

# 웨이퍼 팹공정에서 배칭을 위한 신경회로망의 적용\*

성창섭\*\* · 정유인\*\* · 윤상흠\*\*

## A Neural Network Approach for Wafer-lot Batching

Chang-Sup Sung · You-In Choung · Sang-Hum Yoon

### 〈요 약〉

본 연구에서는 웨이퍼 팹공정에서 웨이퍼 로트들이 배치공정을 위해 확률적으로 도착되는 상황에서 최적 배치크기를 결정하는 배칭문제를 다루고 있다. 배치공정이란 여러 개의 웨이퍼 로트들을 기계의 용량을 넘지 않는 한도 내에서 하나의 배치로 구성하여 한꺼번에 가공하는 공정을 말한다. 목적함수는 생산율을 높이고 재공재고 및 사이클타임을 줄이기 위해 웨이퍼 로트들의 평균 대기시간의 최소화를 채택하였다. 문제의 해결을 위해서, 확률적인 상황변동 하에서 실시간 제어를 위해 많이 활용되고 있는 신경회로망 중 다층 퍼셉트론을 이용한 배치크기 결정 모델을 제시하였다. 제시한 모델의 효율성을 확인하기 위해 기존에 잘 알려져 있는 최저배치크기(MBS) 규칙과 실험, 비교하였다.

### 1. 서론

최근에 반도체 제조와 관련하여 제품, 설비 및 공정 등에 대한 설계기술뿐만 아니라 생산계획, 일정계획 및 생산통제시스템 구축 등의 생산관리 기술에도 많은 관심이 모아지고 있고 관련 문헌들의 발표도 늘어나고 있다[1-9]. 이는 반도체 제조공정이 다른 제조공정과 구별되는 여러 가지 생산관리상의 특수성을 지니고 있고, 더욱이 수요 증가로 인한 생산 규모의 확대로 기존 통제시스템으로는 효율적인 제조라인 운영이 어려워 지고 있기 때문이다.

반도체 제조공정은 크게 웨이퍼 팹(FAB)공정, 웨이퍼의 전기적 특성 검사, 웨이퍼를 절단해서 직접회로칩(Integrated Circuit Chip: IC 칩)으로 형상화하는 조

립과정, 그리고 완성된 IC 칩의 최종검사단계로 구성된다[1], [8]. 이 중에서 웨이퍼 팹공정은 수십개의 세부공정들이 복잡한 연결형태를 이루고 있고 장비의 종류와 특성이 다양하며 특히 하나의 웨이퍼를 완성하기 위해서는 같은 작업장을 반복적으로 수차례 거쳐야 하는 등의 관리기술상의 어려움을 가지는 주요 애로공정이다.

웨이퍼 팹공정은 여러 회로층을 실리콘 웨이퍼 위에 성장시킨다. 하나의 로트(lot)는 일정한 수의 웨이퍼들로 이루어지며(보통 25개 또는 50개), 로트단위로 이동과 처리가 이루어진다. 주요 세부공정으로는 산화공정(oxidation), 포토공정(photolithography), 에칭공정(etching), 이온주입공정(ion implantation), 금속증착공정(metal deposition), 확산공정(diffusion)등이 있다.

\* 본 연구는 과학기술처 특정연구개발사업 연구비 지원에 의해 수행되었음

\*\* 한국과학기술원 산업공학과

하나의 칩은 여러 개의 회로층으로 이루어지며 각 회로층은 위의 세부공정들을 거쳐서 완성된다. 따라서 하나의 칩의 완성을 위해서는 수차에 걸친 세부공정들의 반복이 이루어져야 한다([1],[8]).

