

차압 및 심층신경망 기반 유압 로봇팔 끝단 반력 추정

Hydraulic Manipulator End-tip Reaction Force Estimation Based on Differential Hydraulic Pressure and Deep Neural Network

구본학¹, 여태경², 김진균³, 한종부¹, 이영준², 박대길^{1,*}

(Bonhak Koo^{1,2}, Tae-kyeong Yeu², Jin-Gyun Kim³, Jong-Boo Han^{1,2}, Yeongjun Lee², and Daegil Park^{1,2,*})

¹Department of Ships & Ocean Engineering, University of Science & Technology (UST)

²Korea Research Institute of Ships & Ocean Engineering (KRISO)

³Department of Mechanical Engineering, Kyung Hee University

Abstract: In this study, a method to represent reactive forces at a stick-type controller has been proposed using a haptic master device to effectively communicate work status to users during subsea fracture operations through a teleoperated robot. Estimating reactive forces acting on the tool underwater presents significant challenges. To solve this, we propose a method that combines differential pressure measurement with a deep neural network (DNN) to estimate the reactive forces at the hydraulic manipulator's tool with good accuracy and a high sampling rate. Specifically, the reactive force was predicted from high-sampling-rate differential pressure data, and the DNN was used to update the reactive force estimation with high accuracy. These tasks were performed recursively within a Kalman filter framework. Finally, a plaster fracture experiment was conducted in a terrestrial environment to verify the proposed method. The estimated reactive forces were compared with those measured by a force-torque sensor using data retrieved from the inertial sensors, joint encoders, and other relevant sensors. The differential pressure-DNN-based approach demonstrated high accuracy in estimating reactive forces in key directions while maintaining fast sampling speed.

Keywords: CPOS (Cyber-Physical Operation System), differential hydraulic pressure, DNN (Deep Neural Network), hydraulic manipulator, Kalman filter algorithm, haptic feedback, underwater robot

1. 서론

해저 파쇄 작업은 해양 인프라 구축, 해저 자원 채취, 군사적 목적 등 다양한 분야에서 원격조종로봇(tele-operation robot)을 활용하는 주요 작업 중 하나이다. 작업자는 수중 원격 조종을 위해 주로 카메라 영상 및 소나(sonar) 등의 로봇에 부착된 센서 신호에 의존한다. 그러나 수중에서 카메라는 육상 대비 해상도가 낮고 시야가 제한적이며, 영상 전송 지연이 발생할 수 있다. 특히, 물속 빛의 부족과 높은 탁도는 영상 화질에 영향을 미치며, 때로는 추진 장치나 작업 도구로 인해 수중 환경이 혼탁해질 수 있다. 위와 같은 수중 환경의 단점에 의해 작업 환경에 대한 정보가 부족해지고, 이로 인해 로봇 조종자가 수중 상황을 정확히 인식하지 못하여 작업 효율 저하되거나 장비가 손상되는 사고가 발생할 수 있다.

이러한 문제를 해결하기 위해, 우리는 가상물리융용시스템(CPOS, cyber-physical operation system)을 제안하였다. 이 기술은 로봇에 부착된 센서로부터 수집된 로봇 및 주변 환경 정보를 사이버 환경에서 구현하고, 로봇의 실시간 동역학 및

역동역학 모델을 이용하여 로봇 및 주변 환경간 상호작용을 실시간으로 해석함으로써, 수중 환경변화 및 외란에도 사용자에게 높은 품질의 정보를 제공한다. 이를 위해 CPOS 시스템은 수중 로봇의 동역학 모델을 기반으로 동적 거동을 예측



그림 1. 가상물리융용시스템 개념도[1].

Fig. 1. Concept of CPOS (Cyber-Physical Operation System).

* Corresponding Author

Manuscript received October 26, 2024; revised November 19, 2024; accepted November 28, 2024

구본학: 과학기술연합대학원대학교 대학원생(kbh9974@kriso.re.kr, ORCID[®] 0009-0001-3732-3140)

여태경: 선박해양플랜트연구소 책임연구원(yeutk@kriso.re.kr, ORCID[®] 0000-0003-2742-3284)

김진균: 경희대학교 부교수(jingyun.kim@khu.ac.kr, ORCID[®] 0000-0002-2146-7609)

한종부: 선박해양플랜트연구소 선임연구원(jbhan@kriso.re.kr, ORCID[®] 0000-0002-5670-538X)

이영준: 선박해양플랜트연구소 선임기술원(leeyeongjun@kriso.re.kr, ORCID[®] 0000-0002-3808-8349)

박대길: 선박해양플랜트연구소 선임연구원(daegilpark@kriso.re.kr, ORCID[®] 0000-0001-5724-1794)

※ 본 연구는 선박해양플랜트연구소 주요사업 “해양로봇 가상물리융용시스템(CPOS) 핵심기술 개발 (PES5200)” 및 해양수산부의 “디지털 서비스 플랫폼 및 다목적 항해계획 최적화, 연안선박 탄소배출 모니터링 기술 개발(2520000291, PES5581)”로 수행된 연구결과임.




그림 2. HILS 환경의 로봇팔 끝단 작업 반력 추정 기술.
Fig. 2. Manipulator end-tip work reaction force estimation technology in HILS environment.

하는 실시간 물리 엔진, 수중 로봇의 상태와 주변 환경 및 작업 상황 정보를 계측할 수 있는 수중 센서 시스템, 조종자에게 정확하고 선명한 영상을 제공할 수 있는 실시간 가상 현실 가시화 장치, 그리고 햅틱 기술 기반 실감형 조종 장치로 구성되어 있다[1,2].

가상물리운동시스템의 핵심은 실측된 센서 정보와 실시간 물리 엔진의 가상 센서 정보를 이용하여 조종자에게 로봇의 상태와 로봇 주변 환경 및 작업 상황을 실시간으로 제공하는 것이다. 이를 통해 수중에서 제한된 시야 정보를 보완하고 환경 인식의 강인성을 확보할 수 있다. 또한, 로봇 작업 환경의 실시간 상태를 원격 조종자에게 효과적으로 전달하기 위해 로봇-사람간 HILS (Human-In-the-Loop System) 환경을 구축하여, 마치 조종자가 실제 로봇에 탑승하여 작업하는 것과 같은 경험을 제공한다[3].

