

제 1 차 년 도  
연 차 보 고 서

신경회로망을 이용한 광 패턴인식 기술에 관한 연구

Studies on Optical Pattern Recognition  
using the Neural Networks

연 구 기 관  
한 국 과 학 기 술 원

과 학 기 술 처

## 제 출 문

과학기술처 장관 귀하

본 보고서를 “신경회로망을 이용한 광 패턴인식 기술에 관한 연구” 과제의 연  
차보고서로 제출합니다.

1993. 10. 25

주관연구기관명 : 한국과학기술원

총괄연구책임자 : 이 수 영

연구책임자 및 연구원 : 이수영 : 이혁재

이만규

신상영 : 신상길

이용희 : 하경호

박철훈 : 박래정

# 여 백

## 요 약 문

최근 VLSI 기술이 매우 발전하여 신경회로망을 반도체 칩으로 구현하는 시도가 있지만, 초 대규모 구현이 어려운 형편이다. 빛은 본질적으로 2 차원 신호를 처리하고, 푸리에 변환과 병렬처리 알고리즘에 적합하기 때문에, 대규모 패턴인식에 빛을 사용하는 것은 많은 장점을 제공한다. 그러나, 광신호 처리를 하기 위한 특수 소자의 제작과 광학적 구현에 적합한 패턴인식 모델이 뒷받침 되어야 한다.

본 과제에서는 고성능의 패턴/문자 인식 기술이 정립되고, 그것에 관한 효율적인 광시스템 설계가 이루어 진다. 그리고, 광 시스템의 핵심 소자를 지능적으로 구현하는 기술도 또한 연구한다.

# 여 백

## SUMMARY

Although the semiconductor chip for the neural network model has been made due to recently well-developed VLSI technology, it is very difficult to implement super large-sized system. On the contrary light inherently deals with 2-dimensional input/output signal. Fourier transform and parallel processing algorithms can be easily built with light, and accordingly optics approach for large-sized pattern recognition have been much advantages. But, the fabrication of the sophisticated device for optical signal processing is needed. The pattern recognition model circumventing limitations and rigidity of hardware have to be supported.

In this research we have investigated the neural network model for the pattern/character recognition with high performance, and the architecture of its optical system has been proposed. Also, Active optical logic device for the compact system is designed.

# 여 백

## CONTENT

Chapter 1	Preface .....	1
1.	Project Goal .....	1
2.	Research Scope .....	2
Chapter 2	SOFFA Neural Network Model .....	3
1.	Design Concept .....	3
2.	Local Feature Extraction .....	3
3.	Fuzzy Reduction Transform .....	12
4.	Multi-layer Perceptron .....	15
5.	Simulation Result .....	20
6.	Conclusion and Further Works .....	29
Chapter 3	Design of Optical SOFFA Neural Network .....	31
1.	Optical Implementation of Local Feature Extraction .....	31
2.	Optical Implementation of Fuzzy Reduction Transform .....	34
3.	Optical Implementation of Multi-layer Perceptron .....	37
Chapter 4	Active Optical Logic Device .....	77
1.	Background .....	77
2.	Characteristics of Active Optical Logic Device .....	84
3.	Further Works .....	110
Chapter 5	Conclusion .....	113

# 목 차

제 1 장	서론	1
1.	연구 목표	1
2.	연구 내용	2
제 2 장	SOFFA 신경회로망 모델	3
1.	기본 방향	3
2.	국부 특징 추출	3
3.	퍼지 축약 변환	12
4.	다층 인식자 모델	15
5.	시뮬레이션 결과	20
6.	결론 및 계속 연구과제	29
제 3 장	SOFFA 기법의 광학적 구현 시스템 설계	31
1.	국부 특징 추출의 광학적 구현	31
2.	퍼지 축약 변환의 광학적 구현	34
3.	다층 인식자의 광학적 구현	37
제 4 장	능동형 광학 연산 소자	77
1.	연구배경	77
2.	능동형 광학 연산 소자의 특성	84
3.	개선방향	110
제 5 장	결론	113

# 제 1 장 서 론

## 1. 연구목표

1980년 중반에 Fahrat 등이 Hopfield 모델의 전기 광학적 구현을 처음 수행한 후에, 광 신경회로망을 이용한 패턴 인식이 많이 연구 되고 있다. 생물학적 두뇌 작용을 모방하는 신경회로망은 적응 학습을 통해 복잡한 인식 경계를 형성하는데, 많은 수의 뉴론이 높은 연결 밀도로 연결되어 병렬적으로 작용함으로 광학적 구현에 적합하다.

본연구 과제의 목표는 “고성능의 광 패턴 인식 시스템의 구현 기술” 확립에 있다. 대용량 batch 처리가 가능한 고정확도의 시스템이며, 외부의 여러가지 잡음에 오염된 패턴을 인간과 비슷하게 인식할 수 있는 fault tolerance 기능을 갖는다. 시스템의 하드웨어는 거의 모든 신호를 대규모 병렬성에 의한 초고속 처리가 가능하게 설계 되므로써, 기존의 패턴인식 시스템에서 발생하는 2 차원 영상의 입력 병목 현상이 제거된다. 따라서, 본연구에서는 위와 같은 여러 특징을 갖는 고성능의 광 문자 인식 시스템의 prototype 개발이 최종 목표가 된다.

## 2. 연구내용

연구의 내용은 크게 광 문자 인식 시스템의 구현을 위한 패턴 인식 기술, 광 시스템 기술, 그리고, 핵심 소자 기술로 나누어 진다. 패턴 인식 파트에서는 고 정확성을 갖는 대용량의 인식 기법이 연구되는데, 신경 회로망 기술및 일반 패턴 인식 기술을 토대로 고성능의 패턴/문자 인식 기술이 정립된다. 광 시스템 부문에서는 적응 광 신호 처리 기술과 대규모 광 연결 기술을 연구함으로써 효율적인 광 시스템을 구현한다. 그리고, 핵심 소자 부문에서는 광 신호 처리를 위한 융통성 있는 전기 광학 소자 (Smart Pixel) 기술을 연구한다.

## 제 2 장 SOFFA 신경회로망 모델

### 1. 기본방향

SOFFA(Self-Organizing Feature with Fuzzy Association) 신경회로망 모델은 국부 특징 추출, 퍼지 축약 변환, 그리고 인식의 3 개 모듈로 이루어졌다. 첫번째의 국부 특징 추출 모듈은 Fukushima가 제안한 Neocognitron의 전단부를 이용한다. Neocognitron은 계층적으로 이루어졌으며, 입력층에 가까운 층은 간단한 특징, 즉 수평, 수직 성분 등을 추출하도록 되어 있다. 두번째 모듈은 입력으로 들어오는 패턴이 위치 이동 및 변형에 둔감하도록 국부 특징 모듈로 부터 생성된 특징 패턴에 효율적인 퍼지 축약을 행하는 부분이다. 두개의 모듈을 지나면서 입력 패턴은 자기 자신을 나타내는 축약된 국부 특징 패턴으로 변환되고, 마지막 모듈에서는 다층구조 인식자(Multi-layer Perceptron)을 통하여 최종적인 인식을 행한다. 그림 1 에 SOFFA 신경회로망 모델의 전체적 구성도를 보였다.

### 2. 국부 특징(Local Feature) 추출

일본의 Fukushima에 의해 제안된 Neocognitron 모델은 크기와 위치 이동에 관계없이 패턴인식을 잘 수행할 수 있는 자율 신경회로망(Self-Organizing Neural Network)이다. 즉, 이모델은 지도자(Teacher) 없이 스스로가 패턴 그룹을 형성하여 인식 및 분류를 할 수 있다.

Neocognitron은 계층구조(Hierarchical Structure)를 가졌으며, 입

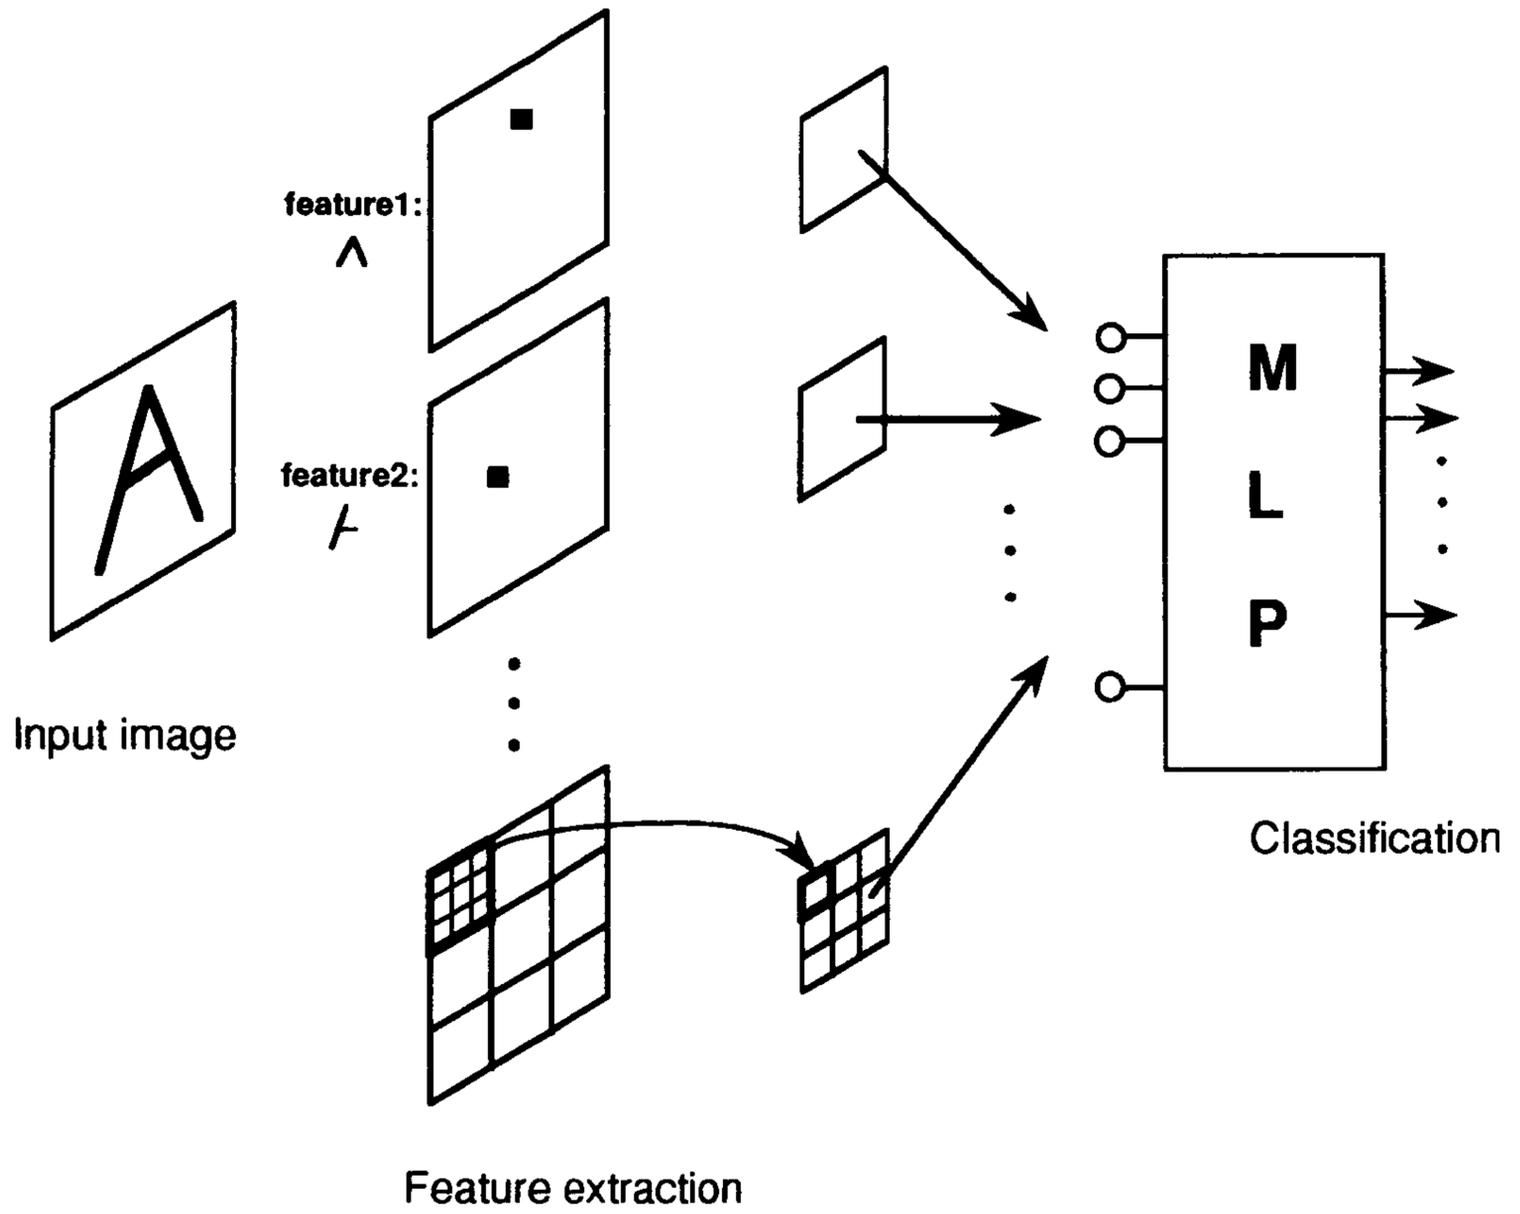


그림 1 SOFFA 신경회로망 모델의 구조

력층과 그 뒤에 여러 레벨(Level)로 이루어 졌다. 하나의 레벨은 Simple Cell(S-cells) 층과 Complex Cell(C-cells) 층의 두개 층으로 이루어 졌다. 그리고, 각 층은 여러개의 Plane으로 되어있다. 여러 레벨을 거치면서 위치및 크기에 불감해지고 입력 패턴의 여러 특징에 더 잘 응답하도록 되어진다. 따라서, 최종 레벨에서의 각 Cell은 어떤 특정한 패턴에만 응답되도록 된다.

그림 2 에 Neocognitron 모델의 전체적 구조를 나타냈다. 이 시스템의 첫번째 층에서 특징 추출(Feature Extraction)을 수행하기 때문에, 본 연구에서 수행하는 모델에 이것을 이용한다.

본 연구에서 사용한 국부 특징 추출 모듈의 구조를 그림 3 에 나타내었다. 출력층에서 하나의 Cell의 값은 다음과 같이 계산된다.

$$w = \phi \left[ \frac{1 + \sum_{i=1}^N a(i)u(i)}{1 + bv} - 1 \right] \quad (1)$$

여기서,

$$\phi(x) = \begin{cases} x & \text{만일, } x \geq 0 \\ 0 & \text{만일, } x < 0 \end{cases}$$

$u(1), u(2), \dots, u(N)$ 은 여기 입력(Excitatory Inputs)이고,  $v$  는 억제입력(Inhibitory Input)이다. 출력층의 어떤 화소(Pixel),  $(i_0, j_0)$ 을 생각하자. 이 출력 Plane을  $k$ 라 하고,  $w_k(i_0, j_0)$ 는  $(i_0, j_0)$  화소의 값이라 하자. 이 출력 Cell은 입력층의  $(i_0, j_0)$  화소 중심으로 둘러싼 면적  $S$  안의 Cell 들로 부터 상호연결(Interconnection)을 통하여 신호를 전달 받는

