

유전 알고리즘을 이용한 다중 양자 우물 구조의 갈륨비소 광수신소자 공정변수의 최적화

Optimization of Device Process Parameters for GaAs/AlGaAs Multiple Quantum Well Avalanche Photodiodes Using Genetic Algorithms

김의승*, 오창훈*, 이서구*, 이봉용*, 이상렬*, 명재민**, 윤일구*
(Eui-Seung Kim*, Changhoon Oh*, Seogoo Lee*, Bongyong Lee*, SangYeol Lee*,
JaeMin Myoung**, Ilgu Yun*)

Abstract

In this paper, we present parameter optimization technique for GaAs/AlGaAs multiple quantum well avalanche photodiodes used for image capture mechanism in high-definition system. Even under flawless environment in semiconductor manufacturing process, random variation in process parameters can bring the fluctuation to device performance. The precise modeling for this variation is thus required for accurate prediction of device performance. This paper will first use experimental design and neural networks to model the nonlinear relationship between device process parameters and device performance parameters. The derived model was then put into genetic algorithms to acquire optimized device process parameters. From the optimized technique, we can predict device performance before high-volume manufacturing, and also increase production efficiency.

Key Words : Genetic Algorithms, Photodiode, Neural Networks, Multiple Quantum Well

1. 서론

다중 양자 우물 구조의 갈륨비소 광수신소자는 고선명도 시스템의 영상 포착 메커니즘에 사용하기 위하여 개발되었다 [1]. 영상 포착 단계에서 매우 민감한 추출이 가능하기 위해서는 광수신소자가 충분한 광학적인 이득을 가져야만 한다. 동시에 추출 동안에 얻어진 이득은 추가적인 잡음에 영향을 주지 않아야 한다. 따라서 광수신소자들은 큰 이득과 작은 잡음을 갖도록 제조되어진다. 실제적인 반도체 제조 공정에 있어서 공정변수의 변위가 개개 소자의

성능 변화에 끼치는 영향을 분석하는 것이 중요하다. 결함이 거의 없는 공정 환경일지라도, 광수신소자 제조공정의 예상할 수 없는 여러 공정변위가 소자 성능에 많은 변화를 가져온다. 제조 공정상의 작은 변화는 항상 치명적인 고장을 가져오지는 않더라도, 때때로 시스템의 요구사항을 만족시키지 못하는 경우가 있다[2]. 특히 이러한 소자들은 하나하나씩 제조되어지는 것이 아니라 대규모로 제조되어지기 때문에 소자 모델의 확률적 분포가 매우 중요하게 여겨지는 것이다. 이러한 이유로 소자의 개발에 있어서 생산자들이 설계단계 초기에 통계적인 분포를 고려하는 것은 매우 중요하다.

본 논문은 다중 양자 우물 구조의 갈륨비소 광수신소자에 있어 모델링을 통한 최적화 방법을 제시한다. 우선, 각각의 공정 변수들의 확률적인 분포를 반영하는 모델을 신경망을 이용하여 찾아낸다. 다음으로, 측정되어진 데이터와 소자성능 모델간의 상관관

* : 연세대학교 전기전자공학과

** : 연세대학교 금속공학과

(서울 특별시 서대문구 신촌동 134

Fax: 02-362-6444, E-mail : iyun@yonsei.ac.kr)

2001년 1월 15일 접수, 2001년 2월 14일 1차심사완료

2001년 2월 21일 2차심사완료

계를 유전 알고리즘을 통해 최적화 시키고, 마지막으로 최적화된 소자공정 변수들을 컴퓨터 시뮬레이션을 이용하여 검증하였다.

