평면에 대해 대칭적이다. 경로 E와 G는 경로 F에서 각각 -y방향, +y방향으로 45도 기울어져서 가는 경로이다. 두 경로는 xz 평면에 대해 대칭적이다. 시점과 종점이 같지만, 경로가 다른 동작을 9가지로 구분하여 조인트 위치 기반 동작을 분류하였다.

- 경로 A: 시점에서 종점으로 가는 직선 경로
- 경로 B: +z방향으로 휘어져서 가는 경로
- 경로 C: -y, +z방향으로 휘어져서 가는 경로
- 경로 D: -y 방향으로 휘어져서 가는 경로
- 경로 E: +y, -z방향으로 휘어져서 가는 경로
- 경로 F: -z방향으로 휘어져서 가는 경로
- 경로 G: +y, -z방향으로 휘어져서 가는 경로
- 경로 H: +y방향으로 휘어져서 가는 경로
- 경로 I: +y, +z방향으로 휘어져서 가는 경로

### 3.3. 동작 예측 모델 설계

3.3절에서는 정의된 동작 명령어를 기반으로 데이터를 수집하여 학습하기 위한 모델을 설계한다. 설계한 동작 예측 모델의 구조도는 Fig. 4와 같다. 먼저, 가정용 협력 로봇의 동작을 예측하기 위해 각 모터에서 전류값을, 로봇 암의 끝단에서 측정된 관성 값을 측정하여 수집한다. 수집한 데이터는 저역 통과 필터(Low Pass Filter)를 통해 노이즈를 제거한다. 동작을 수행하며 수집한 데이터는 모터의 전류값 6가지와 로봇 팔 끝단의 관성 값(자이로 3가지-gx, gy, gz, 가속도 3가지-ax, ay, az) 6가지로 총 12가지의 값을 가진다(Cm1: Current value of joint 1의 평균, gxm: gx의 평균을 의

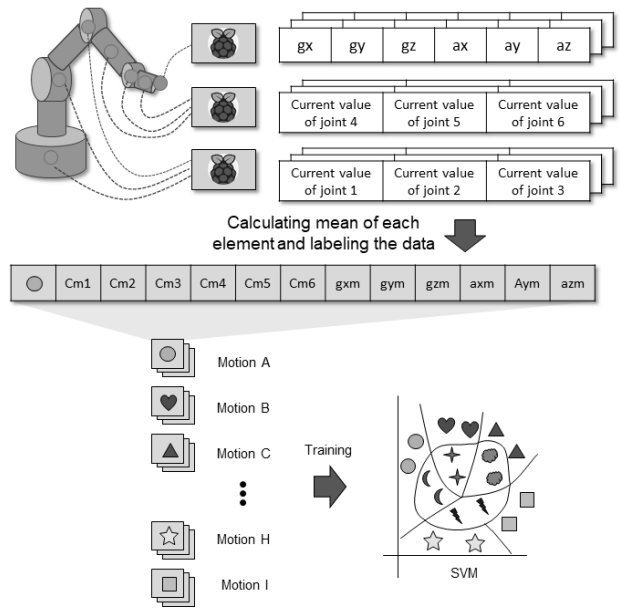


Fig. 4. Implementation and Evaluation of Robot Motion Prediction Model

미). 각각의 동작마다 12가지 데이터의 평균값을 계산하고, 이를 SVM을 통해 동작을 예측한다.

학습을 통해 동작 예측 모델을 설계하는 이유는 학습 모델이 학습된 데이터를 적절한 클래스로 올바르게 분류할 뿐만 아니라, 학습되지 않은 데이터도 유사한 클래스로 적절하게 분류할 수 있기 때문이다[10]. 이러한 학습 모델을 구축하기 위한 다양한 학습 방법이 존재하는데, 최근에는 자동으로 특징을 추출해서 학습하는 인공 신경망을 이용한 학습 모델이 가장 대표적이다[11]. 하지만 인공 신경망은 자동으로 특징을 추출하는 과정 때문에 많은 연산량과 학습 시간이 필요하다[12]. 본 연구에서는 센서로부터 수집한 데이터에서 특징을 벡터 형태로 추출할 수 있으므로, 특징 벡터를 학습하여 인공 신경망 대비 연산량, 학습 시간이 적게 소모되는 SVM을 이용하여[13] 동작 예측 모델을 학습하였다.