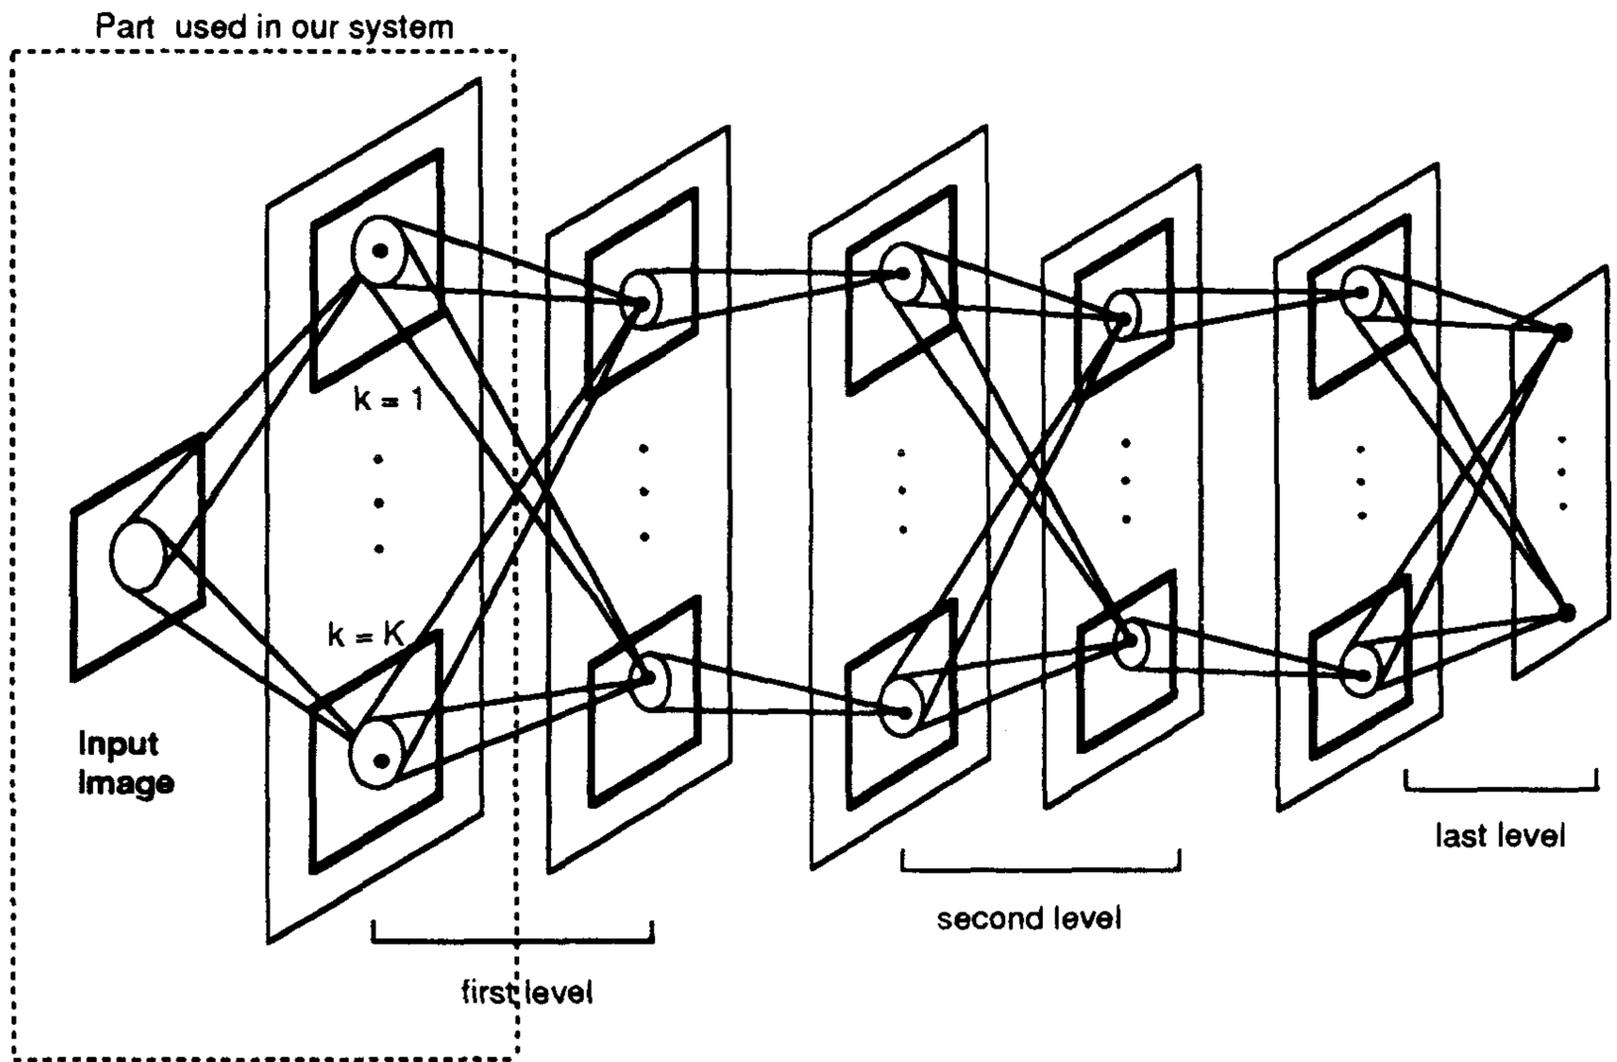


그림 2 Neocognitron의 전체적 구조

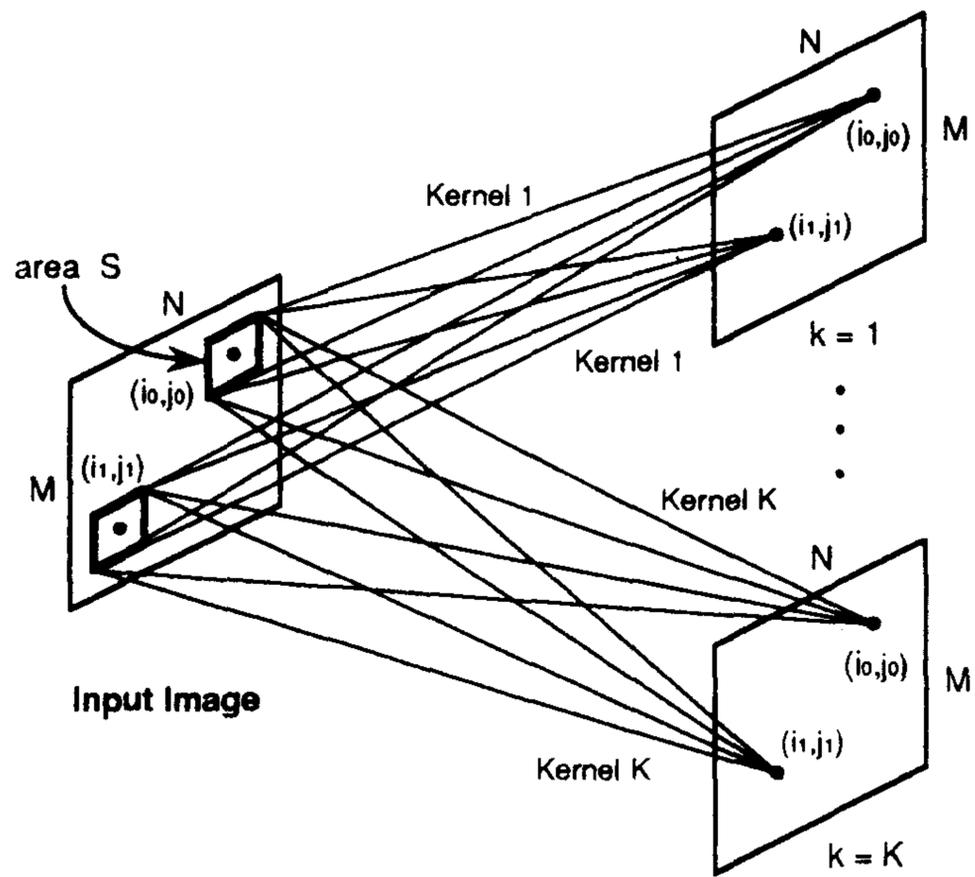


그림 3 국부 특징 추출의 원리

다. 위에서 언급한 동일 출력층의 모든 다른 Cell들도 똑같은 공간분포를 갖는 상호연결을 통하여 입력으로 부터 신호를 받는다.  $w_k$ 는 다음과 같이 주어진다.

$$w_k(i_0, j_0) = r \phi \left[ \frac{1 + \sum_{(\alpha, \beta)} a_k(\alpha, \beta) u(i_0 + \alpha, j_0 + \beta)}{1 + \frac{r}{1+r} b_k v(i_0, j_0)} - 1 \right] \quad (2)$$

여기서,

$$v(i_0, j_0) = \sqrt{\sum_{(\alpha, \beta) \in S} c(\alpha, \beta) u^2(i_0 + \alpha, j_0 + \beta)}$$

그리고,  $a_k$  와  $\beta_k$  는 각각 여기와 억제 입력을 나타내며, Cell  $w_k(i_0, j_0)$ 의 위치  $(i_0, j_0)$ 을 나타내는 인자(argument)가 없음을 주목바란다. 즉, 이 계수는 변수이다. 계수  $r$  은 억제입력의 효율을 의미한다. 만일, 큰  $r$ 을 취하면, 시스템은 더 선택적으로 되어서 유사한 패턴에 대해 잘 구분할 수 있는 능력을 갖게된다. 반대의 경우는 입력 패턴의 변형을 잘 흡수할 수 있게끔 한다.  $c(\alpha, \beta)$ 는 고정 여기 시냅스  $u(i_0 + \alpha, j_0 + \beta)$ 의 효율을 나타내며,  $|\alpha^2 + \beta^2|$ 의 단조 감소함수로 정해진다. 가변 상호연결의 학습은 다음과 같이 이루어 진다.

$$\Delta a_k = q c(\alpha, \beta) u(I + \alpha, J + \beta) , \quad (3)$$

$$\Delta b_k = q v(I, J) , \quad (4)$$

여기서,  $q$ 는 학습속도를 결정하는 양의 상수이다. 알고리즘은 다음과 같이 요약할 수 있다.

---

*For* (모든 입력 패턴) *do*

*For* (모든 출력 Cell) *do*

$w_k(i, j)$  와  $v(i, j)$ 을 계산

*End loop*

    출력값 중에 제일 큰 Cell(Representative)을 선정

*For* (all representatives) *do*

$\Delta a_k$  와  $\Delta b_k$ 을 계산

$a_k$  와  $b_k$ 를 조정

*End loop*

*End loop*

---

위의 알고리즘이 수렴해 감에 따라 상호연결 계수  $a_k$  와  $b_k$ 는 제한 없이 증가한다. 즉,  $\Delta a_k$  와  $\Delta b_k$ 는 '0'로 되지 않는다. 어떤 주어진 입력에 대해 시스템이 수렴할때 항상 똑같은 representative을 갖으며, 바로 전의  $\Delta a_k, \Delta b_k$ 는 현재의  $\Delta a_k, \Delta b_k$ 와 같게된다. 따라서, 이러한 현상이 발생하면, 시스템이 수렴하는 것으로 보고  $a_k$  와  $b_k$  값을 고정시킨다. 이와 같이 학습이 끝난 후에  $a_k$ 의 값은 시스템 스스로가 추출한  $K$  개의 출력 패

턴을 얻게 되며, 이 패턴은 '퍼지를 사용한 추약' 모듈로 전달된다.

Neocognitron의 전단부는 특별한 방향성을 갖는 국부 특징(Local Feature)을 추출하는 것을 담당하는데, 어떻게 동작하는지 알아보자. 출력에서의 Cell은 여기 입력과 그림 4 에서 보인 바와 같이 여기 입력의 효과를 줄이기 위해 고정 연결을 통하여 억제 입력을 동시에 받는다. 하나의 출력 Cell에 대해 다음과 같다.

$$w = r\phi\left[\frac{1 + \sum_i a_i u_i}{1 + \frac{r}{1+r}bv} - 1\right] \quad \text{with } \phi(x) = \begin{cases} x & \text{if } x \geq 0 \\ 0 & \text{if } x < 0 \end{cases} \quad (5)$$

만일,  $bv \neq 0$ 이면, 다음과 같이 쓸 수 있다.

$$w = \gamma\phi\left[\frac{\sum_i a_i u_i}{bv} - \frac{r}{1+r}\right], \quad (6)$$

$$\text{with } v = \sqrt{\sum_i c_i u_i^2} \quad \text{and } \gamma = (1+r) \frac{\frac{r}{1+r}bv}{1 + \frac{r}{1+r}bv}$$

여기서,  $b$ 는 일반적으로 학습후에 큰 값에 도달하고,  $\gamma \approx (1+r)$ 은 상수가 된다. 다차원 벡터 공간에서 분석해 보자.  $\vec{u} = (u_1, u_2, \dots)$ 은 입력 벡터이고,  $\vec{a} = (a_1, a_2, \dots)$  과  $\vec{c} = (c_1, c_2, \dots)$ 는 각각 가변 상호연결과 억제 입력을 위한 고정연결이라 하자. 두 벡터  $\vec{x}$  와  $\vec{y}$ 의 가중 내적(weighted inner product)과 norm을 각각 다음과 같이 정의한다.

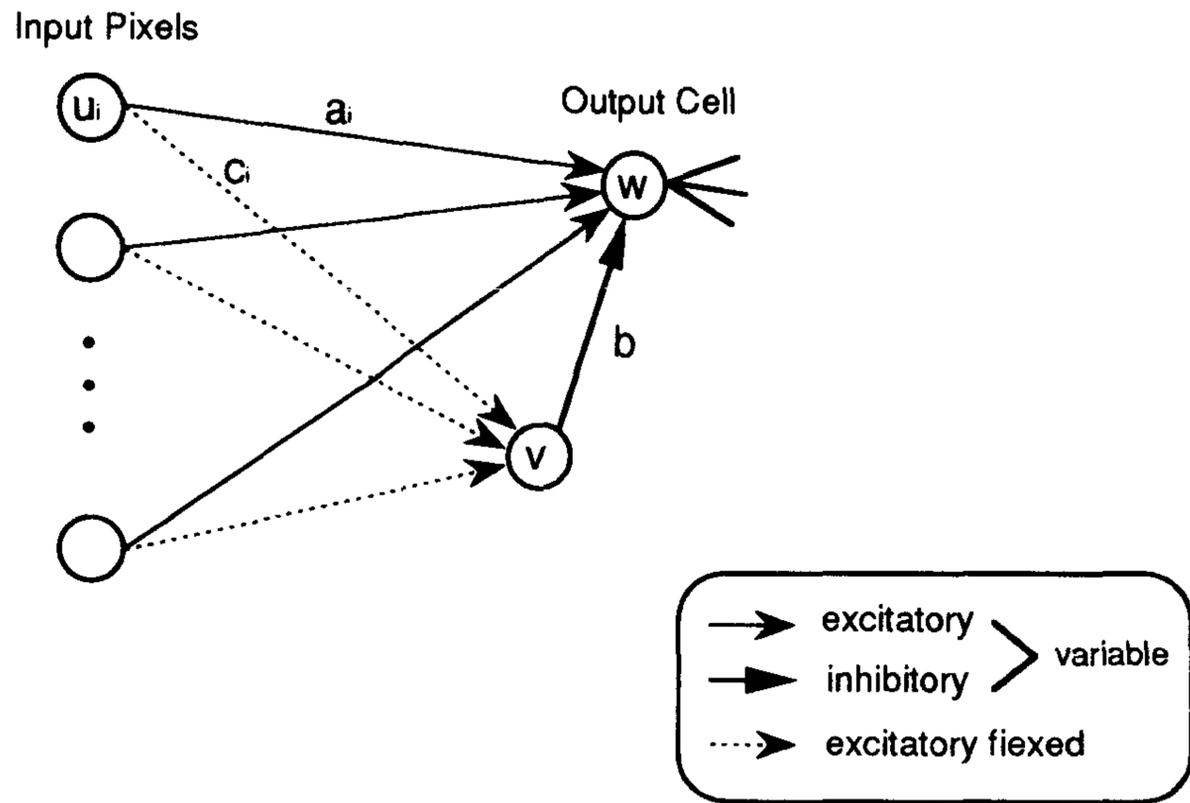


그림 4 한개의 출력 Cell 로의 상호연결 구조

$$(\vec{x}, \vec{y}) = \sum_i c_i x_i y_i, \quad (7)$$

$$\|\vec{x}\| = \sqrt{(\vec{x}, \vec{x})}, \quad (8)$$

벡터  $\vec{u}$ 가 입력 패턴이고,  $U = \sum_n \vec{u}^{(n)}$  이라 정의하자. 이때,  $(n)$ 은 각각의 패턴을 나타낸다. 그리고, 초기에  $\|\vec{a}\| = b = 0$  라 가정하자. 그러면, 다음이 얻어진다.

$$a_i = \sum_n q c_i u_i^{(n)} = q c_i U_i, \quad (9)$$

$$b = \sum_n q \sqrt{\sum_i c_i (u_i^{(n)})^2} = q \sum_n \|\vec{u}^{(n)}\|, \quad (10)$$

$$\sum_i a_i u_i = \sum_i q c_i U_i u_i = q (U, u), \quad (11)$$

$$bv = q \|\vec{u}\| \sum_n \|\vec{u}^{(n)}\|, \quad (12)$$

$$w = \gamma \phi \left[ \lambda s - \frac{r}{1+r} \right], \quad (13)$$

여기서,

$$\lambda = \frac{\|U\|}{\sum_n \|\vec{u}^{(n)}\|},$$

$$s = \frac{(U, \vec{u})}{\|U\| \|\vec{u}\|},$$

$s$ 는 두 벡터  $\vec{u}$  와  $U$  사이의 유사성을 나타내며, 학습이 끝난 후에  $\lambda$ 는  $\vec{u}$ 와 무관한 '0' 과 '1' 사이의 상수가 된다. 만일 입력 벡터  $\vec{u}$ 가  $U$ 와 완전히 같은 방향에 있다면,  $s$ 는 최대치에 도달함을 알 수 있다. 만일 그렇지 않다면,  $s$ 는 '1' 보다 작은 값이 된다. 식 (13)로 부터  $s > r/(1+r)\lambda$  일때  $w > 0$ 가 된다. 이것은 입력 벡터  $\vec{u}$ 의 방향이 그림 5의 빗금친 영역 안에 올때, Cell의 값이 양수를 나타낸다. 이 영역의 크기는 큰  $r$ 에 대해 작게 나타나며, 큰  $r$ 은 입력 패턴의 변형과 잡음에 작은 불감성을 준다.

### 3. 퍼지 축약 변환

이 모듈의 목적은 중요한 특징은 그대로 유지하면서 정보를 압축하여 전달하는데 있다. Neocognitron의 전단부를 사용하여 만든  $K$ 개의 feature plane 각각이 더 작은 패턴으로 변환된다. 이 변환을 설명하기 위해 다음과 같은 예를 들자. 하나의 feature plane이  $25 \times 25$  화소를 갖는 크기이고, 출력 패턴의 크기가  $5 \times 5$ 라 하자. 그림 6에 보인 바와 같이 입력 패턴의 한 부분이 하나의 출력 화소에 상응한다. 변환을 하는 방법으로 간단하게 생각할 수 있는 첫번째 방법은 입력 패턴의 변환영역  $(i, j)$ 에 포함된 화소 값의 합으로 출력 화소  $(i, j)$ 의 값을 정해주는 것이다. 그런데, 이와 같이 하면, 몇가지 문제가 발생한다. 두 변환 영역 경계에 있는 입력 패턴의 화소는 단지 출력 패턴의 어떤 한 화소에만 영향을 주게 된다. 이러한 문제를 해결하기 위해 일종의 퍼지 변환을 도입한다. 즉, 출력의 값은 입력 패턴의 모든 화소 값에 화소 사이의 거리에 따른 함수의

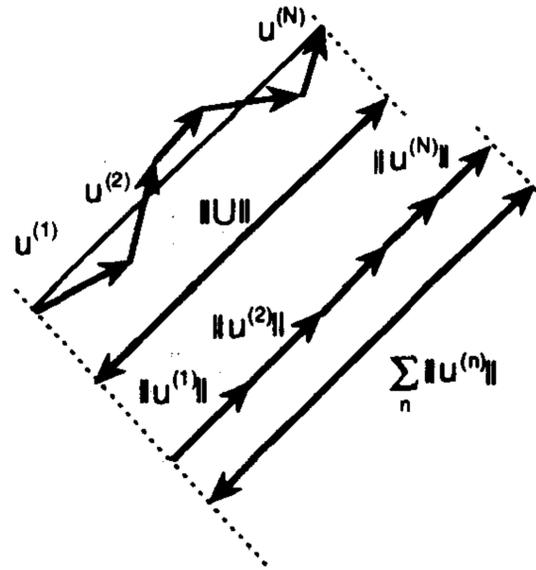
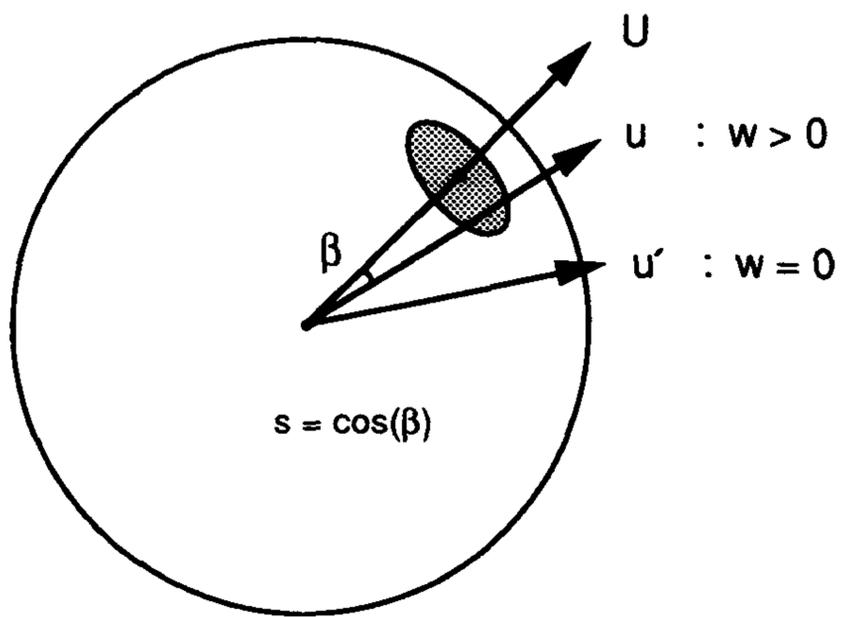


