
신경망과 유전알고리즘을 이용한 고효율 태양전지 접촉형성 공정 최적화

정세원* · 이성준** · 홍상진** · 한승수*

Process Optimization of the Contact Formation for High Efficiency Solar Cells
Using Neural Networks and Genetic Algorithms

Se-Won Jung* · Sung-Joon Lee** · Sang-Jeen Hong** · Seung-Soo Han*

요약

이 논문은 p-type single-crystalline float zone (FZ) 웨이퍼를 이용한 고효율 태양전지 제조 공정상의 공정 모델링과 최적화 기술에 대하여 서술하였다. 태양전지 제조 공정 중 중요한 4가지의 공정: 1)Emitter formation; 2)Anti-Reflection-Coating (ARC); 3)Screen-printing; 4)Contact formation 중에서 제조비용을 줄여주며, 성능을 증대 시키는데 중요한 contact formation 공정을 모델링을 하고, 최적화 하였다. 본 논문에서는 공정에 소요되는 시간과 비용을 줄이기 위해 실험계획법 (design of experiments: DOE) 중 중심합성계획 (central composite design)을 이용하여 24개의 요인 (factorial), 8개의 축점 (axial points), 3개의 중심점 (center points)과 실험의 범위를 증가시키기 위한 6개의 임의점 (random points)으로 실험계획을 수립하였다. 접촉형성 (contact formation) 공정 이후에는 실험 결과를 사용하여 신경망 (neural network)으로 모델링을 하였다. 수립된 신경망 모델을 바탕으로 유전자 알고리즘 (genetic algorithm)을 이용하여 다양한 조합의 공정파라미터를 합성하는 방법으로 최적화를 수행하여 고효율의 태양전지를 구현 할 수 있는 최적의 공정 조건을 수립하였다.

ABSTRACT

This paper presents modeling and optimization techniques for high efficiency solar cell process on single-crystalline float zone (FZ) wafers. Among a sequence of multiple steps of fabrication, the followings are the most sensitive steps for the contact formation: 1) Emitter formation by diffusion; 2) Anti-reflection-coating (ARC) with silicon nitride using plasma-enhanced chemical vapor deposition (PECVD); 3) Screen-printing for front and back metalization; and 4) Contact formation by firing. In order to increase the performance of solar cells in terms of efficiency, the contact formation process is modeled and optimized using neural networks and genetic algorithms, respectively. This paper utilizes the design of experiments (DOE) in contact formation to reduce process time and fabrication costs. The experiments were designed by using central composite design which consists of 24 factorial design augmented by 8 axial points with three center points. After contact formation process, the efficiency of the fabricated solar cell is modeled using neural networks. Established efficiency model is then used for the analysis of the process characteristics and process optimization for more efficient solar cell fabrication.

키워드

Solar cells, Screen-printing, Firing, DOE, Neural Network, GA

* 명지대학교 정보공학과 & NPTC/명지 IT중점연구소
** 명지대학교 전자공학과 & 명지 IT중점연구소

접수일자 : 2006. 10. 18

I. 서 론

우주선의 전원용으로만 사용이 국한된 태양전지는 1970년대 2차례의 석유파동을 겪으면서 지상용 전원으로 활용하기 위한 가능성에 주목을 받게 된다. 이어 선진국의 체계적이고 집중적인 연구개발에 힘입어 1980년대부터 제한적이긴 하지만 지상 발전용으로 사용이 시작되었다. 특히 최근 고유가 및 에너지 환경 문제가 지구적 차원의 문제로 대두됨에 따라 화석연료를 대체 할 수 있는 친환경 대체에너지로써 태양전지에 관심을 기울이고 있다. 하지만 현재까지 태양전지가 널리 사용되지 못하고 있는데, 그 이유로는 에너지 생산비용 측면에서 화석연료를 사용하는 화력발전과 비교하여 경제성이 좋지 않기 때문이다. 그런 이유로 전 세계에서 여러 방법으로 저 비용, 고효율의 태양전지를 개발하려는 노력을 기울이고 있다 [1, 2].

