

FPD용 박막 두께 자동 측정을 위한 지능화 알고리즘

Intelligent algorithm for automatic measuring FPD thickness

문찬우¹, 최우경¹, 김성현², 김용민³, 전홍태¹

¹ 서울시 동작구 중앙대학교 전자전기공학부

² 경기도 광주시 동원대학 디지털정보전자과

³ 충청북도 청원군 충청대학교 컴퓨터학부

E-mail: chan0209@gmail.com

요 약

과거 디스플레이 장치로서 사용되던 CRT를 대신하여, 상대적으로 두께가 얇고 가벼운 영상장치인 평판 디스플레이(Flat Panel Display, FPD)의 사용이 급증하고 있다. 이렇게 평판표시장치(Flat Panel Display) 산업의 폭발적인 성장과 함께 새로운 공정개발을 통해 짧은 시간에 더 많은 양을 생산하고, 불량률을 낮추는가에 생산업체의 사활이 달려있다.

본 논문은 FPD 공정에서 품질을 결정하는 여러 요인 가운데 비중이 큰 박막 두께의 제어를 지능화 알고리즘을 통해 해결하고자 한다. 이는 불필요한 과정을 줄여 공정경비를 절감 및 소요시간을 단축하고, 정밀하게 두께를 측정하는 것을 가능하게 한다. 마지막으로, 제안한 알고리즘을 광 간섭 두께 측정기를 통해 얻은 실제 값을 가지고 시료의 두께를 측정한다.

Key Words : Intelligent system, Neural networks, FPD(Flat Panel Display), Automatic measuring

1. 서 론

최근 이동성이 중요시되는 정보 환경에 대응하여 나타나는 기기의 경박 단소화 추세나 디지털 기술의 진전과 융합에 따라 보편화되는 멀티미디어 환경 등으로 인해 디스플레이에 대한 수요가 변화하고 있다. 과거 디스플레이 장치로서 사용되던 CRT를 대신하여, 상대적으로 두께가 얇고 가벼운 영상장치인 평판 디스플레이(Flat Panel Display, FPD)의 사용이 급증하고 있다. 이렇게 평판표시장치(Flat Panel Display) 산업의 폭발적인 성장과 함께 새로운 공정개발을 통해 짧은 시간에 더 많은 양을 생산하고, 불량률을 낮추는가에 생산업체의 사활이 달려있다.

FPD 공정은 여러 가지 박막을 선택적으로 유리 위에 형성시키는 과정이다. 박막 고유의 전기적, 화학적, 광학적 특성을 이용하거나 반도체의 전기적인 특성을 바꾸기 위해 다양한 공정이 적용된다. 이러한 FPD 공정에서 품질

을 결정하는 여러 요인 가운데 박막 두께의 제어는 가장 큰 비중을 차지하고 있다. 때문에 이를 공정 중에서 직접 모니터링 하는 것이 필수적이라고 할 수 있다.

기존의 박막 두께 측정 방법에서는 측정 시료의 손실 및 손상이 야기될 수 있으며, 추론 과정에서 유연한 결과를 얻지 못한다.

본 논문에서는 기존의 LCD 및 PDP용 박막 두께를 측정하는 장비의 특성에 대하여 이해하고 지능형 알고리즘을 개발하여 공정경비 절감 및 소요시간을 단축하기 위한 지능형 자동화 알고리즘을 구현하고자 한다. 실험에서는 광학적 방법인 광 간섭 두께 측정기를 이용하여 얻은 시료의 광학적 특성을 레퍼런스 데이터와 비교하는 과정을 통해 시료의 두께를 측정한다. 이 과정에서 학습을 통한 지능형 알고리즘을 구현한다.

2. 박막두께 측정기술

FPD의 경우 박막의 두께와 광학적인 상수들이 물리적인 성질을 좌우하므로 이의 조절이 실질적으로 중요한 변수라 할 수 있다.

FPD 공정 및 그 밖의 응용공정 등에서 사용하는 박막의 두께 측정에는 여러 가지 방식이 있지만 탐침(stylus)을 이용한 기계적인 방법, 현미경적인 방법, 그리고 광학적(optical)방법 등 세 가지 방법이 가장 일반적이다.