웨이퍼 팹공정의 세부공정들은 대부분 뱃치공정(batch process)이라는 공통적인 특징을 가지는데, 뱃치공정이란 가공을 위해 대기 중인 여러개의 웨이퍼 로트들을 공정기계의 용량을 넘지 않는 한도내에서 하나의 뱃치로 구성하여 한꺼번에 가공하는 공정을 말한다. 이는 하나의 뱃치로 묶여진 웨이퍼 로트들은 동일 시점에 가공이 시작되어 동일 시점에 완료됨을 의미한다. 일반적으로, 각 뱃치의 가공시간(processing time)이 뱃치크기(구성된 로트의 수)에 상관없이 일정하다는 것도 웨이퍼 팹공정에 속한 뱃치공정들의 특징이다.

각 뱃치공정에서 각 뱃치의 크기를 결정하는 문제(본 연구에서는 뱃칭문제라고 부름)는 전체 웨이퍼 팹공정의 생산효율을 결정하는 매우 중요한 의사결정요소이다. 따라서, 본 연구에서는 웨이퍼 로트들이 뱃치공정을 위해 확률적(stochastic)으로 도착되는 상황에서 최적 뱃치크기를 결정하는 뱃칭문제를 다루고 있다. 뱃치결정을 위한 의사결정을 시의적절히 동적으로 수행해야 함이 필요하다고 하겠다. 목적함수로는 생산률을 높이고 재공재고 및 사이클타임을 줄이기 위해 웨이퍼 로트들의 평균 대기시간(queueing time)의 최소화를 채택한다. 이 문제의 해결을 위해서, 확률적인 상황변동 하에서 실시간 제어(real-time control)를 위해 많이 활용되고 있는 신경회로망 기법을 도입하려 한다.

뱃칭문제를 다룬 기존 연구들은, 크게 분류해서, 웨이퍼 로트들의 도착간격시간을 지수분포로 가정하는 경우와 도착시간을 미리 확정적으로 알고 있다고 가정하는 경우의 두가지로 나눌 수 있다. 예를 들면, Neuts[6]는 로트들의 도착간격시간과 뱃치가공시간이 지수분포인 경우의 뱃칭문제를 적하처리 대기(bulk service queueing)문제로 모형화하고 평균 대기시간의 최소화를 대상으로, 최소 뱃치크기(minimum batch size:MBS)규칙을 제시하였다. 이 규칙은 어느 시점에서 대기 중인 로트의 수가 미리 정해진 일정한 정수,

(즉, MBS)를 넘으면 MBS 이상의 로트들로 뱃치를 구성하여 가공을 시작하고 그렇지 않은 경우는 로트의 추가 도착을 기다리게 하는 것이다. 또, Deb과 Serfozo [3]는 평균 운용비용을 최소화하는 MBS값을 결정하는 동적계획법을 제시하였다. 이러한 MBS규칙은 다른 연구들의 주요 비교대상이 되어 왔다.

Glassey와 Weng[5]은 평균 대기시간의 최소화를 대상으로, 미래에 도착할 일정한 수의 웨이퍼 로트들의 도착 시간을 알고 있다는 상황에서의 뱃칭문제를 고려하면서 문제해결을 위한 효율적인 발견적 기법을 제시하였다. Fowler 등[4]은 Glassey와 Weng[5]의 연구를 여러 종류의 제품을 대상으로 확장하였다. 또한, 어느 시점에서 바로 다음에 도착할 한 로트의 도착시점만을 안다는 좀 더 현실적인 가정으로 문제를 모델화하였다. Weng과 Leachman[9]은 Fowler 등[4]의 문제를 대상으로 단위시간당 평균 지연비용함수를 제시하고 이를 최소화하는 기법을 제시하였다. 천과 홍[2]은 Weng과 Leachman[9]의 연구를 확장하여 로트의 준비비용을 포함하는 모델을 다루었다. Robinson 등[7]은 Fowler 등[4]이 도입한 기회고정기간(rolling horizon) 개념을 Weng과 Leachman[9]의 비용 함수에 도입하여 새로운 발견적 기법을 제시하였다.