이러한 최적화 기법은 많은 소자 설계 조건과 생산성과의 관계를 이해할 수 있게 하며, 비교적 작은 집합의 시험 구조를 제조하여 소자 성능에 관한 정보를 예측할 수 있게 한다. 이 장점들은 결국 대량 생산 전의 소자 성능의 예측을 가능하게 하여 소자 설계 및 제조의 능력을 향상시킨다. 이 방법을 다중 양자 우물 구조의 광수신소자에 적용하면 적은 수의 시험 소자들만을 이용하여 수광직경(active diameter), 장벽너비(barrier width) 및 도핑 농도와 같은 소자공정 변수를 예측하여 이득 또는 잡음과 같은 원하는 광수신소자의 성능을 얻을 수 있다.

2. 소자 구조

본 연구에서 이용할 광 다이오드의 구조는 그림 1에 나타나 있다. 이 광수신 소자는 P-I-N의 기본구조로 되어있으며, 1 μ m 두께의 베릴륨(Be)으로 도핑된 p+층과 1.5 μ m 실리콘으로 도핑된 n+층으로 구성된다 [3]. 다중 양자 우물 구조의 광수신소자 진성층(intrinsic layer) 부분의 도핑장벽에 있어서, 1~3 μ m 두께를 갖는 GaAs/AlGaAs 다중 양자 우물 고조는 양자장벽과 양자우물이 10주기로 구성되어 있다.

소자들은 포토리소그래피(photolithography) 기술을 이용하여 수광직경이 75~200 μ m를 갖는 매사구조로 이루어진다.




그림 1. GaAs/AlGaAs MQW APD의 단면도.

Fig. 1. Cross Section of GaAs/AlGaAs MQW APD.

3. 신경망 모델링 방법론

3.1 실험 계획법 (Experimental Design)

광 수신소자의 성능 변수인 이득과 잡음 특성에 영향을 끼치는 4개의 입력 변수와 그 값의 범위를 표 1에 요약하였다.

표 1. 실험 계획법을 위한 입력 변수와 값의 범위.

Table 1. Input factors and their ranges.

Parameter	Abbreviation	Range
Active Diameter	AD	75~200 [μ m]
Barrier Width	BW	200~800 [μ m]
Mean Doping	MD	10^{17} ~ 10^{18} [cm^{-3}]
Standard deviation of Doping	SD	0.1~2 [10^{17}cm^{-3}]

각각의 범위는 소자공정 상에 쓰인 여러 동작조건을 설명할 수 있게 선택되어졌다. 통계실험적 방법을 위한 가능한 많은 접근방법 중 위에서 정의한 입력변수 범위에서의 이득과 잡음변위를 특성화하기 위해 D-optimal 실험계획법을 선택하였다 [4]. 이 입력 변수들은 각각의 범위 안에서 변해가면서 그 시스템의 특성을 최대한 표출하기 위한 조합들로 이루어져 있으므로 시스템의 비선형적 관계의 모델링에 있어 신뢰성을 주게 된다.

3.2 신경망 모델링 (Neural Network Modeling)

위에서 설명한 광 수신 소자의 소자 공정변수와 소자 성능변수 사이의 관계를 모델링 하기 위하여 신경망을 사용하였다. 신경망은 다수의 입력과 다수의 출력 관계를 갖는 미지의 선형 혹은 비선형 시스템을 제한된 수의 실제 입출력 값을 바탕으로 만족할 만한 시스템 특성을 갖는 일반적 모델을 구하는 기법이다 [5]. 이러한 기법은 여러 연구자에 의하여 반도체 공정 또는 소자 모델링에 성공적으로 응용되고 있다 [6][7].

일반적인 feed-forward 신경망 구조를 그림 4.2에 나타내었다. 그 구조는 입력층, 은닉층, 출력층으로 구분되어져 있다. 입력 변수들이 입력층의 뉴런에 공급되고 그 뉴런에 각각의 Weight와 Bias를 곱하여 은닉층에 전달한다. 은닉층에는 여러 개의 은닉 뉴런(hidden neuron)이 들어있는데 각각의 뉴런은 입력층으로부터 여러 개의 입력 값을 받아서 합하고 그 값을 시그모이드(sigmoid) 함수를 이용하여 필터링 한 뒤 출력층의 뉴런에 각각의 Weight와 Bias를 곱하여 전달한다. 은닉층은 여러 개의 층으로 구성 되어질 수도 있다. 본 연구에서는 귀환전달학습(back propagation training)을 이용하여 모델링을 수

행하였다.