그림 5 삼차원 벡터 공간에서 패턴사이의 유사성

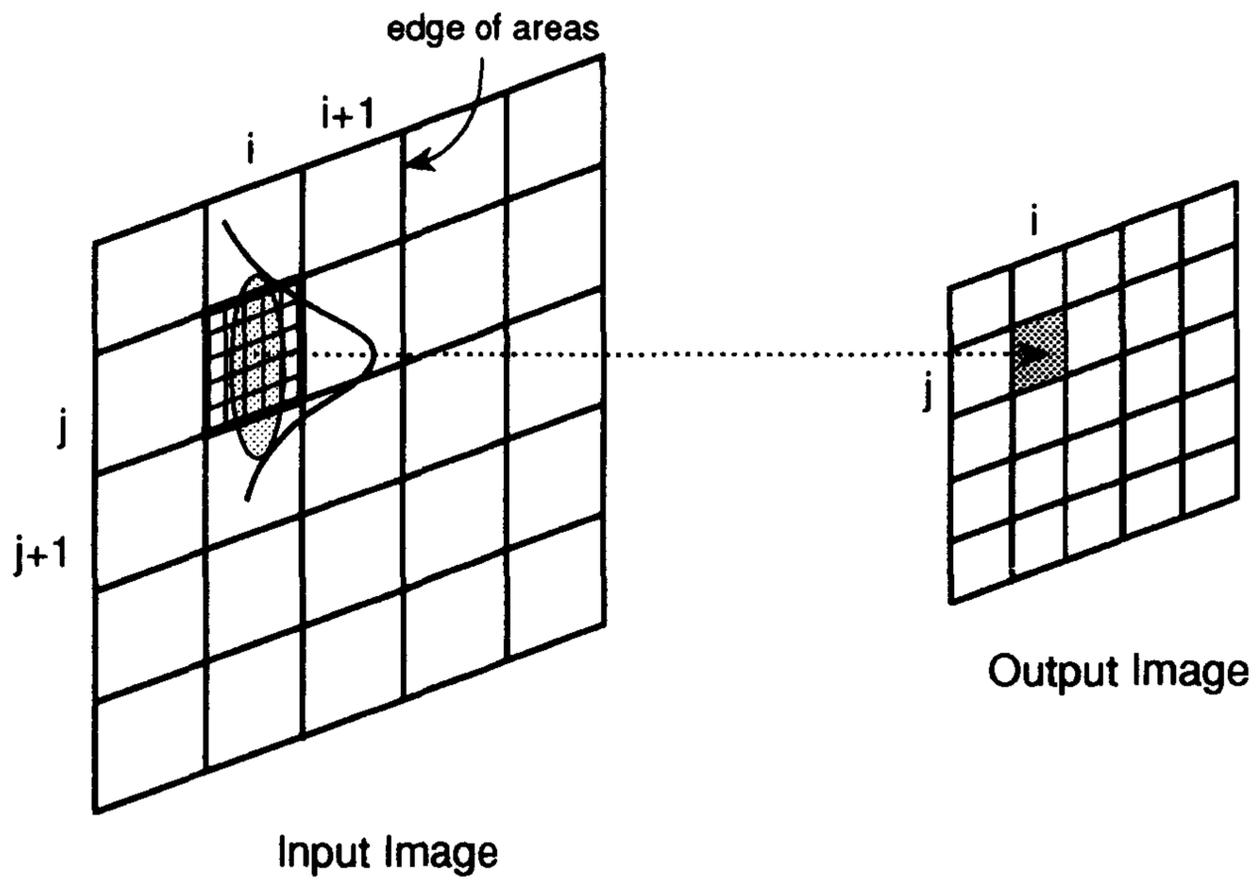


그림 6 축약 변환을 위한 입력과 출력과의 관계

weighted sum으로 구한다.

입력 패턴의 크기를  $N \times M$ 라 하고, 출력 패턴의 크기를  $A \times B$ 라 하자. 입력 패턴의  $(I_i, J_j)$ 화소는 출력 cell  $(i, j)$ 로 다음과 같이 연관된다.

$$I_i = \frac{N}{A}(i - \frac{1}{2}), \quad J_j = \frac{M}{B}(j - \frac{1}{2}) \quad (14)$$

$(I_i, J_j)$ 은 출력 화소  $(i, j)$ 에 연관된 직사각형 면적의 중심점을 의미한다. 출력 cell의 값을 다음과 같이 계산할 수 있다.

$$y(i, j) = \sum_{I, J} f(I - I_i, J - J_j) x(I, J) \quad 1 \leq i \leq A, 1 \leq j \leq B \quad (15)$$

여기서,

$$f(I, J) = \exp\left(\frac{-(I^2 + J^2)}{\sigma^2}\right) \quad 1 \leq I \leq N, 1 \leq J \leq M$$

#### 4. 다층 인식자 모델(Multi-layer Perceptron)

이제 MLP의 입력( $K \times A \times B$ )으로  $A \times B$  pixels 의  $K$  개의 패턴을 생각한다. 본 연구에서 사용한 MLP는 이층 구조(단지 하나의 은닉층을 갖는다.)로 구성 되어있고, 출력 갯수는 우리가 분류하고자 하는 그룹의 수( $N_s$ )와 같다. 본 연구에서는 열개의 서로 다른 패턴을 구별하고 싶기 때문에 열개의 출력을 가진다. 은닉층의 뉴런 갯수는  $N_s$  와  $2 \times N_s$  사이로 하였다. 그림 7 에 본 연구에서 사용한 다층 인식자의 구조를 보였

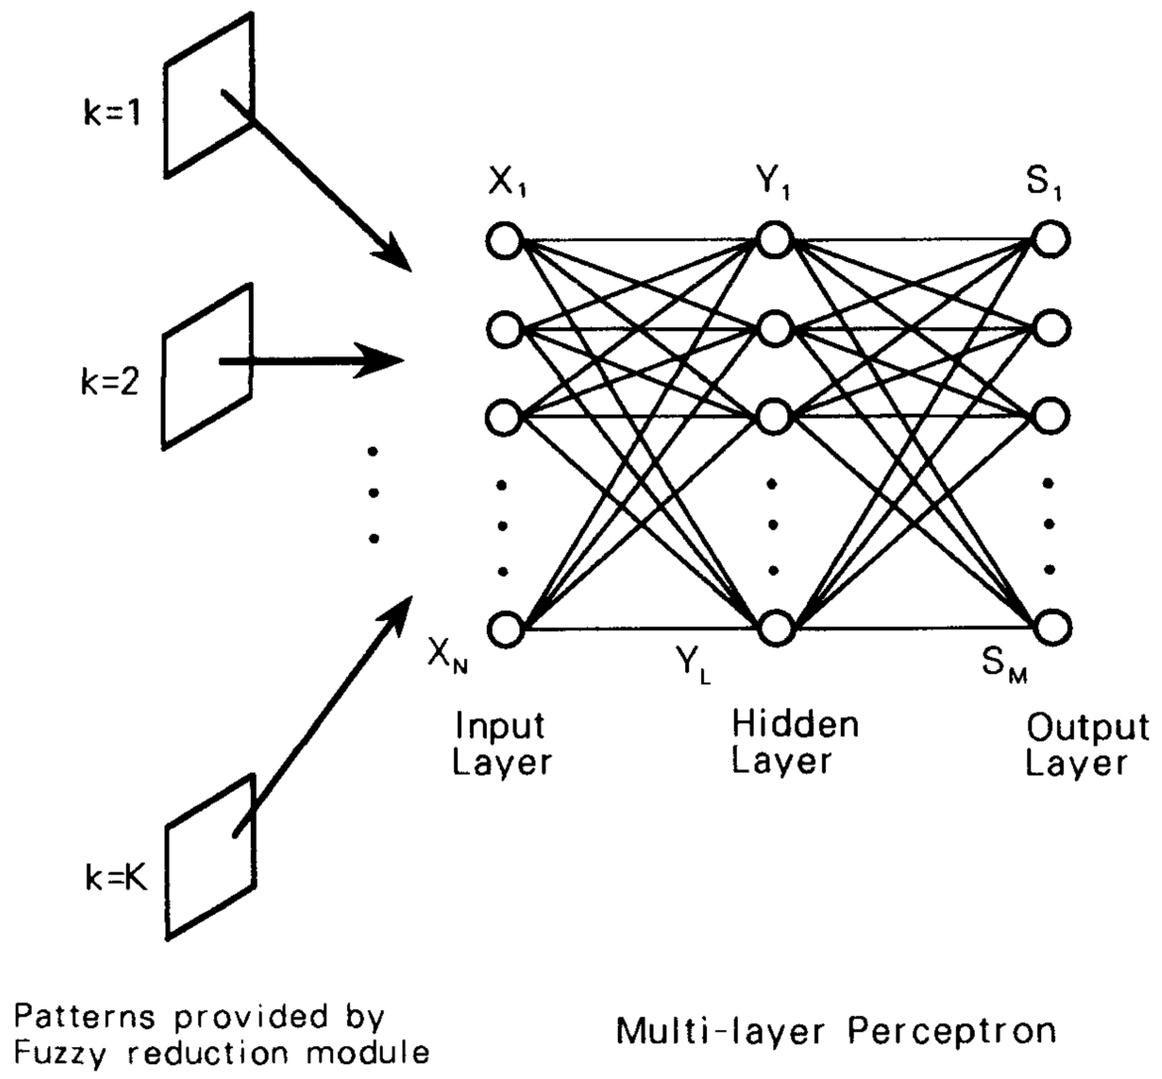


그림 7 다층 인식자의 구조

다.

각 iteration 마다  $K$  개의  $A \times B$  화소가 가해지고, 순방향 전달 (forward propagation)을 통하여 출력 값을 얻는다. 그때 시냅스 값을 바꾸기 위하여 역전파 알고리즘(back propagation algorithm)을 쓴다. 출력 측에서 원하는 출력 패턴을 생성할때 까지 역전파 알고리즘에 의한 상호 연결의 update을 계속한다.

MLP에서 입력층의 뉴론을 제외한 모든 뉴론은 McCulloch & Pits 모델 뉴론이다. 입력층의 목적은 MLP에 "패턴"을 제시할 뿐이다. 그래서, 그 뉴론들은 엄격한 의미에서 뉴론으로 간주될수 없다. 다층 인식자에 사용할 비선형 함수는 다음과 같은 비선형 함수이다.

$$f(x) = \frac{1}{1+e^{-2\alpha x}} \quad (16)$$

여기서,  $\alpha$ 는 비선형 함수의 기울기를 나타낸다.  $N, L, M$ 을 각각 입력층, 은닉층, 출력층의 뉴론의 갯수라 하자. 전장의 표기방법으로 나타내면, 다음과 같이 쓸 수 있다.

$$N = K \times A \times B, M = N_s, \text{ 그리고 } N_s \leq L \leq 2N_s \quad (17)$$

$(X_1, X_2, \dots, X_N)$ ,  $(Y_1, Y_2, \dots, Y_N)$ , 그리고  $(S_1, S_2, \dots, S_N)$ 은 입력 뉴론 값, 은닉층의 뉴론 값, 그리고 출력 값을 각각 의미한다. 그리고  $W_{ij}$  과  $V_{jm}$  ( $1 \leq i \leq N, 1 \leq j \leq L, 1 \leq m \leq M$ )은 각각 입력층의 뉴론  $i$  와 은닉층의 뉴론  $j$ , 그리고 같은 뉴론  $j$  와 마지막 층의 뉴론  $m$  사이의 시냅스라고 하자. 그때  $(Y_i)_{1 \leq j \leq L}$  과  $(S_m)_{1 \leq m \leq M}$  은 다음과 같다.

$$Y_j = f\left(\sum_{i=1}^N w_{i,j}X_i\right) \quad (18)$$

$$S_m = f\left(\sum_{j=1}^L v_{j,m}Y_j\right) = f\left(\sum_{j=1}^L v_{j,m}f\left(\sum_{i=1}^N w_{i,j}X_i\right)\right) \quad (19)$$

학습을 한다는 것은 아래 정의한 Least Mean Square 오차가 최소화 되도록  $(W_{i,j})$  와  $(V_{i,j})$  을 찾는 것을 의미한다.

$$LMS \text{ Error} : E = \frac{1}{2} \sum_{m=1}^M (d_m - S_m)^2 \quad (20)$$

여기서  $S_m$ 은 다층 인식자의 실제 출력이고,  $d_m$ 는 학습되기 원하는 값이다. LMS 오차가 줄도록 학습과정에  $(W_{i,j})$  와  $(V_{i,j})$ 의 gradient 계산이 필요하다. 마지막 두 층사이의 상호연결  $V_{i,j}$ 에 대하여 다음과 같이 계산된다.

$$\begin{aligned} \Delta V_{j,m} &= -\eta \frac{\partial E}{\partial V_{j,m}} \\ &= \eta(d_m - S_m) \frac{\partial S_m}{\partial V_{j,m}} \\ &= \eta(d_m - S_m) f' \left( \sum_{j=1}^L V_{j,m} Y_j \right) Y_j \\ &= \eta \delta_m Y_j \end{aligned} \quad (21)$$

$$\text{where, } \delta_m = (d_m - S_m) f' \left( \sum_{j=1}^L V_{j,m} Y_j \right)$$

그리고, 상호연결  $W_{i,j}$ 에 대해서는 다음과 같다.

$$\begin{aligned} \Delta W_{i,j} &= -\eta \frac{\partial E}{\partial W_{i,j}} = \eta \left( \sum_{m=1}^M (d_m - S_m) \frac{\partial S_m}{\partial W_{i,j}} \right) \\ &= \eta \left( \sum_{m=1}^M (d_m - S_m) f' \left( \sum_{j=1}^L V_{j,m} Y_j \right) V_{j,m} \frac{\partial Y_j}{\partial W_{i,j}} \right) \quad (22) \\ &= \eta \left( \sum_{m=1}^M \delta_m V_{j,m} \right) f' \left( \sum_{i=1}^N W_{i,j} X_i \right) X_i \\ &= \eta \delta'_j X_i \end{aligned}$$

$$\text{where, } \delta'_j = \left( \sum_{m=1}^M \delta_m V_{j,m} \right) f' \left( \sum_{i=1}^N W_{i,j} X_i \right)$$

$$\delta_m = 2\alpha (d_m - S_m) S_m (1 - S_m)$$

$$\delta'_j = 2\alpha \left( \sum_{m=1}^M \delta_m V_{j,m} \right) Y_j (1 - Y_j)$$

다층 인식자를 학습시키는 오차 역전파 알고리즘은 다음과 같이 요약된다.

---

For (모든 학습 패턴) do

$(Y_j)_{1 \leq j \leq L}$  과  $(S_m)_{1 \leq m \leq L}$  계산

$(\delta_m)_{1 \leq m \leq M}$  계산

$(\Delta v_{j,m})_{1 \leq j \leq L, 1 \leq m \leq M}$  계산

$(\delta_j)_{1 \leq j \leq L}$  계산

$(\Delta w_{i,j})_{1 \leq i \leq N, 1 \leq j \leq L}$  계산

$w_{i,j}$  와  $v_{j,m}$  조정

End loop

---

국부 특징 추출 모듈에서와 마찬가지로 상호연결 값이 안정화를 얻을 때까지 시냅스의 update를 계속한다. 그러나, MLP에서는 수렴해감에 따라 시냅스의 증분값은 '0'로 가기 때문에 시냅스의 값은 어떤 값에서 stable해진다. 일반적으로 각각의 뉴론에 문턱값(threshold value)을 고려해 준다. 그것을 고려하기 위하여 입력층에서 뉴론 한개를, 그리고 은닉층에서 또다른 뉴론을 더할필요가 있다. 그 뉴론의 입력은 항상 '1'이 된다.

## 5. 시뮬레이션 결과

### 첫번째 실험

이진 값을 갖는 필기체 패턴을 사용한다. 이미지의 크기는  $28 \times 28$  화소이나 패턴의 실제 높이와 넓이는 약 각각  $22 \times 15$  화소이다. 전체 데이터 베이스는 한가지 패턴당 27개의 다른 샘플로 구성되어진다. 그림 8에 27쌍의 학습 패턴을 보였다. 16개는 Neocognitron 모듈과 MLP를 학습할 목적으로 사용되어지고, 시스템의 테스트를 위해 나머지 11개의 패턴을 준비했다.