이러한 기존 연구들은, 각기 채택한 가정들이 현실적인 공정상황에 적합치 못한 몇 가지 사항들을 가지고 있다. 즉, 수 많은 세부공정들이 수차 반복되는 상황에서 한 공정에 도착되는 로트들의 도착시간간격은 다양해지는 반면, 각 뱃치별 실제 가공시간은 설비의 자동화 등으로 일정하다고 볼 수 있다. 따라서, 관련 시간들에 대한 지수분포 가정은 비현실적이라 할 수 있다. 또한, 설비의 고장 및 정비, 로트들의 이동시간, 로트들의 검사와 불량 로트들에 대한 재작업(rework) 등 수많은 변동요소를 가진 현실상황에서 미래에 도착할 로트들의 도착시간을 미리 알고 있다고 가정함도 무리가 따를 수 있다.

따라서, 본 연구에서는 로트들의 도착시점을 특정 확률분포형태로 미리 정형화하기 힘든 상황에서, 여러 상황변수들의 변화를 뱃칭결정에 적절히 반영할 수 있게 하기 위해서 최근 제조시스템의 실시간 제어를 위해 많이 이용되고 있는 신경회로망 기법을 도입

하고자 한다. 2절에서는 사용될 신경회로망 기법에 대해 살펴보고 3절에서는 신경회로망 기법을 이용한 배치크기 결정모델을 제안한다. 4절에서는 제안된 모델의 성능평가를 위해, 기존의 MBS규칙과 시뮬레이션을 통한 성능비교 실험을 수행한다.

## 2. 신경회로망 기법의 도입배경

본 연구에서 사용될 신경회로망 모델은 3층 퍼셉트론(그림 1) 참조)인데, 이는 오차역전파 학습법(Error back propagation algorithm)의 발표 이후 가장 많이 응용되는 모델이다.



〈그림 1〉 3층 퍼셉트론


〈그림 1〉에서,  $\{x_{i,j} | j=1, 2, \dots, n_i\}$ 는 망의 입력값이자 입력층 각 노드  $j$ 의 출력값으로, 채택된 목적함수에 크게 영향을 미치는 상황변수들로 선택된다. 예를 들어, 로트의 평균대기시간을 목적함수로 하는 경우에는 현재 대기중인 로트의 수, 이미 도착된 로트들의 도착시간, 각 대기로트별 현재까지의 대기시간 등이 채택가능한 상황변수들이다.  $\{x_{2,j} | j=1, 2, \dots, n_2\}$ 는 중간층 노드  $j$ 의 출력값이며,  $\{x_{3,j} | j=1, 2, \dots, n_3\}$ 는 출력층 노드  $j$ 의 출력값을 나타낸다.

중간층과 출력층의 각 노드는 자신으로 들어오는 입력들을 모아서 이를 다시 비선형함수를 통하여 자신의 출력으로 내보낸다(그림 2) 참조). 그림에서  $w_{k,i}$ 는  $i$ 번째 입력값인  $x_{k,i}$ 에 대한 가중치이며 노드의 출력값은 다음과 같이 표현된다.

$$f(\sum_{i=1}^{n_k} w_{k,i} \cdot x_{k,i}) \tag{1}$$

(1)에서의  $f(\cdot)$ 로는 본 연구를 위해 다음의 시그모이드(sigmoid)함수를 사용하는데, 이 함수는 신경회로망 기법에서 많이 사용된다.

$$f(z) = 1 / (1 + e^{-z}) \tag{2}$$



〈그림 2〉 중간층과 출력층 노드의 입·출력관계

오차역전파 학습법은, 위에서 언급한 바의 가중치들을 반복적으로 변화시키면서 퍼셉트론의 실제 출력값과 원하는 출력값사이의 평균자승오차(mean square error)를 최소화하는 알고리즘이다. 퍼셉트론과 오차역전파 학습법의 자세한 내용과 그 응용의 예들은 Zurada[10]에 잘 나타나 있다.