본 논문에서는 HILS 기술 중 하나로 작업 상황 전달을 위한 햅틱 기술 개발을 개발하였다. 이 기술은 해저 파쇄 작업 중 발생하는 수중 로봇팔 끝단의 반력을 사용자에게 전달하여 작업 상황을 보다 명확하게 이해할 수 있도록 지원한다. 이를 통해 작업자는 햅틱 마스터 디바이스에서 재현되는 반력 정보를 통해 작업의 유무 및 강도를 촉각적으로 인지할 수 있다. 그러나 햅틱 마스터 장치를 통해 작업 상황을 정확하고 자연스럽게 전달하려면, 높은 샘플링 속도로 반력을 추정하고, 작업 상태와 강도에 따른 정확한 반력 정보를 제공할 수 있어야 한다.

그러나 수중 환경에서 작업 반력을 추정하는 것은 매우 어려운 문제이다. 햅틱 피드백을 위한 작업 반력 추정 방법은 센서를 이용해 로봇팔 끝단의 힘을 직접 측정하는 방법과 로봇팔과 수중 환경 간의 상호작용을 렌더링하여 계산하는 방법이 있다. 하지만 수압과 압력 보상 문제로 인해 수중에서 F/T (Force and Torque) 센서나 압력 센서와 같은 기존의 센서의 사용이 제한되며, 이러한 센서를 이용하여 힘을 직접적으로 측정하는 것이 어렵다. 또한, 수중 환경의 렌더링을 위해 수중에서 소나 센서를 이용할 수 있으나 낮은 해상도로 인해 렌더링 정확도가 부족하고, 카메라 영상을 활용하더라도 해저의 높은 탁도와 작업 중 발생하는 부유물로 인해 수중 환경을 렌더링하는 것이 어렵다. 따라서 햅틱 렌더링을 통해 로봇팔과 수중 환경 사이의 반력을 정확히 계산하는 것은 매우 어려운 일이다.

이를 해결하기 위해 본 논문에서는 로봇팔 각 관절에서 측정하는 유압 차이(differential hydraulic pressure)와 심층신경망(DNN, deep neural network) 정보를 이용한 끝단 반력 학습 데이터를 활용하여 빠르고 정확한 끝단 반력 추정 기술을 제안한다. 관절에서 얻어지는 차압 정보를 활용한 끝단 반력 추정 방법은 빠른 측정 주기를 가지지만 예측 정확도가 떨어지는 단점을 가진다. 반면에, 심층신경망 모델 기반 반력 추정 기술은 높은 정확도를 가지지만 반력 계산 주기가 늦으며, 학습되지 않은 각도에 대한 정확도가 떨어질 수 있다. 두 가지 정보를 칼만필터를 이용하여 정합함으로써 빠른 측정 주기와 높은 정확도를 갖는 반력 정보를 추정하고자 하였다.

이를 위해 로봇팔 각 관절의 차압 정보와 끝단 반력 간의 상관관계를 정의하고, 차압 및 엔코더 정보를 활용해 충돌 지점을 추정하고 반력을 계산하여 사용자에게 전달하는 차압 기반 반력 추정 기술을 개발하였다. 또한, 심층신경망(DNN)을 활용하여 수중 로봇의 다양한 센서 데이터를 학습한 모델을 기반으로, 실제 작업 상황에서 얻은 센서 데이터를 로봇팔 끝단의 반력으로 계산하는 센서 데이터 기반 반력 예측 심층신경망 모델을 활용하였다.

제안된 기술은 육상 환경에서의 석고 파쇄 실험의 반력 추정 실험을 통해 검증하였다. 본 실험 시 로봇팔 끝단에 부착한 6축 F/T 센서의 반력정보와 본 논문에서 제안한 차압심층신경망 반력을 비교하여, 파쇄 작업의 주요 반력 성분인 F_x , F_z , M_y 에 대해 검증하였다.

II. 본론

1. 차압기반 로봇팔 끝단 반력 추정 연구

각 관절에서 차압센서를 통한 전압과 엔코더를 통한 관절 각도를 측정하여 로봇팔 끝단 반력을 추정할 수 있다. 이 반력 추정은 조종자가 작업 상황을 더 빠르게 인식할 수 있는 정보를 제공한다. 차압기반 로봇팔 끝단 반력 추정에 대한 제어 흐름도는 그림 3과 같다.

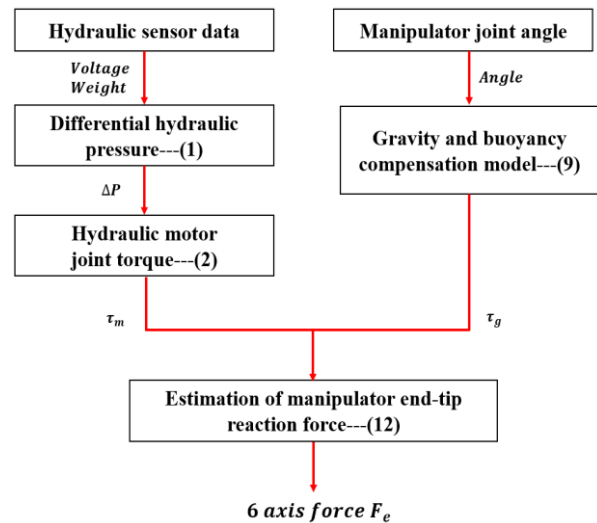


그림 3. 차압기반 로봇팔 끝단 반력 추정 흐름도.
Fig. 3. Flowchart of manipulator end-tip reaction force estimation based on differential hydraulic pressure.