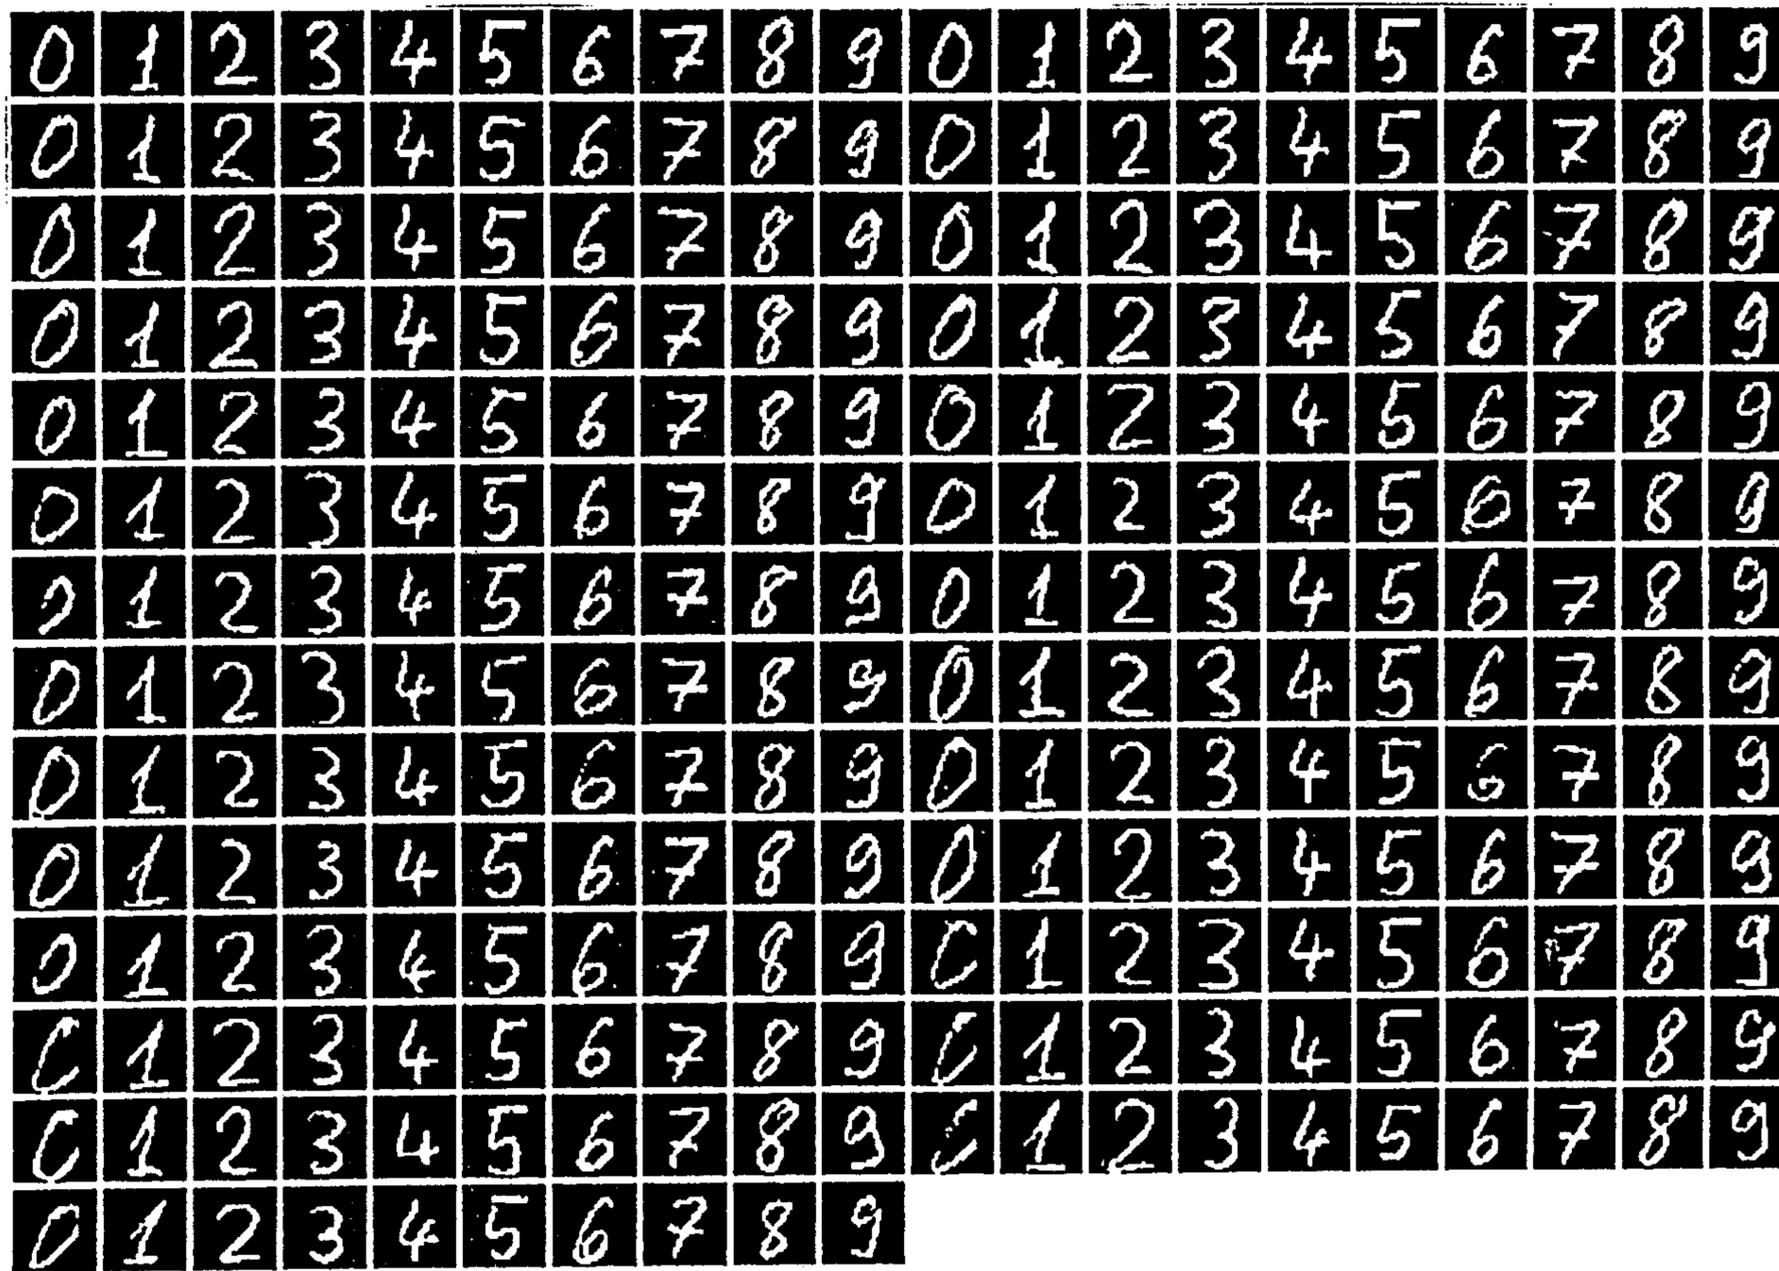


그림 8 실험에 사용한 숫자 패턴 (10 숫자 x 27 set)

시스템이 잘 동작할 수 있는지 보기 위하여 “4”, “7”, “8” 세개의 패턴만을 우선 다루자. 10개 패턴 대신에 세개 가지고 작업하는것은 다음과 같은 이유때문에 더 실제적이다. 첫째, 문제의 복잡도가 그다지 높지않다. 따라서, 사용된 시스템을 실제로 신뢰할 수 있는지를 볼 수 있는 좋은 기회를 가진다. 둘째, 계산시간이 무척 짧다. 빠르게 주어지는 결과로부터 어떤 파라미터나 그 밖의 어떤것을 바꿀수 있는 방법을 미리 배울수 있다면, 많은 시간이 절약될 것이다.

국부 특징 추출 모듈 : Fukushima가 그의 Neocognitron 모델에서 10개의 다른 패턴을 인식하기 위하여 24개의 특징을 사용한것처럼 우리는 3개의 문자인식에 대해 6개의 특징이 적절할 것이라고 생각한다. 파라미터  $r$ , 면적의 크기  $q$ 에 대하여 Fukushima에 의하여 제시된 값을 취한다. 즉,

$$r = 4, \quad q = 1 \quad 5 \times 5 \text{ pixels for the window} \quad (23)$$

식 (2) 에서 사용된 함수  $c(x,y)$ 에 대하여 다음과 같은 Gaussian이 선택된다.

$$c(x,y) = \exp\left(-\frac{x^2+y^2}{\sigma^2}\right) \quad (24)$$

여기서,  $\sigma$  는 2로 고정된 파라미터이다. Fukushima에 의하면  $a_k$ 의 초기 값은 작은 양의 수이며,  $b_k$ 는 초기에 영으로 잡는다.

퍼지 축약 모듈 : 먼저 결정해야 할 두개의 파라미터가 있는데, 축약 윈도우의 크기와 식 (15) 의 weight 함수를 정해야 한다. 윈도우 크기는 서

로 다른 패턴을 구별할 수 있을 만큼 커야 하지만, 위치 이동 tolerance의 특성을 유지할 만큼 작아야 한다. 3×3 화소과 5×5 화소 사이가 좋을 것 같다. 처음에는 3×3 화소 윈도우가 취해진다. 왜냐하면, 첫째로 그것이 더 빠를 것 같다. 두번째로 그것은 취할수있는 최소값이다. 함수로는 다음과 같은 Gaussian함수를 택한다.

$$f(x,y) = \exp\left(-\frac{x^2+y^2}{\sigma_g^2}\right) \quad (25)$$

$\sigma_g$ 는 입력과 출력 패턴 크기에 따라 정해지는데, 여기서는 10으로 정했다. 그것은 다층 문제에 적절할 것 같은 두 중앙 화소 사이의 거리에 상응한다.

다층 인식자 모듈 : 사용된 다층 인식자는 6×(3×3)개의 입력뉴런이 있고, 출력층에서는 각 패턴에 하나씩 3개의 뉴런이 있고, 은닉층에서는 출력의 두배, 즉 6개의 뉴런으로 시작한다.

- 입력층에서 55개의 뉴런(threshold을 위한 뉴런 포함)
- 은닉층에서 7개의 뉴런(threshold을 위한 뉴런 포함)

여전히 정해져야할 두개의 파라미터가 있다.

- 첫째, sigmoid함수의 기울기  $\alpha$ , 몇번의 실험후 그것은 0.4로 정한다.
- 둘째, 학습율  $\eta$  는 '1'로 잡는다.

결 과 : 우선 그림 9 에 Neocognitron의 전단부에 의해 추출한 국부 특징 패턴을 보였다. 예상되어진 대로 다소 경사진 막대형태가 나온다. Neocognitron은  $16 \times 3 = 48$ 개의 패턴에 의하여 학습되어졌다. 학습된후  $a_k$  와  $b_k$  을 고정시키고, 이 모듈을 통과한 학습 패턴은 퍼지축약 모듈로 전달된다. 퍼지 축약 모듈에서 첫번째로 주목되어져야 할 점은 중앙 출력 화소의 값이 다른것에 대해서 우세하다는 것이다. 따라서, 중앙 출력화소를 기준으로 한 원내에 있는 것만을 제외하고는 모든 입력화소는 출력화소 값에 기여할수 없도록 하고, 원의 면적으로 나누어 정규화가 행해진다. 원의 반지름은 weight 함수의 최대값을 10으로 나눈 것으로 정의한다.

$$d = x_0 \text{ as } f(x_0) = \frac{f_{MAX}}{10} = \frac{f(0)}{10} \quad (26)$$

다층 인식자에서도 학습을 언제 그만두도록 할지 알아야한다. 즉 얼마나 많은 iteration이 필요한지를 알아야한다. 그것을 더 쉽게 하기 위한 한 가능성은 매번  $\Delta W_{i,j}$  와  $\Delta V_{i,j}$  를 보이는 것이다. 이 값이 만족할 만큼 작어지면 학습은 멈춰지고 연결 계수는 고정된다. 학습은 약 700 번의 iteration 을 요구하고, "Winner Take All" 판정 기준을 도입하여 100%의 인식율을 얻었다. 이 시스템이 패턴인식에 대해서 잘 동작할수 있다는 것을 보이기위해 10가지 종류의 패턴을 학습시켰을 때의 결과를 다음장에 보인다.

## 두번째 실험

첫번째 실험과 같은 진행이지만 이번에는 학습 데이터로  $16 \times 10$  개의 패턴을 가진다. 전체 시스템에 대해 사용한 파라미터는 다음과 같다.

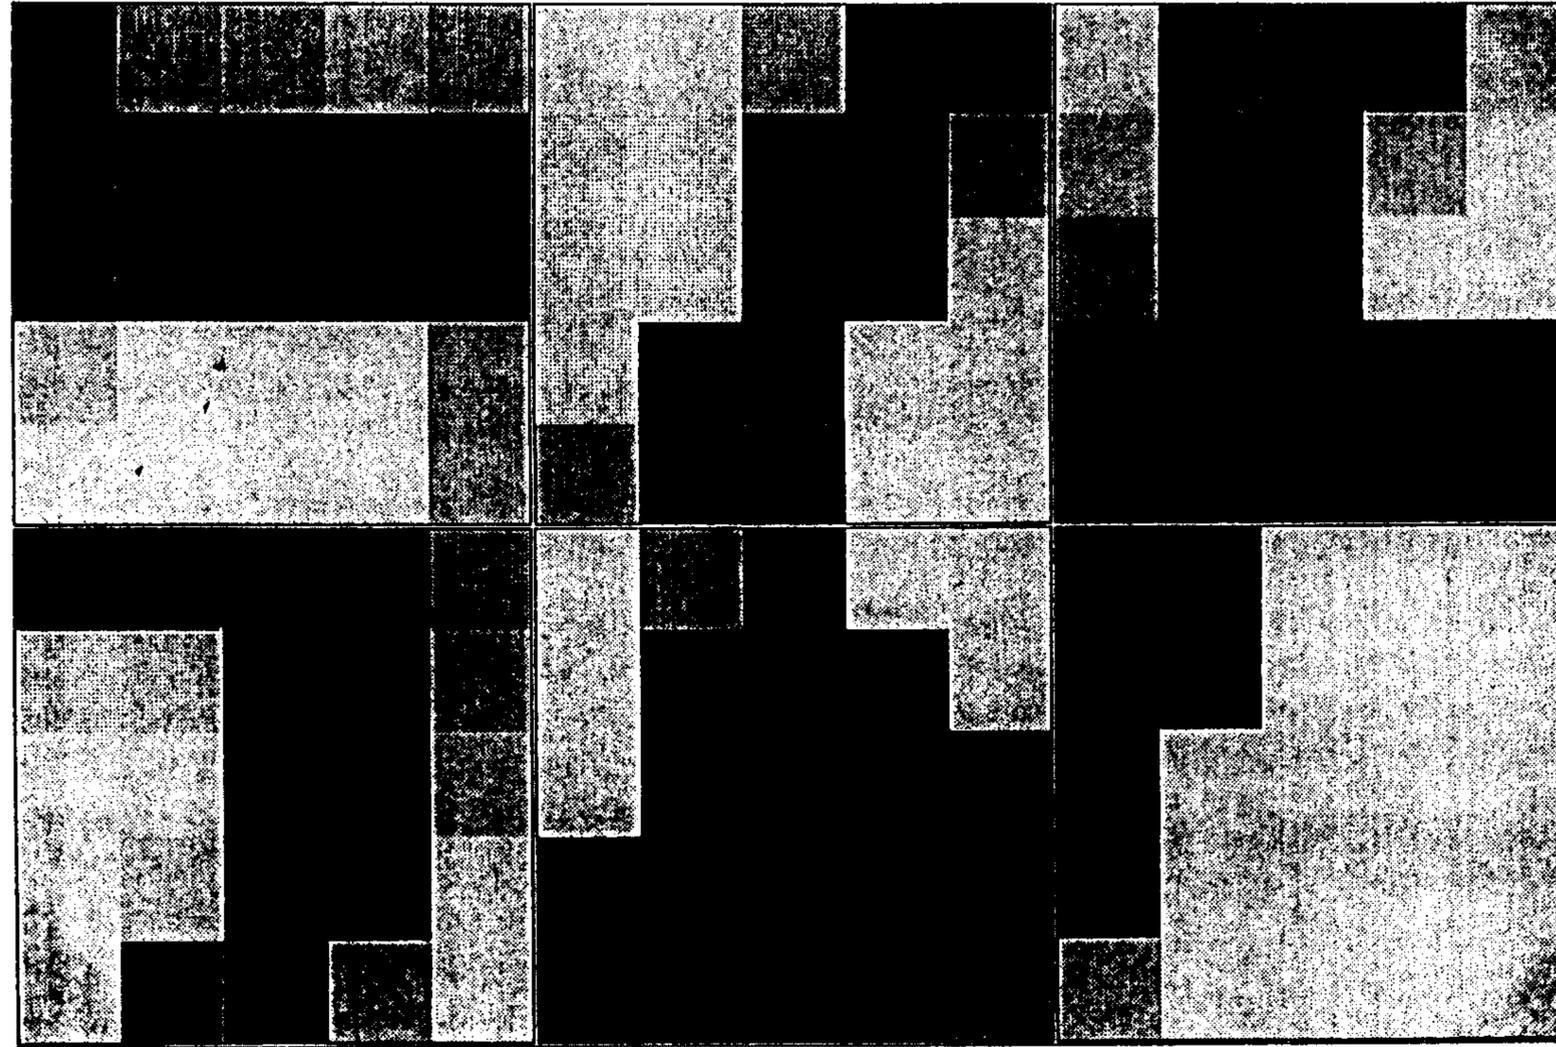


그림 9 숫자 패턴 '4', '7', '8' 로 부터 추출된 특징 패턴

- 20개의  $5 \times 5$  화소의 local feature window 사용
- $\sigma=2, q=1, r=4$
- $3 \times 3$  축약 변환
- $\sigma_g = 10$
- 20 + 1 개의 은닉뉴론 사용
- MLP 학습은 1000번의 iteration을 최대회수로 함
- $\alpha = 0.4, \eta = 1.0$

20개의 추출된 특징을 그림 10 에 보였다. 전 결과처럼 여러종류의 막대형태가 있고 또한 겹쳐있다. 이것은 Neocognitron의 국부 특징 추출 모듈이 잘 동작하고있다는 좋은 증거이다. 시스템의 출력값은 '0' 과 '1' 사이 값이고, 인식율을 평가하기 위한 두가지 기준을 마련했다.

- 기준 1 : 출력이 0.5 이상일때는 "1"이 되고 그렇지 않을때는 "0"이 된다.
- 기준 2 : 10 개의 출력중에서 가장 큰 값이 "1"로 다른것은 "0"으로 한다.

인식율은 테이블 1 과 같다. 바뀌어질 수 있는 파라미터는  $\sigma_g$  이며, 그것은 축약 화소 면적의 반지름에 비례한다. 값이 더 크면 클수록 출력의 어떤 한 화소에 많은 입력 화소가 기여한다. 아마도 성능 저하가  $\sigma_g = 10$  이 너무 큰 값이라는 데서 오는 것 같아  $\sigma_g=5$  로 줄여 테스트를 했다. 그 결과 테이블 1 로 알 수 있듯이 성능 향상이 있었다. 그러나, 그 값이 작아짐에 따라서 shift에 둔감해 지기 때문에 너무 줄이는 것은 안 좋다.