## 3. 신경회로망 기법에 의한 배치크기 결정

신경회로망을 이용한 배치크기 결정모델을 설명하기에 앞서 사용될 기호들을 소개하면 다음과 같다;

$C$  : 배치공정기계의 용량, 한 배치로 구성될 수 있는 웨이퍼로트의 최대수,

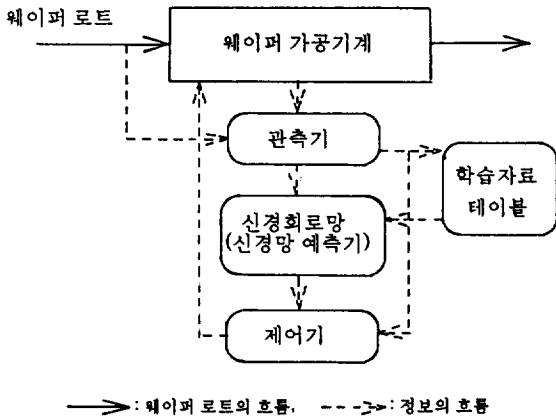
$T$  : 배치 가공시간(배치크기에 상관없이 일정함),

$td$  : 배치형성 결정시점, 한 배치의 가공이 완료된 시점이거나, 기계가 유향한 상태에서 새로운 로트가 도착된 시점,

$ta_i$  :  $i$ 번째 웨이퍼로트의 도착시점,

$ts$  : 가장 최근에 가공이 완료된 배치의 가공이 시작된 시점.

본 연구에서 제시하는 신경회로망을 이용한 배치크기 결정모델의 기능적 구조는 <그림 3>과 같다.




→ : 웨이퍼 로트의 흐름, - - -> : 정보의 흐름

<그림 3> 신경회로망을 이용한 배치크기 결정모델

관측기는 여러 상황변수값들의 변화와 각 배치에 포함된 로트들의 평균 대기시간을 관측한다. 본 연구에서는 다음의 두가지 상황변수,  $x_{1,1}$ ,  $x_{1,2}$ 를 고려하였다;


- $x_{1,1}$ : 현재 시점에서 대기 중인 웨이퍼로트의 수,
  - $x_{1,2}$ : 시간 구간  $[t_s - T, t_s]$ 에 도착한 웨이퍼로트의 수.
- $x_{1,1}$ 와  $x_{1,2}$ 의 설명을 위한 예를 <그림 4>에서 보여주고 있다. 그림에서  $t_d$ 는 현시점으로 현재 대기중인 로



<그림 4> 상황변수  $x_{1,1}$ 와  $x_{1,2}$ 의 설명

트들로 배치를 형성하여 가공할 것인가 아니면, 다음 로트의 도착을 기다릴 것인가를 결정하는 배치형성 결정시점이다. 만약, 바로 직전에 가공된 배치  $B$ 가  $ta_i$ ,  $ta_{i+1}$ 에 도착한 두 개의 로트로 구성되었다면, <그림 4>의 (a)에서는  $x_{1,1} = 2$ ,  $x_{1,2} = 2$ 가 되고, (b)에서는  $x_{1,1} = 3$ ,  $x_{1,2} = 2$ 가 된다. 이와 같이 관측기에서 관측된  $x_{1,1}$ ,  $x_{1,2}$ 는 신경회로망, 제어기와 학습자료 테이블에 입력된다.

신경회로망(또는, 신경망 예측기)은 <그림 5>와 같이 입력층, 중간층 노드의 수가 각각 두 개이고 출력층 노드의 수가 한 개인 3층 퍼셉트론이 사용된다.