2.1 기계적 방법

기계적 방법은 탐침이 웨이퍼(Wafer)표면을 긁고 지나감으로써 표면 단차의 변화로 발생하는 압력을 감지하여 그 단차의 두께를 측정하는 장비이다.

시료 및 박막에 대한 사전 지식이 없어도 두께를 측정할 수 있어서 편리하지만 접촉에 의한 시료의 파괴와 오염을 유발하며, 측정 속도가 매우 느리고, 측정자의 주관에 따라 측정 오차가 발생할 수 있다.

2.2 현미경적 방법

전자현미경 또는 원자현미경을 이용하여 초고배율의 이미지를 얻어서 그 두께를 계측하는 방법이다. 시료를 절단하여 단면을 보아야 하므로 앞의 탐침에 의한 방식보다 더 많은 시단을 필요하며 시료를 가공하는 특별한 기술이 요구된다.

2.3 광학적 방법

광학적 방법은 박막 표면에서 반사광과 하부의 계면에서 반사되는 광 사이의 간섭현상 또는 광의 위상차를 이용하여 박막의 특성들을 결정하는 것이다. 이 방법을 이용하면 박막의 두께 및 광학적 상수도 측정할 수 있다.




그림 1. 단층 박막에서의 간섭현상

다른 방법과 비교하여 광학적 측정 방법은 정확도 및 측정 속도가 우수하다. 박막이 투명하고 광 간섭성을 유지할 수 있다면 어떠한 종류의 시료라도 측정할 수 있으며, 다층 박막 구조라 하더라도 수학적 계산에 의해 각각의 박막 두께를 측정할 수 있다. 측정 시료의 표

면을 손상하지 않으면서 설치가 용이하고, 빠른 측정 속도로 극히 얇은 막에서부터 두꺼운 막까지 측정할 수 있다.

본 논문에서는 박막의 두께를 측정하기 위해 광 스펙트럼 분석기(Spectrometer)에서 구해지는 반사도(reflectance)를 이용하였다. 어떤 물체의 반사도란 입사된 광량 $E_s(\lambda)$ 에 대비하여 반사된 광량 $E_r(\lambda)$ 의 비율로 정의되며, 반사광간의 광로차 존재로 인해 사용된 광의 파장(λ)과 물체를 이루는 재질의 광학적 물성(N 굴절률, 흡수계수), 두께(d)에 따라 다른 값을 갖게 된다.

$$R(\lambda) = E_r(\lambda)/E_i(\lambda) = \text{func}(\lambda, N, d) \quad (1)$$

즉, 파장에 따른 반사도 분포(Spectral reflectance)는 물체의 특성을 나타내는 주요 지표로서 활용이 가능하다. 물성과 두께를 알고 있으면 광학적 모델링을 통해 그에 해당하는 모사 반사도(Simulated reflectance) $R_s(N, d)$ 의 예측이 가능하다.

광 스펙트럼 분석기(Spectrometer)를 이용하면 물체의 측정 반사도 (Measured reflectance) $R_m(N, d)$ 를 직접 측정할 수 있다.

반사도계에 의한 두께 측정원리는 측정 반사도를 모사 반사도와 비교하여 미지의 두께 (d)를 유추하는 것이다.

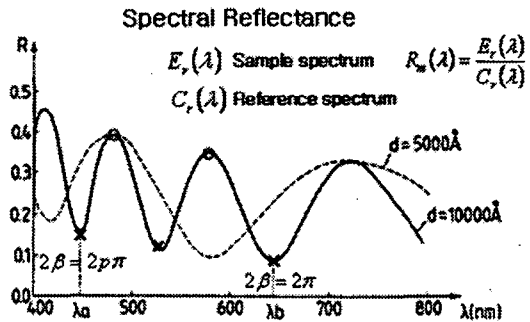


그림 2. Reflectance Spectrum

간단한 단일층(Single layer)의 경우는 반사도 스펙트럼상의 피크(Peak) 검지 등을 이용한 해석적인 방법으로 손쉽게 두께를 산출할 수 있으나, 다중층(Multi layer)의 경우는 광학모델의 비선형성 때문에 반복연산 최적화 알고리즘을 적용해야 해를 얻을 수 있다.

