

# 실험계획법과 신경망을 이용한 웨이퍼 이송 핸들러의 설계 방법 Design Process for Wafer Handling Robot using DOE and Neural Network

\*전혜영<sup>1</sup>, 양학진<sup>1</sup>, #김성근<sup>2</sup>

\*H. Y. Jeon<sup>1</sup>, H. J. Yang<sup>1</sup>, #S. K. Kim(kimskun@hoseo.edu)<sup>2</sup>

<sup>1</sup> 호서대학교 기계공학과 대학원, <sup>2</sup> 호서대학교 자동차공학과

Key words : DOE, Neural Network, Design Sensitivity Analysis, Wafer Handling Robot, Bending Stiffness

## 1. 서론

웨이퍼 핸들링 공정에서는 생산성 향상을 위하여 많은 종류의 로봇들이 고속으로 동작된다. 특히 웨이퍼 핸들링 중, 이송과 반송 및 정지 시에 고속 동작으로 인하여 이송 장치에 불필요한 잔류 진동 및 사이클링 타임 증가, 로봇 수명 단축등 문제가 야기 된다<sup>1)</sup>. 핸들링 유니트의 굽힘 강성을 높임으로써 변형이 적어지고, 잔류진동과 사이클링 타임이 감소되며 동시에 로봇의 수명이 증가하게 된다. 그러나, 굽힘 강성을 높이기 위해 모든 설계 변수를 고려해서 재설계 및 해석을 하는 것은 시간과 비용 면에서 효율적이지 못하므로 효과적인 재설계 방법이 필수불가결하다. 이 중 확률론적인 절차가 내재되어 있어 불확실성을 다룰 수 있는 실험계획법과 대량의 복잡한 비선형적인 관계도 연관 관계를 자체 조직화 할 수 있는 병렬 연산 모델인 신경망의 적용에 대한 연구가 이루어져 왔다<sup>2)</sup>.

본 연구에서는 굽힘 강성 즉, 총 변형량에 영향을 미치는 주요 설계 변수들을 실험계획법을 통하여 민감도 분석을 행하고, 선정이 된 설계 변수들을 사용하여 총 변형량의 예측을 위해 신경 회로망을 도입하였다. 그로 인하여 실제 값과 신경회로망 값이 거의 일치함을 검증하였으며, 범위 안에 있는 모든 변수들 중, 총 변형량의 최소화를 목적으로 최적 설계 변수를 추정하는 설계 방법을 개발하였다. 해석결과를 예측할 수 있어 전체적인 재설계에 소요되는 시간과 비용을 절감 할 수 있으므로 보다 효과적인 설계 방법에 기여할 것으로 기대된다.

## 2. 웨이퍼 이송 핸들러의 유한요소 해석

Fig. 1의 (a)는 웨이퍼 이송로봇의 결합체이며, 웨이퍼 이송 핸들러는 (b)와 같이 슬라이딩 결합부분이 벨트를 따라 움직이며, 주행 후 멈췄을 때 굽힘 강성의 변화가 가장 크게 나타난다.<sup>1)</sup> 본 연구는 유한요소해석을 위하여 (c)부분만 해석 하였고 물성치는 해당 재질의 대표적인 공개 물성치를 사용하였다<sup>3)</sup>. 멈춤 동작을 구사하기 위해 작용·반작용의 원리를 이용하여 힘을 주었는데, 그 크기는 핸들러 무게 1.99kg, 실험가속도<sup>1)</sup> 14.237m/s<sup>2</sup>에 따라 힘을 28.474N(분포하중)으로 설정하여 주었으며 (d), Fix부분을 설정하고, Z축의 방향 변형을 Free로 하여 이동

