

인공신경망 사용 핵연료용기 파지 장치의 위치/방향 예견

김기훈, 박종범
한전전력연구원

윤지섭
한국원자력연구소

요 약

Remote nuclear cask handling device (RNCHD)는 사용후 핵연료cask의 원격 조작에 있어서 안전성과 성능을 향상을 목적으로 한다. RNCHD의 한부분인 grapple은 사용후 핵연료cask의 이동 및 수송 또는 용기뚜껑의 개폐를 위하여 cask의 벽에 대각선으로 돌출되어있는 두 개의 trunnion에 삽입되어야한다. 그러나 trunnion으로의 grapple 삽입은 용기중심과 grapple 장치 중심사이의 위치와 방향편차 때문에 어렵게된다. 인공신경망은 grapple에 설치된 광전센서를 사용하여 용기의 중심으로 부터 grapple 장치의 상대적 위치를 계측하기위해 사용된다. 인공신경망 학습은 광전센서값과 grapple의 상대적 위치와 방향사이의 함수적 관계를 추론하기 위해 수행된다. 이렇게 측정된 RNCHD의 중심위치는 grapple의 자세를 맞추기 위한 제어입력값으로 제공된다. 인공신경망 학습을 위한 데이터는 grapple 장치와 trunnion을 모사한 1/2 스케일의 실험장치를 사용함으로써 얻어진다. 학습된 인공신경망은 학습에 사용 안된 센서입력값, 즉 새로운 grapple의 위치에 대해서도 정확성을 가지고 grapple 장치의 위치와 방위를 측정할 수 있었다.

1. 소 개

원격 기술은 작업수행의 효율 향상과 편리뿐만 아니라 안전성 보장을 위해 발전되어왔다. 원자력 산업과 관련된 안전과 규제는 방사성 물질을 다루는데 있어 안전하고 신뢰도 있는 작업수행을 요구해 왔기 때문에 많은 연구자들은 사용후 핵연료(nuclear spent fuel) 조작 문제에 대한 로봇의 응용을 연구해왔다[1,2,3]. 로봇의 이용은 사용후 핵연료 cask에서 방출되는 방사선으로 부

터 작업자의 피폭을 줄일 수 있다. Remote nuclear cask handling device (RNCHD)는 cask를 원격으로 파지하여 용기(cask)의 탈염과 수송, 용기의 뚜껑을 개폐하도록 디자인 되어졌다. RNCHD를 사용함으로써 사용후 핵연료 cask의 원격 조작에 있어 안정성과 조작성능이 향상되고 또한 개발된 원격조작 기술이 일반 산업 전반에도 응용될수 있을 것 이다.

RNCHD는 그림 1에서 보여지는 바와 같이 한쌍의 grapple과 개폐용 토오크 렌치장치로 구성되어있다. 두 grapple은 용기의 벽 표면에 대각선으로 돌출된 두 개의 상위 trunnion을 파지하기 위해 trunnion쪽으로 이동한다. 네 개의 trunnion을 장착한 KSC-4형 cask는 16개의 스티드 볼트로 고정되는 뚜껑을 가지고 네 개의 사용된 PWR 연료를 내장하도록 디자인되어 있다. trunnion을 향한 grapple의 삽입을 위해서는 RNCHD의 중심을 용기중심과 trunnion의 방향에 일치하도록 맞추어야 한다. 그러나, 일반적으로 조작 정밀도가 낮은 크레인을 사용하여 RNCHD의 중심위치를 용기중심에 일치하도록 하기는 기술적으로 매우 어렵다. 더욱이, 장치가 용기의 뚜껑위에 매우 근접했을 때 원거리에 있는 조작자는 장치가 용기의 중앙에 있는지 그리고 두 개의 grapple 중심선이 정확하게 trunnion의 중심을 연결한 가상적인 선에 정렬해 있는지 알아내기는 매우 곤란할 것이다. 그러므로 RNCHD장치 중심의 위치, 방향의 보정은 용기의 trunnion에 grapple을 안전하고 충돌없이 삽입하기 위해 필요하다.