먼저, 각 관절에 입력되는 유압 정보와 압력센서를 통해 얻은 전압 정보를 이용하여 각 구동기 입출력 포트 간의 압력 차이를 식 (1)과 같이 계산한다. ΔP 는 입출력 포트 간 차압, $P_{i,A}$ 는 i 번째 입력 압력, $P_{i,B}$ 는 i 번째 출력 압력, w_i 는 i 번째 구동기의 전압-압력 가중치로, 관절에 입력되는 유압과 관계가 있으며, V_i 는 i 번째 구동기의 압력센서 전압 값을 나타낸다.

$$\Delta P = (P_{i,A} - P_{i,B}) = w_i V_i \quad (1)$$

계산된 차압 정보를 이용하여 유압모터의 압력-힘 관계 식 (2)를 통해 각 관절의 토크를 계산한다. τ_m 은 차압을 이용한 유압모터의 토크, η 은 기계적 효율, N 은 모터 감속비, D_m 은 유압모터의 유효 체적 변위량을 나타낸다[4].

$$\tau_m = \frac{\eta N D_m \Delta P}{2\pi} \quad (2)$$

유압 로봇팔 각 링크의 무게와 부력에 의한 힘의 영향을 고려하여 실제 관절에 작용하는 토크를 계산한다. 엔코더를 통해 얻은 관절 각도를 이용한 회전 행렬 $A(q)$ 와 질량 중심 벡터를 계산할 비대칭 행렬(skew-symmetric matrix) $skew(\rho)$ 를 식 (3), 식 (4)로 정의한다.

$$A(q) = \begin{pmatrix} \cos(q) & \sin(q) & 0 \\ -\sin(q) & \cos(q) & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad (3)$$

$$skew(\rho) = \begin{pmatrix} 0 & -\rho_z & \rho_y \\ \rho_z & 0 & -\rho_x \\ -\rho_y & \rho_x & 0 \end{pmatrix} \quad (4)$$

식 (3)에서 정의한 회전 행렬과 관절 각도 $q_1 \sim q_6$ 를 이용하여 각각의 자세 행렬 $A_1 \sim A_6$ 을 식 (5)와 같이 계산한다. 여기서 C_{ij} 는 각 링크 사이의 변환 행렬이다. 각 관절의 위치 벡터와 질량 중심 벡터를 식 (6), 식 (7)과 같이 계산한다. r_i 는 각 관절 위치 벡터, s_{ij} 는 각 관절 간의 거리 벡터, ρ_i 는 각 관절 질량 중심 벡터, ρ_{init} 은 각 관절의 초기 질량 중심 벡터를 나타낸다.

$$\begin{aligned} A_1 &= A(q_1) \\ A_2 &= A_1 C_{12} A(q_2) \\ A_3 &= A_2 C_{23} A(q_3) \\ A_4 &= A_3 C_{34} A(q_4) \\ A_5 &= A_4 C_{45} A(q_5) \\ A_6 &= A_5 C_{56} A(q_6) \end{aligned} \quad (5)$$

$$\begin{aligned} r_1 &= r_0 + s_{01} \\ r_2 &= r_1 + s_{12} \\ r_3 &= r_2 + s_{23} \\ r_4 &= r_3 + s_{34} \\ r_5 &= r_4 + s_{45} \\ r_6 &= r_5 + s_{56} \end{aligned} \quad (6)$$

$$\rho_i = A_i + \rho_{init} \quad (i = 1, \dots, 6) \quad (7)$$

각 링크에 작용하는 중력에 의한 힘 F_i 와 부력에 의한 힘 B_i 를 통해 총 힘 Q_i 를 식 (8)과 같이 계산한 후, 앞서 정의한 비대칭 행렬과 힘 벡터를 이용하여 토크 T_{ij} 를 계산한다. 최종적으로 중력 보상을 포함한 각 관절의 총 토크 $\tau_{g,i}$ 는 식

(9)로 계산한 후, 이를 유압모터 토크에서 제외하여 중력 보상을 고려한 각 관절의 토크 τ_t 를 식 (10)과 같이 계산한다. m_i 는 각 링크의 무게, g 는 중력, ρ_w 는 물의 밀도, v_i 는 각 링크의 부피, $r_j - r_i$ 는 두 위치 벡터 간의 차이로, j 는 i 보다 이전 위치에 대한 관절 인덱스에 해당한다.

$$F_i = \begin{pmatrix} 0 \\ 0 \\ -m_i g \end{pmatrix}, B_i = \begin{pmatrix} 0 \\ 0 \\ \rho_w v_i g \end{pmatrix} \quad (8)$$

$$Q_i = F_i + B_i \quad (8)$$

$$T_{ij} = skew(r_j - r_i) Q_j \quad (9)$$

$$\tau_{g,i} = A_i^T \sum_{j \geq i} T_{ij} \quad (9)$$

$$\tau_t = \tau_m - \tau_g \quad (10)$$

차압 정보를 통해 계산한 관절 토크에서 중력 보상 모델로 보상한 유압모터의 토크 값을 이용하여, 식 (11)에 정의된 관절 자코비안 행렬 $J(q) \in \mathbb{R}^{6 \times 6}$ 과 식 (12)를 통해 로봇팔 끝단 반력을 추정할 수 있다. F_e 는 로봇팔 끝단에 발생하는 반력, $J(q)$ 는 작업물에 대해 역자코비안을 계산하여 토크-힘 사이의 관계를 매핑하는 자코비안 행렬을 나타낸다.

$$J(q) = \begin{pmatrix} \frac{\partial x}{\partial q_1} & \dots & \frac{\partial x}{\partial q_6} \\ \vdots & \ddots & \vdots \\ \frac{\partial y}{\partial q_1} & \dots & \frac{\partial y}{\partial q_6} \end{pmatrix} \quad (11)$$

$$F_e = J(q) \tau_t \quad (12)$$

최종적으로 식 (12)를 이용하여 로봇팔 끝단 반력을 추정할 수 있다. 차압 정보를 활용한 끝단 반력 추정은 높은 샘플링 속도(100~300Hz)로 가능하지만, 차압을 계산할 때 실제 관로 길이, 마찰, 작업 시 발생하는 온도 영향, 누수를 고려하기 어렵고, 중력 모델은 로봇팔의 CAD 모델을 바탕으로 설계하여 정확한 무게, 무게 중심, 관로 무게를 고려하기 어렵기 때문에 바이어스(bias)가 되거나 불확실성(uncertainty)이 높은 정보로 반력이 계산된다. 이러한 문제를 해결하기 위해 심층신경망 기반 로봇팔 끝단 반력으로 정확성을 보완하는 연구가 진행되었다.