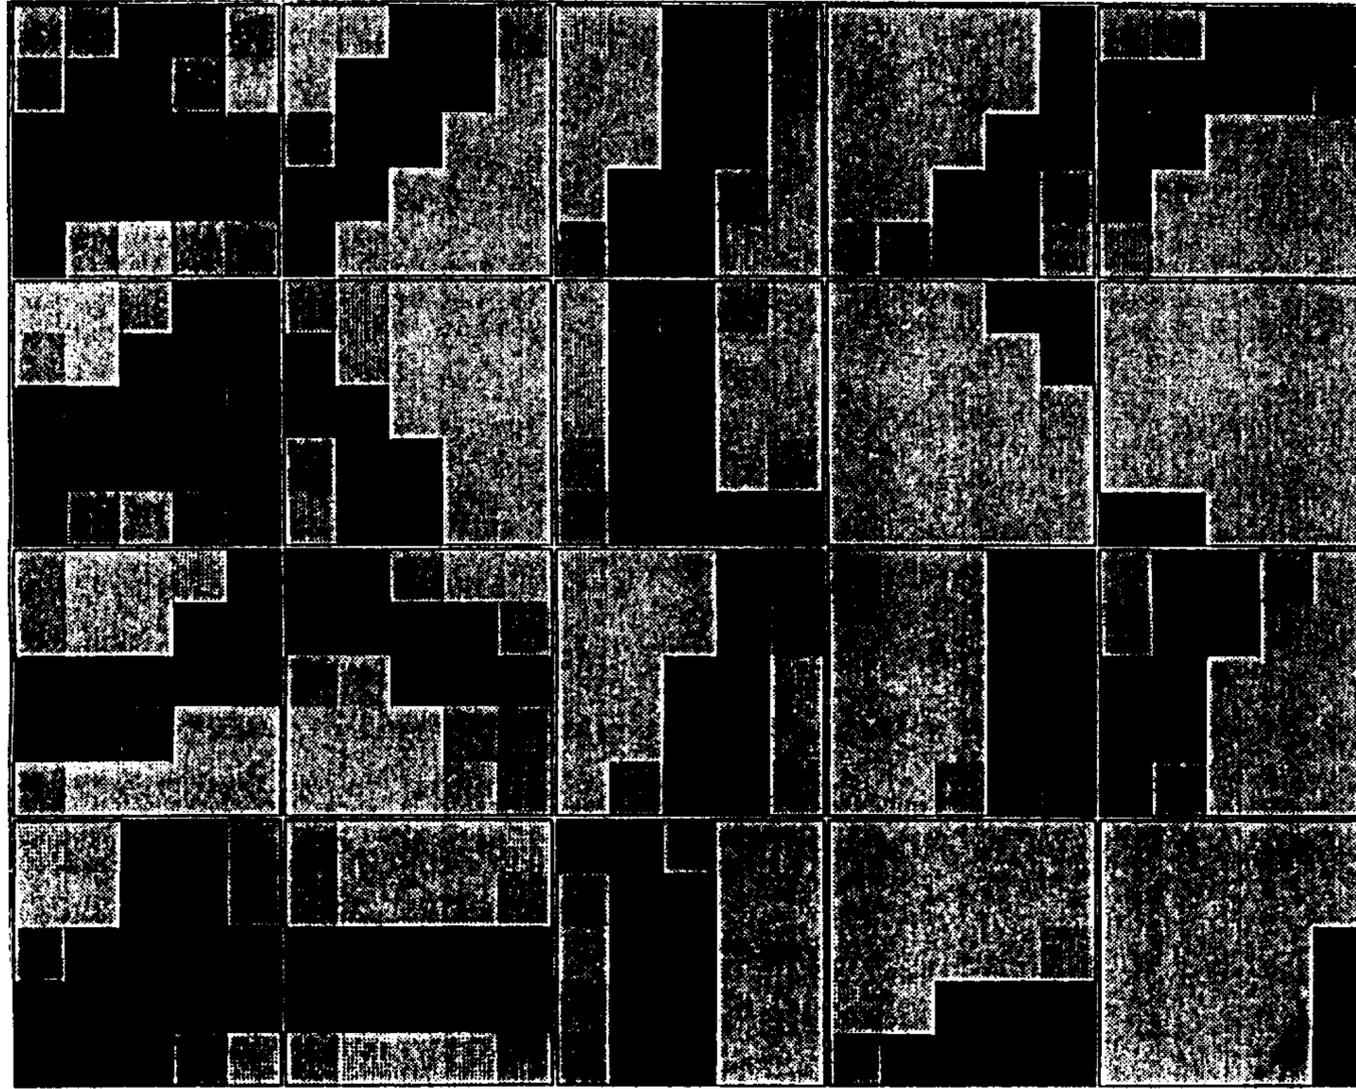


그림 10 숫자 학습 패턴으로 부터 추출된 특징 패턴

$\sigma_g$	기 준 1	기 준 2
10	75.5	90.9
5	79.1	92.7

테이블 1 3×3 축약 변환일때의 성능

지금까지 3×3 축약 변환을 사용했는데, 이 크기는 MLP가 정확한 분류를 할 수 있도록 충분히 구별된 데이터를 제공 할 만큼 충분치 않을지 모른다. 따라서, 5×5 윈도우가 취해지고 동시에  $\sigma_g$ 의 값은 [ $\sigma_g$ 의 값/출력 화소의 크기]의 비가 거의 같게 유지되도록 5로 줄인다. 테이블 2로부터 알 수 있듯이 실제 개선은 이 방법에 의하여 되어진다. 기준 1에 대해서는 85%, 그리고 기준 2에 대해서는 98% 정도의 인식율을 보였다.  $\sigma_g$ 의 값이 5에서 3으로 줄였으며 오히려 성능이 저하됨을 테이블 2로부터 알 수 있다. 아직까지 MLP에서는 어떤 파라미터도 바꾸지 않았다. 은닉층의 뉴런 갯수를 바꾸고 테스트한 결과를 테이블 2에 보였다.

$\sigma_g$	n	기 준 1	기 준 2
5	20	85.0	98.2
3	20	83.6	91.8
5	40	83.6	98.2

테이블 2 5×5 축약 변환일때의 성능  
(n : MLP의 은닉층 뉴런 수)

## 6. 결론 및 계속 연구 과제

본 연구에서 가장 좋은 인식율은 20 종류의 특징을 추출하고, 5×5 축약 변환을 하고,  $\sigma_g=5$  일때 기준 2 를 적용하여 98.2%를 얻었다. 그러나, 기준 1 을 적용하면, 85% 정도의 인식율을 보인다. 이는 아직까지 만족할 만한 결과는 아니다. 성능을 더 올릴 수 있는 방법을 생각하면 다음과 같다.

- 축약 모듈에서 weight 함수와  $\sigma_g$  의 선정
- 적당한 축약 윈도우 크기 선택
- 다층 인식자의 적당한 파라미터 선정
- 다층 인식자가 충분히 학습되도록 iteration 의 증가

앞으로의 연구 과제는 위에 언급한 사항을 좀 더 여러가지로 테스트하여 최적의 조건을 구하고, 더 많은 패턴에 대해 시스템의 일반적인 특성을 알아내는데 있다.

## 참 고 문 헌

- [1] B. Muller and J. Reinhardt, *Neural Networks - An Introduction*, Springer - Verlag Berlin Heidelberg 1990.
- [2] K. Fukushima and S. Miyake, "Neocognitron : A New Algorithm for Pattern Recognition Tolerant of Deformations and Shifts in Position", *Pattern Recognition*, Vol. 15, No 6, pp. 455-469, 1982.
- [3] K. Fukushima, "Neocognitron : A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position", *Biol. Cybernetics* 36, 193-202, 1980.
- [4] K. Fukushima, "Analysis of the Process of Visual Pattern Recognition by the Neocognitron", *Neural Networks*, Vol.2, pp. 413-420, 1989.
- [5] B.Solaiman, "Les reseaux neuronaux multi couches", ENST de Bretagne-Departement MSC-Groupe Traitement d'Images.
- [6] D.R. Hush and B.G. Horne, "Progress in Supervised Neural Networks - What's New Since Lippmann?", *IEEE Signal Processing Magazine*, January 1993.
- [7] R.Y. Wu and W.H. Tsai, "A Single-Layer Neural Networks for Parallel Thinning", *International Journal of Neural Systems*, Vol.3, No.4, pp. 395-404, 1992.
- [8] W.S.McCulloch and W.Pitts, "A Logical Calculus of the Ideas Immanent in Nervous Activity", *Bull. Math. Biophys.* 5, p.115, 1943.

# 제 3 장 SOFFA 기법의 광학적 구현

## 시스템 설계

### 1. 국부 특징(Local Feature)의 추출의 광학적 구현

국부 특징의 추출은 입력패턴과 window 내의 국부 특징 패턴과의 2차원 convolution을 통하여 이루어 진다. 입력 패턴을  $u(x,y)$ 라 하고 국부 특징 패턴을  $h(x,y)$ 라 하면 다음과 같이 2차원 convolution을 구할 수 있다.

$$w(x,y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u(\xi,\eta)h(x-\xi,y-\eta)d\xi d\eta \quad (1)$$

$$= F^{-1}\{U(f_x,f_y)H(f_x,f_y)\} \quad (2)$$

여기서,

$$U(f_x,f_y) = F\{u(x,y)\}, \quad H(f_x,f_y) = F\{h(x,y)\}$$

식 (1),(2)로 부터 알수 있듯이 2차원 convolution을 광학적으로 구현하는 방법이 두가지로 가능하다. 첫번째가 Fourier transform 영역에서의 filtering을 통해 구현하는 방법이고, 두번째가 실 공간 영역에서의 convolution을 수행하는 방법이다.

## 공간 주파수 영역에서의 convolution

그림 1 에 convolution을 수행하기 위한 광학적 구현도를 나타내었다. 입력 패턴  $u(x,y)$ 는 렌즈 L1 뒷면의 초점 거리에서 Fourier transform  $U(f_x, f_y)$ 가 만들어지고 convolution 필터  $H(f_x, f_y)$ 와 곱해진다.  $U(f_x, f_y)$  와  $H(f_x, f_y)$  곱해진 convolution 필터의 출력은 다시 렌즈 L2에 의해 Fourier transform이 수행된다. 따라서, 출력면으로 부터 convolution 결과를 얻을 수 있다. 그러나, 본 연구에서의 국부 특징 추출 모듈에 쓰려면 각각의 특징 window에 대한 convolution 필터가 필요하게 되어 시스템이 방대해 지고 alignment에 큰 부담을 주게 되는 단점을 갖게된다.

## 실공간 영역에서의 convolution

위에서 살펴본 convolution 필터는 Fourier transform plane에 놓이기 때문에 일종의 공간 주파수 필터이다. 때때로 필터 설계를 공간 주파수 영역에서 하는 것보다는 실공간 영역에서 하는 것이 더 간단하게 이루어 지는 경우가 있다. 본 연구에서의 국부 특징 모듈이 바로 그런 경우에 해당하는 것으로 그림 2 에서와 같이 구성할 수 있다. 특징 window가  $N \times M$ 일때 식 (1)은 다음과 같이 표현된다.

$$w_{ij} = \sum_{m=1}^N \sum_{n=1}^M u(m,n)h(m-i,n-j) \quad (3)$$

즉, 그림 2 의 SLM1은 입력 패턴  $u(m,n)$ 이 되고, SLM2는  $3 \times 3$ 의 국부

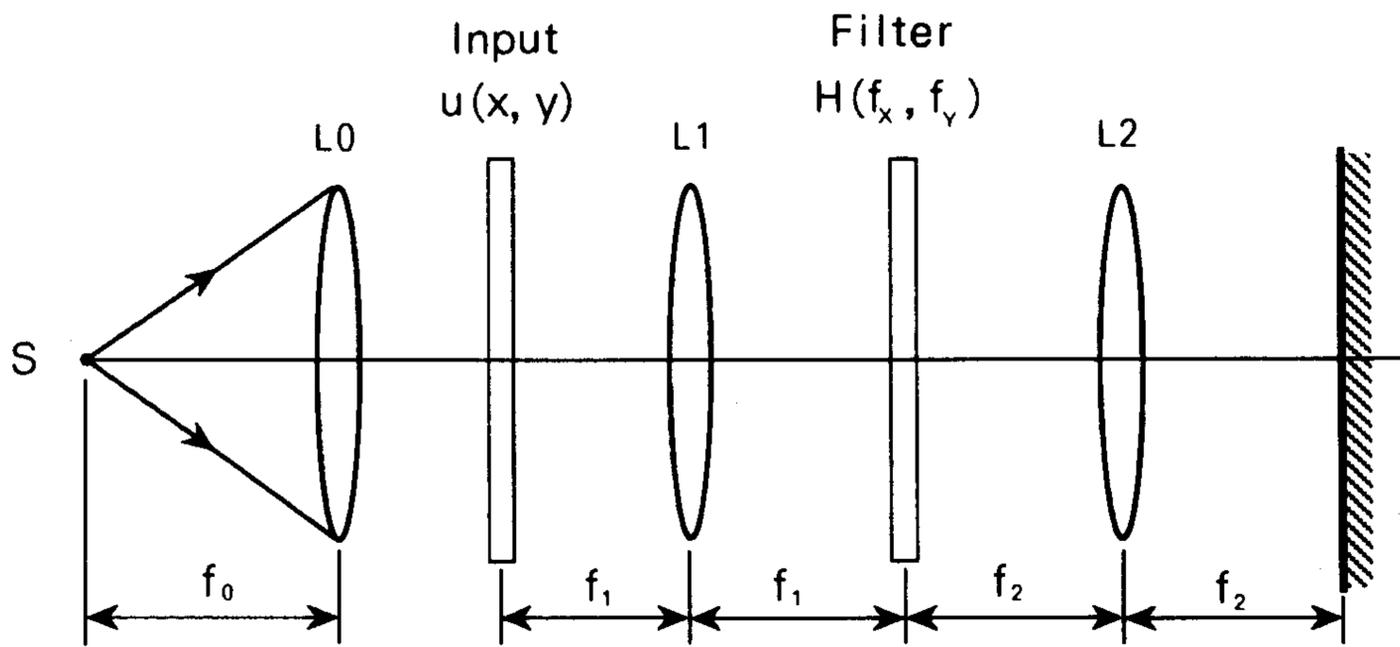


그림 1 공간 주파수 영역에서의 convolution

특징을 수록한 실공간 영역에서의 필터함수  $h(k,l)$ 이 된다. 따라서, SLM2는 SLM1 보다  $3 \times 3$  배의 element가 필요하다. 광 검출기(또는 LCLV의 detector면)에 입력과 local feature의 2차원 convolution이 형성된다. 각 국부 특징에 대해 각각 그림 2 의 시스템을 구현해야 되나, 하나의 시스템으로 각 국부 특징에 대해 time multiplexing(SLM2 변화)하여 간단히 구성할 수 있다.

## 2. Fuzzy 축약 변환의 광학적 구현

Gaussian 함수를 이용하여 퍼지 연상 변환을 행하므로 변환 함수가 local 특성을 보유한다. 따라서, 퍼지 축약 변환 역시 국부 특징 모듈과 마찬가지로 2차원 convolution으로 생각할 수 있으며, 그림 2 와 같이 축약 변환 모듈을 구현할 수 있다. 그러나, 퍼지 축약 모듈에 사용한 convolution kernel이 모든 국부 특징에 대해 동일하게 적용되므로 그림 2 에서의 SLM2를 쓸 필요가 없으며, gray level을 갖는 필름 마스크 만으로도 족하다. 혹은, 식 (3) 을 matrix-vector 곱셈으로 생각하고,  $h(i,j,m,n) = h(m-i,n-j)$ 을 rank-4(2차원 입력 패턴을 2차원 출력 패턴으로의 연결 텐서)의 고정연결을 이룰 수 있게 하는 다면 홀로그램(multi-facet hologram)을 이용하여 간단히 그림 3 과 같이 구성할 수 있다. 다면 홀로그램을 사용한 구현은 렌즈 배열과 공간 광 변조기를 사용한 구현 보다 매우 저렴하며, 대용량의 구현(한변이 1cm 인 입방체의 홀로그램은 기록하는 빛의 파장이 1 $\mu$ m 일때 약  $10^{12}$  개의 연결정보를 저장한다.)이 가능하다. 그림 4 에 국부 특징 추출 모듈과 퍼지 축약 모듈을 연결하고 그 뒤에 다층 인식자를 붙인 전체적인 광 시스템을 보였다.

