

대면적 서셉터의 온도 균일도 검증 알고리즘

A Verification Algorithm for Temperature Uniformity of the Large-area Susceptor

양학진¹, 김성근^{2,✉}, 조종근³
Hac Jin Yang¹, Seong Kun Kim^{2,✉}, and Jung Kun Cho³

¹ 동양미래대학교 로봇자동화공학부 (School of Robot & Automation Engineering, Dongyang Mirae University)

² 호서대학교 기계공학부 (School of Mechanical Engineering, Hoseo University)

³ ㈜포톤 (Photon Co.)

✉ Corresponding author: kimskun@hoseo.edu, Tel: +82-41-540-5811

Manuscript received: 2014.5.22 / Revised: 2014.8.20 / Accepted: 2014.8.27

Performance of next generation susceptor is affected by temperature uniformity in order to produce reliably large-sized flat panel display. In this paper, we propose a learning estimation model of susceptor to predict and appropriately assess the temperature uniformity. Artificial Neural Networks (ANNs) and Support Vector Machines (SVMs) are compared for the suitability of the learning estimation model. It is proved that SVMs provides more suitable verification of uniformity modeling than ANNs during each stage of temperature variations. Practical procedure for uniformity estimation of susceptor temperature was developed using the SVMs prediction algorithm.

Key Words: Artificial Neural Networks (신경 회로망), Support Vector Machines (서포트 벡터 머신), Susceptor (서셉터), Temperature Uniformity (온도 균일도), Verification Algorithm (검증 알고리즘)

1. 서론

능동 유기 발광 다이오드 (Active Matrix Organic Light Emitted Diode, AMOLED)와 액정 디스플레이 (Liquid Crystal Display, LCD) 등에 사용되는 평판 디스플레이에는 두 개의 유리판과 그 사이에 액정 물질이나 유기물질이 배치되며 이러한 유리 기판의 다음 세대는 약 2.5 m x 2.5 m 정도의 대형화에 이르렀다. 평판 디스플레이 제조 공정은 CVD (Chemical Vapor Deposition), PVD (Physical Vapor Deposition) 및 PECVD (Plasma Enhanced Chemical

Vapor Deposition)등으로 이루어진다. 제조공정을 위한 공정 챔버의 개략적인 단면도가 Fig. 1에 나와 있다. 상부에서 공정가스가 균일하게 공급되면서 RF 전원을 인가하여 플라즈마를 생성하고 측면이나 하부에 설치된 배기구를 통하여 가스가 배출된다.

이러한 공정 챔버에는 기판을 지지하도록 Fig. 2와 같은 온도제어식 서셉터(Susceptor)가 설치되어 있으며, 일반적으로 서셉터는 상온으로부터 약 400°C 정도의 고온으로 가열되며, 고온과 자중으로 인한 변형을 방지하기 위해 하부에 지지대를 설치하기도 한다.