## 4. 로봇 동작 예측 모델의 구현 및 평가

### 4.1 실험 환경

실험을 진행하기 위해 구축한 실험 환경은 Fig. 5와 같다. 실험 환경은 구동기, 수집기, 분석기, 제어기로 구성되어 있다. 먼저, 구동기는 제어기로부터 명령을 받아 가정용 협력 로봇을 제어하는 모듈이다. 또한, 수집기는 가정용 협력 로봇으로부터 센서 데이터를 수집하는 모듈이다. 이때, 로봇의 각 조인트에 전류 센서를, 로봇 암의 끝단에 관성 센서를 부착하였고, 이 센서들을 수집기와 연결하였다. 또한, 각 센서로부터 수집한 데이터는 내부 저장장치에 저장하였다. 분석기는 테스트 메타 정보를 데이터베이스에 기록하고, 수집한 데이터를 통해 기계학습을 하는 모듈이다. 이 과정에서는 선행 연

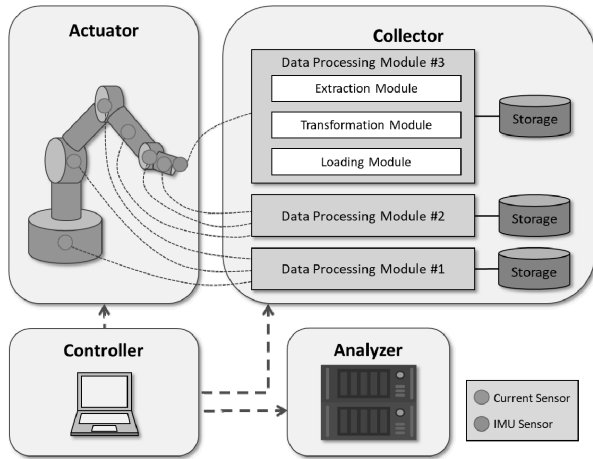


Fig. 5. Experimental Environment Structure Diagram of Sensor Data Collection and Motion Analysis for Home Co-robot

구를 참고하여 테스트 데이터의 메타 정보를 기록하고, 테스트 데이터를 체계적으로 저장하였다. 마지막으로, 제어기는 구동기, 수집기, 분석기를 제어하는 모듈이다. 실험을 시작하면 제어기는 구동기가 가정용 협력 로봇을 동작하도록 하고, 수집기는 협력 로봇의 전류값과 관성 값을 수집하도록 명령을 내린다. 그 후, 실험이 끝나면 테스트 메타 정보를 분석기의 데이터베이스에 기록한다.

4.2 구현

4.2절에서는 로봇 동작 예측 모델을 구현한 결과를 소개한다. 4.1절에서 설명한 실험 환경을 Fig. 6과 같이 구현하였다. 먼저, 구동기는 Niryo One 협력 로봇과 제조사에서 제공한 python API를 활용하여 제어하였다. 다음으로 수집기는 라즈베리파이 3B+ 보드와 python 언어를 사용하였으며, 전류 센서와 관성 센서로부터 데이터를 수집하기 위해 각각 ina219, mpu6050 라이브러리를 활용하였다. 분석기는 센서로 수집한 데이터를 가공하고, 동작 예측 모델을 학습하기 위해 pandas, matplotlib, numpy, scipy, sklearn 라이브러리를 활용하였다. 이때, 사용한 분석기의 CPU와 GPU는 각각 Intel i5-7200U와 Intel HD Graphics 620이다. 마지막으로 제어기는 python 언어를 사용하였고, 분석기에 테스트 데이터의 메타 정보를 전송하기 위해 pymysql 라이브러리를 활용하였다.

또한, 3.2절에서 동작 명령어를 사용하여 Table 4와 같은 명령어 조합을 생성하였다. 조합한 모든 명령어의 입력 파라미터 중 roll, pitch, yaw는 모두 0으로, Table 4에서는 생략하였다. 각 동작은 3번의 move\_pose 동작 명령어로 구성되며, 첫 번째와 마지막 입력 파라미터에 동일한 수치를 입력하여 동작의 시점과 종점이 동일한 명령어 조합을 생성하였다. [9] 실험의 완전성을 보완하기 위해 Table 4에서 각 동작의 두 번째 명령어 입력 파라미터에 약간의 마진(margin)을 더하였다. 마진은 x, y, z축에 대해서 -0.02에서 0.02 사이의 랜덤




Fig. 6. Experimental Environment of Sensor Data Collection and Motion Analysis for Home Co-Robot