전 세계에서 현재 사용되는 태양전지 중 결정질 실리콘 태양전지 (crystalline silicon cells)의 점유율은 80.1%를 차지하고 있다. 특히 결정계 실리콘 태양전지는 재료 및 공정비용이 태양전지의 가격에 반영 된다 [3].

본 논문에서는 단결정질 실리콘 태양전지 (single-crystalline silicon solar cell)의 제조 공정상에서 효율을 높일 수 있는 방법에 대해 연구하였다.

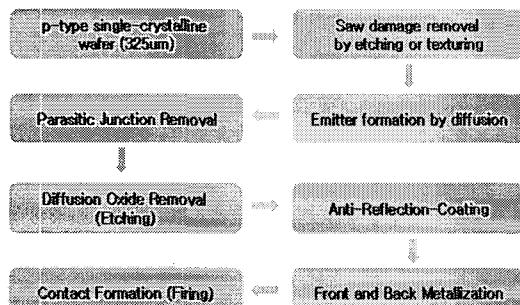


그림 1. 태양전지의 제조 공정.
Fig. 1/ Solar cell fabrication process.

그림 1은 태양전지의 제조 공정 과정을 보여준다. 태양전지 제조 공정 중에서 마지막 공정인 접촉 형성 (contact formation)은 공정의 경제적인 측면과 효율에 밀접한 관계가 있는 공정으로 중요하다 [3]. 효율적이고 경제적인 금속공정을 위해 본 연구에서는 screen printing으로 contact metalization을 실시하였다.

접촉 형성 공정은 전 · 후면 금속화 공정이 belt furnace에 의해서 이루어지는 firing 공정에 의하여 형성되는데 belt furnace 내 온도에 따라 전 · 후면 metallization된 금속들이 용융되면서, 접촉이 생성되게 된다 [4]. 위에서 설명한 접촉형성 공정에 대한 실험을 하기 위해 실험계획법을 이용하여 실험을 설계 하였다. 또한 실험 데이터를 이용하여 모델링을 통해 예측하고, 그 모델링을 통해 유전자 알고리즘을 이용하여 최적의 공정 파라미터 찾아냈다.

II. 배 경

2.1. 태양전지의 제조 공정 및 효율

실험에 사용한 태양전지 제조 공정은 그림 1과 같이 p-type single-crystalline wafer를 사용해서 제조를 하였다. 먼저 saw damage를 제거 해주기 위해 DI water로 rinse 해주고, 에칭(etching)과 텍스처링 (texturing)을 해준다. 텍스처링은 태양전지가 빛의 반사손해를 최소화하기 위해 역파라미드형으로 태양전지표면을 가공해주는 것을 말한다. 그 다음으로는 확산 (diffusion)공정을 이용하여 에미터(emitter)를 형성하였고, edge isolation을 하여 parasitic junction성분을 제거 해주었다. 다음으로 diffusion oxide를 제거 해주고, 빛의 반사손실을 막기 위해 반사방지막 (anti-reflection-coating: ARC)을 PECVD (plasma enhance chemical vapor)를 이용하여 증착시킨다. 마지막 공정으로 전 · 후면의 전극을 금속화(metallization) 해주고, 전극 형성을 위해 belt furnace에서 고온을 가해주어 접촉이 일어나게 해준다. 이때 그림 2의 optimal case와 같이 Ag 전극이 n층에 접촉하는 것이 가장 좋은 접촉이 일어나므로 접촉저항이 작아 fill factor를 향상시켜 결과적으로 태양전지의 효율을 좋게 해 준다 [5].

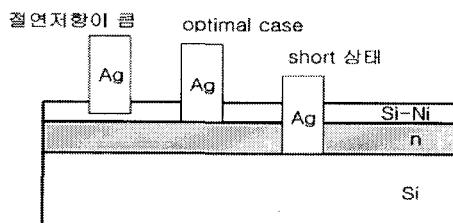


그림 2. 접촉공정과정에서 전면 전극의 접촉
Fig. 2. Front contact in contact formation process.