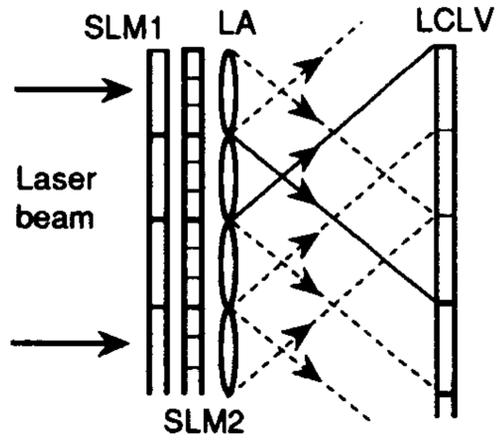


그림 2 공간 영역에서의 convolution에 의한 국부 특징의 추출

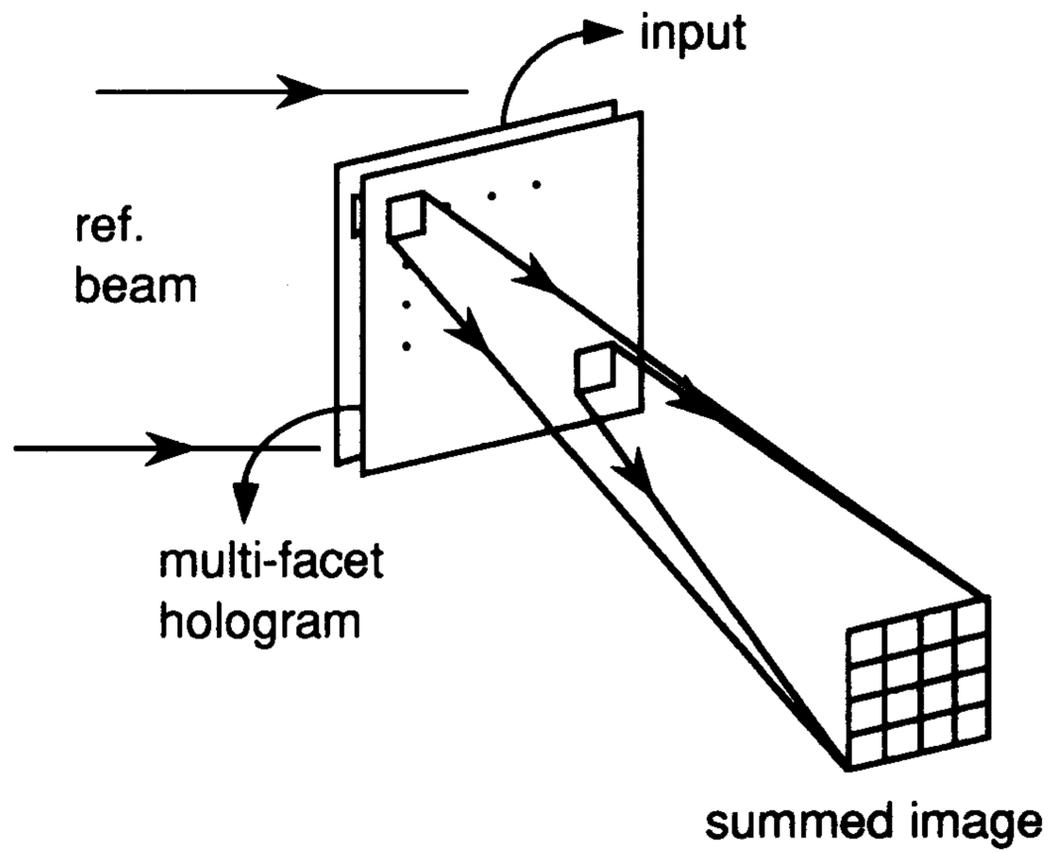


그림 3 다면 홀로그램을 이용한 퍼지 추약 변환

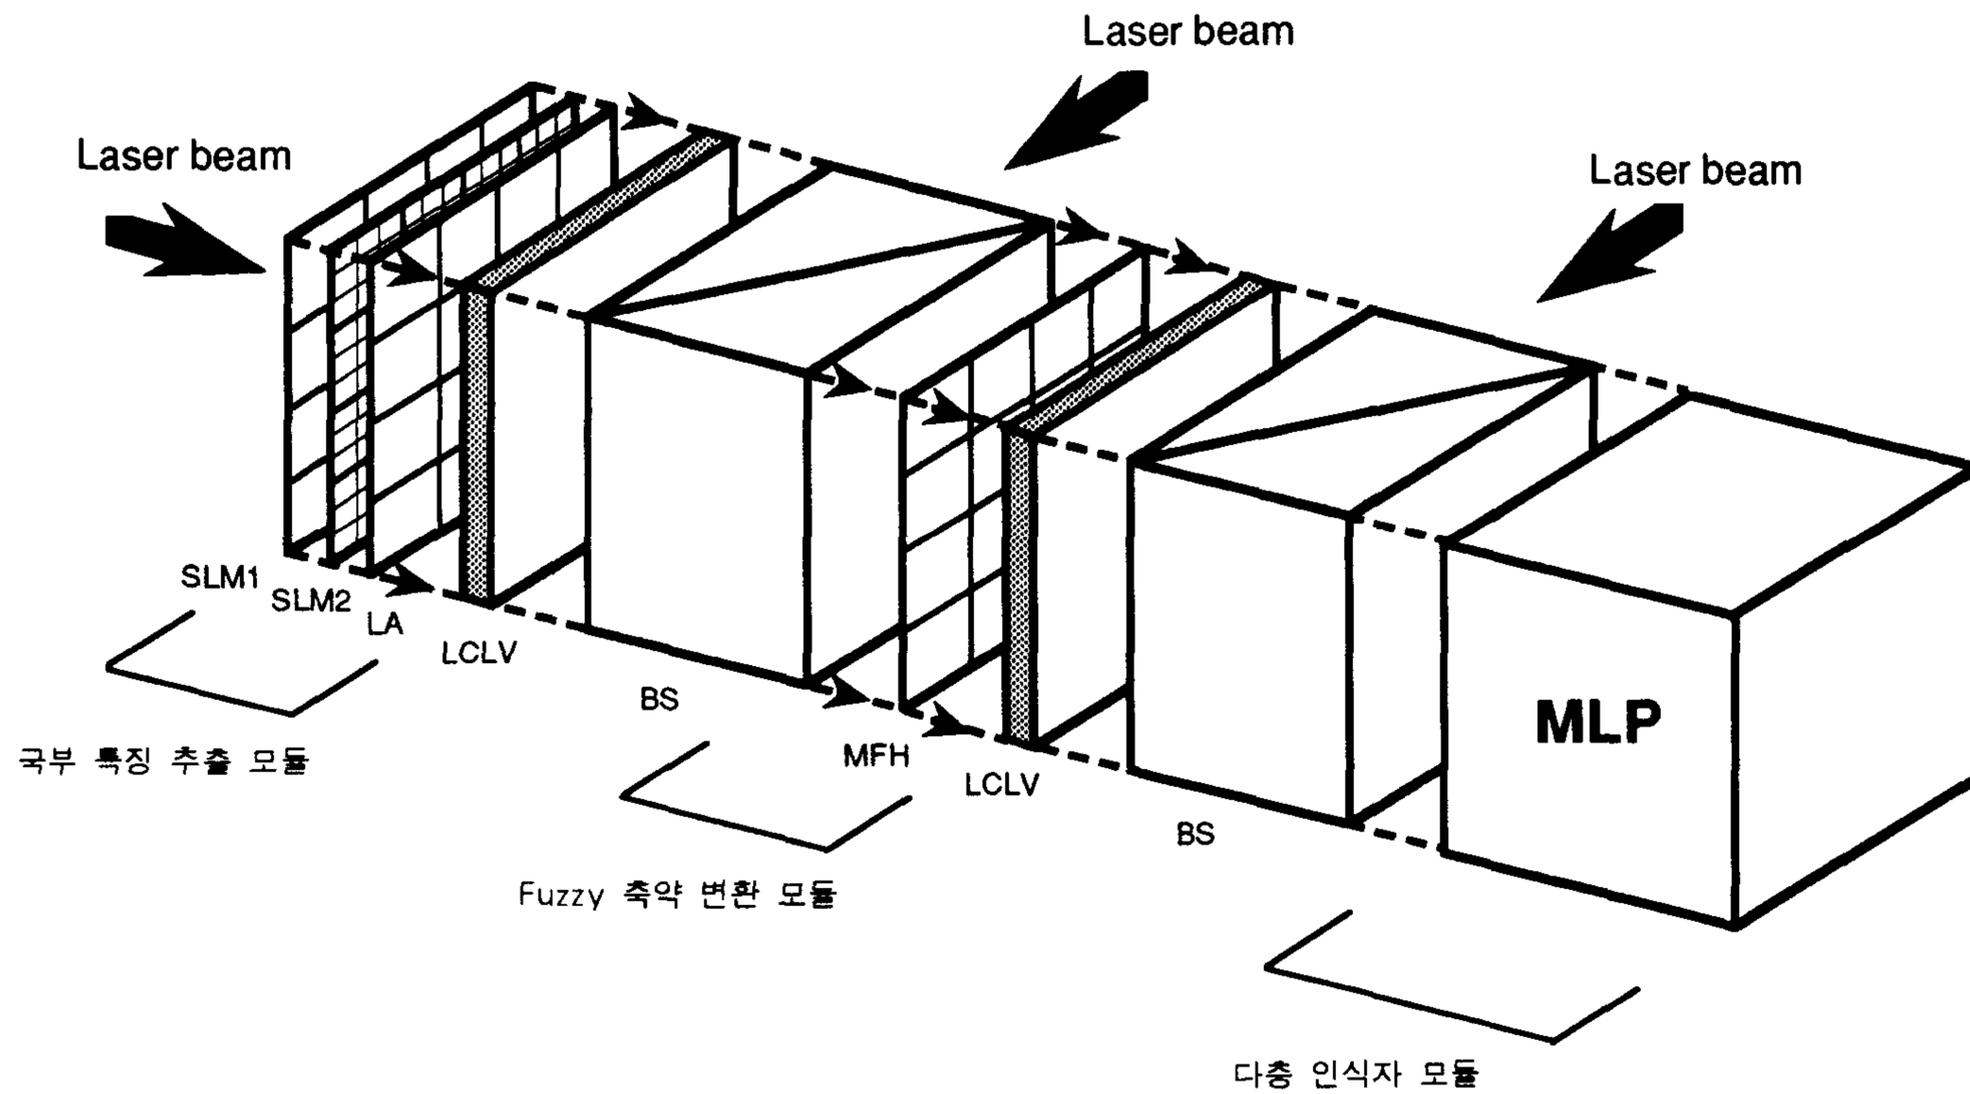


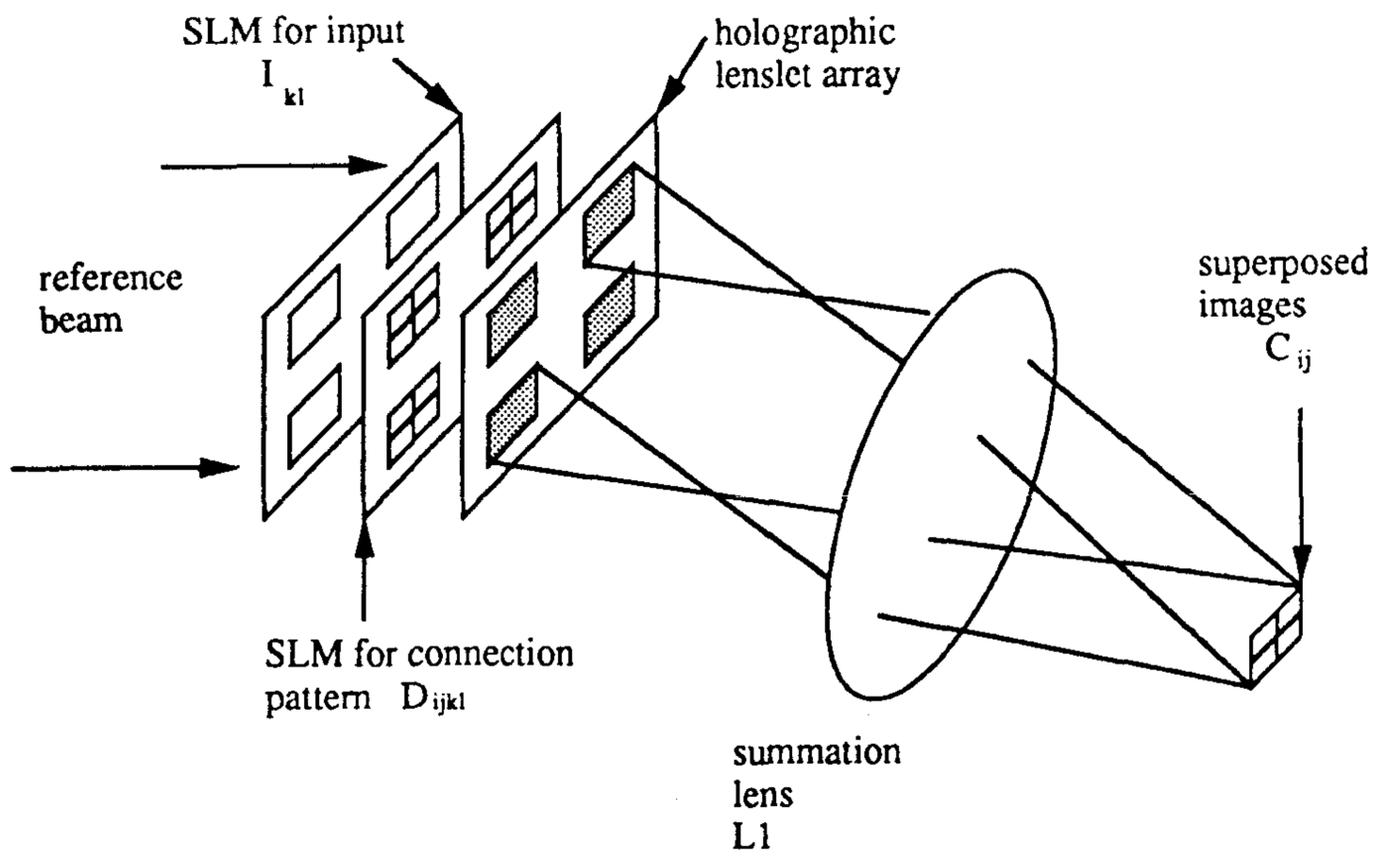
그림 4 SOFFA 모델의 전체적인 광학적 구현도

### 3) 다층인식자의 전기 광학적 구현

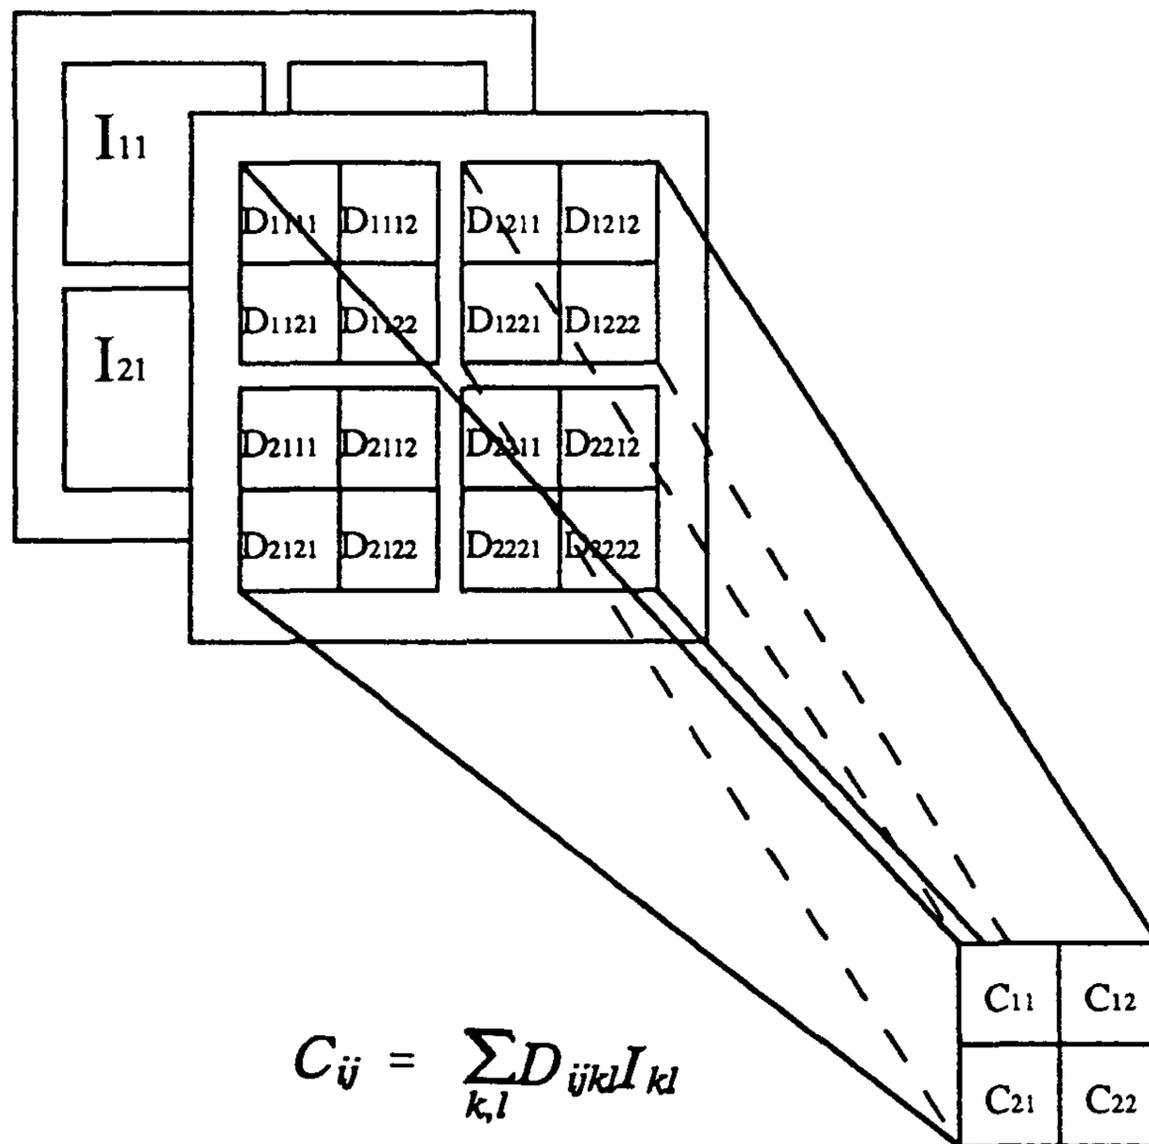
#### 3.1 홀로그램 렌즈 배열(HLA)과 LCD panel을 이용한 상호연결

##### 3.1.1 HLA를 이용한 행렬-벡터 곱셈기 제작

홀로그램은 기준광과 물체광의 두 광의 간섭패턴을 기록한 것으로, 이 홀로그램에 기준광을 입사함으로써 물체광을 재생할 수 있다. HLA는 물체광으로 렌즈를 통과하는 광과 기준광으로 평면파를 사용하여 홀로그램을 2차원 배열로 제작한 것이다. 여기에 기록시와 반대방향으로 기준광을 입사하면, 기록시와 반대 방향으로 렌즈를 지나는 광과 같은 특성의 1차 회절광을 얻을 수 있다. 그림 3.1의 a)에서와 같이 HLA의 초점면과 평행하게 summation 렌즈 L1을 놓으면, L1의 초점면에 각 홀로그램 렌즈를 통과하는 모든 영상을 중첩시킬 수 있다. 이것을 이용하여 각 홀로그램 렌즈마다 입력과 연결세기를 공간 광변조기로 광변조하여, 입력과 연결세기의 곱이 HLA를 통과하여 L1을 지나도록 하면 L1의 초점면에서 입력벡터와 연결세기 행렬의 곱을 얻을 수 있다[8][18]. 이와 같은 방법으로 행렬-벡터 곱셈기를 제작한다. 이 상호연결의 개념을 그림 3.1에 나타냈다.



a) HLA와 LCD panel을 이용한 행렬 벡터 곱셈기의 구조



b) 렌즈를 제외했을 때의 광 행렬-벡터 곱셈기

그림 3.1 HLA를 이용한 행렬 벡터 곱셈기의 개념

### 3.1.2 HLA의 제작

대량의 가변 광연결을 구현하기 위해서는 가변 연결세기를 나타내기 위한 LCD panel의 여러가지 제한요소들을 고려하여 HLA의 크기와 홀로그램 렌즈의 크기를 정하여야 한다. 본 실험에 사용된 LCD panel은 보통의 LCTV와 비슷한 구조 [19]를 가지며, pixel 갯수는 가로 세로 256×256이다. 그리고 각 pixel의 크기는 가로 0.2(mm) 세로 0.24(mm)이다. 하나의 상호연결 세기를 나타내는 데 2×2 pixel을 사용하고 그 사이에 가로간격 256×1, 세로간격을 1×256개로 한다. 그리고 각 홀로그램 렌즈에 들어가기 위한 상호연결세기를 6×6으로 묶어 연결세기