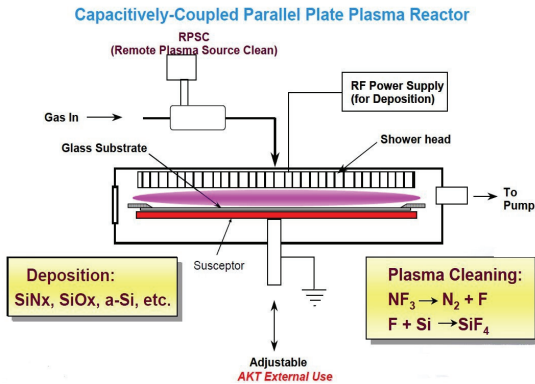


Fig. 1 Schematic Diagram of Large-scaled PECVD Equipment




Fig. 2 Conventional Susceptor

이러한 서셉터는 PVD나 CVD 공정뿐만 아니라, 사진 공정이나 열처리 공정 등 여러 가지 공정에 사용되는데 가장 중요한 정밀 성능은 온도 균일도를 확보하는 것이다. 기관에 증착되는 박막의 증착율은 기관 온도에 민감하게 반응하기 때문에 같은 조건으로 증착해도, 기관 온도가 높은 곳에 증착되는 막의 두께는 온도가 낮은 곳보다 두껍다. 따라서 기관이 안착되는 서셉터 상면의 온도 균일도는 CVD 박막의 두께 균일도에 대한 품질 정밀도를 좌우하는 가장 큰 요인이 된다. 박막의 두께 변화는 박막 스트레스 등의 기계적 성질과 굴절률 등의 광학적 성질의 불균일성을 가져오게 되며 특히 온도 변화 구배에 따라 약 1-10nm/°C의 두께 오차를 가져올 수 있으며, 단순한 두께의 선형적 변화가 아닌 국부적인 섬 형태의 박막 단면 형상을 초래하는 문제도 발생되므로 온도 균일도는 매우 중요하다.

서셉터 온도 균일도 향상을 위한 하드웨어적 연구가 진행되어 왔는데, 서셉터가 대면적화 되면




Fig. 3 New Design of Susceptor Heater Panel using Sheet Metal Type

서 열변형 및 자중에 의한 처짐을 방지하기 위해서 서셉터 하단에 지지대를 두는 구조를 적용하는 경우도 있으며, 알루미늄 모재에서 일정한 패턴을 가공하여 열선을 심은 후 알루미늄 덮개로 덮고 용접하는 방식과 열선과 모재 사이에 주물을 부어서 빈 공간을 없애는 방법도 적용되었다.¹ 그리고 서셉터 모재에 열선을 넣고 커버를 체결하기 위해 단조 방식을 제시하는 방법 등도 있다.

일반적으로는 사용되는 방법으로는 스테인레스 파이프에 Ni-Cr이나 Ni-Fe 등의 열 저항선을 설치하고 MgO 입자를 충전하여 사용하는 파이프 형식의 쉬스(Sheath) 열선을 사용하였으나, 본 연구의 전단계로서 2013년도에 개발된 Fig. 3과 같은 판형 메탈을 사용한 새로운 열선 설계로서¹ 시도되어 좋은 성능 결과를 얻고 있다. 또한 상판과 하판에 직접적으로 열선이 접촉할 수 없게 하기 위하여 부도체인 운모판을 상·하판과 열선 사이에 삽입하는 구조를 개발하였다.

본 연구에서는 이러한 판형 메탈 열선 대면적 서셉터¹의 표면온도에 대한 균일도를 확보하기 위해서, 소프트 센싱 방식으로 온도 센서의 측정 온도에 대한 균일도를 추정하는 알고리즘을 개발하여 설계단계에서부터 균일도를 검증하고 확보하는 알고리즘을 개발하고자 한다. 이러한 추정을 위해서는 신경 회로망(Artificial Neural Networks, ANNs),^{2,5} 은닉 마르코프 모델(Hidden Markov Models), 유전자 알고리즘(Genetic Algorithms), 그리고 서포트 벡터 머신(Support Vector Machines, SVMs)^{5,6} 등을 사용한 연구가 이루어져왔다. 타 모델에 비하여 학습(Learning) 능력이 뛰어난 ANNs은 학습 구간에서의 측정값과 입력 데이터에 의해서 학습되며, 그 결과로 가중치(Weight)가 결정된 후, 검증 구간에

서의 입력 데이터가 주어질 때 학습된 예측 값을 결정하도록 되어 있다. 하지만 ANNs은 학습이 된 영역에서는 효율적이지만 학습하지 않은 데이터에 대한 일반화 능력(Generalization)은 부족한 성향이 있다. 그러나 SVMs은 기존의 통계적 학습 방법에서 이용되는 ‘경험적 위험 최소화(Empirical Risk Minimization)’와는 다른 ‘구조적 위험 최소화(Structural Risk Minimization)’을 이용하여 일반화 에러를 감소시킴으로써 일반화 능력을 향상시킬 수 있다. 본 연구에서는 ANNs와 SVMs을 사용하여 온도 균일도 검증에 대한 추정 알고리즘을 구성하여 그 유용성을 비교·검증하고, 대면적 서셉터의 온도 균일도에 대한 검증 알고리즘을 개발하여 유용성을 확보하였다.