본 연구의 최종 목표인 태양전지의 효율 (efficiency, η)은 아래 식 1로 표현된다.

$$\eta = \frac{V_{oc} \cdot J_{sc} \cdot FF}{P_{in}} \times 100[\%] \quad (1)$$

V_{oc} (open circuit voltage)는 태양전지의 개방전압을 말한다. 무한대의 임피던스가 걸린 상태에서 빛을 받았을 때 태양전지 양단에 형성되는 전위차이다. J_{sc} (short circuit current)는 단락전류이며 이는 외부저항이 없는 상태에서 빛을 받았을 때 나타나는 역방향의 전류밀도이다. FF (fill factor)는 최대 전력점에서 전류밀도와 전압의 곱을 V_{oc} , J_{sc} 의 곱으로 나눈 값이다. 따라서 FF 는 빛이 가해진 상태에서 J-V곡선 모양이 사각형에 얼마나 가까운지를 나타내는 지표로 표현된다. 결국 태양전지의 효율 (η)은 태양전지에 의해 생산된 최대전력과 입사광 에너지 (P_{in})의 비율에 대한 백분율 (%)을 말한다.

2.2. 실험계획법(Design of Experiments)

실험계획법이란 실험에 대한 계획법을 의미하는 것으로 해결하고자 하는 문제에 대하여 실험을 어떻게 행하고, 데이터를 어떻게 취하며, 어떠한 통계적 방법으로 데이터를 분석하면 최소의 실험횟수에서 최대의 정보를 얻을 수 있는지를 계획하는 것이라고 정의할 수 있다.

본 논문에서는 실험계획법 중 중심합성계획법 (central composite design: CCD)을 사용하여 실험을 계획을 수립하였다 [6]. 이 방법은 공업제품의 생산 공정에서 인자들의 최적공정조건을 찾는데 효과적으로 사용되어 품질관리 (quality control)에 유용하게 응용되고 있다.

중심합성계획 (CCD)는 완전요인설계 (full factorial design)와 다르게 rotatable이 가능하게 설계한다. 이를 위해서 axial points의 위치 (α)를 구하여야 하는데, 식 2를 이용하여 구한다.

$$\alpha = (2^k)^{\frac{1}{4}} \quad (2)$$

여기서 k 는 입력 파라미터의 개수이다. 본 논문의 입력 파라미터 (zone 1, 2, 3의 온도, belt speed)가 4개 이므로 $k = 4$ 이며, 따라서 axial points의 위치 (α)는 2가 된다. 실

험의 variation을 확인하기 위해서 3번의 반복 실험을 center point에서 실현하였다. 또한, 신경망 (neural network)의 복잡한 입, 출력 파라미터의 매핑 (mapping) 능력이 탁월한 장점을 활용하여, 실험계획의 범위 (capacity)를 높이기 위해 5개의 random point에서의 추가실험을 하였다 (표 2 참조).

2.3. 신경망 (Neural Network)

신경망은 다층 퍼셉트론에 관련된 가중치 및 임계값들에 관한 해를 반복적으로 구하는 일반적이고, 가장 많이 사용하는 방법이다. 특히 매우 복잡한 입출력 관계를 매핑 (mapping)하는 능력이 탁월하여 본 논문에서 학습을 거친 신경망을 사용하여 접촉형성공정의 모델링을 수행한 후 태양전지의 효율 예측에 사용하였다.

접촉형성공정에서 실제 실험한 결과 데이터 셋을 7:3으로 나누어 70%의 데이터 셋으로 학습을 시켜 각각의 뉴런의 가중치를 구한 후 나머지 30%의 데이터 셋으로 예측 결과가 어느 정도의 에러가 나오는지 확인 하여 신경망 구조를 바꾸어가며, 에러가 적게 나오는 모델링을 선정하였다. 특히 PI (performance index)를 이용하여 신경망 모델링을 통해 확인된 학습 에러 (training error) · 예측 에러(prediction error)를 비교하여 가장 적은 학습 · 예측 에러가 나는 신경망 구조를 체계적으로 선정하였다 [7].

