

신경망과 커널 회귀를 이용한 웨이퍼 이송 핸들러 설계 Design of Wafer Handling Robot using Kernel Regression and Neural Network

*양학진¹, #김성근²

*H.J. Yang¹, #S.K. Kim(kimskun@hoseo.edu)²

¹ 호서대학교 대학원, ² 호서대학교 자동차공학과

Key words : Wafer Handling, Design of Experiments, Neural Network, Kernel Regression

1. 서론

국내 반도체 얼라인먼트 제조 장비 산업의 핵심 기반기술 요소로서 초정밀 및 쾌속 이송이 가능한 전용로봇이 등장하게 되었다. 그러나 이송과 반송 및 정지 시에 고속 동작으로 인하여 이송 장치에 불필요한 잔류 진동 및 사이클링 타임 증가, 로봇 수명 단축등 문제가 야기 된다¹⁾. 이러한 문제는 굽힘 강성을 높임으로써 변형이 적어지고, 잔류진동과 사이클링 타임이 감소되며 동시에 로봇의 수명이 증가하게 된다. 하지만, 굽힘 강성을 높이기 위해 모든 설계 변수를 고려해서 재설계 및 해석을 하는 것은 시간과 비용 면에서 효율적이지 못하므로 효과적인 재설계 방법이 필수불가결 하다. 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 망과 커널 회귀를 도입하여 해석값과 비교함으로써 커널회귀의 우수성을 검증하였다. 또한, 총 변형량의 최소화를 목적으로 최적 설계 변수를 추정하는 설계 방법을 개발하였다. 해석결과의 예측을 통해 전체적인 재설계에 소요되는 시간과 비용을 축소할 수 있는 웨이퍼 핸들링 지지부 설계 절차를 구성하였다.

3. 설계 변수 선정

총 변형량에 영향력이 있는 웨이퍼 핸들링 지지부에 대하여, 강성에 영향력이 있는 변수 7개를 후보 설계변수로 선택하였으며, 이러한 후보 변수의 제한 조건내에서 분산분석을 실시하여 설계변수를 선정하였다.

Table 2. Level of Factor

Level Factor	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

각 인자의 수준은 Table 2에 나타내었다. 분산분석에 사용된 직교배열표는 설계변수의 개수를 고려하여 $L_{18}(2^1 \times 3^6)$ 를 이용하였으며 해석의 단순화를 위하여 설계변수들의 교호작용은 고려하지 않았으며, 설계변수 SP는 재료에 대한 보강의 유·무를 나타낸다. 특성치는 총 변형량으로 설정하였고, Table 3는 유한 요소 해석 후 결과에 대한 설계변수의 영향을 평가하기 위해 분산분석을 실시한 결과이며 P값에 대한 유의수준은 95%인 0.05로 평가하였다. 분산분석 시 SP는 수치로 표현하여 P값을 표현하도록 하였으며, P값에 의한 후보 설계변수 SP, A, D, T는 특성치에 유의한 변수로 나타났다. 이 결과를 기반으로 SP, A, D, T만을 설계변수로 선정하고 설계변경을 하도록 하였다.

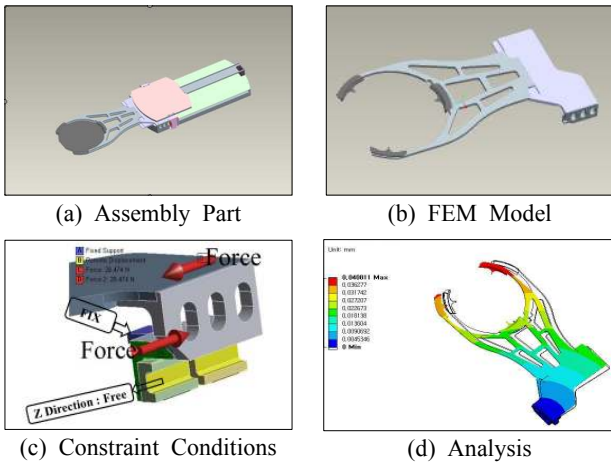


Fig. 1 Wafer Handling Robot and Support

Table 1. The Material Property for Analysis

Material	Density (kg/mm ³)	Young's Modulus (GPa)	Poisson's Ratio
SM45C	7.86112E-06	205	0.290
PEEK	1.183E-06	2.7	1.300
AL6061	2.6988E-06	68.9	0.330

2. 웨이퍼 이송 핸들러의 유한 요소 해석

Fig. 1의 (a)는 웨이퍼 이송로봇의 결합체이며, 본 연구는 유한요소해석을 위하여 (b)부분만 해석 하였으며, 물성치는 Table 1에서처럼 해당 재질에 대한 보편화된 물성치를 사용하였다³⁾. 멈춤 동작을 구사하기 위한 힘은, 핸들러 무게 1.99kg, 실험가속도¹⁾ 14.237m/s²에 따라 힘을 28.474N(분포하중)으로 설정하였으며 (c)와 같이 고정부 및 Z축 방향 변형(= Free)로 하였다. 초기 해석에 대한 총 변형량(Total Deformation, TD)은 40.811μm이로서, (d)와 같다.