2. 추정 알고리즘

2.1 상관 인자 선별

판정 모델의 입출력 관계 설정을 위한 상관 인자의 선정은 최적의 추정 모델을 설정하기 위해서 중요하며, 상관 인자의 적절하지 못한 선택은 다음과 같은 문제점을 야기시킨다.⁷⁻⁹

- 인자 수가 많아지면, 계산이 복잡해져서 학습 및 인식 속도가 느려진다.
- 불필요한 인자는 학습을 어렵게 만든다.
- 부적합한 인자의 추가로 인하여 모델의 정밀도가 약화된다.

분별력 있는 데이터 분석이 되기 위해서는 일반적으로 복잡한 데이터를 단순한 인과 관계 데이터로 정제시켜야 하며, 추정 알고리즘의 학습 단계인 전처리 과정으로 습득 데이터에 대한 필터링 작업¹⁰을 해야 한다. 또한 적절한 입력 인자 및 인자 수에 대한 선정이 진행되어야 한다.

$$r_{ij} = \frac{s_{ij}^2}{\sqrt{s_{ii}s_{jj}}} \tag{1}$$

$$\text{where } s_{ij}^2 = \frac{\sum (y_i - \bar{y}_i)(y_j - \bar{y}_j)}{N - 1}$$

본 연구에서는 상관 인자 상호관계를 판정을 위하여 피어슨 상관 계수 식(1)을 사용하여 변수간의 영향력을 파악하였으며, 각 온도센서 별로 가장 상관도가 높은 4-5개의 항목들을 우수 인자 항목으로 정의하였다.

2.2 신경 회로망(ANNs)

신경 회로망에서 가장 문제가 되는 것은 학습 시간을 최소화하는 문제와 오차의 국부적 최소로 수렴하는 것을 방지하기 위함이며, 과거의 연구에서 활발하게 진행되었다.^{11,12} 학습 시간을 줄이기 위한 방법들은 학습의 반복과정에서 오차 곡선에서의 탐색 방향과 그 벡터 크기를 결정하는 과정에서 차이가 나는데, 본 연구에서는 대표적인 학습 규칙 중에 하나이며 활성화 함수의 미분 값이 사용되는 특징이 있는 델타 학습 규칙을 사용하였다. 이는 역전파 알고리즘을 사용하기 위함이며, 역전파 알고리즘은 활성화 함수를 최소화시키는 기울기 강화 알고리즘에 기초를 두기 때문에 신경 회로망의 비선형 함수가 미분 가능하여야 역전파 알고리즘에 적용할 수 있기 때문이다.

활성화 함수 중에서 미분 가능한 비선형 함수로는 연속 함수인 시그모이드 함수(Sigmoid Function)와 하이퍼볼릭 탄젠트 함수(Hyperbolic Tangent Function)가 있으며,^{13,14} 본 연구에서는 보편적으로 많이 사용하는 시그모이드 함수를 사용하였다. 또한, 단-은닉층으로서, 뉴런 수는 입력층의 뉴런 수와 동일하게 하였으며, 신경 회로망의 안정성에 직접적인 영향을 미치는 학습률은 0.5를 설정하였다. 그리고 현 변화율에 대한 의존도를 반영하는 모멘텀은 0.5, 0.9를 설정하였다.