Table 4. Commands Used for Each Motion

Motion	Sequence	Command	Input Parameters		
			x	y	z
A	1	move_pose	0.12	0	0.28
	2	move_pose	0.2	0.1	0.28
	3	move_pose	0.323	0	0.28
B	1	move_pose	0.12	0	0.28
	2	move_pose	0.2	0	0.36
	3	move_pose	0.323	0	0.28
C	1	move_pose	0.12	0	0.28
	2	move_pose	0.2	-0.05	0.33
	3	move_pose	0.323	0	0.28
D	1	move_pose	0.12	0	0.28
	2	move_pose	0.2	-0.1	0.28
	3	move_pose	0.323	0	0.28
E	1	move_pose	0.12	0	0.28
	2	move_pose	0.2	0.05	0.23
	3	move_pose	0.323	0	0.28
F	1	move_pose	0.12	0	0.28
	2	move_pose	0.2	0	0.14
	3	move_pose	0.323	0	0.28
G	1	move_pose	0.12	0	0.28
	2	move_pose	0.2	0.05	0.23
	3	move_pose	0.323	0	0.28
H	1	move_pose	0.12	0	0.28
	2	move_pose	0.2	0.1	0.28
	3	move_pose	0.323	0	0.28
I	1	move_pose	0.12	0	0.28
	2	move_pose	0.2	0.05	0.33
	3	move_pose	0.323	0	0.28

값을 균일하게 생성하였다. 마진을 고려한 Table 4의 9가지 동작을 각각 100번씩을 수행하여 총 900번의 동작을 수행하였다. 마진을 고려한 명령어를 수행한 협력 로봇 동작 경로는 Fig. 7과 같다. 이를 통해 동일한 경로를 따라 이동하는 9가지 동작뿐만 아니라 각 동작과 비슷한 경로를 따라 이동하는 동작에 대해서도 예측하는 모델을 구축할 수 있다. 수행한 실험의 메타 정보를 분석기의 데이터베이스에 저장하여 체계적으로 데이터를 수집하였고, 수집한 데이터는 지역 통과 필터를 통해 노이즈를 제거하였다. 또한, 정제된 데이터를 SVM으로 학습하여 아홉 가지의 동작을 구분하였다. 동작마다 학습하는데 사용되는 데이터는 90개, 검증하는데 사용되는 데이터는 10개로 10겹 교차검증(10-cross validation)을 진행하였다.

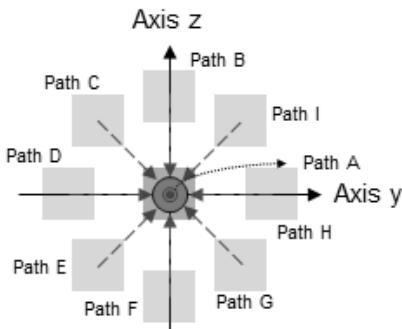


Fig 7. The Range of Motion Path of Home Co-Robot that Operated the Commands Considering Margin

4.3 평가

4.3절에서는 구현된 모델에 대한 평가를 진행한다. 실험의 평가는 정확도(Accuracy), 재현율(Recall), 정밀도(Precision), F1-점수(F1-score)를 지표로 사용하였다. 9가지 동작을 SVM으로 학습하여 10겹 교차검증을 한 결과, 모든 평가 지표가 0.94 이상이고 모델의 성능은 평균적으로 정확도, 정밀도, 및 재현율이 모두 97%로 평가되었다. 학습에 사용된 센서 데이터는 Fig. 8과 같다. 랜덤 변수 생성기를 통해 생성한 마진을 명령어 입력 파라미터에 더하여 Table 4와 비슷한 동작을 수행하였다. 이때 생성된 데이터를 97% 정확도로 동작 예측하는 것을 Table 5를 통해 볼 수 있다. 이를 통해 동작의 입력 파라미터가 어느 정도의 차이가 있더라도 동작 구분에 높은 성능을 보이는 확인했다. Table 6은 10번의 테스트 중 결과가 가장 낮게 나온 테스트 케이스 8에 대한 상세 결과이다. 테스트 결과, 동작 A를 동작 G와 동작 H로, 동작 B를 동작 C, 동작 I로, 동작 D를 동작 C로 잘못 예측하여 동작 A, B, C의 정밀도가 떨어지고 동작 C, 동작 G, 동작 H, 동작 I의 재현율이 떨어진 것을 볼 수 있다. 이는 비슷한 경로를 따라 이동하는 근접한 동작으로 잘못 예측하여 그렇다. 향후에는 이러한 오차를 줄이기 위해서 12가지 데이터의 대푯값을 선정하는 데 세분된 평균값을 구하거나 분산 값을 활용함으로써 모델을 개선하는 연구를 진행할 계획이다.