<그림 5> 제안한 신경회로망의 입·출력모델

신경회로망은 배치형성 결정시점에서 입력값들을 바탕으로 배치를 형성하여 가공을 시작할 것인지, 아니면, 배치형성을 미루어 가공을 연기(즉, 다음 로트의 도착을 기다림)할 것인지의 결정에 참고가 되는 예측값,  $E$ 를 제시한다. 신경회로망 내부에서는 효과적인 학습을 위하여 입력된  $x_{1,1}$ ,  $x_{1,2}$ 를 다음과 같이 정규화된 형태로 변형하여 사용한다;

$$i = 1, 2 \text{에 대해 } x_{1,i} \leq C \text{이면 } a_{1,i}(x_{1,i}) = x_{1,i} / C \text{이고,}$$

$$\text{그렇지 않으면 } a_{1,i}(x_{1,i}) = 1. \quad (3)$$

제어기는 배치형성 결정시점에서 신경회로망으로부터 입력된 예측값  $E$ 를 바탕으로 다음과 같은 알고리즘을 통해 가공 시작 또는 가공 연기를 결정한다.

If 기계 유휴 then,  
If  $x_{1,1} \geq C$  then,

```

    가공 시작
else if E ≥ 0.5 then,
    가공 시작
    학습자료 테이블 보완 실시
else
    가공 연기
end if
end if
else
    가공 연기
end if
    
```

제어기를 통해 현 시점에서 배치의 가공시작이 결정되었다면 그 배치의 크기는,  $x_{i,1} \geq C$ 인 경우는  $C$ 이고,  $x_{i,1} < C$ 인 경우는  $x_{i,1}$ 이다.

학습자료 테이블은 배치 가공시작때 마다  $x_{i,1}$ ,  $x_{i,2}$ 와 그 배치에 포함된 로트들의 평균 대기시간을 바탕으로 보완된다. 본 연구에서 사용된 학습자료 테이블은 다음과 같다.

		$x_{i,2}$			
		0	1	...	$C$
$x_{i,1}$	0	*	*	...	*
	1	*	*	...	*
				...	
	$C$	*	*	...	*

만약 관측된  $x_{i,1}$ 가,  $i = 1, 2, C$ 보다 클 경우 해당 행 (또는 열)은  $C$ 이다. 이는 예측능력의 감소없이 사용되는 저장량을 줄이기 위한 것이다.  $Cell_{k,m}$ 를  $k$ 행,  $m$ 열의 위치에 저장되는 \*값이라 정의한다.  $Cell_{k,m}$ 은 0 또는 1의 값을 가지는데,  $Cell_{k,m}$ 이 0이라면 어떤 배치형성 결정시점에서  $x_{i,1} = k$ ,  $x_{i,2} = m$ 인 경우에 가공 연기가 유리함을 의미하며, 반대로 1인 경우는 가공 시작이 유리함을 의미한다. 신경회로망의 학습시킬 경우에 이  $x_{i,1} = k$ ,  $x_{i,2} = m$ 이 신경회로망의 입력값이 되고,  $Cell_{k,m}$ 이 신경회로망의 원하는 출력값이 된다.

현재 상황을 반영하여  $Cell_{k,m}$ 를 보완하는 것이 필요한데, 본 연구에서는 다음과 같은 규칙을 이용한다.  $x_{i,1} = k$ ,  $x_{i,2} = m$ 일 때 가공이 시작되었다고 할 때, 그

배치에 속한 로트들의 평균 대기시간이 미리 정한 한계치(threshold)값,  $TH$ 보다 작을 경우는 평균 대기시간을 최소화하는 입장에서 원하는 결과이다. 따라서, 다음 배치형성 결정시점에서  $x_{i,1} = k$ ,  $x_{i,2} = m$ 과 같은 상황이 발생하면 가공 시작하는 것이 유리할 것이므로  $Cell_{k,m}$ 을 1로 보완하고,  $TH$ 보다 클 경우는 원하지 않는 결과이므로  $Cell_{k,m}$ 을 0으로 보완하여 다음 배치형성 결정시점에서  $x_{i,1} = k$ ,  $x_{i,2} = m$ 과 같은 상황이 발생하면 가공 시작을 피한다. 그러나, 모든  $m$ 에 대해  $Cell_{C,m}$ 은 항상 1로 둔다. 이 연구에서 다양한 실험을 통해 파악한 최선의 한계치는  $TH = 0.6 \times T$ 이다.