2.3 서포트 벡터 머신(SVMs)

서포트 벡터 머신은 통계적 학습 이론에 기반을 두고 있는 방법으로서, 일반적인 통계적 학습에서의 경험적 리스크 최소화와는 다른 구조적 리스크 최소화를 통해 오류를 최소화 시키는 방법을 이용한다. 일반적으로 통계적 방법을 통한 학습에서의 정확도는 학습에 이용된 데이터에 의해 제약을 받는다. 따라서 수집된 데이터의 양과 분포에 따라 함수의 성능이 좌우된다고 볼 수 있으며, SVMs는 이러한 단점을 보완하며 서로 다른 설계 및 제작 조건에서의 서셉터 균일도 추정을 위해 사용될 수 있다.^{15,16}

SVMs는 벡터 공간에서 임의의 경계면을 찾아서 두 개의 집합을 분류하는 방법으로, 주어진 조건하에서 통계학적으로 최적의 해를 찾음으로써 일반화 능력을 극대화한다고 알려져 있다. 이러한 SVMs의 이론적인 접근 방법을 정리하면 다음과 같다.¹⁶

$$y(x) = \sum_{i=1}^n (\lambda_i - \lambda'_i) K(x \cdot x_i) + w_0 \quad (2)$$

$$w_0 = \varepsilon + y_{di} - \sum_{i=1}^n (\lambda_i - \lambda'_i) K(x_i \cdot x_j) \quad (3)$$

SVMs 모델에서 선형적으로 분류할 수 없는 경우에는 커널 함수를 이용하여 비선형문제를 해결해야 한다. 비선형 변환 함수를 이용하여 보다 고차원의 공간으로 사상(Mapping) 시키면 선형 분리 가능한 조건이 되며, 사상된 공간에서의 식별을 위해 구체적인 사상 함수를 설정하지 않고도 식별 함수를 구현할 수 있게 된다. 이와 같이 사상 함수에 대한 계산을 회피하는 방법을 커널 트릭(Kernel Trick)이라고 한다. 그러나 커널 트릭은 실제로 매핑 함수가 존재해야 하며, 이러한 커널은 선형 서포트 벡터 머신을 비선형 벡터 머신으로 확장하는데 사용할 수 있다. 본 연구에서는 대표적인 커널 함수 중에서 선형 커널 함수를 사용하였다.

2.4 균일도 판정 알고리즘

Fig. 4는 균일도 판정 알고리즘에 대한 흐름도이며 다음과 같은 절차에 의하여 온도 균일도에 대한 검증 판단을 하게 된다.

- ① 모든 온도센서에서 측정 데이터를 추출하여 데이터셋을 설정한다.
- ② 임의의 온도 센서 하나를 선정하고 이에 대한 데이터(검증 대상 온도 데이터)를 기준으로 모든 온도 센서에 대한 데이터의 상관 계수를 구한다.
- ③ 검증 온도 데이터에 대한 상관 계수가 우수한 센서 항목을 4-5개 선별하고 학습 데이터로 설정한다.
- ④ 이러한 학습 데이터의 검증 구간 데이터를 갖고 ANNs 나 SVMs 추정 알고리즘을 활용하여, 추정값을 계산한다. 또한, 이러한 (②-④)의 과정을 모든 센서에 대하여 적용하여 비교한다.
- ⑤ 식 4를 이용하여 실제 측정된 온도에 대한 균일도 및 추정 데이터의 균일도를 계산한다. 그리고 균일도에 대한 오차값을 계산하여 균일도 차를 판단하게 된다.

$$T_{Uniformity} = \frac{(T_{max} - T_{min})}{(T_{max} + T_{min})} \times 100 \quad (4)$$