신경망에서 모델링 할 소자의 수광직경(diameter), 도핑(mean doping), 도핑 편차(standard-deviation of doping), 장벽 너비(barrier width)에 대한 소자의 성능(즉, 이득과 잡음) 값들은 ATLAS simulator를 이용하여 만들어냈다. 여기서 이득지표(G: gain index)는 GainReverse bias 곡선에서 항복 전압(breakdown voltage)까지의 곡선 아래부분의 면적으로 정의하고, 잡음지표(N: noise index)는 전자와 정공의 Impact Ionization Rate의 비로 정의하였다.

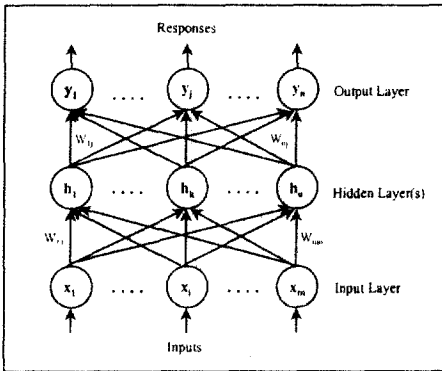


그림 2. 기본적인 feed-forward 신경망 구조.
Fig. 2. Typical feed-forward neural networks.

본 연구에서는 신경망을 이용한 모델링을 수행하기 위해 매트랩(MATLAB)이라는 소프트웨어 패키지를 이용하였다[8]. 신경망이 시스템 특성을 잘 표현하는지 확인하기 위해 실험 데이터를 이용하여 신경망 모델을 검증하고자 하였으나 한정된 실험 데이터를 보완하기 위해 시뮬레이션을 이용하였다. APD 시뮬레이션의 목적은 시뮬레이션 되어진 데이터를 사용하여 제조 공정에 따른 APD의 이득과 잡음에 대한 영향을 이해하는 것이다. 계산된 출력 데이터가 충분히 실험치에 근사화 되었는지를 알아보기 위해 정교한 시뮬레이션이 필요하다. APD 시뮬레이션은 ATLAS II 소자 시뮬레이션 프로그램으로 수행되었다. 이 도구는 다중 양자 우물 구조의 광수신 소자를 시뮬레이션 하기에 적당하다.

ATLAS 모델을 간단히 하고 프로그램 수행 시간을 단축시키기 위하여, 시뮬레이션 될 구조를 고려하여 다음과 같은 가정을 하였다. 1) 모든 소자는 사각형(rectangular)구조를 갖는다. 2) Shockley-Reed-Hall 재결합(recombination)과 Auger 재결합만이 고려된다. (광, 표면 재결합은 무시한다.) 3) PN 접합은 완벽한 오믹(Ohmic) 접합이다. 4) MQW 도핑

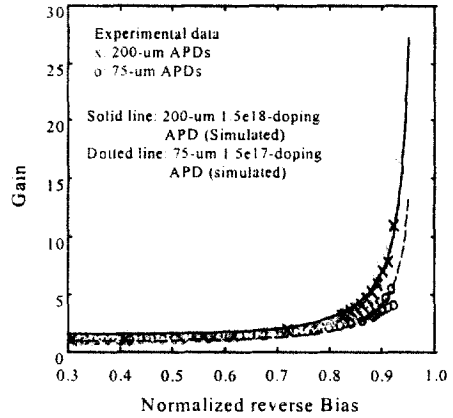


그림 3. 다중 우물 구조 광수신소자 이득의 실험치와 시뮬레이션 값의 비교[10].
Fig. 3. Comparison of experimental and simulated data of gain index for APDs.