3. 시스템 구성

본 논문에서 구성하는 시스템은 다음과 같다. 우선, 광 스펙트럼 분석기(Spectrometer)를

통해 측정하고자 하는 시료의 스펙트럼 (spectrum)을 확인한다. 이 스펙트럼 데이터를 일정 간격으로 샘플링(sampling)한 다음 샘플링 데이터를 기존의 레퍼런스 데이터와 비교한다. 비교할 때, 사전에 학습된 신경회로망에 의해서 비교, 추론하여 두께를 확인한다.

다음은 시스템의 개요도이다.

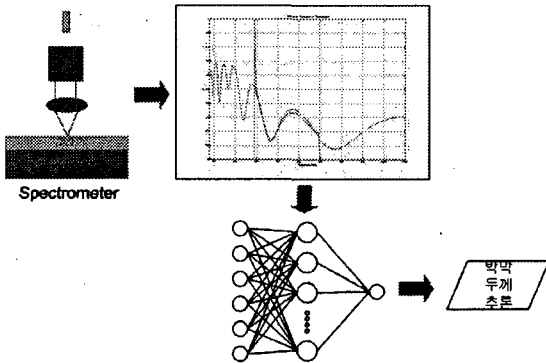


그림 5. 시스템 개요도

논문에서 제안한 신경회로망은 대칭형 시그모이드 함수(Symmetric Sigmoid function)를 사용하였기 때문에 입력과 출력 모두 1에서 -1사이에 있어야 한다. 그래서 입력은 선처리 과정을 통해 해당 범위 안으로 조정하여 적용한다. 결과 값 또한 실제 적용 가능한 값으로 나오지 않기 때문에 후처리 과정이 필요하다. 본 실험에서는 4000을 곱해주는 것으로 문제를 해결하였다.

4. FPD용 박막 두께 측정 알고리즘

4.1 신경회로망을 이용한 두께 측정 알고리즘

광 간섭 두께 측정기를 통해 얻어지는 다량의 데이터를 가지고 두께를 추론하기 위해서 본 논문에서는 다층 퍼셉트론(Multi Layer Perceptron)을 사용하였다. 입력 데이터는 측정하고자 하는 시료의 스펙트럼 데이터 (Spectrum data)를 샘플링(sampling)하여 구성한다. 먼저 학습을 위한 데이터로, 다양한 박막 두께를 가진 레퍼런스 물체들의 레퍼런스 스펙트럼 데이터(Reference spectrum data)를 수집한다. 레퍼런스 데이터가 많아지게 되면 신경회로망 학습에 있어 빠른 수렴 속도를 얻을 수 있다.

학습에 필요한 출력 층의 오차(E)는 식 (2)와 같이 구한다.

$$E = \frac{1}{2} \cdot \sum_k (d_k - y_k)^2 \quad (2)$$

여기서 d_k 는 출력단 k 번째 뉴런의 목표 값이며, y_k 는 출력단 k 번째 뉴런의 실제 출력 값을 나타낸다. 연결강도 변화량은 경사 하강법 (gradient-descent method)에 의해 다음과 같이 구할 수 있다.

$$\begin{aligned} \Delta w_{kj} &= -\eta \cdot \frac{\partial E}{\partial w_{kj}} \\ &= -\eta \cdot \frac{\partial E}{\partial v_{kj}} \cdot y_j \\ &= \eta \cdot \delta_k \cdot y_j \end{aligned} \quad (3)$$

η 는 학습률을 나타내고 δ_k 는 역방향으로부터 전달되어 오는 오차이다. 다음은 신경회로망의 구성도이다.