본 연구에서는 가능한 모든  $k, m$ 에 대해  $Cell_{k,m}$ 을 (단,  $k \neq C$ ) 0으로, 모든  $m$ 에 대해  $Cell_{C,m}$ 을 1로 초기화하는데,  $i \neq C$ 인 모든  $i$ 에 대해  $Cell_{i,m}$ 이 0인 경우,  $x_{i,1}$ 이  $C$  이상이 되어야만 가공이 시작될 가능성이 크게 된다. 이 경우, 로트의 도착률이 낮은 상황에서는 평균 대기시간이 지나치게 높게 나타난다. 이 문제를 타파하기 위해서,  $Cell_{k,m}$ 이 1이 되면,  $Cell_{i,m}$ 을( $i=1, \dots, k-1$ ) 1이 되게 한다. 이 방안의 강구로  $x_{i,1}$ 의 값이 작더라도 배치형성 가능성을 주게 되어 평균 대기시간을 줄일 수 있게 된다.

신경회로망의 학습은 학습자료 테이블로 부터 학습주기마다 이루어 지는데, 매 학습시에 학습자료 테이블의 자료 전체를 학습하는 것이 이상적이거나 이는 많은 시간이 소요된다. 그러므로 본 연구에서는 학습자료 테이블의 내용 중 일부를 학습하기로 하는데, 주어진 문제의 의사결정이 최근 상황정보를 이용하여 배치가공 여부를 결정해야 하므로 현재 상황에서의  $x_{i,1}$ ,  $x_{i,2}$ 와  $Cell_{x_{i,1}, x_{i,2}}$ 을 학습하게 된다.

신경회로망의 학습에서 오차역전파 학습 알고리즘은 참고문헌[10](188쪽)을 이용하는데, 여기서 학습율은 매우 중요한 역할을 한다. 일반적으로 0과 1사이의 값인 학습율은 학습시에 수렴속도를 조정하는데, 초기에는 낮은 학습율을, 시간이 지난 안정된 상태에서는 높은 학습율을 적용하는 것이 좋다[10]. 적절한 학습율은 반복실험을 통해 찾게 되는데, 본 연구에서 다양한 실험을 통해 파악한 최선의 초기 학습률 0.05를 사용하고, 안정된 상태에 대하여는 0.5를 사용하였다.

### 4. 성능평가실험

본 절에서는 앞에서 제시한 신경회로망에 의한 배치 크기 결정모델과 기존에 많이 사용되고 있는 MBS 규칙을 비교·평가하기 위해, 시뮬레이션으로 실험을 수행한다. 시뮬레이션실험은 C언어로 구현하였고, IBM-PC에서 수행되었다. 시뮬레이션실험의 기본조건들은 다음과 같으며, 이는 Glassey와 Weng[5]이 사용했던 조건들과 같다.

시뮬레이션실험의 기본조건:

C : 5 웨이퍼로트

T : 25시간

웨이퍼로트의 도착시간분포 :

일양(uniform)과 지수(exponential)분포

(일양분포에서의 구간 크기 :

0.5×평균, 1.0×평균, 1.5×평균, 2.0×평균)

시뮬레이션 시간 : 10,000시간

실험은 트래픽강도(traffic intensity)에 따른 정규화 평균지연(normalized average delay)을 기준으로 실행되는데 이를 표현하면 다음과 같다;

$$\text{트래픽강도} = (\lambda \cdot T) / C,$$

$$\text{정규화 평균지연} = \sum_{j=1}^J WT_j / (J \cdot T).$$

여기서,

$\lambda$  : 웨이퍼로트의 도착률(단위시간당 도착 웨이퍼로트의 수),

$WT_j$  :  $j$ 번째 가공 배치에 속하는 웨이퍼로트들의 평균 대기시간,

$J$  : 시뮬레이션 수행 동안 가공된 배치의 수.

트래픽강도는 0.1에서 시작해서 0.1만큼씩 증가하여 0.9까지의 값을 택했다.