불균형은 전체 구조에서 상수로 취급한다. 5) AlGaAs에서의 bandgap narrowing의 영향은 GaAs에서와 비슷하다. [9]

앞선 연구에서 시뮬레이션 된 I-V 곡선과 실험 데이터의 I-V 곡선이 그림 3에서와 같이 잘 일치하고 있는 것을 보여주고 있다[10]. 그러므로 소자의 특성화를 실험 데이터 대신 시뮬레이션 데이터로 모델링 하겠다.

3.3 최적화 기법 - 유전 알고리즘

유전 알고리즘은 진화에 근거를 둔 하나의 계산적 모델링으로 분류된다. 과거 수년 동안 유전 알고리즘은 산업체의 여러 분야에서 그 응용 가능성이 증명되었다 [11]. 이 알고리즘은 최초로 랜덤하게 결정된 입력 변수 값에서 출발하여 유전 조작인 재생산(reproduction), 교배(crossover), 변이(mutation)를 이용하여 정한 변수 범위 내에서 원하는 출력 변수 값을 얻도록 효과적으로 입력 변수 공간을 탐색한다. 이러한 특성 때문에 지역적인 최소값 또는 최대값에 빠질 가능성을 배제할 수 있다.

재생산은 여러 개의 생성된 스트링 중에서 원하는 결과에 가까운 값을 내는 스트링일수록 적합함수의 값(fitness value; Fi)에 큰 값을 부여 받게 되고 이 적합치가 큰 스트링 일수록 다음 세대에 다른 스트링들보다 자신과 같은 스트링을 더 많이 만들어 낼 수 있다. 적합함수는 식(1)과 같이 주어진다.

$$F_i = \frac{1}{1 + \sum_j (V_{meas} - V_{model})^2} \quad (1)$$

즉, 유전자와 같은 적자 생존이 이루어져서 더욱 적합한 결과를 산출하는 입력 스트링 일수록 더 많은 후손을 남기게 되는 것이다. 이렇게 후손 스트링(offsprings)들이 재생산 되면 교미방(mating pool)이라는 곳으로 저장되어 교배와 변이를 기다린다. 전형적으로 교배는 0.6~0.95, 변이는 0.001~0.01 사이의 확률을 가지고 발생된다. 교배는 두 개의 스트링이 교배지점(cross over point)에서 잘라져 교환되어, 새로운 스트링을 생성하는 것이고 변이는 임의의 한 값이 바뀌는 것을 말한다.

4. 결과와 토의

소자 공정변수와 소자 성능변수간의 관계를 신경망을 이용하여 모델링 하였다. 사용한 신경망은 3개의 층으로 구성되어 있으며 4개의 입력 뉴런, 11의 은닉 뉴런 및 2개의 출력 뉴런으로 이루어져 있다. 신경망 모델링을 효율적으로 하기 위해 4개의 입력 변수값의 범위를 스케일링 하였고, 4개의 입력과 하나의 출력력을 갖는 신경망 2개를 각각의 출력값들에 대

하여 모델링 하였다. 실험 계획법에 있는 31개의 입력변수집단 중에 24개의 입력변수집단은 신경망을 학습시키는데 사용하였다. 나머지 7개의 입력변수집단은 구현된 신경망이 입출력 관계를 일반화 하는 모델인지를 테스트하기 위해 사용하였다.