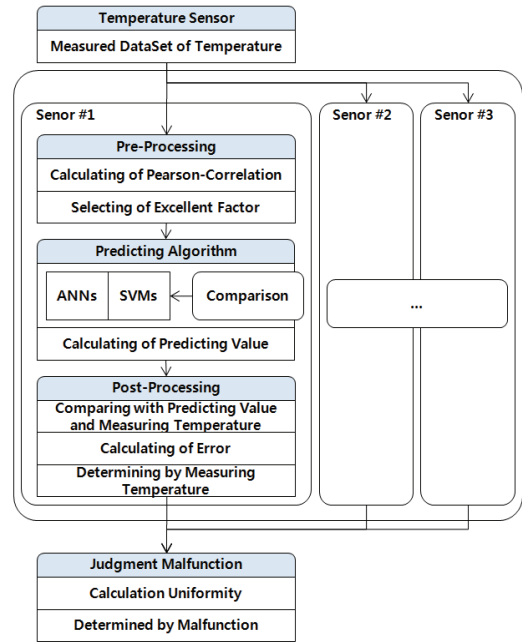


Fig. 4 Flow-Chart of Judgment Algorithm for Malfunction Identification of Uniformity

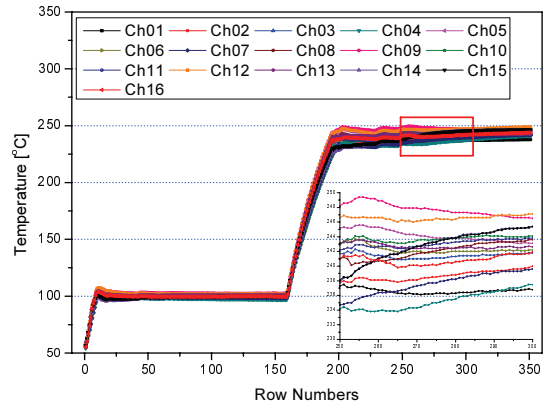


Fig. 5 Pattern of Measured Temperature of Susceptor

3. 균일도 검증 과정 및 비교결과

3.1 인과 관계 변수 구성

Fig. 5는 대면적 서셉터의 온도 측정 데이터 패턴이며, 대면적 서셉터의 상부 표면 및 내부에 16개의 온도 센서를 적절한 위치에 설치하여 측정 데이터를 추출하였다. 서셉터의 내부 발열체를 가열하면 목표 치까지 도달하여도, 안정화될 때까지 온도는 계속 변하며 목표 치에서는 지속되게 된다.




Fig. 6 Correlation Coefficients for Window of 40, 50, 60 and 70 datasets

Table 1 Rank Matrix of Pearson Correlation

Ch.	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10	#11	#12	#13	#14	#15	#16
#1	1	-	-	3	-	-	7	3	-	-	5	2	-	-	-	6
#2	-	1	-	6	-	-	2	3	-	-	7	-	-	-	5	4
#3	-	5	1	-	-	2	6	-	-	4	3	-	-	6	-	-
#4	-	6	-	1	-	-	7	2	-	-	-	4	5	-	-	3
#5	3	-	-	-	1	-	-	7	2	-	-	5	3	-	-	6
#6	-	5	2	-	-	1	7	-	-	4	3	-	-	6	-	-
#7	-	2	-	5	-	-	1	4	-	-	-	-	-	7	3	6
#8	-	5	-	3	-	-	7	1	-	-	-	4	6	-	-	2
#9	4	-	-	-	2	-	-	7	1	-	-	5	3	-	-	6
#10	-	6	4	-	-	3	-	-	-	1	2	-	-	5	7	-
#11	-	5	2	-	-	4	-	-	2	1	-	-	6	7	-	-
#12	4	-	-	7	-	-	-	5	5	-	1	3	-	-	2	-
#13	4	-	-	-	6	-	-	7	2	-	-	3	1	-	-	5
#14	-	4	7	-	-	-	3	-	-	6	5	-	-	1	2	-
#15	-	4	-	6	-	-	3	5	-	-	7	-	-	2	1	-
#16	6	-	-	5	-	-	-	3	7	-	-	2	4	-	-	1