신경회로망의 학습에 관계되는 조건은 다음과 같다:

학습 주기: 0.1시간,


초기상태 학습률: 0.05,

안정상태 학습률: 0.5.

로트의 도착시간 분포가 일양분포인 경우와 지수분포인 경우의 시뮬레이션 결과가 각각 <그림 6>과 <그림 7>에 나타나 있다. <그림 6>에서 표시된 정규화 평균지연은 일양분포의 4가지 구간에 대한 결과의 평균값이다. 비교된 MBS규칙은 가능한 모든 MBS에 대해 수행되었다. 모든 경우에 대해 제시된 신경회로망 모델에 의한 제어가 좋은 결과를 보이고 있다. 로트의 도착시간 분포가 지수분포인 경우 역시 모든 경우에 대해 MBS규칙보다 좋거나 비슷한 결과를 보여 주고 있다.




<그림 6> 신경회로망 모델과 MBS규칙의 실험 결과 비교 (로트의 도착시간 분포: 일양분포)




<그림 7> 신경회로망 모델과 MBS규칙의 실험 결과 비교 (로트의 도착시간 분포: 지수분포)

제시한 신경회로망 모델의 수렴속도에 대해 알아보기 위해, 로트의 도착시간 분포가 일양분포일때 도착율을 상·중·하로 나누어 실험하였는데, <그림 8>의 (a), (b), (c)와 같은 결과를 얻었다. 그래프에서 각각의 점은  $j$ 번째 배치가공이 수행될 때 그 배치에 속한


로트의 정규화 평균지연,  $WT_i/T$ 을 표시하는 것이다. 수렴이 소수의 배치 가공이 있을 후, 즉, 짧은 시간 내에 이루어진다는 것을 알 수 있다.



(a) 트래픽강도가 낮은 값을 가지는 경우



(b) 트래픽강도가 중간 정도의 값을 가지는 경우




(c) 트래픽강도가 높은 값을 가지는 경우


〈그림 8〉 신경회로망 모델의 수렴속도의 실험 결과

또한, 신경회로망 모델의 트래픽강도의 변화에 대한 적응성을 알아보기 위해, 로트의 도착시간 분포가

일양분포일 때 트래픽강도를 500시간에서 변화시켜 보았다. 트래픽강도가 0.2에서 0.8로 변하는 경우는 〈그림 9〉의 (a)에, 0.8에서 0.2로 변하는 경우는 〈그림 9〉의 (b)에 결과를 제시하였다. 여기서 트래픽강도가 변하더라도 시간이 지남에 따라 수렴하는 것을 볼 수 있다. 따라서, 신경회로망 모델은 트래픽강도의 변화에 잘 적응한다고 할 수 있다.



(a) 트래픽강도가 낮은 값에서 높은 값으로 변하는 경우



(b) 트래픽강도가 높은 값에서 낮은 값으로 변하는 경우

〈그림 9〉 신경회로망의 트래픽강도 변화에 대한 적응성 결과

### 5. 결론 및 추후과제

본 연구에서는 일반적 웨이퍼 제조 공정에서 중요한 생산계획 및 일정계획 문제 중 배치공정에서 배치 크기 결정문제를 다루었다. 확률적으로 도착하는 웨이퍼 로트들을 배치로 형성할 때 발생하는 배치크기 결정문제에 대해 작업장의 지능화와 종합화를 위해 많이 사용되고 있는 신경회로망 기법을 도입하여 해

결하고자 하였다. 여러 상황변수, 특히, 웨이퍼 로트의 수를 입력변수로 지정하고, 가공 시작 또는 연기를 결정하는 변수를 출력변수로 하는 다층 퍼셉트론으로 학습시키며 제어하는 모델을 제시하였다.