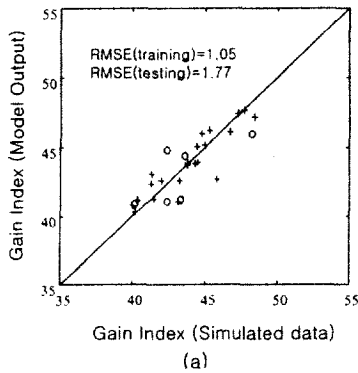
그림 4를 보면 각각 이득과 잡음에 대한 시뮬레이션 값과 신경망 모델을 통하여 얻은 값을 그림으로 표시하고 있다. + 표시는 신경망 학습이 이루어진 모델의 입력변수집단의 값과 시뮬레이션 값을 나타내고 있고, o 표시는 7개의 입력변수집단이 또한 얼마나 시뮬레이션 값과 가까운지를 나타내고 있다. 이득모델의 경우 학습 RMSE(Root Mean Square Error)는 1.05이고 테스트 RMSE는 1.77이었다. 한편 잡음모델의 경우 학습 RMSE는 0.035이고 테스트 RMSE는 0.073이었다. 이 결과에서 신경망 모델은 신뢰할 수준의 에러를 보여준다.

위에서 찾아낸 이득과 잡음 신경망 모델에 대하여 유전 알고리즘을 적용하여 원하는 출력 값을 찾는 시뮬레이션을 수행하였다. 검증용 위한 소자 성능변수인 이득지표(gain index)와 잡음지표(noise index)를 각각 45와 15로 하여 유전 알고리즘을 수행하였다. 유전 알고리즘을 수행하여 최적화된 결과를 표 2에 나타내었다.

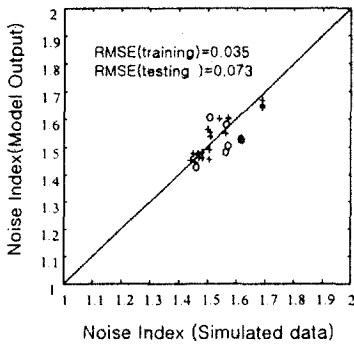
표 2. 유전 알고리즘 최적화 결과.

Table 2. Optimized results using GAs.

Optimized Input Set	AD [μm]	BW [\AA]	MD [10^{17}cm^{-3}]	SD [unitless]	Fitness Value
Set 1	120	500	8.70	1	0.996
Set 2	150	720	5.40	1	0.999



(a)



(b)

그림 4. 신경망 모델링 결과: (a) 이득지표 및 (b) 잡음지표

Fig. 4. Neural network modeling results :

(a) Gain index and (b) Noise index.

이 결과는 적합 함수값이 0.995 이상으로 최적화된 것이며, 여기서 서로 다른 두 입력 변수 조건들이 원하는 이득지표와 잡음지표를 얻을 수 있는 변수들이 된다. 이 최적화된 값이 시뮬레이션 또는 실제의 실험 결과로 확인이 된다면, 찾아낸 모델과 또한 그 안에서 찾은 입력 조건들(4가지의 소자 공정변수)로 원하는 출력력을 얻어낼 수 있다.

표 2의 최적화 결과를 ATLAS simulator를 이용하여 소자의 이득지표와 잡음지표를 계산하고 그 결과를 표 3에 나타내었다. 시뮬레이션으로 얻은 이득지표와 잡음지표는 최적화하고자 하는 값에 비해 얼마간의 오차를 가지고 있음이 확인되었다. 이러한 오차는 실제 반도체 공정 중에 발생하는 공정변수의 변위가 소자 성능변수에 영향을 미치는 것에 기인하

며, 본 연구에서 이용한 신경망 모델 자체가 가지고 있는 오차와 비선형 시스템의 모델링 과정에서 발생하는 오차가 공정변수의 변위를 야기시키는 원인이 된다.

표 3. 유전 알고리즘 최적화 검증결과.

Table 3. Verification of GA optimized results.

Optimized Input Set	Device Performance Parameter	
	Gain Index	Noise Index
Set 1	45.103	1.482
Set 2	44.448	1.501

따라서 이러한 결과로부터 공정변수의 변위가 성능변수에 끼치는 영향을 알 수 있었으며 원하는 소자 성능을 얻기 위해서는 공정제어를 통하여 가능한 한 소자 제작공정에서 발생하는 변위를 최소화하는 것이 필요하다.