Table 3. 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 지지부 모델을 설계하기 위해서는 선정된 설계 변수들을 입력층(SP, A, D, T)으로 설정하고, 총 변형량을 출력층으로 하는 구조로 설계하였다(Fig. 2). 은닉층은 단층으로 n개의 뉴런 개수(n = 8, 12, 15)를 갖고 있으며, 활성화 함수는 Sigmoid 함수를 사용하였다.

신경망을 학습시키는데 필요한 데이터는 민감도 분석시 사용했던 각 수준의 범위 안에서 학습 데이터를 생성하였으며, 각 층은 입력과 가중치를 곱해서 더한 결과를 하나의 활성화 함수에 적용하는 방식(식(1))으로 계산하였다.




Fig. 2 Structure of the Neural Network Model

$$S = \sum_{i=1}^n x_i w_i + b_i \quad (1)$$

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

여기서 S 는 은닉층 출력, x_i 는 입력층 값, w_i 는 가중치, b_i 는 바이어스, f 는 활성화함수, 그리고 β 는 임계치(=1)이다.

학습률을 0.1로 정하고, 신경회로망을 시뮬레이션한 결과 ($n=8, 12, 15$), 모두 시뮬레이션의 오차범위 5% 이하였으며 (Fig. 3), 뉴런개수가 8개일 때 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. 4는 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.




Fig. 3 Relation between MSE and Number of Neurons in Hidden Layer




Fig. 4 Comparison between Predicted Value and Real Experimental Value

5. 커널 회귀

커널 회귀에 기초를 둔 웨이퍼 핸들러 지지부 모델을 설계하기 위해서는 선정된 설계 변수 및 총변형량에 대한 표본 데이터 쌍(SP, A, D, T, TD)을 갖고, 함수의 근사치를 구하고자 할 때, 입력 데이터와의 유클리디안 거리(Euclidean Distance)를 계산하여 최소 에러(E_{\min})를 찾는다(Fig. 5).

이러한 근사치 함수(\hat{y})는 식(2)와 같이 표현할 수 있다.

$$\hat{y}(x) = \frac{\sum_{i=1}^n \left[\frac{1}{\sqrt{2\pi h^2}} e^{-\sqrt{(x_i-x)^2}/2h^2} y_i \right]}{\sum_{i=1}^n \frac{1}{\sqrt{2\pi h^2}} e^{-\sqrt{(x_i-x)^2}/2h^2}} \quad (2)$$

여기서, x_i, y_i 는 표본 데이터의 입력층, x 는 검증 데이터의 입력층, h 는 커널의 폭(Band Width)이다. 그리고 유클리디안 거리가 작을수록 에러가 작다는 것을 의미하는 데, 가우시안 커브에서는 상대적으로 더 높은 값을 부여하게 된다.

Fig. 6은 커널 회귀를 이용하여 MSE가 가장 낮은 h 를 찾는 시뮬레이션 결과이며, $h=0.14$ 일 때 가장 낮다.




Fig. 5 Structure of the Kernel Regression Model




Fig. 6 Comparison between Bandwidth of the Kernel Regression ($h = 0.08, 0.11, 0.14, \dots, 0.23$)

Table 3. Comparison of the Kernel Regression, Neural Network and the Experimental Measurement for Test Sets

Trial No.	Parameters(mm)				Total Deformation(μm)		
	SP	A	D	T	Analysis	Neural	Kernel
1	144	206	134	8.5	37.640	37.500	37.245
2	144	189	145	9	34.688	34.605	34.695
3	64	208	143	7	42.416	42.274	42.710
4	64	209	104	6.5	42.233	41.602	42.252
5	144	191	109	6	40.137	39.975	40.014
6	64	211	118	6.5	43.306	42.762	43.178
7	64	212	139	7.5	40.668	41.417	40.715
8	64	220	140	8	41.816	41.544	41.236
9	144	193	117	8	35.657	35.567	35.562
10	144	215	123	7	42.147	42.067	42.006
11	64	216	113	7.5	40.477	40.606	40.126
12	64	217	141	8	41.325	41.131	40.971

6. 결론

웨이퍼 핸들러 지지부의 최적의 굽힘 강성을 유지하도록 민감도 해석을 통해 설계인자를 선택하여 해석 과정을 축소시킬 수 있는 예측 모델의 인자를 구성하였다. 예측 모델의 일반성과 정확도를 개선하기 위하여 신경회로망 및 커널 함수로 예측 모델을 구성하여 해석값과 비교하였다.

웨이퍼 핸들러의 지지부 형상에 대한 예측 모델은 Table 3.에서처럼 신경회로망보다 커널 함수가 우수하다는 것을 보여 주었다. 커널 회귀의 인자에 대한 최적 선택은 최소 오차를 위해 선택되었으나, 모델의 일반성을 증대시키기 위한 후속 연구가 필요한 것으로 판단된다.

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, 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
5. J. O., Ramsay, "Kernel Smoothing Approaches to Nonparametric Item Characteristic Curve Estimation", PSYCHOMETRIKA, Vol.56, NO.4, pp.611-630, 1991.