2. 심층신경망 기반 로봇팔 끝단 반력 추정 연구

로봇팔 끝단 반력을 정밀하게 추정하기 위한 기술로 심층신경망 기반 끝단 반력 추정을 제안하였다. 광섬유 자이로(FOG, fiber optical gyro) 톨의 유량 및 압력, 관절의 차압, 작업기 부근에 설치된 6축 F/T 센서, 엔코더 및 순기구학 기반 관절 위치를 포함해 다양한 센서로부터 수집된 총 27개의 물리량을 입력 데이터로 활용하였다. 심층신경망 모델의 입력 레이어는 CNN 레이어, 시간 종속적인 특징을 학습한 RNN(LSTM) 레이어, 최종 출력 차원인 선형 레이어로 구성되어 있으며, 6축 힘을 예측하는 출력 레이어의 센서 데이터들 중 결과에 대해 민감도가 높은 정보들을 활용하여 최적화된 입력 데이터를 구성하였다. 총 12회에 걸쳐 실험한 동일한 조건의 석고 파쇄 작업 데이터를 584,682개의 파라미터와 gelu 활성화 함수로 구성된 CNN-LSTM 모델을 이용하여 학습하는 연구가 진행되었다[6].




그림 4. 심층신경망 모델 구조.

Fig. 4. Sensor data-based DNN model structure.

표 1. 6축 힘의 각 출력에 대한 민감도 높은 입력 데이터.

Table 1. Highly sensitive input data from each output of DNN.

Input	Output	Count
Tool Position: y, roll, pitch, yaw FOG: x linear acceleration, pitch Differential pressure: joint1, joint2 Hydraulic pressure	$F_x(N)$	9
Tool Position: x, z FOG: y linear acceleration, z linear acceleration, roll angular velocity, pitch angular velocity, yaw angular velocity, roll, yaw Differential pressure: joint1, joint2, joint3, joint4 Hydraulic pressure Depth	$F_z(N)$	15
Tool Position: x, y, z, roll, pitch, yaw FOG: x linear acceleration, z linear acceleration, pitch angular velocity, pitch Differential pressure: joint1, joint3 Depth	$M_y(Nm)$	13

그림 4는 심층신경망 모델 구조를 주요 반력에 대해 입력, 은닉, 출력 레이어로 나타낸 그림이다. 각 출력 데이터에 대해 민감도가 높은 입력 정보는 표 1에 나열되어 있다.

심층신경망 기반 반력 추정 방법은 센서 데이터 기반으로 학습 모델을 만들어 학습시킨 결과로 값의 발산이나 외부로부터의 간섭에 강한 견고성을 보이며, 상대적으로 정확한 반력 정보를 제공한다. 하지만 낮은 샘플링 속도(6~7Hz)로 인해 작업 간의 실시간성이 크게 저해되며 학습 데이터가 부족한 환경 및 로봇팔 자세에 따라 추정 성능이 떨어질 수 있다. 이로 인해 햅틱 피드백시 사용자가 높은 이질감을 경험할 수 있다. 이러한 문제를 해결하기 위해 높은 샘플링 속도의 차압 기반 반력을 기반으로 심층신경망 반력 정보를 보정하는 방법을 제안한다.

3. 칼만필터를 이용한 추정 정보 정합

차압 기반 끝단 반력 예측 기술과 심층신경망 기반 끝단 반력 추정 방법의 단점을 보완하여 햅틱 마스터 디바이스의 입력으로 활용하기 위해 두 정보를 칼만 필터(Kalman filter)를 활용하여 정합하였다. 차압 기반 반력 정보는 그림 9~11

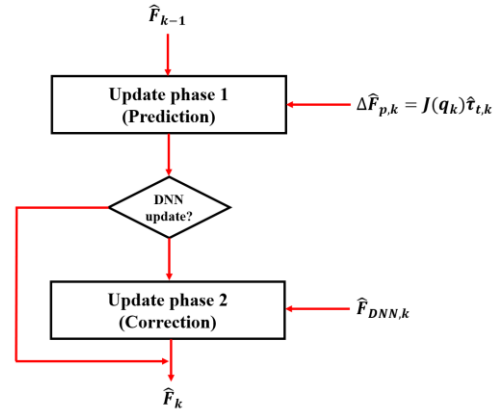


그림 5. 칼만필터를 이용한 차압-심층신경망 반력 추정 알고리즘 구성도.

Fig. 5. Diagram of the differential pressure-deep neural network force estimation algorithm using Kalman filter.

에서 보이듯이 빠른 측정 주기 대비 낮은 정확도를 가진다. 이는 이전 스텝과 현재 스텝 사이의 힘 차이를 계산하여 추세를 만들고, 이를 예측 단계 제어 입력으로 활용하였다. 또한, 상대적으로 정확도가 높은 심층신경망 기반 반력 정보를 보정 단계의 측정값으로 활용하여 칼만필터 알고리즘을 구성하였다.

칼만필터의 예측(prediction) 단계에서 식 (13)과 같이 차압 센서 데이터를 활용한 로봇팔 끝단 반력의 변화량 정보($\Delta \hat{F}_{p,k}$)로 빠르게 추정한다. $\hat{F}_{k|k-1}$ 는 k 시점에서의 예측된 상태 벡터, A 는 상태 전이 행렬로, 외부 영향을 받지 않는다고 가정하여 6×6 단위 행렬로 정의하였다.

$$\hat{F}_{k|k-1} = A \hat{F}_{k-1} + \Delta \hat{F}_{p,k} \quad (13)$$

보정(correction) 단계에서 식 (14)와 같이 심층신경망 기반의 반력 정보($\hat{F}_{DNN,k}$)가 업데이트된 경우 이를 활용하여 반력을 보정하고, 업데이트 되지 않은 경우 차압 기반 반력 정보만을 사용하여 현재 단계의 반력 정보(\hat{F}_k)를 최종적으로 출력한다. K_k 는 칼만이득, H 는 관측행렬을 나타낸다[7].

$$\hat{F}_k = \hat{F}_{k|k-1} + K_k(\hat{F}_{DNN,k} - H \hat{F}_{k|k-1}) \quad (14)$$

위 과정을 통해 높은 샘플링 속도를 유지하며 동시에 주요 반력 방향에 대해 비교적 정확한 반력 추정을 달성할 수 있고, 그림 5는 칼만필터 반력 추정 알고리즘을 도식화한 구성도이다.

