

서포트벡터머신과 신경망을 이용한 웨이퍼 이송 핸들러 설계 검증

Verification of Wafer Handler Design Using Support Vector Machines and Neural Network

*양학진¹, #김성근²

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

¹호서대학교 대학원, ²호서대학교 자동차공학과

Key words : Wafer Handling, Neural Network, Support Vector Machines

1. 서론

웨이퍼 핸들링의 이송과 반송 및 정지 시에 고속 동작으로 인하여 잔류 진동 및 사이클링 타임 증가, 로봇 수명 단축등 문제가 야기 된다¹⁾. 굽힘 강성을 최적으로 설계함으로써 사이클링 타임이 감소되며 동시에 로봇의 수명이 증가하게 된다. 하지만, 굽힘 강성을 높이기 위해 모든 설계 변수를 고려해서 재설계 및 해석을 하는 것은 효율적이지 못하므로 효과적인 재설계 방법이 필요하다. 본 연구에서는 커널 회귀를 사용했던 연구 결과²⁾를 바탕으로 더욱 정확한 재설계 모델을 구축하기 위하여 서포트 벡터 머신(SVM, Support Vector Machine)을 사용한 회귀모델을 구축하여 신경회로망에 의한 재설계 모델과의 비교를 시도하였다.


2. 웨이퍼 이송 핸들러의 유한 요소 해석

이송 핸들러는 Fig. 1의 (a)와 같은 웨이퍼 이송 로봇의 결합체이며, 본 연구는 유한요소해석을 위하여 (b)부분만 해석 하였다¹⁾. 총 변형량에 영향력이 있는 웨이퍼 핸들링 지지부에 대하여, 강성에 영향력이 있는 변수들을 후보 설계변수로 선택 하였으며, 이러한 후보 변수의 제한 조건 내에서 분산분석을 실시하여 설계변수를 선정하였다.

설계변수 SP는 재료에 대한 보강의 유·무를 나타낸다. 특성치는 총 변형량으로 설정하였다. 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 설계변경 절차를 구축하도록 하였다.

3. 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 n 개의 뉴런 개수 ($n = 8, 12, 15$)를 갖는다.



(a) FEM Model (b) Constraint Conditions
Fig. 1 Wafer Handling Robot and Support

Table 1. 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





Fig. 2 Structure of the Neural Network Model
학습률을 0.1로 정하고, 신경회로망을 시뮬레

이선한 결과(n=8, 12, 15), 모두 시뮬레이션의 오차범위 5% 이하였다. Fig. 3는 신경 회로망에 의해 학습된 예측값과 웨이퍼 핸들링 장치의 지지부의 총 변형량의 유한요소해석 값을 비교하여 나타낸 것이다. 몇 개의 포인트를 제외하고는 예측값과 실제 값이 대부분 유사하였다.



Fig. 3 Comparison between Predicted Value and Real Experimental Value

4. 서포트 벡터머신

서포트 벡터 머신 회귀 모델(SVM Regression)에 기초를 둔 웨이퍼 핸들러 지지부 모델을 설계하기 위해서는 선정된 설계 변수 및 총변형량에 대한 표본 데이터 쌍(SP, A, D, T, TD)을 사용하여 회귀 모델을 구성하였다.

최적 회귀모델 $\hat{f}^*(\bar{x}) = \bar{w}^* \cdot \bar{x} - b^*$ 을 구하기 위한 최적화 모델은 다음과 같이 구성된다.

$$\min_{\bar{w}, b, \xi, \bar{\xi}} \Phi(\bar{w}, b, \xi, \bar{\xi}) = \quad (1)$$

$$\begin{aligned} & \min_{\bar{w}, b, \xi, \bar{\xi}} \frac{1}{2} \bar{w} \cdot \bar{w} + C \sum_{i=1}^l (\xi_i + \bar{\xi}_i') \\ & y_i - \hat{f}(\bar{X}_i) \leq \xi_i + \epsilon \\ & \hat{f}(\bar{X}_i) - y_i \leq \bar{\xi}_i' + \epsilon \\ & 0 \leq \xi_i, \bar{\xi}_i' \end{aligned} \quad (2)$$

$$\text{for } i = 1, \dots, l \quad \hat{f}(\bar{x}) = \bar{w} \cdot \bar{x} - b$$

Lagrangian 최적모델은 구속조건을 포함하여 다음과 같이 구성된다.