timestamp	1	2	3	4	5	6	gx	gy	gz	ax	ay	az
156283608142	372.16	896.36	652.09	136.46	99.58	23.62	-0.88	8.53	0.31	-1.29	0.44	9.92
156283608143	371.67	896.85	652.81	136.07	99.25	23.61	-0.90	8.80	0.34	-1.29	0.41	9.93
156283608144	371.23	897.19	653.46	135.80	98.97	23.61	-0.91	9.06	0.37	-1.30	0.38	9.95
156283608145	370.84	897.47	654.05	135.66	98.77	23.60	-0.91	9.32	0.40	-1.31	0.35	9.96
156283608146	370.52	897.69	654.55	135.68	98.67	23.60	-0.92	9.56	0.43	-1.33	0.32	9.98
156283608147	370.26	897.80	654.96	135.88	98.68	23.60	-0.93	9.79	0.45	-1.35	0.30	9.99

Fig. 8. Part of Sensor Data Used to Develop Prediction Model

Table 5. Analysis of Learning Performance for Motion Prediction Model by SVM

Test Case	Accuracy	Precision	Recall	F1-Score
1	0.99	0.99	0.99	0.99
2	0.94	0.94	0.95	0.94
3	0.99	0.99	0.99	0.99
4	0.96	0.96	0.96	0.96
5	0.98	0.98	0.98	0.98
6	0.98	0.98	0.98	0.98
7	0.98	0.98	0.98	0.98
8	0.94	0.94	0.95	0.94
9	0.98	0.98	0.98	0.98
10	0.98	0.98	0.98	0.98
Avg	0.97	0.97	0.97	0.97

5. 결론 및 향후 연구

본 논문에서는 로봇의 동작을 인지하기 위해 가정용 협력 로봇에서 전류 및 관성 데이터를 수집하기 위한 실험 환경을 구축하고, 수집한 센서 데이터를 기반으로 한 동작 예측 모델을 제안하였다. 제안한 방식은 로봇의 동작 명령어를 조인트 위치 기반으로 분류하고 전류와 위치 센서값을 사용하여 학습을 통해 예측하는 방식이다. 적용된 학습 모델은 SVM이

Table 6. Analysis of Learning Performance for Motion Prediction Model by SVM (Test Case 8)

Test Case: 8		Accuracy: 0.94	
Motion	Precision	Recall	F1-Score
A	0.80	1.00	0.89
B	0.80	1.00	0.89
C	1.00	0.83	0.91
D	0.90	1.00	0.95
E	1.00	1.00	1.00
F	1.00	1.00	1.00
G	1.00	0.91	0.95
H	1.00	0.91	0.95
I	1.00	0.91	0.95
Avg	0.94	0.95	0.94

며, 학습 성능은 평균 정확도, 정밀도, 및 재현율 모두 97%로 높게 평가되었다. 제안한 모델은 디지털 트윈을 구축하기 위해, 실행환경에서 동적으로 대응하는 협력 로봇의 동작을 인지하는 과정에 활용할 수 있다. 향후에는 동작 예측 모델의 오차를 줄이기 위해서 12가지 데이터의 대푯값을 선정하는데 세분된 평균값을 구하거나 분산 값을 활용함으로써 모델을 개선하는 연구를 진행할 계획이다.