차압 기반 반력의 낮은 정확도의 문제와 심층신경망 기반 반력의 낮은 샘플링 속도의 문제를 보완한 차압-심층신경망 끝단 반력 추정은 높은 샘플링 속도를 유지하는 동시에 주요 반력 방향에 대해 비교적 정확한 반력 추정을 기대할 수 있다.

III. 실험 검증

1. 실험 조건 및 방법

차압 및 심층신경망 기반 반력 추정 성능과 이 두 정보를 칼만필터를 이용하여 정합했을 때의 반력 추정 성능을 확인하기 위해 그림 6과 같이 육상 환경에서 유압 매니플레이터

가 장착된 로봇 플랫폼을 활용하였다. 글로벌 기준점 위치에 FOG 센서를, 각 조인트에는 유압 센서를, 매니플레이터 끝단에는 F/T 센서를 설치하였다. 또한, HPU (Hydraulic Power Unit) 단에서 출력되는 압력을 이용하여 튜브의 압력을 측정하고, 이를 바탕으로 각 센서에서 데이터를 수집할 수 있도록 석고 파쇄 작업 실험 환경을 구성하였다. 실험에서는 로봇팔을 파쇄면에 대해 수직(-z 방향)으로 이동시켜 약 2cm의 수직 파쇄를 수행한 후 수평(-x 방향)으로 약 20cm 이동하며 수평 파쇄를 진행하였다. 이 과정에서 각 센서의 정보와 힘 데이터를 측정하였고, 이를 3개의 반력 추정 모델과 비교하였다.

석고를 파쇄하는 동안 로봇팔 작업기 부근에 설치된 6축 F/T 센서에서는 3축 힘(F_x, F_y, F_z)과 3축 모멘트(M_x, M_y, M_z) 정보를 계측하고, 각 관절의 차압, 엔코더를 통한 각도, FOG 센서, 작업기의 유량 및 압력이 실시간으로 계측된다. 앞서 언급한 HILS 환경의 로봇팔 끝단 작업 반력 추정 기술을 위해, 실시간으로 센서에서 계측되는 데이터를 활용하여 차압 기반 반력과 심층신경망 반력을 계산하였으며, 동시에 칼만 필터를 통해 정합함으로써 최종적으로 HILS 햅틱 환경에 적용할 수 있는 알고리즘을 구성하였다.




그림 6. 수중로봇을 활용한 육상 환경에서의 석고 파쇄 작업 실험 환경.

Fig. 6. Experimental environment for gypsum crushing work in a ground environment using an underwater robot arm.



그림 7. 실시간 끝단 반력 추정을 위한 ROS 환경 구성.

Fig. 7. Configuring the ROS environment for real-time end-tip force estimation.

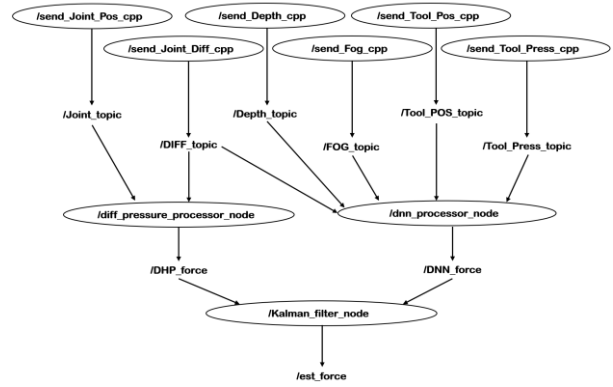


그림 8. ROS 토픽 및 노드 그래프.

Fig. 8. ROS topic and node graph.

차압기반 로봇팔 끝단 반력 추정, 심층신경망 기반 끝단 반력 추정, 칼만필터를 이용한 차압-심층신경망 반력 정합을 실시간으로 수행하기 위해 그림 7과 같이 ROS (Robot Operating System) 환경을 구성하고 실제 작업시 얻어지는 다중 센서 정보를 실시간으로 획득하고 계산할 수 있도록 환경을 구성하였다.

알고리즘의 흐름도는 아래와 같다. 먼저 석고 파쇄 작업을 수행할 때 총 27개의 관절의 차압, 엔코더 정보, FOG 센서, 작업기의 유량 및 압력정보를 한꺼번에 수집하는 환경을 구성한다. 수집된 정보를 내 각 관절에서 출력되는 차압 정보와 관절 각도를 이용하여 II. 1절에서 정의한 수식들을 실시간으로 계산하고, 이를 통해 계산된 차압 기반 끝단 반력은 약 100Hz 주기로 예측된다. 심층신경망 기반 끝단 반력 추정은 실제 수중 로봇에 적용되는 NUC13ANKi7 베어본 PC (프로세서: Intel® Core™ i7-1360P, RAM: DDR4-3200 SODIMMx2)를 활용하여, II. 2에서 구성한 학습 모델에 27개의 데이터를 입력함으로써 약 6.5Hz의 주기로 끝단 반력을 추정한다.

차압-심층신경망 정합 칼만필터는 예측 단계에서 차압 기반 반력 추정 모델을 활용하여 힘의 변화량을 예측하고, 보정단계에 심층신경망 기반 반력 계산 결과가 도출시에만 반력정보를 보정해줌으로써 최종적으로 100hz의 주기로 로봇팔 끝단 반력 정보를 출력한다.

파쇄 작업 시 y축으로의 움직임을 고정된 상태에서 수직 방향에 대해 작업을 수행하게 되고, 이에 대한 반력 추정을 확인하기 위해 세 가지 주요 반력(작업기의 진행 방향 F_x , 지면에 수직한 방향 F_z , 작업기 회전과 진행 방향에 따라 발생하는 모멘트 방향 M_y)을 분석하였다. 이를 F/T 센서의 반력 정보를 기준으로 차압-심층신경망 반력 추정 결과와 심층신경망 반력 추정 결과를 비교하여, 차압-심층신경망 반력 추정 방법을 검증하였다.