Figure 1. Schematic draw of RNCHD

위에 언급된 위치, 방향 보정의 어려움을 해결하기 위해 인공지능망은 RNCHD 중심의 위치와 방향의 편차를 용기중심의 원점에 대하여 예측한다. 각 grapple에 설치된 두 개의 광전센서로부터 얻어지는 신호는 인공지능망을 통하여 장치 중심의 편차를 실제적인 위치와 각도값으로 변

환 된다. 인공지능망 학습을 위한 학습데이터는 한쌍의 grapple와 용기의 trunnion을 모사한 1/2 스케일의 실험장치를 사용함으로써 얻어진다. 학습된 인공지능망은 학습에 사용 안된 새로운 센서값 즉 새로운 grapple의 위치에 대해서도 테스트하였다. 연구결과 인공지능망은 grapple 장치 중심의 위치와 방향편차를 정확하게 예측할 수 있다는 것을 보여준다. 이렇게 예측된 위치와 방향은 용기중심과 RNCHD 장치의 중심을 일치시키는 중심 수정의 제어입력으로 사용되어질 수 있다.

2. 인공지능망을 응용한 위치 측정

2.1 RNCHD의 위치 오차

RNCHD는 카메라를 사용하여 용기의 위치로 옮겨진다. 용기뚜껑 개폐용 토오크 렌치에 부착된 레이저 센서가 RNCHD와 용기의 뚜껑 사이의 거리를 측정하면서 용기 뚜껑을 향하여 천천히 하강한다. 주어진 거리에 도달했을 때 장치는 멈추게된다. 여기서 사용된 레이저 센서는 정확한 거리 측정이 가능하므로 grapple내의 동심원 중심의 높이와 상위 trunnions의 중심이 일치하도록 제어된다고 가정한다. 카메라를 이용한 이미지 프로세싱과 크레인 제어에 연관된 오차 개입으로 RNCHD의 중심과 장치의 방향은 용기 뚜껑위에 근접할 때 용기중심과 trunnion의 방향과는 정확하게 일치하지 않는다. 더욱이 먼 거리에 있는 조작자는 장치가 용기의 뚜껑위에 매우 근접해 있을 경우 장치 중심의 편이와 장치의 방향을 알아내는데 어려움을 겪을 것이다. RNCHD의 위치와 회전 편차는 그림 2 에서 보여지는 용기의 중심 좌표에서 벡터 \mathbf{e} 와 θ_2 로 표현될 수 있다. 벡터 \mathbf{e} 는 오차 e_x 와 e_y 의 성분으로 분리될 수 있고, θ_2 는 RNCHD의 중심축을 따라 회전 되어진 각이다.




Figure 2. Location of the RNCHD center displayed in the cask's coordinates.

2.2 광전센서

장치 양단에 설치된 한쌍의 grapple은 trunnion에 삽입하기 위한 구경이 큰 원과 삽입후 trunnion을 안정하게 파지하여 올리기 위한 작은 원을 갖고 있다. 광전센서는 그림 2에서 보여지는 바와 같이 빛을 보내고 trunnion로 부터 반사되어 오는 빛을 받도록 각 grapple에 2개씩 부착된다. 온-오프 스위치를 목적으로 개발된 이 센서들은 다른 센서에 비해 사용하기 쉽고 외부 환경에 대해서도 안정된 성능을 보이며 매우 저렴하기도 하다. 여기서는 grapple 장치의 편차를 알아내기 위해 이 센서를 간접적 측정도구로 사용한다.

2.3 인공신경망(Neural Networks)

인공신경망(NN)는 주어진 데이터[4,5,6,8]로 부터 데이터들이 표현하고 있는 모함수를 추론할 수 있기 때문에 비선형 모델링을 위해 많은 분야에서 사용되어져 왔다. NN 모델은 한 시스템을 대표하는 입력과 대응되는 출력쌍으로 구성된 학습 데이터로부터 그 시스템 내부의 함수적 관계를 추론할 수 있다. NN는 입력 각신호의 가중치와 곱하여진 값의 합을 비선형 변환하여 출력신호를 내보내는 뉴런 또는 노드로 불리는 상호연결된 단위 처리소자로 구성되어진다. 학습과정동안 하나의 입력 패턴은 NN내부의 상호연결된 뉴런을 통해 공급되어 지고 그 입력 패턴은 대응하는 출력 패턴 y' 를 생성한다. 따라서 y' 은 원하는 출력 y 에 대한 NN의 예측값이다. 각 뉴런에서는 입력된 아래층 뉴런들의 가중된 출력합이 전달함수를 통하여 출력된다. 뉴런에서의 일반적인 계산과정에 대해서는 많은 참고문에 잘 기술되어 있다.[6,7,8]. NN은 학습데이터의 반복 제시를 통해 출력신호 y' 가 y 로 수렴하도록 weight라 불리는 내부뉴런 연결의 가중치 값들을 바꿈으로써 훈련되어진다. 가중치를 조정하는 과정을 학습 또는 훈련이라 불린다. 많은 NN 학습 알고리즘이 있지만 이 논문에서는 일반적으로 사용되는 역전달 학습방법을 쓴다.