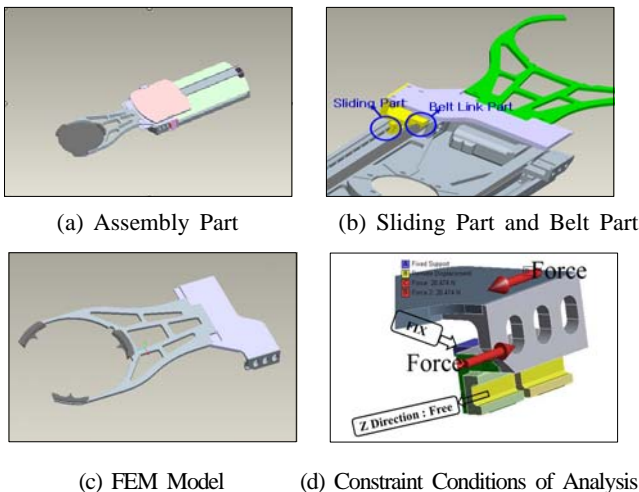


Fig. 1 Wafer Handling Robot

변형을 가정하였다. 총 변형량은 40.811 $\mu$ m이며, Fig. 2와 같다.




Fig. 2 Total Deformation of Wafer Handler

## 3. 분산분석을 이용한 설계 변수 결정 및 민감도 해석

총 변형량에 영향을 미칠 것으로 예상되는 부분 중, 비교적 간섭이나 설계 변경에 자유로운 웨이퍼 핸들링 지지부에 대해 설계변수를 설정하였다. 효과적인 설계를 위하여 강성에 영향을 미칠 것으로 예상되는 변수 7개를 설계변수로 선택하였으며 Fig. 3에 도시하였다.




Fig. 3 Design Variables for Supporting Part of Wafer Handler

총 변형량에 대한 영향도를 알기 위하여 각 설계 변수의 제한 조건 내에서 분산분석을 실시하여 그 영향도를 조사 하였다. 각 인자의 수준은 Table 1에 나타내었다. 분산분석에 사용한 직교배열표는 설계변수의 개수를 고려하여  $L_{18}(2^7 \times 3^6)$ 를 이용하였으며 해석의 단순화를 위하여 설계변수들의 교호작용은 고려하지 않았다. 설계변수 SP는 점선으로 도식한 것처럼 재료에 대한 보강의 유·무를 나타낸다. 특성치는 총 변형량으로 설정하였고, Table 2는 유한요소 해석 후 결과에 대한 설계변수의 영향을 평가하기 위해 분산분석을 실시한 결과이며 P값에 대한 유의수준은 90%인 0.1로 평가하였다. 분산분석 시 SP는 수치로 표현하여 P값을 표현하도록 하였다. P값에 의하여 설계변수 SP, A, D, T는 특성치에 유의한 변수로 나타났다. 이 결과를 기반으로 설계변수 수정 시에는 SP, A, D, T만을 고려하여 설계변경을 하도록 하였다.

Table 1 Level of Factor

Factor	Level	1	2	3
SP		Yes(144)	No(64)	-
A		180	220	260
B		92	106	120
C		67	77	87
D		104	124	144
E		70	85	92
T		7	8	9

Table 2 Analysis of Variance for Total Deformation

Source	DF	Seq SS	Adj SS	Adj MS	F	P
SP	1	4.257	4.257	4.257	5.56	0.078
A	2	594.074	594.074	297.037	387.59	0.000
B	2	2.135	2.135	1.068	1.39	0.347
C	2	1.997	1.997	0.999	1.300	0.367
D	2	17.696	17.696	8.848	11.55	0.022
E	2	4.330	4.330	2.165	2.83	0.172
T	2	78.310	78.310	39.155	51.09	0.001
Error	4	3.065	3.065	0.766		
Total	17	705.865				

4. 신경망 모델링

신경망에 기초를 둔 웨이퍼 핸들러 모델을 설계하기 위해서는 민감도해석에서 도출된 설계 변수들을 입력층으로 설정하고, 총 변형량을 출력층 유니트로 신경망을 설계 하였으며 그 구조를 Fig. 4에 나타내었다.




Fig. 4 Structure of a Neural Network Model

은닉층은 1 Layer에 8개, 12개, 15개의 뉴런개수로 최적의 구조를 찾으려 했고 각 층의 활성화 함수로는 Sigmoid 함수를 사용하였다. 각 층은 입력과 가중치를 곱해서 더한 결과를 하나의 활성화 함수에 적용하는 방식으로 계산되는 처리요소는 식(1),(2)와 같다.

$$S = \sum_{i=1}^n x_i w_i + b_i \tag{1}$$

$$f(x) = \frac{1}{1 + e^{(-\beta x)}} \tag{2}$$

여기서 S는 은닉층 출력,  $x_i$ 는 입력층 값,  $w_i$ 는 가중치,  $b_i$ 는 임계값, f는 활성화함수, 그리고  $\beta$ 는 1이다.