2. 차압 기반 반력 추정 결과

차압 기반 반력 추정 성능을 확인하기 위해 II. 1절을 바탕으로 추정된 F_x, F_z, M_y 를 F/T 센서 정보와 비교하였다. 그림 9, 11의 F_x, M_y 반력 비교 결과를 보면 F/T 센서의 추세를 따르는 것을 확인할 수 있다. 그림 10의 F_z 반력 비교 결과는 z축 방향에 대해 추세를 잘 따르지 못하고, 임펄스(impulse) 구간이 나타나며 반력 정확도가 매우 낮게 추종되는 것을

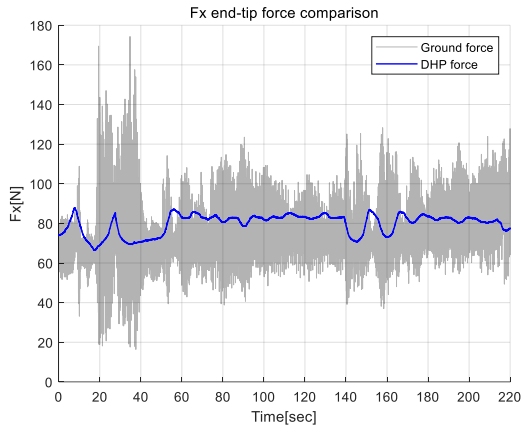


그림 9. F/T vs 차압 F_x 로봇팔 끝단 반력 비교.
Fig. 9. Comparison of F_x manipulator end-tip reaction force.




그림 10. F/T vs 차압 F_z 로봇팔 끝단 반력 비교.
Fig. 10. Comparison of F_z manipulator end-tip reaction force.




그림 11. F/T vs 차압 M_y 로봇팔 끝단 반력 비교.
Fig. 11. Comparison of M_y manipulator end-tip reaction force.

확인할 수 있다. F/T 센서 정보와 비슷한 샘플링 속도(100~300Hz)로 추정이 가능하지만, 전체적으로 F/T 센서 정보 대비 정확도가 낮은 것을 그래프를 통해 확인할 수 있다.

3. 심층신경망 기반 반력 추정 결과

심층신경망을 활용한 반력 추정은 II. 2절을 바탕으로 센서 데이터를 실시간을 입력 받아 데이터를 처리하였다. 그림 12, 14의 F_x , M_y 반력 비교 결과를 보면 F/T 센서 정보를 잘 따

르는 것을 확인할 수 있다. 그림 13의 F_z 반력 비교 결과는 정확도의 추세는 따르지만 F_x , M_y 에 비해 정확한 결과가 나타나지 않는 것을 확인할 수 있다. 차압 정보를 활용한 반력에 비해 높은 정확도를 가지지만, 낮은 샘플링 속도로 추정하는 것을 그림 15에서 확인할 수 있다.




그림 12. F/T vs DNN F_x 로봇팔 끝단 반력 비교.
Fig. 12. Comparison of F_x manipulator end-tip reaction force.

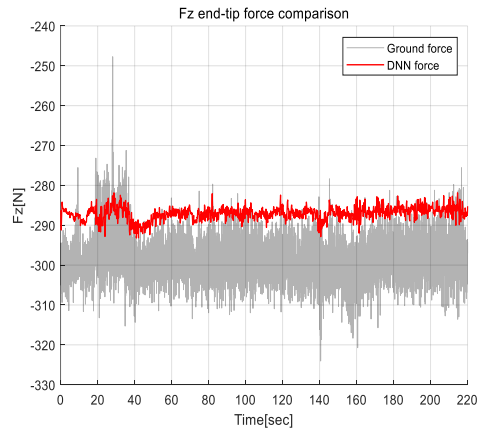


그림 13. F/T vs DNN F_z 로봇팔 끝단 반력 비교.
Fig. 13. Comparison of F_z manipulator end-tip reaction force.

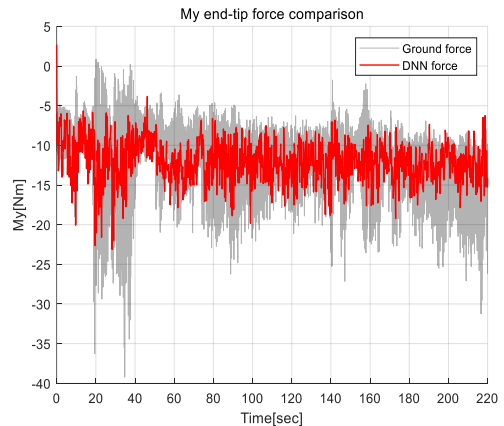


그림 14. F/T vs DNN M_y 로봇팔 끝단 반력 비교.
Fig. 14. Comparison of M_y manipulator end-tip reaction force.

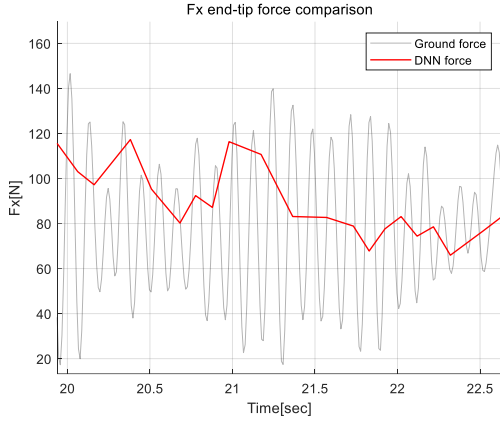


그림 15. F/T vs DNN F_x 20~23초 비교.
 Fig. 15. Comparison of F_x 20~23 seconds.

4. 차압-심층신경망 기반 반력 추정 결과

차압-심층신경망을 활용한 반력 추정은 II. 3절을 바탕으로 차압 정보와 심층신경망 반력을 실시간을 받아 계산하여 그림 16, 17, 18을 그래프로 나타내었다. 심층신경망 반력의 정확도와 유사하면서 더 높은 샘플링 속도로 F/T 센서 반력 정보를 추정하는 것을 확인할 수 있다. 차압 정보와 심층신경망 정보를 칼만필터로 정합할 때 정확도가 높은 심층신경망 반력에 더 신뢰할 수 있도록 공분산 수치를 조정하였다. 이에 따라 F_z 결과도 심층신경망 정보에 더 신뢰하여 반력을 추정하기 때문에 그림 17과 같은 결과가 나타났다. 그림 19는 차압 반력과 심층신경망 반력도 함께 비교하기 위한 그래프이다.