2.4 학습 데이터

인공신경망 모델의 학습과 성능 시험를 위한 데이터는 그림 2에서 도식적으로 보여지는 것처럼 grapple 장치와 KSC-4용기의 trunnion을 모사한 1/2 스케일의 실험장치를 사용함으로써 얻어진다. grapple 장치 중심위치를 다양하게 바꾸어 학습과 성능시험 데이터를 구한다. 선택된 학습 및 성능시험 데이터의 위치는 그림 3에서 용기중심 좌표의 xy평면위에 도시 되어있다. 여기서 원은 학습 데이터에 대한 위치를, 사각형은 성능시험 데이터에 대한 위치를 표현한다. 인공신경망 학습에서는 사용되지 않는 시험 데이터는 grapple 중심의 새로운 위치에 대하여 학습 완료된 인공신경망 모델의 성능을 평가하기 위한 것이다. e_x 와 e_y 로 표현되는 각 데이터 포인트에서 모의 grapple 장치는 일곱 개의 회전각 θ_z 를 가지도록 grapple 중심 좌표의 z축을 따라서 회전시킨다. 여기서 $\theta_z = -3, -2, -1, 0, 1, 2, 3$ 도(degrees)이다. 그러므로 이 실험에서 학습에 쓰이는 238개의

데이터와 성능시험에 사용되는 161개의 데이터, 즉 총 499 데이터가 얻어진다. e_x , e_y 와 θ_2 의 위치에서 trunnion으로부터 반사되는 빛을 수광하여 출력되어지는 광전센서 출력 ν_{ij} 를 얻는다. 여기서 i 는 grapple의 갯수($i=1,2$)를, j 는 각 grapple에서 센서의 갯수($j=1,2$)를 표현한다. 그러므로 인공지능망 모델링에 대한 입-출력은 입력으로써 ($\nu_{11}, \nu_{12}, \nu_{21}, \nu_{22}$)와 입력에 대응되는 위치와 방향값 즉, 출력 (e_x, e_y, θ_2)로 구성된다.

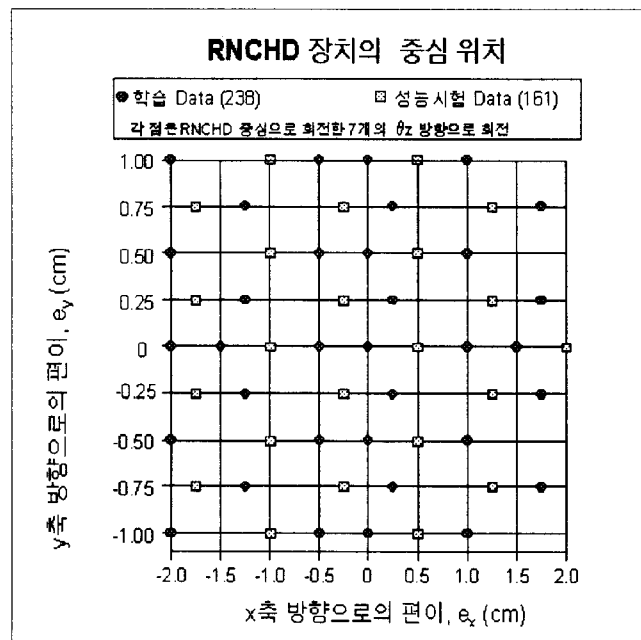


Figure 3. Positions of training and test data displayed in the cask's coordinates.