학습 데이터의 데이터 개수(Window)는 학습 과정에서 중요하다. 본 연구에서는 적절한 윈도우 크기를 결정하기 위하여 데이터 수에 따른 상관 계수의 변화를 알아보았다. Fig. 6은 데이터 수에 따른 상관 계수의 변화로서, 데이터 수를 40, 50, 60, 70으로 했을 때, 상관 계수의 변화 그래프이다. 데이터 수가 40, 50인 경우는 센서별 상관 계수 변화 폭이 심하며, 우수한 상관 관계($|r| > 0.5$)가 존재하지 않거나 상관 정도가 작은 영역(빨간색 타원 영역)이 길게 나타나기 때문에, 상관 관계를 표현하기에 적절하지 않지만, 60, 70인 경우는 상대적으로 상관 계수 변화가 적고 일정한 값을 유지하기 때문에 상관관계의 적절한 표현이 가능하다고 판단하였다. 또한 데이터 수가 많으면 우수한 상관 관계를 갖는 센서의 수가 많아지기 때문에 60인 경우를 선택하였다.

16개소의 센서에서 측정된 데이터를 이용하여 상관 인자와 출력의 강도를 알아보기 위하여 피어슨 상관 계수 식(1)를 사용하여 변수간의 영향력을 파악하였으며, Table 1은 각각의 센서에 대한 영향력을 상관도가 우수한 순위부터 순번을 정한 것이다. 상관도가 가장 우수한 자기 자신의 데이터를 1로 하고, 4-5개의 학습 데이터를 활용하기 위하여 6순위까지 계산한 표이다. 자기 자신의 순위인 1은 출력값으로 설정하고, 나머지 항목 데이터들은 추정 알고리즘에 입력으로 적용하기 위한 학습 데이터로 구성하기 위해서 랜덤으로 재배치하여 사용하였다.

3.2 추정 알고리즘 비교 선정

4-5개의 데이터 쌍으로 구성된 학습 데이터를 활용하기 위한 추정 알고리즘은 신경 회로망과 서포트 벡터 머신을 사용하였다.

Fig. 7은 16개의 센서 중에서 임의의 센서에 대하여 모든 구간에서 신경 회로망과 서포트 벡터 머신 알고리즘을 구동하여 추정 값과 측정 값을 비교한 그래프이다. 신경 회로망인 경우는 발열체가 지속적으로 가열되는 구간에서 많은 오차를 보이고 있으나, 서셉터의 표면 안정화가 된 상태에서는 측정 값과 비슷한 경향을 보이고 있다. 반면, 서포트 벡터 머신은 저온 상태, 온도 상승 구간, 고온 상태 및 안정화된 상태에서도 측정 값과 비슷한 경향을 보이고 있다.

Fig. 8은 각각의 센서별로 편차에 대한 평균값을 나타내는 그래프로써, Fig. 8(A)는 모든 데이터에 대한 추정 값이며, Fig. 8(B)는 고온에서의 안정화된 상태에 대한 추정 값을 나타낸 것이다. 신경 회로망인 경우, Fig. 8(A)에서는 모든 센서에서 최소 3.85 에서 최대 5.35의 평균을 나타내고 있지만, Fig. 8(B)에서는 대부분의 센서에서 1 미만의 평균을 나타내는 것을 알 수 있다. 이는 앞에서 언급했듯이 신경 회로망인 경우 학습되지 않은 데이터에서 일반화 능력이 부족한 성향을 보여주는 것이다. 즉. 온도 상승 구간에서 많은 편차를 나타내는 것은 온도가 계속 상승하면서 새로운 영역에서 추정 값을 제시하기 때문이며, 안정화된 상태에서는 측정값과 근사한 값을 찾는 것을 알 수 있었다. 이에 비해 서포트 벡터 머신은 모든 데이터에 대한 추정값에 대한 편차의 평균이 0.2 미만으로 나타내고 있다.

대면적 서셉터의 각 온도 포인트 추정 알고리즘으로서 신경 회로망과 서포트 벡터 머신을 비교한 결과, Fig. 7와 Fig. 8에서 보듯이 서포트 벡터 머신 알고리즘이 우수하다는 것을 알 수 있었다.