PI는 식3과 4를 이용하여 구하였다.

$$\sigma = \sqrt{\left(\frac{1}{n-1}\right) \sum_{i=0}^n (y_i - \hat{y}_i)^2} \quad (3)$$

$$PI = K_1 \sigma_t^2 + K_2 \sigma_p^2 \quad (4)$$

σ 는 RMSE (root-mean-squared error)이며, y_i 는 실제 측정된 값, \hat{y}_i 는 신경망에서 예측된 값을 말한다. n 은 sample의 개수를 말한다. σ_t 는 학습 (training)과정, σ_p 는 예측 (prediction)과정에서 발생된 RMSE를 말한다.

PI는 학습 · 예측 에러가 적게 나오는 신경망 모델링의 구조를 찾기 위해 사용 되었다. 여기서 쓰인 상수 K_1 , K_2 는 학습 · 예측 에러의 가중치를 말하는데, 학습보다는 예측 에러에 더 큰 가중치를 두기 위해 $K_1 = 1$, $K_2 = 10$ 으로 사용하였으며, 표 1은 신경망의 구조에 따른 PI값의 변화를 보여준다.

표 1. 신경망 구조 선정
Table. 1 Selection of neural network structure

number of neurons in each layer			σ_t	σ_p	PI
input	hidden	output			
4	5	1	1.88	9.13	837.10
4	8	1	2.03	9.77	958.65
4	4-4	1	0.33	1.69	28.67
4	5-3	1	1.78	5.34	288.32

표 1에서 PI가 가장 낮은 신경망 구조인 4-4-4-1 구조의 모델(그림 3)을 사용하여 접촉형성공정의 모델링을 구성하였다.

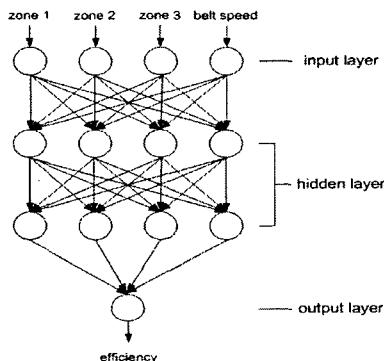


그림 3. 선정된 신경망의 구조.
Fig. 3. Neural network structure.

2.4. 유전자 알고리즘 (Genetic Algorithm)

접촉형성공정조건을 최적화하기 위해서 유전자 알고리즘 (genetic algorithm)을 사용하였다. 유전자 알고리즘은 진화 (evaluation)와 선택 (selection)을 통하여, 개체군 (population) 중에서 가장 적합한 개체를 찾고, 새로운 개체군을 생성시키는 작업을 연속적으로 수행한다. 개체는 이진화된 변수로 재구성하여 사용한다.

새로운 개체군은 재생산 (reproduction), 교배 (crossover), 돌연변이 (mutation)에 의해서 생성된다. 재생산은 아래 식 5, 6로 표현되는 룰렛 휠 선택 (roulette wheel selection)으로 알려져 있는 개체가 선택될 확률 (P_{select_i})로 이루어진다.

$$P_{select_i} = \frac{F_i}{\sum F} \quad (5)$$

$$F = \frac{1}{1 + \sum_n |K_n(y_d - y_o)|} \quad (6)$$

K_n 는 사용자에 의해 결정된 주어진 값의 중요도를 나타내는 가중치이고, y_d 는 목표값을 말하며, y_o 는 현재 입력 파라미터의 출력값을 말한다. F 는 선택될 개체의 적합도를 말하며, F_i 는 i 번 째 개체의 적합도를 말한다. 재생산이 끝난 후에는, 교배가 일어나는데, 부모의 유전 정보가 합쳐져 새로운 개체가 생산되는 것을 말한다. 마지막으로 돌연변이는 미리 정해 놓은 돌연변이 확률에 따라 이진화된 개체의 선택된 비트의 수를 바꿔 준다.

본 논문에서는 위와 같은 과정으로 구현된 유전자 알고리즘을 이용 한다 [8]. 접촉형성공정의 신경망 모델링을 토대로, 예측된 공정파라미터 조건들과 결과값에서 최적 효율을 얻을 수 있는 공정파라미터 조건을 찾는데 사용 되었다.