그림 3. Multi-layer Neural Network

본 논문에서는 6가지 입력에 대하여 각기 780가지 패턴을 만들었으며, 이를 학습 시켰다. 이때 사용된 전달함수는 대칭형 시그모이드 함수(Symmetric Sigmoid function)로 사용하였으며, hidden layer는 총 2-layer로 각 hidden layer 당 노드 수는 30개이다. 이를 100만 번의 반복 학습을 통해 시스템을 구성하였다.




그림 4. reference data for training

그림 4는 신경회로망을 학습 시킬때 사용한 레퍼런스 데이터의 그래프이다. 각 두께에 따른 탄사도를 주파수 대역에 따라 그렸다. x축은 입력 과정을

나타내고 y축은 반사도를 의미한다.

5. 시뮬레이션

실험에서는 6가지 레퍼런스 시료를 사용하여 학습(training)하였다. 우선 광 스펙트럼 분석기(spectrometer)를 통해 각 주파수대별 반사도 데이터(reflectance data)를 연속적 그래프 형태로 받았으며, 이를 샘플링하여 한 가지 시료 당 780개의 패턴으로 정하였다.




그림 6. spectrometer

780개의 패턴씩 6개의 데이터를 가지고 학습을 하였으며, hidden layer는 2개, 히든 hidden 당 노드 수는 30개로 정하였다. 다음으로, 미지의 시료를 광 스펙트럼 분석기(spectrometer)로부터 스펙트럼 데이터를 받은 후, 학습된 신경회로망으로부터 결과를 얻어냈다.




그림 7. 신경망의 학습 결과

결과는 -1에서 1사이로 나오기 때문에 후처리 과정을 통해 추론된 두께를 확인할 수 있다. 이번 실험에서는 결과 값에 1000을 곱하였다.

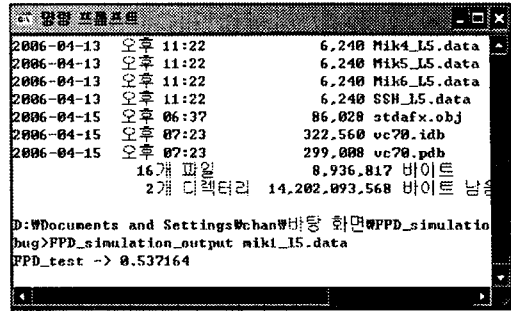


그림 7. 실험 결과

6. 결과 고찰

기계적 방법이나 현미경적 측정방법은 시료에 손상을 가하고 많은 시간이 소요되어 사용이 제한적이다. 간편하고 실시간으로 사용할 수 있는 광학적 방법에 신경회로망을 이용한 지능형 알고리즘을 적용하면 측정시간을 줄이고, 측정 가능한 범위를 넓힐 수 있다.

이후 과제는 다층 박막에서의 측정 오차를 줄이고 신경회로망의 구조를 모듈라 네트워크를 이용하여 구성하고자 한다.

감사의 글: 본 논문은 중소기업청의 산학연 컨소시엄에 의해 지원받았습니다.

참 고 문 헌

- [1] Knipp, D., Stiebig, H., Bhalotra, S. R., Bunte, E., Kung, H. L., Miller, D.A.B, "Silicon-based micro-Fourier spectrometer," IEEE trans, Vol. 52, Issue 3, pp. 419-426, Mar 2005.
- [2] Parlos, A. G., Chong, K. T., Atiya, A. F, "Application of the recurrent multilayer perceptron in modeling complex process dynamics," IEEE trans, Vol. 5, pp. 255-266, 1994
- [3] Draelos, T., Hush, D., "A Constructive Neural Network Algorithm for function Approximation", IEEE International Conference on Neural Networks, Vol. 1, pp. 12-19, 1996.
- [4] T. Poggio., F. Girosi., "Networks for approximation and learning," IEEE proc, Vol. 78, no. 9, pp. 1481-1497, Sep. 1990.
- [4] Simon Haykin, "Neural Networks - A Comprehensive Foundation 2nd edition," Prentice Hall, Reading, 1999.
- [5] 정석균, 디스플레이 공정과 박막 두께 측정, 케이맥(주), 2005