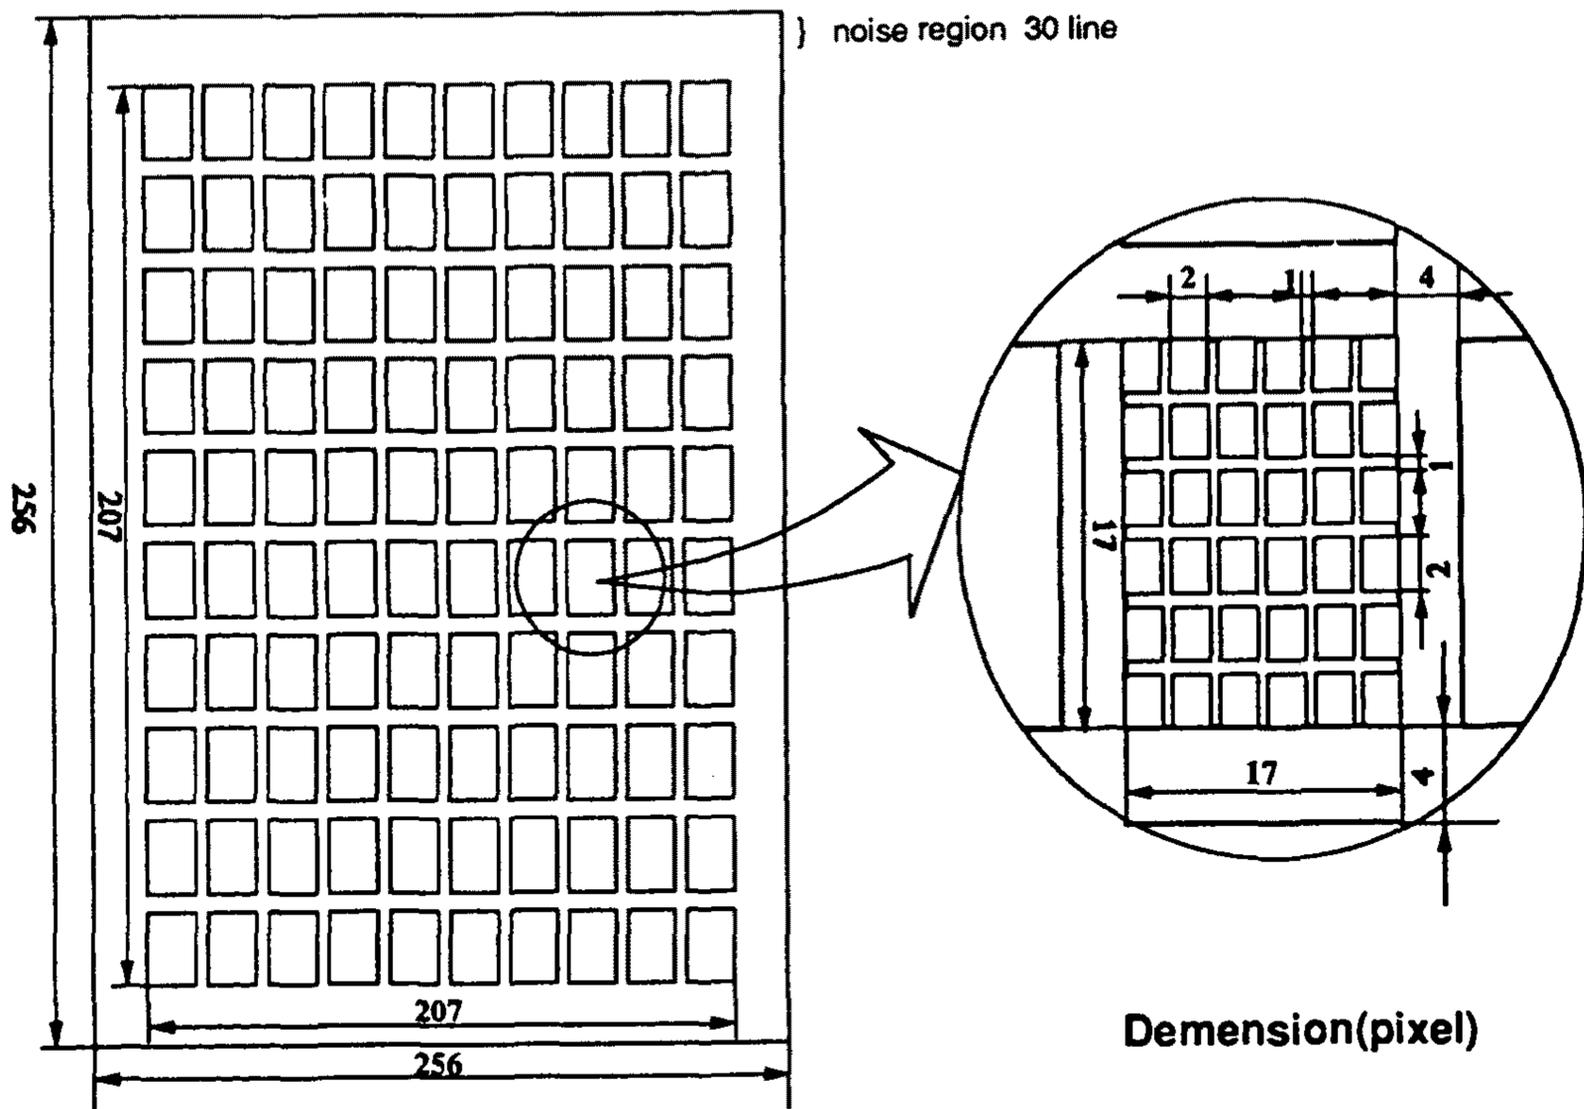


그림 3.2 패턴을 나타내기 위한 LCD panel의 구성

군으로 정하여 이들 연결세기 군의 가로간격  $4 \times 256$  세로간격  $256 \times 4$ 으로 한다. 그래서 본 논문에서 총 사용한 LCD panel의 pixel 갯수는  $207 \times 207$ 이다. 이러한 구성으로 전체 입력패턴과 상호연결세기를 나타내는 실제의 LCD panel의 크기는  $50 \times 53.1(mm^2)$ 이다. 그림 3.2에 실제 패턴을 나타내는 LCD panel의 구성을 나타내었다.

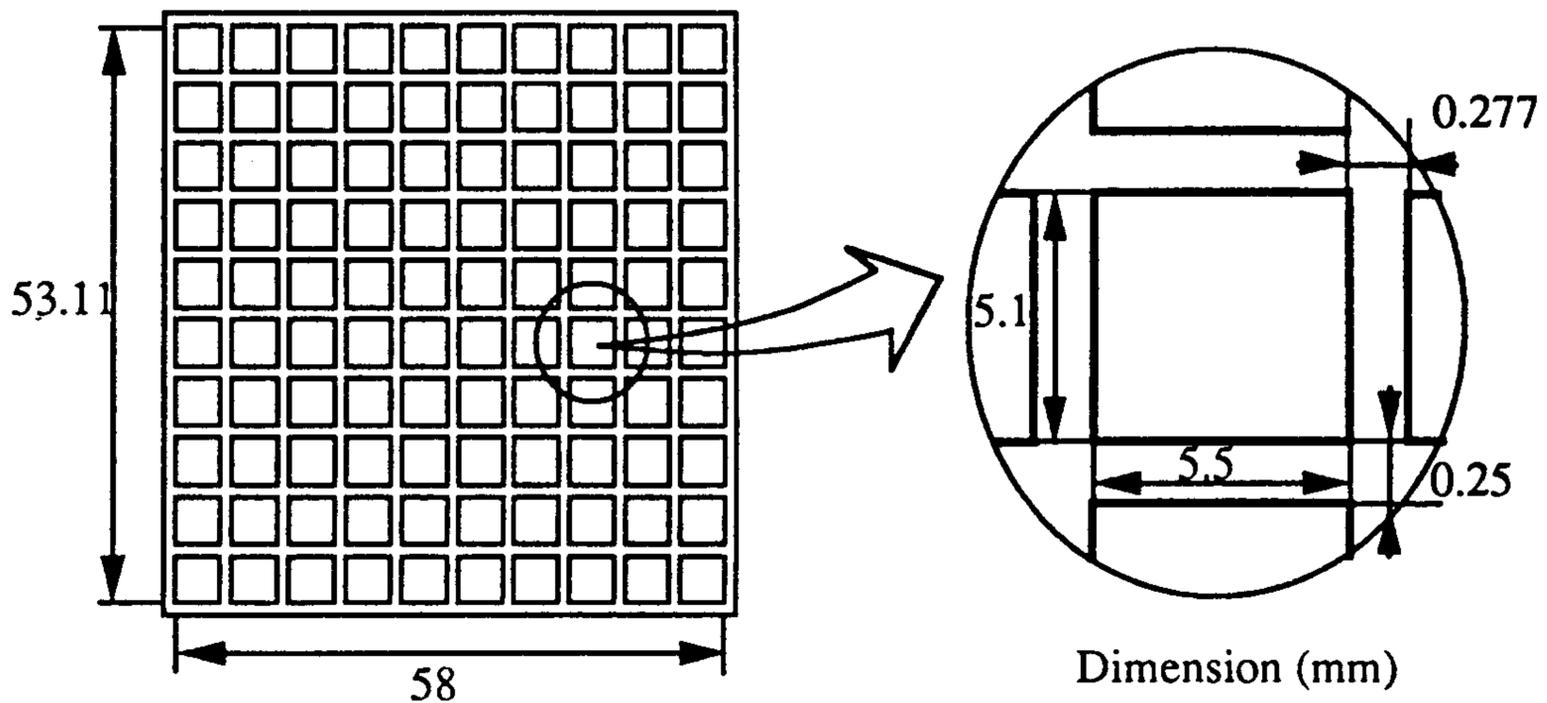
위의 LCD panel의 구성을 고려하여 HLA의 크기를 LCD panel의 패턴크기에 가로  $\sqrt{2}$ 배와 같은 세로길이를 설계되었다. 이것은 기준광의 진행방향과 물체광의 진행방향을 서로  $45^\circ$ 로 기울인 채로, 즉 홀로그램을 기준광의 파면과  $45^\circ$ 로 기울인 상태에서 간섭패턴을 기록하여 off-axis 홀로그램[20]으로 HLA를 제작한다. 그래서 재생시 1차 회절광을 0차 회절광과 분리가 쉽다. 더 큰 각도로 기울이면 HLA의 효율문제[21]와 summation lens의 한계가 따르며, 작게 기울이면 물체광과의 분리가 까다롭다. 그리고 각각의 홀로그램 렌즈들의 크기는 LCD panel의 연결세기군을 완전히 통과시킬 수 있도록 연결세기군의 전체 크기보다 가로 세로 각각 3 pixel 씩 더 크게 설계하였고, 각 홀로그램 렌즈들간의 간격을 줄였다. 물론 가로 길이는 해당길이 당  $\sqrt{2}$ 배로 하였다. 설계된 HLA의 가로는  $58(mm)$ 를 가지며, 세로는  $53.1(mm)$ 이다. 각 홀로그램 렌즈의 가로는  $5.5(mm)$ 이며, 세로는  $5.1(mm)$ 를 가진다. 그리고 가로 간격은  $0.25(mm)$ , 세로 간격은  $0.21(mm)$ 로 두었다. 실제 설계된 HLA와 제작된 HLA는 그림 3.3에 나타냈다.

HLA의 제작순서는 다음과 같다.

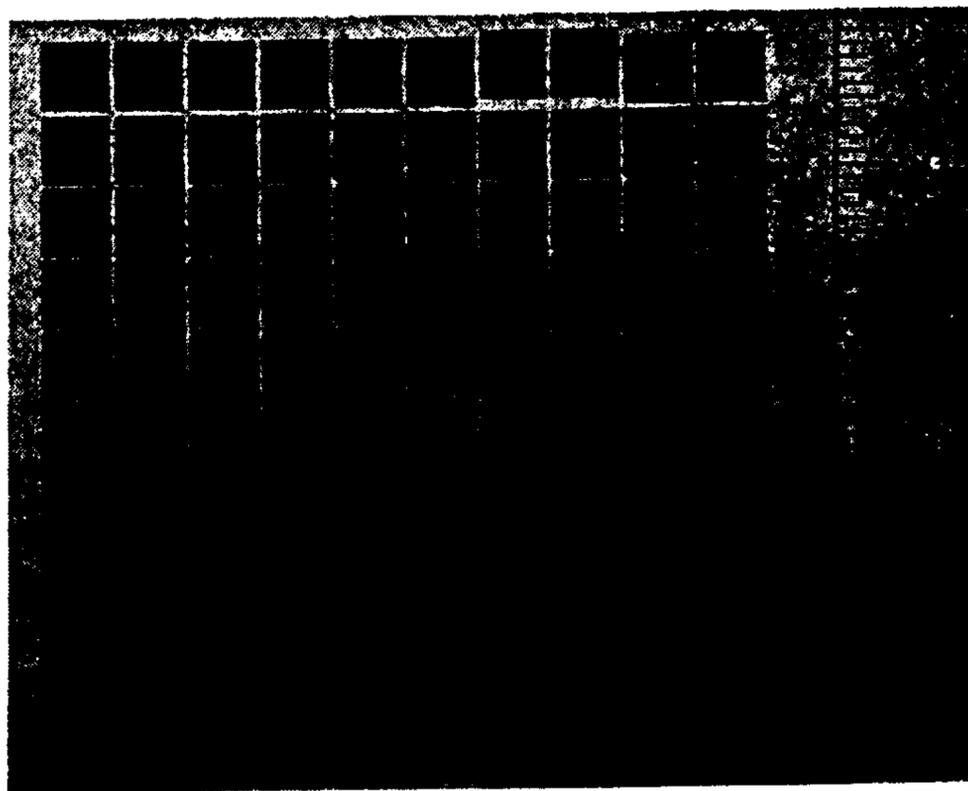
- 1) 원하는 크기의 홀로그램 렌즈 크기의 aperture를 갖는 mask를 제작한다.
- 2) 이것을 holographic panel 앞에 고정하고, 그림 3.4의 a)에서와 같이

holographic panel에 기준광과 object 렌즈의 물체광을 동시에 노출시켜서 mask의 aperture 부분에만 두 광의 간섭영상을 기록한다.

- 3) X-Y translator를 사용하여 holographic panel를 움직이면서 2D array 형태로 원하는 갯수 만큼의 간섭영상을 기록한다.
- 4) hologram plate를 화학적으로 처리한다.[표.1]



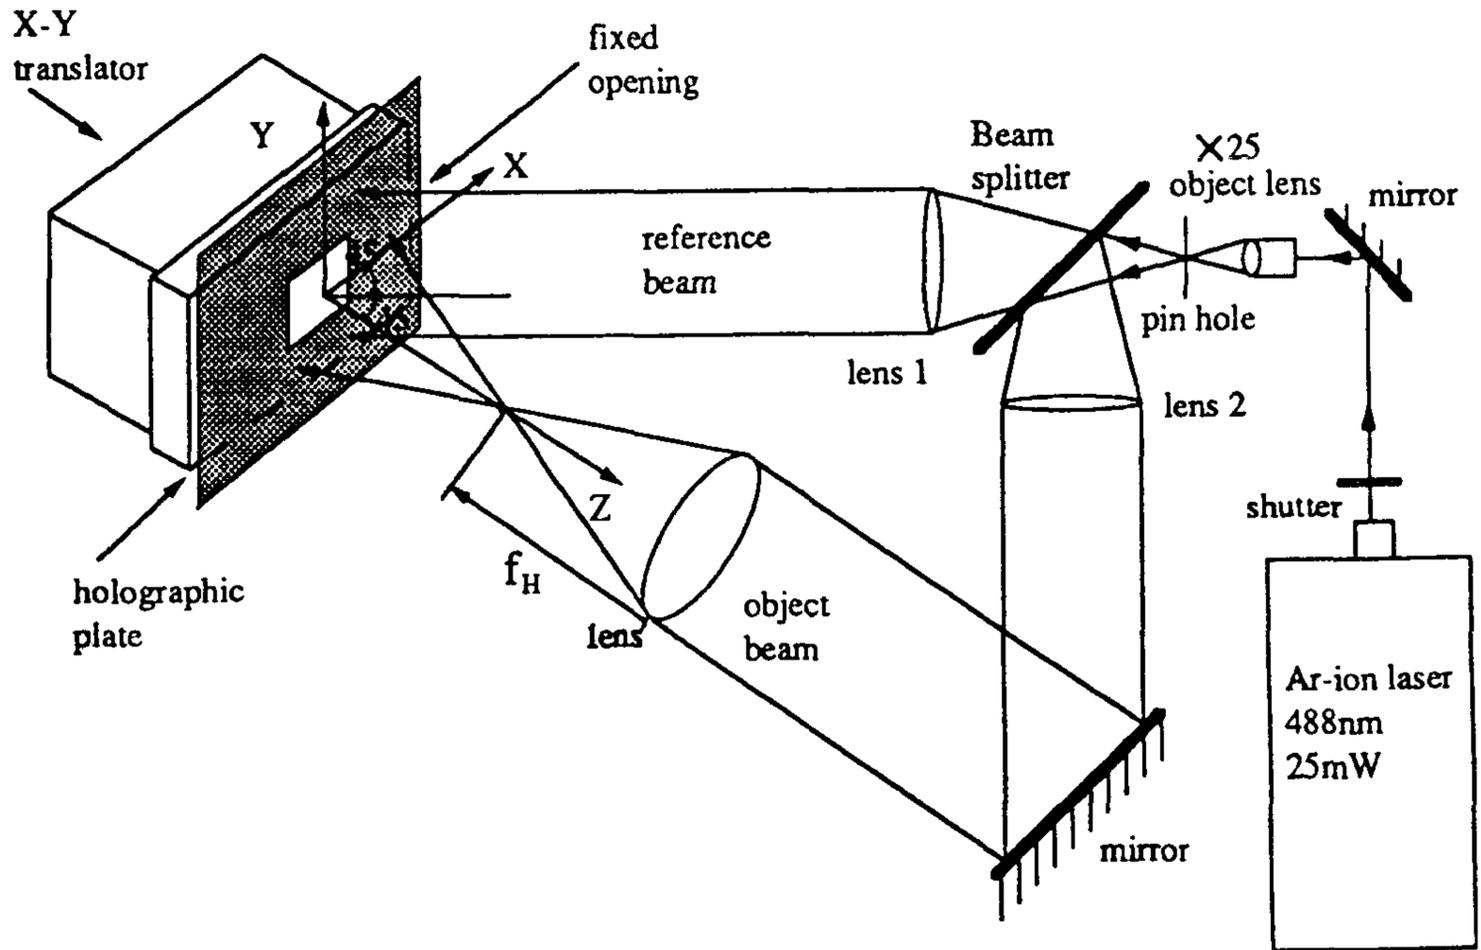
a) 제작될 HLA의 설계



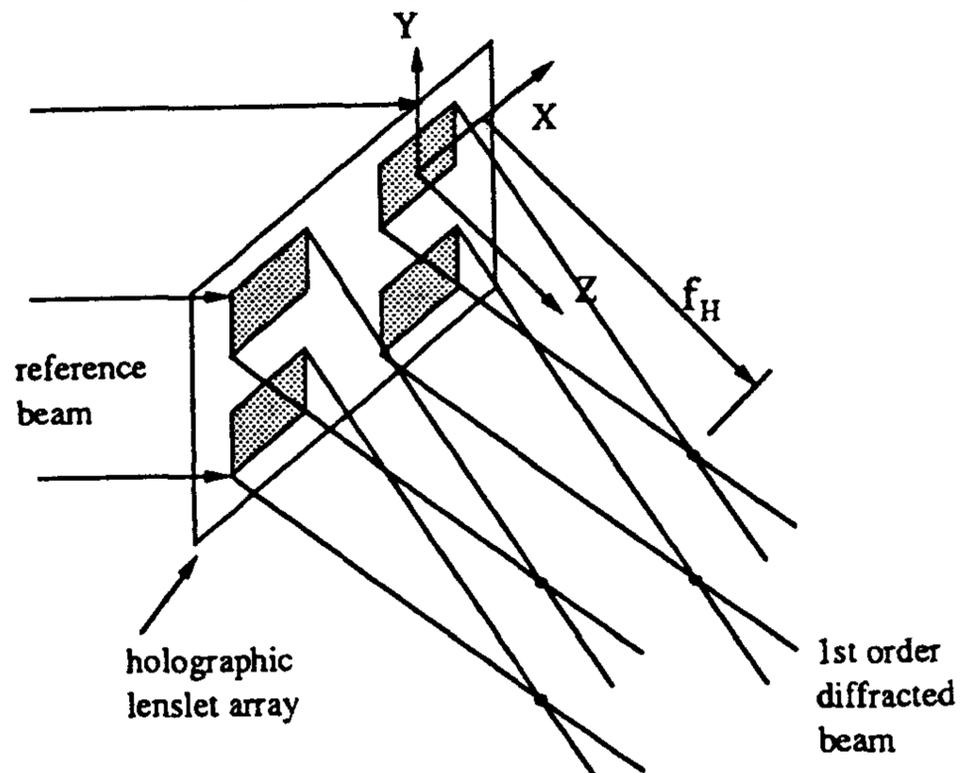
b) 제작된 HLA

그림 3.3 HLA의 설계와 제작

제작된 HLA는 효율을 높이기 위하여 표백한다[22]. 기록장치는 그림 3.4에 나타냈다. 레이저 power는 25(mW)로 하였으며, 그 외의 노출시간과 화학적 처리 시간은 표1.과 같다.