## References

- [1] Q. Qi and F. Tao, "Digital Twin and Big Data Towards Smart Manufacturing and Industry 4.0: 360 Degree Comparison," in *IEEE Access*, Vol.6, pp.3585-3593, 2018.
- [2] Jay Lee, Hossein Davari Ardakani, Shanhu Yang, and Behrad Bagheri, "Industrial Big Data Analytics and Cyber-physical Systems for Future Maintenance & Service Innovation," in *Procedia CIRP*, Vol.38, pp.3-7, 2015.
- [3] Stephan Weyer, Torben Meyer, Moritz Ohmer, Dominic Gorecky, and Detlef Zuhlke, "Future Modeling and Simulation of CPS-based Factories: An Example from the Automotive Industry," in *IFAC-PapersOnLine*, Vol.49, Issue 31, pp.97-102, 2016.
- [4] Patricia Derler, Edward A. Lee, and Alberto Sangiovanni Vincentelli, "Modeling Cyber-physical Systems," in *Proceedings of the IEEE*, Vol.100, No.1, pp.13-28, 2012.
- [5] Luyang Jing, Ming Zhao, Pin Li, and Xiaoqiang Xu, "A Convolutional Neural Network Based Feature Learning and Fault Diagnosis Method for the Condition Monitoring of Gearbox," in *Measurement*, Vol.111, pp.1-10, 2017.
- [6] Michael Schluse, Marc Priggemeyer, Linus Atorf, and Juergen Rossmann, "Experimentable Digital Twins-streamlining Simulation-based Systems Engineering for Industry 4.0," *The IEEE Transactions on Industrial Informatics*, Vol.14, No.4, pp.1722-1731, 2018.
- [7] Eric J. Tuegel, Anthony R. Ingraffea, Thomas G. Eason, and S. Michael Spottswood, "Reengineering Aircraft Structural Life Prediction using a Digital Twin," in *International Journal of Aerospace Engineering*, Vol.2011, Article ID 154798, 2011.
- [8] Hao Zhang, Qiang Liu, Xin Chen, Ding Zhang, and Jiewu Leng, "A Digital Twin-based Approach for Designing and Multi-objective Optimization of Hollow Glass Production Line," in *IEEE Access*, Vol.5, pp.26901-26911, 2017.
- [9] Sungyeob Yoo, Yeseul Park, and Jung-Won Lee, "Development of Sensor Data-based Motion Prediction Model for Home Co-robot," in *Proceeding of KIPS Spring Conference*, Seoul, pp.552-555, 2019.
- [10] S. B. Kotsiantis, "Supervised Machine Learning: A Review of Classification Techniques," in *Emerging Artificial Intelligence Applications in Computer Engineering*, I. Maglogiannis, et al., Ed., IOS Press, Vol.160, pp.3-24, 2007.
- [11] Junfei Qiu, Qihui Wu, Guoru Ding, Yuhua Xu, and Shuo Feng, "A Survey of Machine Learning for Big Data Processing," in *EURASIP Journal on Advances in Signal Processing 2016*, Article number 67, pp.1-16, 2016.
- [12] Moussa Hamadache, Joon Ha Jung, Jungho Park, and Byeng D. Youn, "A Comprehensive Review of Artificial Intelligence-based Approaches for Rolling Element Bearing PHM: Shallow and Deep Learning," in *JMST Advances*, Vol.1, Issue 1-2, pp.125-151, 2019.
- [13] Rodrigo Moraes, Joao Francisco Valiati, and Wilson P. Gavião Neto, "Document-level Sentiment Classification: An Empirical Comparison Between SVM and ANN," in *Expert Systems with Applications*, Vol.40, Issue 2, pp.621-633, 2013.



### 유 성 엽

<https://orcid.org/0000-0002-7783-9176>

e-mail : sungyeob.yoo@gmail.com

2013년 ~ 현재 제주대학교 전자공학과  
학사과정

관심분야 : Embedded Software, Digital  
Twin



### 유 동 연

<https://orcid.org/0000-0002-5780-0661>

e-mail : dongso125@ajou.ac.kr

2013년 제주대학교 전자공학과 (학사)

2019년 ~ 현재 제주대학교 전자공학과  
석사과정

관심분야 : Bio-medical Data Modeling,  
Big-Data Analysis, Ontology,  
Embedded Software



### 박 예 슬

<https://orcid.org/0000-0003-2584-7489>

e-mail : yeseuly777@gmail.com

2015년 제주대학교 전자공학과(학사)

2017년 제주대학교 전자공학과(석사)

2017년 ~ 현재 제주대학교 전자공학과  
박사과정

관심분야 : Bio-medical Data Modeling, Data Analysis,  
Medical Images, Ontology, Machine Learning,  
Deep Learning, Industrial Robot, Embedded  
Software



### 이 정 원

<https://orcid.org/0000-0001-8922-063X>

e-mail : jungwony@ajou.ac.kr

1993년 이화여자대학교 전자계산학과(학사)

1995년 이화여자대학교 전자계산학과(석사)

1995년 ~ 1997년 LG종합기술원 주임연구원

2003년 이화여자대학교 컴퓨터학과(박사)

2003년 ~ 2006년 이화여자대학교 컴퓨터학과 BK교수, 전임강사(대우)

2006년 ~ 현 재 아주대학교 전자공학과 교수

관심분야: Embedded Software, Automotive Software,

Bio·Medical Data Modeling