3. 인공지능망을 이용한 위치 간접측정 결과

역전달 학습 인공지능망은 grapple 장치의 위치와 방향을 계측 하기위해 사용된다. 사용되는 NN의 구조는 입력층에서 4개의 입력 뉴런을 포함하고 처음과 두번째의 은닉층에서 각각 14개와 6개의 은닉뉴런을, 출력층에서 3개의 출력 뉴런(4-14-6-3)을 갖는 4층구조로 구성되어진다. 이 구조는 시행착오(trial and error) 방법으로 선택되어졌다. NN은 238개의 학습데이터 집합에 대한 목표 함수의 값 즉 root-mean-square 값이 0.157이 될때까지 학습되어진다. 주어진 센서값에 대해 NN은 RNCHD의 위치와 방향을 e_x , e_y , θ_2 로 예측한다.

161개의 성능시험 데이터는 grapple 장치가 새로운 위치와 방향에 놓였을때 NN 모델의 위치 예측에 대한 성능을 평가하는데 사용된다. 성능시험의 결과는 Table 1에 있다.

Table 1에서 보여진 오차는 장치의 실제 위치와 NN 예측값 차이의 절대값을 나타낸다. 첨자 des 와 $pred$ 는 각각 desired와 predicted를 의미한다.

NN 모델에 의해 예측된 값에 대한 실제적 오차는 매우 작다. 95%의 신뢰구간을 가지고 NN 모델 예측의 오차는 e_x , e_y , θ_2 에 대해 각각 $[0.0714 \pm 0.1054]$, $[0.0417 \pm 0.0619]$, $[0.0769 \pm 0.1191]$ 로 나타난다. RNCHD의 중심과 용기의 중심이 일치할 때 grapple 내의 구멍과 trunnion사이의 clearance가 이 장치에서 0.5cm 임을 고려한다면 NN 예측은 정확하고 만족 할 만하다. 예를들어 θ_2 예측에서 가장 큰 오차인 0.307도(degrees)을 변위로 환산하면 0.19cm이고 이것은 장치의 clearance 보다 충분히 작다.

	$ e_{x_{dn}} - e_{x_{pred}} $	$ e_{y_{dn}} - e_{y_{pred}} $	$ e_{\theta_{dn}} - e_{\theta_{pred}} $
mean	0.0714 cm	0.0417 cm	0.0769 degrees
std. deviation	0.0538	0.0316	0.0608
max. error	0.253 cm	0.134 cm	0.307 degrees

Table 1. Performance test of NN model with the 161 test data.

4. 결 론

이 작업에서 RNCHD의 중심위치 예측은 거리와 회전각등등 같은 직접적인 측정없이 주어진 광전센서값을 입력으로한 인공신경망을 사용하여 성공적으로 수행할 수 있었다. 이 연구에서 개발된 기술은 간접적인 방법으로 위치와 방향예측 또는 측정을 필요로 하는 다른 분야에도 적용될 수 있다.

참고문헌

1. J. M. Griesmeyer, W. D. Drotning, A. K. Morimoto, and P.C. Bennett, "CAsk System Design Guidance For Robotic Handling," Intelligent Machine System and Transportation Systems Development, Sandia National Laboratories, Albuquerque, New Mexico, SAND-89-2444.
2. P.Gautier. "Optimising an Automated Stud Handling Machine for Vessel Headers," Nuclear Engineering International, 38 (469), 46-48, August. 1993.
3. D. R. Strip, "Robotic Handling of Spent Fuel Shipping Casks: Preliminary Assessment of Cask Design Impacts and Technology Development Needs, Intelligent Machines Division. Sandia National Laboratory, Albuquerque, New Mexico. SAND-86-2470.
4. G. Cybenko, "Approximation by Superposition of a Sigmoidal Function." Mathematics of Control. Signals, and System. vol. 2, pp. 303-31, 1989.
5. D. H. Wolpert. "A Mathematical Theory of Generalization: Part I and Part II." Complex Systems. vol. 4. pp. 151-249. 1990.
6. V.Kurkova. "Kolmogorov's Theorem and Multilayer Neural Networks." Neural Networks. vol. 5. pp. 501-506. 1992.
7. R. Hecht-Nielsen. Neurocomputing, Addison-Wesley, Reading, MA, 1990.
8. A. Lapades and R. Farber, Nonlinear Signal Processing using Neural Networks: Prediction and System Modeling. Los Alamos National Laboratory Technical Report LA-UR-87-2662. 1987.