신경망을 학습시키는데 필요한 데이터는 민감도 분석 시 사용했던 각 수준의 범위 안에서 학습 데이터를 생성하였다.

이번 연구에서는 학습률을 0.1로 정하였으며 4개의 입력층과 시스템에 따른 은닉층의 개수 그리고 1개의 출력층으로 신경회로망을 구성하여 시뮬레이션 하였다. 은닉층에서 각각 8개, 12개, 15개의 뉴런개수를 설정하였을 경우의 비교 결과를 Fig. 5에 나타내었다. 실험한 3개의 경우는 모두 오차범위 5% 이하였지만, Fig. 5에서와 같이 뉴런 개수가 8개의 경우에서 MSE(Mean Square Error)의 값이 가장 낮고, 정확도가 99.3% 이상이고, 동일 시간동안 수렴 속도가 가장 빠르므로 이와 같은 조건으로 신경망 구조를 설정하는 것이 바람직하다고 판단된다.

Fig. 6은 신경 회로망에 의해 학습된 예측값과 웨이퍼 핸들링 장치의 지지부의 총 변형량의 유한요소해석 값을 비교하여 나타낸 것이다. 몇 개의 포인트를 제외하고는 예측 값과 실제 값이 대부분 비슷하였다.

Table 3은 검증데이터 12개의 결과값을 나타낸다. 뉴런수를 8개로 사용한 결과 값과 실제 해석한 값을 비교하여 유사하다는 것을 검증하였다.

50개의 학습데이터와 12개의 검증데이터 중 총 변형량 값이 가장 작은 32.60 $\mu$ m값에 따른 설계 변수인 SP=64mm, A = 188mm, D = 100mm, T = 9mm을 사용함으로써 설계변경전의 총 변형량인 40.811mm에 비해 20.12%의 감소를 보였기에 최적의 굽힘 강성의 성능을 유지하기 위한 설계 방법을 구성할 수 있었다.




Fig. 5 Relation between MSE and Number of Neurons in Hidden Layer




Fig. 6 Comparison between Predicted Value and Real Experimental Value

Table 3. Comparison of Prediction Values with Experimental Measurement for Test Sets

Trial No.	Parameters(mm)				Total Deformation( $\mu$ m)	
	SP	A	D	T	Real value	Neural
1	144	206	134	8.5	37.64	37.50
2	144	189	145	9	34.69	34.61
3	64	208	143	7	42.42	42.27
4	64	209	104	6.5	42.43	41.60
5	144	191	109	6	40.14	39.98
6	64	211	118	6.5	43.31	42.76
7	64	212	139	7.5	40.67	41.42
8	64	220	140	8	41.82	41.54
9	144	193	117	8	35.66	35.57
10	144	215	123	7	42.15	42.07
11	64	216	113	7.5	40.48	40.61
12	64	217	141	8	41.33	41.13

5. 결론

웨이퍼 핸들러의 최적의 굽힘 강성을 유지하도록 설계하기 위해 다수의 설계인자 중 총 변위 량의 특성치에 부합 할 수 있도록 민감도해석을 통해 설계인자를 선택하였으며, 신경회로망으로 예측모델을 구성하여 해석의 과정을 축소하며 설계 과정의 비용과 시간을 절감할 수 있는 설계 방법을 구성하였다.

참고문헌

1. S. K. KIM, "Optimization of Cycle Time and Reduction of Residual Vibration in Wafer Positioning Control," KDNS report, Hoseo University, 2005
2. D. H. KIM, D. J. KIM, H. K. KIM, B. M. KIM AND J. C. CHOI, "Process Design of a Hot Forged Product Using the Neural Network and the Statistical Design of Experiments," KSPE, Vol.15, NO.9, pp. 15~24, 1998
3. <http://www.matweb.com/>
4. D. W. Lee, S. J. Lee, "A Study on Optimal Design for Vertical Roller Mill using DOE and Neural Network," KSME, PP. 1130~1135, 2004