$$\max_{\bar{\alpha}, \bar{\alpha}', \bar{\beta}} \min_{\bar{w}, b, \xi, \bar{\xi}} L(\bar{\alpha}, \bar{\alpha}', \bar{\beta}, \bar{w}, b, \xi, \bar{\xi}') \quad (3)$$

$$\begin{aligned} & = \max_{\bar{\alpha}, \bar{\alpha}', \bar{\beta}} \min_{\bar{w}, b, \xi, \bar{\xi}} \left(\frac{1}{2} \bar{w} \cdot \bar{w} + C \sum_{i=1}^l (\bar{\xi} + \bar{\xi}') \right. \\ & \quad - \sum_{i=1}^l \alpha_i (\xi_i + \epsilon - y_i + \hat{f}(\bar{x}_i)) \\ & \quad - \sum_{i=1}^l \alpha_i' (\bar{\xi}_i' + \epsilon - \hat{f}(\bar{x}_i) + y_i) \\ & \quad \left. - \sum_{i=1}^l \beta_i \xi_i - \sum_{i=1}^l \beta_i' \bar{\xi}_i' \right) \\ & \text{with constraints, } \alpha_i, \alpha_i', \beta_i, \beta_i' \geq 0 \end{aligned} \quad (4)$$

또한, Dual 최적화 모델은 식 5)과 같이 정해지며, 최적 SVM 회귀 모델은 식 6)을 사용하여 구성된다.

$$\max_{\bar{\alpha}, \bar{\alpha}'} \Phi(\bar{\alpha}, \bar{\alpha}') = \quad (5)$$

$$\begin{aligned} & \max_{\bar{\alpha}, \bar{\alpha}'} \left(-\frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i - \alpha_i') (\alpha_j - \alpha_j') \bar{x}_i \cdot \bar{x}_j \right. \\ & \quad \left. + \sum_{i=1}^l y_i (\alpha_i - \alpha_i') - \epsilon \sum_{i=1}^l (\alpha_i + \alpha_i') \right) \end{aligned}$$

$$\hat{f}^*(\bar{x}) = \bar{w}^* \cdot \bar{x} - b^* \quad (6)$$

$$\begin{aligned} & = \sum_{i=1}^l (\alpha_i^* - \alpha_i'^*) \bar{x} \cdot \bar{x} \\ & \quad - \frac{1}{l} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i^* - \alpha_i'^*) \bar{x} \cdot \bar{x}_j - y_j \end{aligned}$$

신경회로망과 서포트벡터머신을 사용한 최적 모델의 구축은 Table 2.에 요약되었다. 다항식 2차의 커널을 사용한 SVM 회귀 모델을 적용하였다.

Table 2. Comparison of the SVM, Neural Network and the Experimental Measurement for Test Sets

Trial No.	Parameters(mm)				Total Deformation(μm)		
	SP	A	D	T	Analysis	Neural	SVM
1	144	206	134	8.5	37.640	37.500	37.767
2	144	189	145	9	34.688	34.605	32.920
3	64	208	143	7	42.416	42.274	43.825
4	64	209	104	6.5	42.233	41.602	39.699
5	144	191	109	6	40.137	39.975	39.198
6	64	211	118	6.5	43.306	42.762	41.250
7	64	212	139	7.5	40.668	41.417	42.890
8	64	220	140	8	41.816	41.544	43.881
9	144	193	117	8	35.657	35.567	35.783
10	144	215	123	7	42.147	42.067	43.065
11	64	216	113	7.5	40.477	40.606	40.331
12	64	217	141	8	41.325	41.131	43.224

6. 결론

웨이퍼 핸들러 지지부의 최적의 굽힘 강성을 유지하도록 민감도해석을 통해 설계인자를 선택하여 해석 과정을 축소시킬 수 있는 예측 모델의 인자를 구성하였다. 예측 모델의 일반성과 정확도를 개선하기 위하여 신경회로망 및 서포트벡터머신으로 예측 모델을 구성하여 해석값과 비교하여 재설계 모델을 구축하였다.

참고문헌

1. S. K. Kim, "Optimization of Cycle Time and Reduction of Residual Vibration in Wafer Positioning Control", KDNS report, Hoseo University, 2005
2. 양학진, 김성근, "신경망과 커널 회귀를 이용한 웨이퍼 이송 핸들러 설계", 정밀공학회 춘계학술대회 논문집, 2010