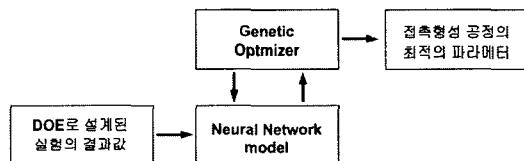


그림 4. 신경망-유전자알고리즘 최적화 과정.
Fig. 4. Neuro-genetic optimization process.

III. 실험

접촉형성공정은 그림 5와 같이 belt furnace에서 실시하였다. p-type single-crystalline wafer가 컨베이어 벨트를 통해 이송되어 각 zone에서 온도에 의해 metallization되어 있는 금속이 용융되어 접촉이 형성되게 된다.

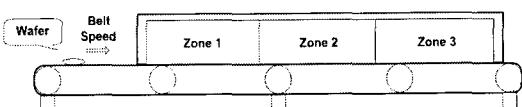


그림 5. Belt furnace.
Fig. 5. Belt furnace.

본 논문의 실험계획은 실험계획법 중 central composite design을 이용하여 설계 하여, 표 2, 표3과 같이 총 32번의 실험을 계획하여 수행 하였다.

표 2. Central Composite Design을 이용하여 설계된 실험계획.

Table. 2 Experiments design using CCD.

Run	Zone 1	Zone 2	Zone 3	Belt speed
1	1	1	1	1
2	1	1	1	-1
3	1	1	-1	1
4	1	1	-1	-1
5	1	-1	1	1
6	1	-1	1	1
7	1	-1	1	1
8	1	-1	1	1
9	-1	1	1	1
10	-1	1	1	-1
11	-1	1	-1	1
12	-1	1	-1	-1
13	-1	-1	1	1
14	-1	-1	1	-1
15	-1	-1	-1	1
16	-1	-1	-1	-1
17	2	0	0	0
18	-2	0	0	0
19	0	2	0	0
20	0	-2	0	0
21	0	0	2	0
22	0	0	-2	0
23	0	0	0	2
24	0	0	0	-2
25	0	0	0	0
26	0	0	0	0
27	0	0	0	0
28	1	1	1	2
29	0	1	1	2
30	-2	2	1	1
31	-2	0	0	1
32	-1	1	1	2

표 3. Firing 공정실험 횟수 계획.

Table. 3 Number of the firing process experiments.

Structure	Number of Experiments	run
Full factorial (24)	16	1-16
Axial point (8)	8	17-24
Center point (1×3)	3	25-27
Random point (5)	5	28-32
Sum	32	32

Zone1, 2에서 metallization되어 있는 금속이 합금이 생성되는 온도가 되면 접촉이 형성된다. 후면전극은 Al을 사용하는데, Al이 용융되어 실리콘(Si)기판과 합금이 이루어지는 온도는 577°C (AlSi 합금의 용융 온도)이고, 전면전극 Ag 금속이 용융되어 실리콘(Si) 기판과 합금이 이루어지는 온도는 830°C (AgSi 합금의 용융 온도)가 된다 [9].

하지만 belt furnace 내 zone 1, 2, 3의 온도와 belt speed의 조건의 유기적인 조합에 따라 접촉형성공정에서 전극의 접촉 깊이가 변화하게 된다[10]. 그런 이유로 실험에 쓰일 입력 파라미터의 범위를 위 전·후면 접촉 온도 조건을 기준으로 15°C와 belt speed 속도는 2.5 inch/min으로 변화를 주어 표 4와 같이 결정하였다.

표 4. 실험계획에 사용된 공정 파라미터.