3.3 온도 균일도 검증

Fig. 9는 측정값과 서포트 벡터 머신을 이용한 추정 값을 적용한 온도 균일도 검증에 대한 그래프이다. 대체적으로 측정 값과 비슷한 온도 균일도를 나타내고 있다. 하지만 160번째 측정 값에 대한 온도 균일도에서 차이가 보이는 것은 저온 상태에서 온도가 상승하는 구간으로서 추정된 최대값이 측정 값보다 낮음으로써 온도 균일도가 낮은 것을 알 수 있었다. 그리고 약 230 - 240 번째

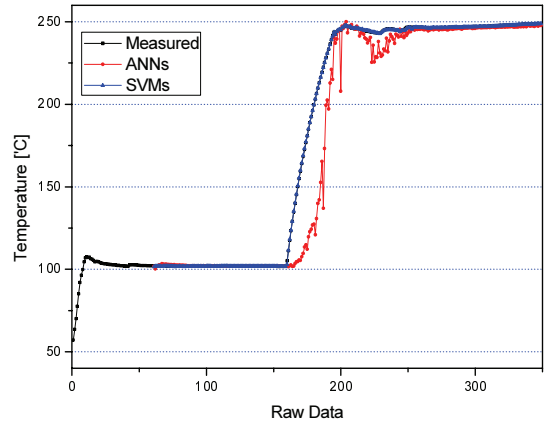


Fig. 7 Comparison with Measurement Data and Predicting Value (ANNs and SVMs)

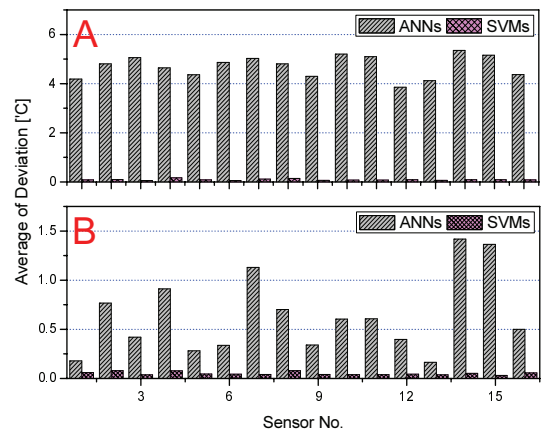


Fig. 8 Average of Deviation in case of ANNs and SVMs




Fig. 9 Temperature Uniformity estimation by SVMs

측정값에 대한 온도 균일도는 고온 상태에서 안정화되는 상태의 온도 균일도로서 추정된 최소값이 측정 값보다 높음으로써 온도 균일도가 낮은 것을 알 수 있었다. Fig. 9에서와 같이 우수한 균일도 예측 성능을 확보함으로써, 설계 단계에서부터 서셉터의 온도 균일도를 확보하기 위한 검증 모델을 구성할 수 있었다.

4. 결론

평판 디스플레이의 대형화를 위해서는 대면적 서셉터의 개발이 이루어져야 하는데, 이러한 대면적 서셉터의 온도 균일도는 성능의 중요한 인자라고 할 수 있다. 이러한 대면적 서셉터의 온도 균일도에 대한 예측 능력을 갖기 위하여 본 연구에서는 다음과 같은 성과를 도출하였다.

(1) 측정 온도 데이터와 주변 측정 온도 데이터를 활용하여 우수한 상관 모델을 구성할 수 있었다.

(2) 온도 추정 알고리즘으로서 신경 회로망과 서포트 벡터 머신 알고리즘을 비교함으로써 서포트 벡터 머신 알고리즘 적용의 우수성을 알 수 있었다.

(3) 추정 값을 예측하고, 이러한 추정 값과 측정 값을 비교하여 신뢰성 있는 알고리즘을 제시함으로써, 온도 균일도에 대한 예측 알고리즘의 신뢰성을 높일 수 있었다.