제안된 신경회로망 배치크기 결정모델은 그 효율성을 검증하기 위해, 기존의 MBS규칙과의 비교를 실시하였는데, 여러가지의 상황변화를 대상으로 시뮬레이션 실험을 통하여 비교, 평가하였다. 그 결과는 MBS 규칙에 비해 좋은 성능을 보였다. 특히, 도착 시간 간격이 일정하지 않을 때에도 MBS규칙보다 좋거나 비슷한 성능을 보임을 알 수 있었다. 또한, 신경회로망 기법에서의 요소인 학습과 관련해서는 수렴이 짧은 시간 내에 이루어진다는 것과 트래픽강도의 변화에 잘 적응한다는 사실을 알 수 있었다.


전체 웨이퍼 제조 시스템의 효율적인 운용을 위해서 배칭문제뿐만 아니라 웨이퍼 원판의 제조라인으로의 투입시점 결정문제, 사진공정에서의 투입순서 결정문제 등과 같은 생산관리 문제들에 대해 신경회로망 기법을 적용한 해결방안을 모색할 수 있을 것이다.

### 【참고문헌】

- [1] 과학기술처, 반도체공정의 생산 및 공정관리 시스템 개발-1차년도 연차보고서, 1995.
- [2] 천길웅, 홍유신, "반도체 생산 배칭공정에서의 배치 크기의 결정," 대한산업공학회지, 22권, 2호, pp. 231-245, 1996.
- [3] Deb, R. K. and Serfozo, R. F., "Optimal Control of Batch Service Queues," Advances in Applied Probability, Vol. 5, pp. 340-361, 1973.
- [4] Fowler, J. W., Hogg, G. L. and Phillips, D. T., "Control of Multiproduct Bulk Service Diffusion/Oxidation Process," IIE Transactions, Vol. 24, pp. 84-92, 1992.
- [5] Glassey, C. R. and Weng, W. W., "Dynamic Batching Heuristic for Simultaneous Processing," IEEE Transactions on Semiconductor Manufacturing,

Vol. 4, pp. 77-82, 1991.

- [6] Neuts, M. F., "A General Class of Bulk Queues with Poisson Input," Annals of Mathematical Statistics, Vol. 38, pp. 759-770, 1967.
- [7] Robinson, J. K., Fowler, J. W., and Bard, J. F., "The Use of Upstream and Downstream Information in Scheduling Semiconductor Batch Operations," International Journal of Production Research, Vol. 33, pp. 1849-1869, 1995.
- [8] Uzsoy, R., Lee, C-Y, and Martin-Vega, L. A., "A Review of Production Planning and Scheduling Models in the Semiconductor Industry. Part I: System Characteristics, Performance Evaluation and Production Planning," IIE Transactions on Scheduling and Logistics, Vol. 24, pp. 47-61, 1992.
- [9] Weng, W. and Leachman, R. C., "An Improved Methodology for Real-Time Production Decisions at Batch-Process Work Stations," IEEE Transactions on Semiconductor Manufacturing, Vol. 6, pp. 219-225, 1993.
- [10] Zurada, J. M., Introduction to Artificial Neural Systems, West Info Access, 1992.



성창섭

1971년 한양대학교 화학공학과 학사  
 1974년 Iowa State University 산업공학 석사  
 1978년 Iowa State University 산업공학 박사  
 현재 한국과학기술원 산업공학과 교수  
 한국경영과학회 네트워크 연구회 위원장  
 관심분야 생산계획 및 스케줄링, 통신망 분석 및 설계, Systems Engineering, Logistics, Clustering





정유인  
1991년 성균관대학교 산업공학과  
학사  
1994년 한국과학기술원 산업공학과  
석사  
현 재 한국과학기술원 산업공학과  
박사과정  
관심분야 생산계획 및 스케줄링, 신경  
회로망, Systems Engineering



윤상호  
1990년 성균관대학교 산업공학과  
학사  
1992년 한국과학기술원 산업공학과  
석사  
현 재 한국과학기술원 산업공학과  
박사과정  
관심분야 생산계획 및 스케줄링, Logis-  
tics, Systems Engineering