Table. 4 Process parameter in DOE.

zone 1 Temperature(°C) Δ=15				
-2	-1	0	1	2
545	560	575	590	605
zone 2 Temperature(°C) Δ=15				
-2	-1	0	1	2
800	815	830	845	860
zone 3 Temperature(°C) Δ=15				
-2	-1	0	1	2
830	845	860	875	890
belt speed (inch/min) Δ=2.5				
-2	-1	0	1	2
110	112.5	115	117.5	120

실험계획이 수립 된 후 실험계획에서 결정된 조건으로 실제 실험을 수행한 결과를 사용하여 효율 (efficiency)에 대하여 표 1에서 PI의 값이 가장 작은 구조로 선정된 신경망(neural network) 구조와 표 5의 파라미터를 이용하여 모델링을 하였다. 표 6은 모델링이 끝난 신경망의 학습 및 예측 RMSE를 나타내며, 표 7은 실험에 사용된 공정 파라미터 값의 범위를 나타낸다.

표 5. 신경망의 파라미터

Table. 5 Parameters of the neural network

Training Data : Test Data	7 : 3
Structure	4-4-4-1
Training Tolerance	0.05

표 6. 신경망의 학습/예측 RMSE
Table. 6 Training/Test RMSE (Root Mean Square Error)

Training RMSE	Test RMSE
0.33	1.69

표 7. 신경망 모델링의 입력 공정 파라미터 범위
Table. 7 Range of input parameters

input parameter	input parameter range		
	high	middle	low
zone 1	605	575	545
zone 2	860	830	800
zone 3	875	860	830
belt speed	120	115	110

위 파라미터들을 사용한 신경망 모델링을 통해 예측된 데이터를 분석한 결과 zone 3의 온도 변화와 태양전지의 효율간의 관계는 다른 입력 파라미터들 (zone 1, 2, belt speed)과의 관계보다 더 민감함을 확인 할 수 있었다. 아래 그림 6, 그림 7에서 보는 것과 같이 zone 3의 온도 변화에 따라 관련된 response surface plot의 효율 (efficiency)축의 값이 변화가 가장 커졌지만, 온도의 값이 low (830°C) 값 또는 high (875°C) 값에서 효율이 높게 나오는 공통점을 볼 수 있었다.

그림 7에서 belt speed의 전반적인 성향은 middle (115 inch/min) 값 부근이 효율이 좋은 것을 볼 수 있다.

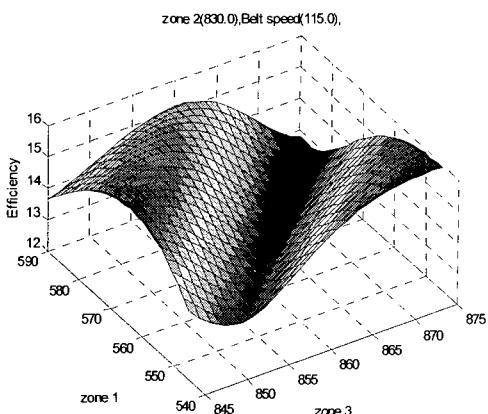


그림 6. zone 2와 belt speed를 중간값으로 고정하고 그린 response surface plot

Fig. 6. Response surface plot with fixed zone 2 and the belt speed to middle values.

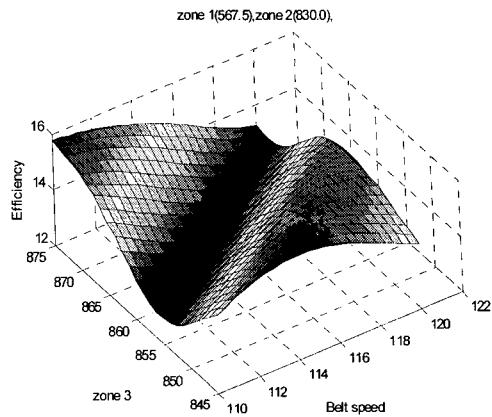


그림 7. zone 1와 zone 2를 중간값으로 고정하고 그린 response surface plot.

Fig. 7. Response surface plot with fixed zone 1 and zone 2 to middle values.

이러한 분석 결과를 이용하여 belt speed와 민감한 입력 파라미터로 분석된 zone 3를 효율이 높게 예측되었던 온도인 830°C와 875°C로 고정 하여 response surface plot을 다시 조사하여 보았다 (그림 8, 9).