학습 데이터를 바탕으로 추정 값을 예측하고, 측정 값과 비교함으로써 신뢰성을 갖기 때문에, 초기 학습 데이터에 대한 신뢰성이 필요하다. 하지만 설치된 센서가 초기에 오작동을 발생한다면 초기 학습 데이터에 대한 신뢰성이 떨어지기 때문에 온도 균일도에 대한 신뢰성이 낮아지게 될 것으로 판단되며, 이에 대한 연구가 진행되어야 할 것이다.

후 기

본 연구는 호서대학교 연구과제(2011-0303)로 산학 협력으로 수행되었으며 관계자 여러분들께 감사드립니다.

REFERENCES

1. Kim, S. K. and Cho, C. K., "Development of High

Performance Susceptor for Manufacturing of Display," Hoseo R&D Report, Hoseo University, 2014.

2. Yang, H. J., Kim, H. T., and Kim, S. K., "Comparative Study of Modeling of Hand Motion by Neural Network and Kernel Regression," Trans. Korean Soc. Mech. Eng. A, Vol. 34, No. 4, pp. 399-405, 2010.
3. Yang, H. J. and Kim S. K., "Design of Wafer Handling Robot Using Kernel Regression and Neural Network," Proc. of KSME Spring Conference, pp. 67-68, 2010.
4. Hines, J. W., Garvey, D., Seibert, R., and Usynim, A., "Technical Review of On-line Monitoring Techniques for Performance Assessment Volume 2: Theoretical Issues," U.S.NRC, Document ID: NUREG/CR-6895, 2008.
5. Yang, H. J. and Kim, S. K., "Verification of Wafer Handler Design Using Support Vector Machines and Neural Network," Proc. of KSME Autumn Conference, pp. 765-766, 2010.
6. Yang, H. J. and Kim S. K., "A Comparison between Kernel Regression and SVM for Robot Hand Model," Proc. of KSME Spring Conference, pp. 443-444, 2011.
7. Battiti, R., "Using Mutual Information for Selection Features in Supervised Neural Net Learning," IEEE Transaction on Neural Networks, Vol. 5, No. 4, pp. 537-550, 1994.
8. Back, A. D. and Trappenberg, T. P., "Input Variable Selection Using Independent Component Analysis," Proc. of International Joint Conference on Neural Networks, Vol. 2, pp. 989-992, 1999.
9. Fernando, T. M. K. G., Maier, H. R., and Dandy, G. C., "Selection of Input Variables for Data Driven Models: An Average Shifted Histogram Partial Mutual Information Estimator Approach," Journal of Hydrology, Vol. 367, No. 3, pp. 165-176, 2009.
10. An, S. H., Heo, G. Y., and Chang, S. H., "Detection of Process Anomalies using an Improved Statistical Learning Framework," Expert Systems with Applications, Vol. 38, No. 3, pp. 1356-1363, 2011.
11. Denoeux, T., Lengelle, R., and Canu, S., "Initialization of Weights in a Feedforward Neural Network using Prototypes," Proc. of the International

- Conference on Artificial Neural Networks, 1991.
12. Hagiwara, M., "Theoretical derivation of momentum term in back-propagation," International Joint Conference on Neural Networks, Vol. 1, pp. 682-686, 1992.
 13. Cybenko, G., "Approximation by Superpositions of a Sigmoidal Function," Mathematics of Control, Signals and Systems, Vol. 2, No. 4, pp. 303-314, 1989.
 14. Hsieh, W. W., "Machine Learning Methods in the Environmental Sciences: Neural Networks and Kernels," Cambridge University press, pp. 125-145, 2009.
 15. Burges, C. J. C., "A Tutorial on Support Vector Machines for Pattern Recognition," Data Mining and Knowledge Discovery, Vol. 2, No. 2, pp. 121-167, 1998.
 16. Vapnik, V. N., "An Overview of Statistical Learning Theory," IEEE Transactions on Neural Networks, Vol. 10, No. 5, pp. 998-999, 1999.