5. 결 론

지금까지 다중 양자 우물 구조의 갈륨비소 광 수신 소자의 공정변수(수광직경, 장벽너비, 도핑농도)와 성능변수(이득, 잡음) 간의 비선형적 시스템을 신경망을 이용하여 모델링 하였고, 그 모델링 된 결과를 유전 알고리즘을 적용하여 얻고자 하는 이득지표와 잡음지표를 만족시키는 소자 공정 변수를 찾아내는 방법론을 제시하였다. 유전 알고리즘을 이용하여 얻은 최적화된 결과는 ATLAS simulator를 이용하여 검증되었고, 그 결과 공정변수 변위를 고려할 경우 원하는 이득지표와 잡음지표를 얻을 수 있는 공정 조건을 제시 하였다.

이 방법론은 비단 특정 광수신소자뿐 아니라 여러 가지 비선형적 공정 관계를 가지고 있는 반도체 소자의 공정변수 및 성능변수 최적화에의 응용 가능성을 제시한다. 이 방법론을 이용하여 수 많은 입력 조건과 비선형적이고 불확실한 실제의 반도체 공정을 통계적으로 모델링 할 수 있으며, 그러한 소자 공정변수 중에서 어느 것이 소자 성능변수에 더 큰 영향을 끼치는지도 알 수 있다. 본 연구의 결과를 토대로 볼 때 소자 공정변수 변위와 소자 성능변수 간의 관계를 알 수 있었으며 보다 나은 성능 및 생산성을 가진 소자를 제작하기 위해서는 공정제어를 통한 공정변수 변위의 최소화가 필요하다.

감사의 글

본 연구는 2000년도 연세대학교 교내 연구비 지원에 의해 수행되었습니다.

참고 문헌

- [1] I. Yun, et al., Effect of Doping on the Reliability of GaAs Multiple Quantum Well Avalanche Photodiode, *IEEE Trans. Semic. Manufac.*, Vol. 44, pp. 535-544, 1997.
- [2] I. Yun, Examination of Diffusion Process for High-speed Avalanche Photodiode Fabrication, *J. KIEEME*, Vol. 13, No. 11, pp. 954-958, 2000.
- [3] P. Aristin, et al., New Doped Multiple Quantum Well Avalanche Photodiode: The doped-barrier Al(0.35)Ga(0.65)As/GaAs multiple quantum well avalanche photodiode, *Appl. Phys. Lett.*, Vol. 60, No. 1, pp. 85-87, Jan. 1992.
- [4] G. Box, W. hunter, and J. Hunter, *Statistics for Experimenters*. New York: Wiley, 1978.
- [5] A. Freeman, and D. M. Skapura, *Neural Networks : Algorithms, Applications, and Programming techniques*, New York: Addison-Wesley, 1992.
- [6] H. J. Lee, Physical and Circuit Modeling of Inductive Characteristic for a Non - Hydrogenated Amorphous SiC / Si Heterojunction Diode , *J. KIEEME*, Vol. 1, No. 1, pp. 6-10, 1996.
- [7] H. C. Cho, et al., - D Underwater Object Restoration Using Ultrasonic Transducer Fabricated with Porous Piezoelectric Resonator and Neural Network, *J. KIEEME*, Vol. 9, No. 8, pp. 6-10, 1996.
- [8] *MATLAB Users Guide*, The Math Works, Inc., 1992.
- [9] *ATLAS Users manual*, Silvaco Int'l, 2000.
- [10] I. Yun, et al., Evaluation the Manufacturability of GaAs/AlGaAs Multiple Quantum Well Avalanche Photodiodes Using Neural Networks, *IEEE Intl Elec. Manufac. Conf.*, pp. 105-112, 1997.
- [11] J. F. Frenzel, Genetic Algorithms. *IEEE potentials*, Oct. 1993, pp. 21-24.