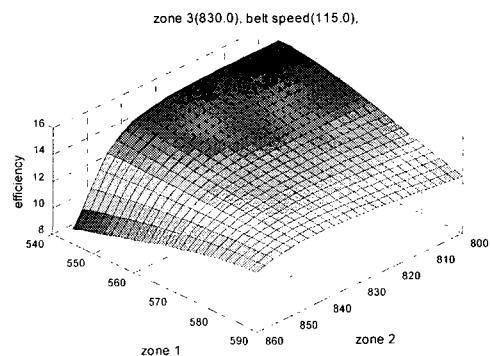


그림 8. 태양전지 효율과 민감한 반응을 보이는 입력 파라미터를 고정한 후 그린 response surface plot (zone 3 온도 : 830°C, belt speed : 115 ipm)
Fig. 8. Response surface plot with fixed sensitive parameters. (zone 3 temp. : 830°C, belt speed : 115 ipm)

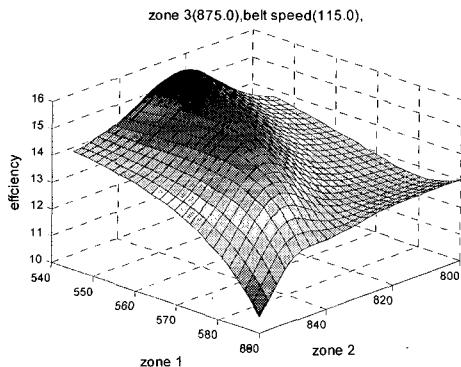


그림 9. 태양전지 효율과 민감한 반응을 보이는 입력 파라미터를 고정한 후 그린 response surface plot. (zone 3 온도 : 875°C, belt speed : 115 ipm)
Fig. 9. Response surface plot with fixed sensitive parameters. (zone 3 temp. : 875°C, belt speed : 115 ipm)

그림 8을 보면 zone 3를 830°C, belt speed를 115 inch/min로 고정 하였을 때, zone 1과 zone 2가 온도가 모두 low일 때 효율 높은 것을 볼 수 있다. 그림 9을 보면 zone 3를 875°C, belt speed를 115 inch/min로 고정 하였을 때, zone 1의 온도는 low value이고, zone 2의 온도는 middle 일 때 효율이 가장 높은 것을 볼 수 있다.

그림 8과 그림 9의 효율 최고점의 차이는 0.02% 차이로 그림 8의 조건이 좋게 나왔지만, 큰 차이는 나지 않았다.

이러한 신경망 모델을 이용하여 효율을 최대화로 하기 위하여 공정 파라미터 조건값을 최적화 하였으며, 이를 위해 유전자 알고리즘 (GA)을 사용하였다. 유전자 알고리즘에 사용된 파라미터는 표 8과 같다.

표 8. 유전자 알고리즘의 파라미터.
Table. 8 Parameters of genetic algorithm.

Weights	1.0
Desired	20
Population	100
Max Generation	400
Minimum Error	0.05
Probability of Crossover	0.65
Probability of Mutation	0.01

유전자 알고리즘으로 최대의 효율이 나올 수 있는 공정 파라미터 조건 (recipe)은 표 9와 같다.

표 9. 유전자 알고리즘 (GA)를 이용하여 구한 최적 공정 파라미터 조건.

Table. 9 Optimal recipes using genetic algorithm.

zone 1	zone 2	zone 3	belt speed	efficiency
557.243	821.454	846.524	117.613	15.813
560.055	821.455	846.126	116.040	15.805

IV. 결 론

실험 계획법 (DOE)을 이용하여 특징적인 공정파라미터의 조건들을 실험계획법을 사용하여 실험 횟수를 줄여 실험에 소요되는 시간과 비용을 절약할 수 있었으며, 그 실험에 의해 만든 신경망 모델링으로 예측하여 많은 실험을 한 것과 유사한 효과를 얻을 수 있었다.

향후 과제로는 유전자 알고리즘을 통해 찾게 된 공정파라미터 조건 (recipe)을 사용하여 효율이 최대가 되는지에 대한 검증 실험을 해야 하는 것과, 또한 효율을 최대로 증가 시킬 수 있도록 최적공정의 민감도 (sensitivity)와 재현성 (reproducibility)에 대한 연구가 진행되어야 할 것이다.