표 2와 표 3은 피어슨 상관계수, RMS 오차를 이용하여 F/T 센서 반력과의 유사성과 정확도를 비교한 결과이다. 차압기반 반력은 약 0.4 이하의 낮은 피어슨 상관계수와 33.1 이상의 높은 RMS 오차를 보여준다. 차압-심층신경망 반력 추정 결과에서 F_x 와 M_y 의 정확도는 심층신경망 정보 대비 약 8%, 4.5% 향상되었고, F_z 의 경우 반대로 약 1.2% 감소한 것을 확인하였다. 이는 F_z 의 차압 정보에서 이상치가 발생하고, 칼만필터 게인 값이나 중력 보상 모델의 부정확한 파라미터 정보 사용으로 인한 것으로 예상된다. 또한, RMS 오차는




그림 16. F/T vs Est F_x 로봇팔 끝단 반력 비교.
 Fig. 16. Comparison of F_x manipulator end-tip reaction force.

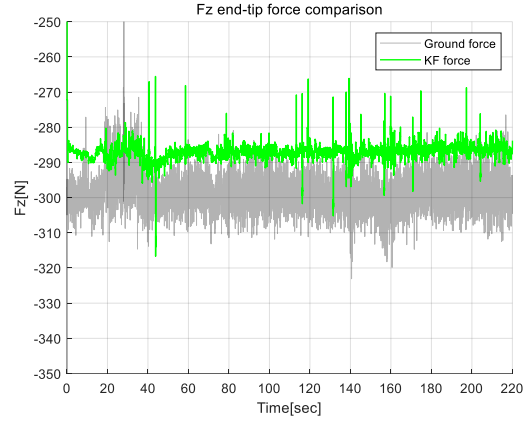


그림 17. F/T vs Est F_z 로봇팔 끝단 반력 비교.
 Fig. 17. Comparison of F_z manipulator end-tip reaction force.

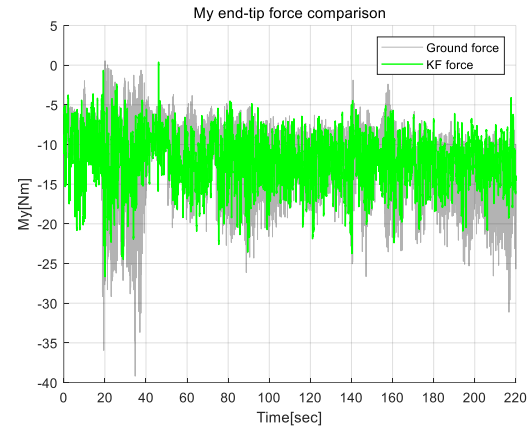


그림 18. F/T vs Est M_y 로봇팔 끝단 반력 비교.
 Fig. 18. Comparison of M_y manipulator end-tip reaction force.

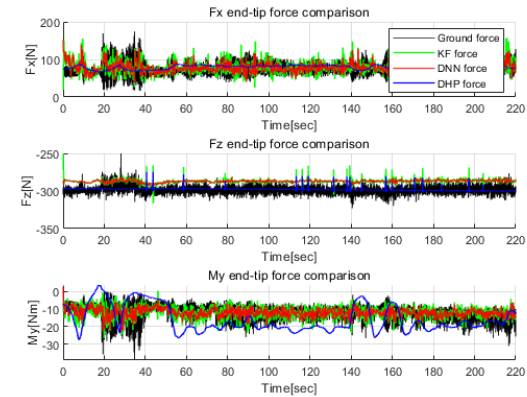


그림 19. F_x, F_z, M_y 로봇팔 끝단 반력 비교.
 Fig. 19. Comparison of F_x, F_z, M_y reaction force.

표 2. 피어슨 상관계수 비교[8].

Table 2. Pearson correlation coefficient comparison.

Pearson Correlation Coefficient			
Model name	F_x	F_z	M_y
DHP force	0.3955050	0.3878552	0.2202809
DNN force	0.5245019	0.4805692	0.5802036
EST force	0.6041261	0.4681685	0.6250089

표 3. RMS 오차 비교.

Table 3. RMS error comparison.

RMSE (Root Mean Square Error)			
Model name	F_x	F_z	M_y
DHP force	44.6926	33.11340	50.6568
DNN force	21.2303	11.57920	3.47690
EST force	16.4823	11.45670	1.89540

세 가지 주요 반력 모두 감소한 것을 확인하였다. 이로써, 본 논문에서 제안한 차압-심층신경망 기반 반력 추정이 높은 샘플링 속도와 향상된 정확도를 가지는 것을 실험을 통해 검증하였다.

IV. 결론

본 논문에서는 로봇팔 각 관절에서 측정하는 유압 차이(differential hydraulic pressure)와 심층신경망(DNN, deep neural network) 정보를 이용한 끝단 반력 학습 데이터를 활용하여 빠르고 정확한 끝단 반력을 추정하는 차압 및 심층신경망 기반 유압 로봇팔 끝단 반력 추정 기술을 제안하였다. 관절에서 얻어지는 차압 정보를 활용한 끝단 반력 추정 방법은 빠른 측정 주기를 가지지만 예측 정확도가 떨어지는 단점을 가진다. 반면에, 심층신경망 모델 기반 반력 추정 기술은 높은 정확도를 가지지만 반력 계산 주기가 늦으며, 학습되지 않은 각도에 대한 정확도가 떨어질 수 있다. 두 가지 정보를 칼만 필터를 이용하여 정합함으로써 빠른 측정 주기와 높은 정확도를 갖는 반력 정보를 추정하고자 하였다.