감사의 글

이 연구는 2006년도 한국학술진흥재단의 지원을 받아 수행된 연구임. (KRF-2006-013-D00242)

참고문헌

- [1] S. Arimoto, M. Nakatani, Y. Morikawa, M. Hayashi, H. Namizaki, and K. Namba, "Simplified mass-production process for 16% efficiency multi-crystalline Si solar cells," in Proc. IEEE Photovoltaic Specialists Conference., Anchorage, AK., 2000, pp. 188-193.
- [2] J. Rentsch, J. Jaus, K. Roth and R. Preu, "Economical and ecological aspects of plasma processing for industrial solar cell fabrication," in Proc. IEEE Photovoltaic Specialists Conference., Jan. 3-7, 2005, pp. 931-934.
- [3] 김윤곤, "인류의 석유문명 붕괴에 대비한 재생에너지,"

풍력발전·태양전지·조력발전 시설의 발전 동향 분석," 한국과학기술정보연구원, 2005년.

- [4] J. H. Nijjs, J. Sclufcik, J. Poortmans, S. Sivoththanam, and R. P. Mertens, "Cost Effectiveness of High Efficiency Cell Processes As Applied to Cast Polycrystalline Silicon," in Proc. IEEE Photovoltaic Specialists Conference., Kissimmee, FL., May. 21-25, 1990, pp. 221-226.
- [5] M. M. Hilali, A. Rohatgi, "A Review and Understanding of Screen-Printed Contact and Selective-Emitter Formation," in Proc. NREL Workshop in crystalline Silicon Solar Cells and Modules., Winter Park, CO, Aug. 8-11, 2004.
- [6] 박성현, "현대실험계획법," 민영사, 2004.
- [7] S. Han, L. Cai, G. May and A. Rohatgi, "Modeling the Growth of PECVD Silicon Nitride Films for Solar Cell Applications Using Neural Networks," IEEE Trans. Semi. Manufac., vol. 9, pp. 303-311, August 1996.
- [8] D. Goldberg, "Genetic Algorithms in Search, Optimization & Machine Learning," Addison Wesley, 1989.
- [9] S. Narasimha and A. Rohatgi, "Optimized Aluminum Back Surface Field Techniques for Silicon Solar Cells," in Proc. IEEE Photovoltaic Specialists Conference., Anaheim, CA., 29 Oct 1997, pp. 63-66.
- [10] M. Hilali, A. Rohatgi and S. Asher, "Development of Screen-Printed Silicon Solar Cells With High Fill Factors on $100\Omega/\text{sq}$ Emitters," IEEE Trans. Electron Devices., vol. 51, pp. 948-955, June. 2004.

저자소개



정 세 원(Se-Won Jung)

명지대학교 전기정보제어공학부 학사
명지대학교 정보공학과
차세대전력기술연구센터 연구원

※ 관심분야: 태양전지, 반도체 설계, SoC, 인공지능



이 성 준(Sung-Joon Lee)

명지대학교 전자공학과 학사
명지대학교 전자공학과
Georgia Institute of Technology, 객원
연구원

※ 관심분야: 태양전지, SPC, 반도체 공정, 인공지능



홍 상 진(Sang-Jeen Hong)

명지대학교 제어계측공학과 학사
Georgia Institute of Technology, M.S.
Georgia Institute of Technology, Ph. D.
일본 동북대학교 외국인 특별 연구원
명지대학교 전자공학과 조교수 (현재)
명지대학교 IT중점연구소 연구원 (현재)

※ 관심분야: 태양전지, 반도체 공정, APC, 인공지능



한 승 수(Seung-Soo Han)

연세대학교 전기공학과 학사
연세대학교 전기공학과 석사
Georgia Institute of Technology, Ph. D.
명지대학교 정보공학과 부교수 (현재)
차세대전력기술연구센터 연구원 (현재)
명지대학교 IT중점연구소 연구원 (현재)

※ 관심분야: 반도체 공정, APC, 신경망 및 인공지능