이를 위해 로봇팔 각 관절의 차압 정보와 끝단 반력 간의 상관관계를 정의하고, 차압 및 엔코더 정보를 활용해 충돌 지점을 추정하고 반력을 계산하여 사용자에게 전달하는 차압 기반 반력 추정 기술을 개발하였다. 또한, 심층신경망을 활용하여 수중 로봇의 다양한 센서 데이터를 학습한 모델을 기반으로, 실제 작업 상황에서 얻은 센서 데이터를 로봇팔 끝단의 반력으로 계산하는 센서 데이터 기반 반력 예측 심층신경망 모델을 활용하였다.

본 연구에서는 100Hz의 높은 샘플링 속도를 제공하는 차압 기반 반력 추정과 48% 이상의 정확도를 제공하는 심층신경망 기반 반력 추정을 칼만필터 알고리즘으로 정합하여 처리하는 연구를 제시하였다. 차압-심층신경망 기반 반력 추정은 100Hz의 속도를 유지하며, F_x , M_y 의 경우 심층신경망 보다 높은 반력 추정이 가능하여 샘플링 속도 향상을 바탕으로 보다 자연스러운 햅틱 피드백 성능을 기대할 수 있다.

추후 연구에서는 차압 모델 및 중력 보상, 심층신경망 모델 고도화 및 학습 데이터 확보를 통한 반력 추정 성능 향상과 추가적인 측정 정보(FOG, SONAR 등)를 활용하여 반력 정확도를 향상시키는 연구가 진행될 것이다. 또한, 추정된 반력 정보를 바탕으로 조종석(2축 햅틱 마스터 디바이스)에 실시간 반력 전달을 통해 햅틱 기반 매니플레이터 제어 기술 개발에 기여할 수 있을 것이다[9].

REFERENCES

- [1] J. B. Han, D. G. Park, T. K. Yeu, J. D. Jung, and Y. J. Lee, "A study on the digital twin modeling of an underwater tracked vehicle based on the multibody dynamics," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 28, no. 5, pp. 427-435, May. 2022.
doi: <http://doi.org/10.5302/J.ICROS.2022.22.0045>
- [2] T. K. Yeu, J. B. Han, Y. J. Lee, D. G. Park, S. S. Kim, and S. Hong, "Preliminary Study on development of CPOS (Cyber Physical Operation System) for underwater robot," *OCEANS 2023-Limeric*, 2023.
doi: <http://doi.org/10.1109/OCEANS2023.10244254>
- [3] J. B. Han, Y. J. Lee, D. G. Park, and T. K. Yeu, "Development of HILS for validation of cyber physical operation system of underwater robot," *The Korean Society of Mechanical Engineers*, vol. 47, no. 10, pp. 821-827, July. 2023.
doi: <http://doi.org/10.3795/KSME-A.2023.47.10.821>
- [4] M. H. Kim and S. S. Kim, "A study on a precise controller and a HILS simulator to enhance the performance of hydraulic manipulator systems," *A Dissertation for the Degree of Doctor of Philosophy in Mechatronics Engineering, Chungnam National University*, April. 2020.
- [5] D. G. Park, J. B. Han, T. K. Yeu, S. G. Cho, S. S. Kim, H. W. Kim, and Y. J. Lee, "Development of an autonomous cleaning robot with a hydraulic manipulator arm for the cleaning of niche areas of a ship hull," *Journal of Marine Science and Engineering*, no. 11, pp. 973, 2023.
doi: <http://doi.org/10.3390/jmse11050873>.
- [6] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, pp. 436-444, May. 2015.
doi: <http://doi.org/10.1038/nature14539>
- [7] Q. Li, R. Li, K. Ji, W. Dai, "Kalman filter and its application," *Institute of Electrical and Electronics Engineers*, November. 2015
doi: <http://doi.org/10.1109/ICINIS.2015.35>
- [8] J. Benesty, J. Chen, Y. Huang, and I. Cohen, *Pearson Correlation Coefficient*, Springer, vol. 2, January. 2009.
doi: http://doi.org/10.1007/978-3-642-00296-0_5
- [9] T. K. Yeu, Y. J. Lee, D. G. Park, J. B. Han, and S. S. Kim, "Development of CPOS (Cyber Physical Operation System) framework for working-class underwater unmanned robot – perspective of sensory perception," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 29, no. 11, pp. 872-879, November. 2023.
doi: <http://doi.org/10.5302/J.ICROS.2023.23.0116>



구본학

2024년 충남대학교 메카트로닉스공학과 졸업. 2024년~현재 과학기술연합대학원대학교 석사과정. 관심분야는 수중로봇 제어, 4족 보행 로봇 제어, 로봇팔 힘제어.



여 태 경

2003년 일본 쿠마모토대학 시스템정보공학부 박사. 2003년 동 대학원 객원연구원. 2004년 KIST 연수연구원. 2005년~현재 선박해양플랜트연구소 책임연구원. 관심분야는 수중로봇 및 장비 설계, CPS 기반 제어 및 운용.



김 진 균

2008년 고려대학교 토목공학 학사. 2010년 동 대학원 석사. 2014년 KAIST 박사. 2014년~2017년 한국기계연구원 선임연구원. 2017년~현재 경희대학교 부교수. 관심분야는 계산 동역학, 진동, 진동, 다물리 모델링 및 시뮬레이션.



한 중 부

2009년 충남대학교 메카트로닉스공학과 졸업. 2011년 동 대학원 석사. 2018년 동 대학원 박사. 2018년~2020년 한국로봇융합연구원 선임연구원. 2020년~현재 선박해양플랜트연구소 선임연구원. 2022년~현재 과학기술대학원대학교 조교수. 관

심분야는 다물체동역학 모델링 및 실시간 물리엔진.



이 영 준

2009년 충남대학교 메카트로닉스공학과 졸업. 2014년 동 대학원 석사. 2022년 동 대학원 박사과정. 2011년~현재 선박해양플랜트연구소 선임기술원. 관심분야는 소나영상기반 물체인식 및 항법, 해양 시스템 자율기술.



박 대 길

2011년 서울과학기술대학교 기계공학과 졸업. 2016년 포항공과대학교 기계공학과 박사. 2016년~2020년 한국로봇융합연구원 선임연구원. 2020년~현재 선박해양플랜트연구소 선임연구원. 2022년~현재 과학기술대학원대학교 부교수. 관심분

야는 수중로봇, 자율로봇기술, 환경-로봇 상호작용제어.