a) Recording of holographic lenslet array



(b) Imaging operation of HLA

그림 3.4 HLA기록을 위한 실험 장치

표1. 화학적 처리 과정[23][24][25]

과 정	시 간
1. 노 출	1/25초
2. 현 상(Kodak develop D-19)	1분 30초
3. 증류수 세척	2분
4. 정 착(Kodal rapid fixer sol.A)	4분
5. 증류수 세척	2분
6. 표 백(표2. 참고)	4분
7. 에탄올 처리	2분
8. 이소프로필 알코올 처리	4분
10. 건 조	5분

표2. 표백액 조성비[23][24][25]

성 분	합 량
증 류 수	1000(ml)
중크롬산 칼륨	0.8(g)
브롬화 칼륨	4.0(g)
황 산	1.0(ml)

현상할 때 소요된 시간은 노출시간과 사용된 레이저의 power에 영향을 받는다. 레이저의 power가 높아지고 노출시간이 길어지면 현상시간을 짧게 해야 한다. 그러나 높은 회절효율을 가지는 HLA를 얻으려면 홀로그램 fringe visibility를 높게 하여야 한다. 그러기 위해서는 짧은 노출시간에서 비교적 높은 레이저의 power가 요구된다. 이것은 보통의 optical table이 약 1Hz정도로 진동하고 있기 때문이다 [26]. 그리고 amplitude 홀로그램보다 phase 홀로그램의 회절효율이 우수하기 때문에 표백하여 phase 홀로그램으로 만들어 이용하는 것[23]이 좋다. 현상시간이 길어지면 표백시간도 길어야 한다. 보통 홀로그램을 표백과정까지 거치려면, 레이저 power를 비교적 높게하여 홀로그램 plate를 짧게 노출시킨 후, 충분히 현상하고 표백처리하여 세척을 완전히 하는 것이 효율을 높이고 표백에 의한 잡음[27]을 제거할 수 있다.

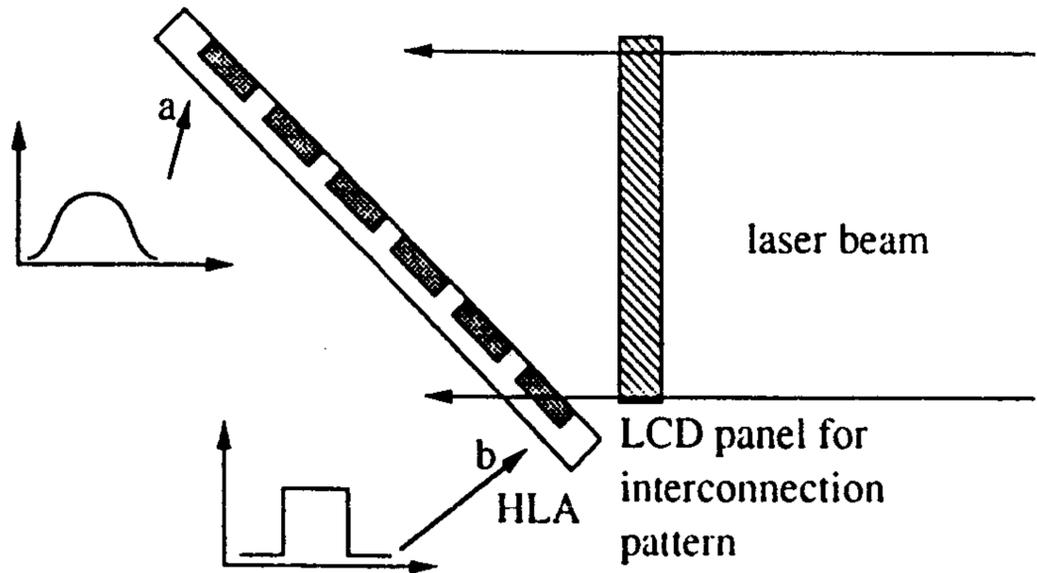
### 3.1.3 HLA과 LCD panel를 이용한 상호연결의 제한요소 고찰

대량의 광연결을 HLA와 LCD panel로 구현하기 위해서는 많은 제한요소가 따른다.

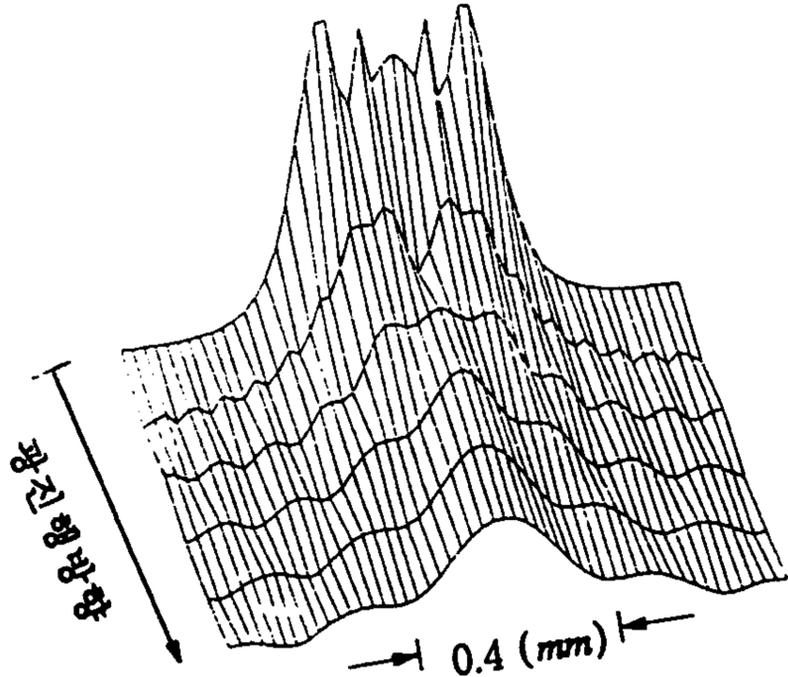
첫번째로는 홀로그래프 렌즈가 많아지면, 그 만큼 전체 HLA의 크기가 크게 되어 HLA의 모든 1차 회절광을 모을 수 있는 충분한 크기의 summation 렌즈가 필요하게 된다. 만약 홀로그래프 렌즈의 크기를 줄여, HLA의 크기를 키우지 않게 되면 홀로그래프 렌즈에 들어가는 패턴의 크기가 제한을 받는다. 본 실험에는 직경 3(in.) 렌즈를 summation 렌즈로 사용하였다.

두번째로는 그림 3.5 a)에서 볼 수 있는 것처럼  $45^\circ$  기울인 HLA 때문에 LCD panel의 패턴을 나타내는 pixel의 크기가 작아질 경우, a 지점에서는 b 지점과 달리 광신호의 회절 때문에 각 홀로그래프 렌즈에 들어가는 패턴의 모양이 달라진다. 특히 본 실험에서처럼 HLA의 전체크기가 크지면 이 문제는 심각해진다. 그림 3.5에 LCD panel의 pixel 한개와 두개를 주었을 때의 길이와 같은 단일 slit으로 나타내고, 영(Young)의 이론으로 시뮬레이션하였을 때의 결과를 나타냈다. 그림 3.4 c)에 나타낸 것처럼 pixel 한개로 패턴을 나타냈을 때, LCD panel과 HLA의 거리가 커질수록 이웃패턴에 영향을 주게 된다. 그림 3.5의 b)에서 처럼 pixel 두개를 나타낼 때는 패턴이 smooth해지기는 하지만 이웃의 패턴에 큰 영향을 주지는 않는다.

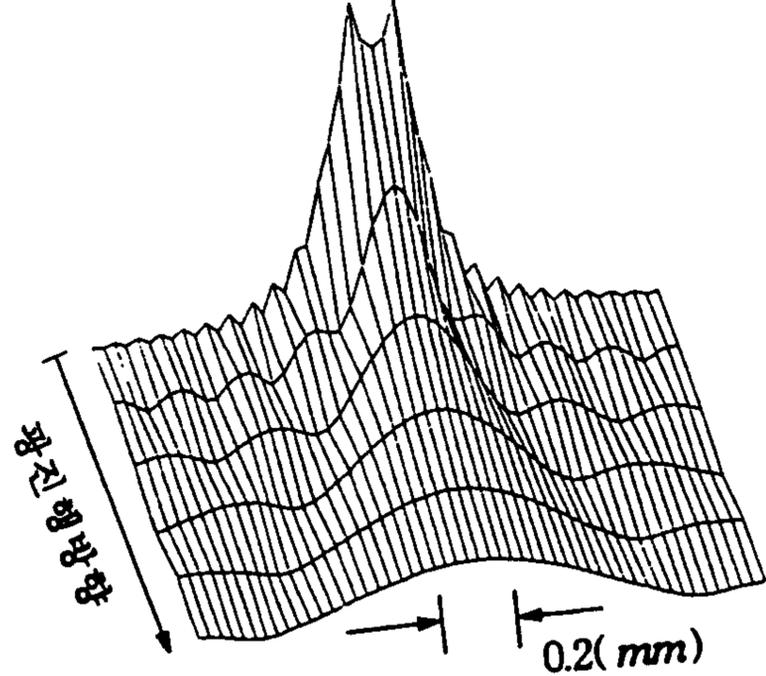
세번째로는 LCD panel 구조의 제한이다. 이 제한요소들은 앞절에서 상세하게 언급하였다. 그리고 그 외에 polarizer, liquid crystal, analyzer로 광이 진행하면서 생기는 반사효과는 나타낸 패턴에 공간적으로 fringe를 만들어 패턴의 contrast를 줄이게 된다.



a) HLA가 커질때의 영향



b) LCD panel 두 pixel 크기의 슬릿에서 광회절



c) LCD panel 한 pixel 크기의 슬릿에서 광회절

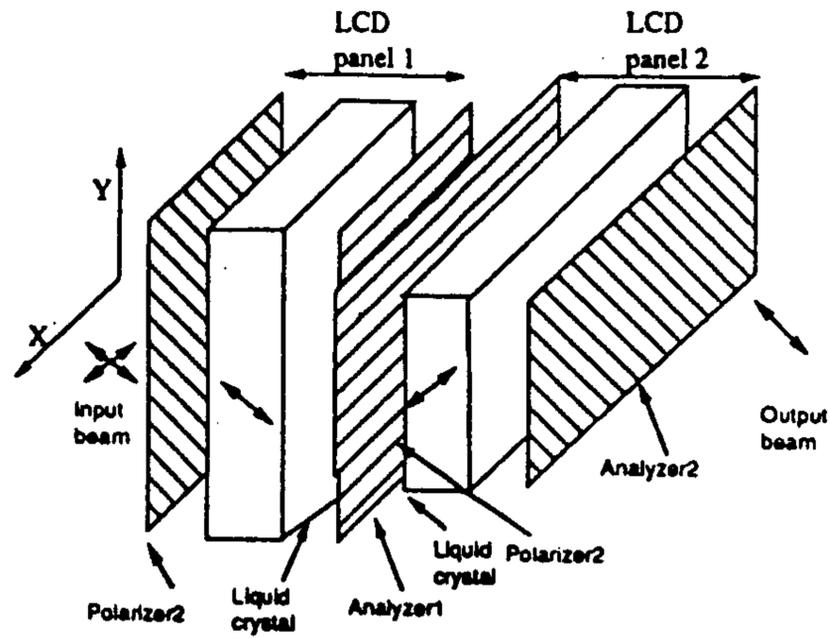
그림 3.5 HLA의 크기에 의한 광연결의 제한

네번째로는 인터페이스용 PC의 제한이다. 영상처리용 Frame grabber DT2853의 매크로 명령들이 C 언어 컴파일러의 모델중, Large 모델에서만 사용 가능하다. 그러면 C 프로그램 상에서 사용할 수 있는 배열의 크기가 제한을 받게된다. 본 논문에서의 3600개의 광연결의 제한은 이 인터페이스용 PC의 제한에 의해 거의 결정되었다. 더 많은 광연결을 위해서는 보다 효율적으로 프로그래밍하는 기술도 요구된다고 할 수 있다.

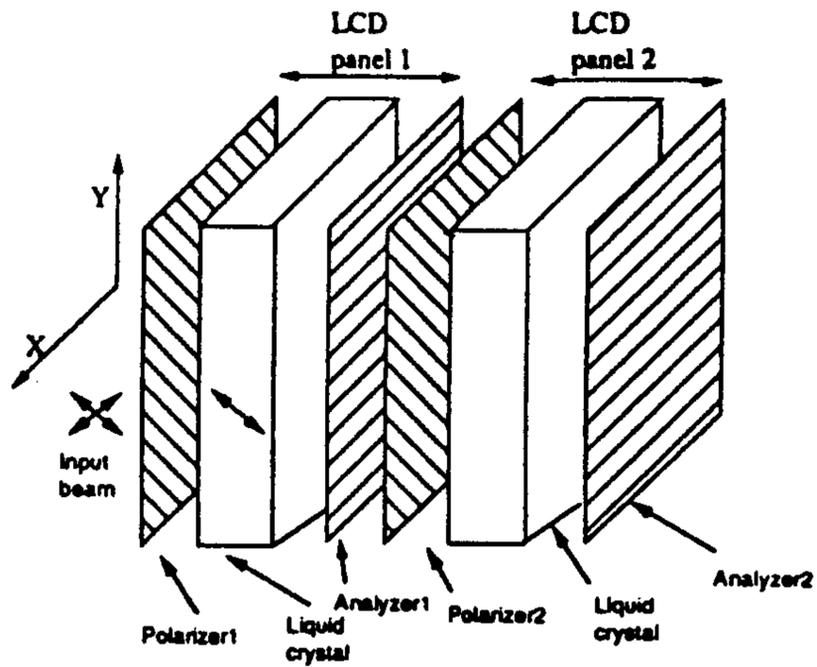
### 3.2 연결요소의 전달특성

대량의 광연결을 위해서는 LCD panel를 효율적으로 이용하여야 한다. LCD panel는 그림 3.2에서처럼, 가로 세로크기가 4 : 5이다. 그리고 liquid crystal을 중심으로 양쪽의 polarizer와 analyzer가 서로  $90^\circ$ 의 polarization 차를 가지면서, Y축에 대해서  $\pm 45^\circ$ 로 기울어져 있다. 그래서 그림 3.6 a)와 같이 서로  $90^\circ$ 로 엇갈리게 놓게 되면 광은 두 panel로 제어시킬 수 있으나, LCD panel에 나타나는 패턴의 크기를 제어하기가 쉽지 않게 되며, LCD panel를 전체 넓이의 16/25(전체 64%)만을 사용할 수밖에 없기 때문에 대량 광연결을 시킬 수 없다. 그리고 그림 3.6 b)와 같이 2개의 LCD panel를 같은 형태로 광의 진행방향에 cascade하게 놓을 경우, analyzer1과 polarizer2의 polarization이 서로  $90^\circ$  차이가 있어 어떠한 경우에도 광은 통과할 수 없다.

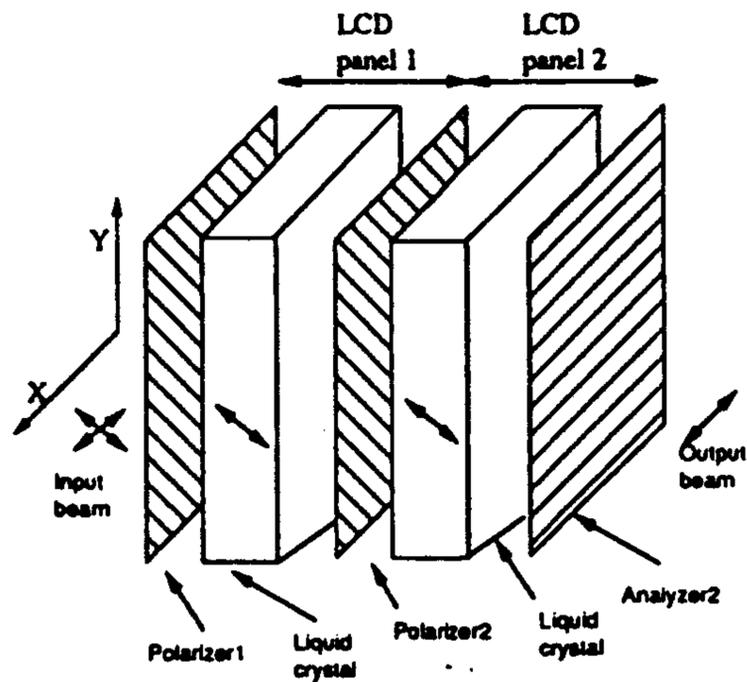
그래서 본 실험에서는 그림 3.6 c)처럼 LCD panel1에서 analyzer1를 제거하고 그림 3.6 b)와 같이 구성하여 LCD panel2의 polarizer2는 LCD panel1의 analyzer를 접하게 하였다. 이와 같이 시스템을 구성하면, 약간 더 적은 레이저 power로도 실험이 가능하게 된다. 그리고 나서 LCD panel1과 LCD panel2의 선형성과 전체 광연결 시스템을 구성하였을 때의 선형성을 측정하였다.



a) LCD panel module 1



b) LCD panel module 2



c) LCD panel module 3

그림 3.6 LCD panel module의 구성 모양

### 3.3.1 LCD panel의 전달특성

먼저 LCD panel2는 64로 최대값을 저장한다. 그리고 LCD panel1을 0에서 80까지 변화시키면서 CCD 카메라에 관측되는 값을 그림 3.7에 나타냈다. 그림에서 볼 수 있듯이 64이상의 값에서 완전히 차단되지 않는다.

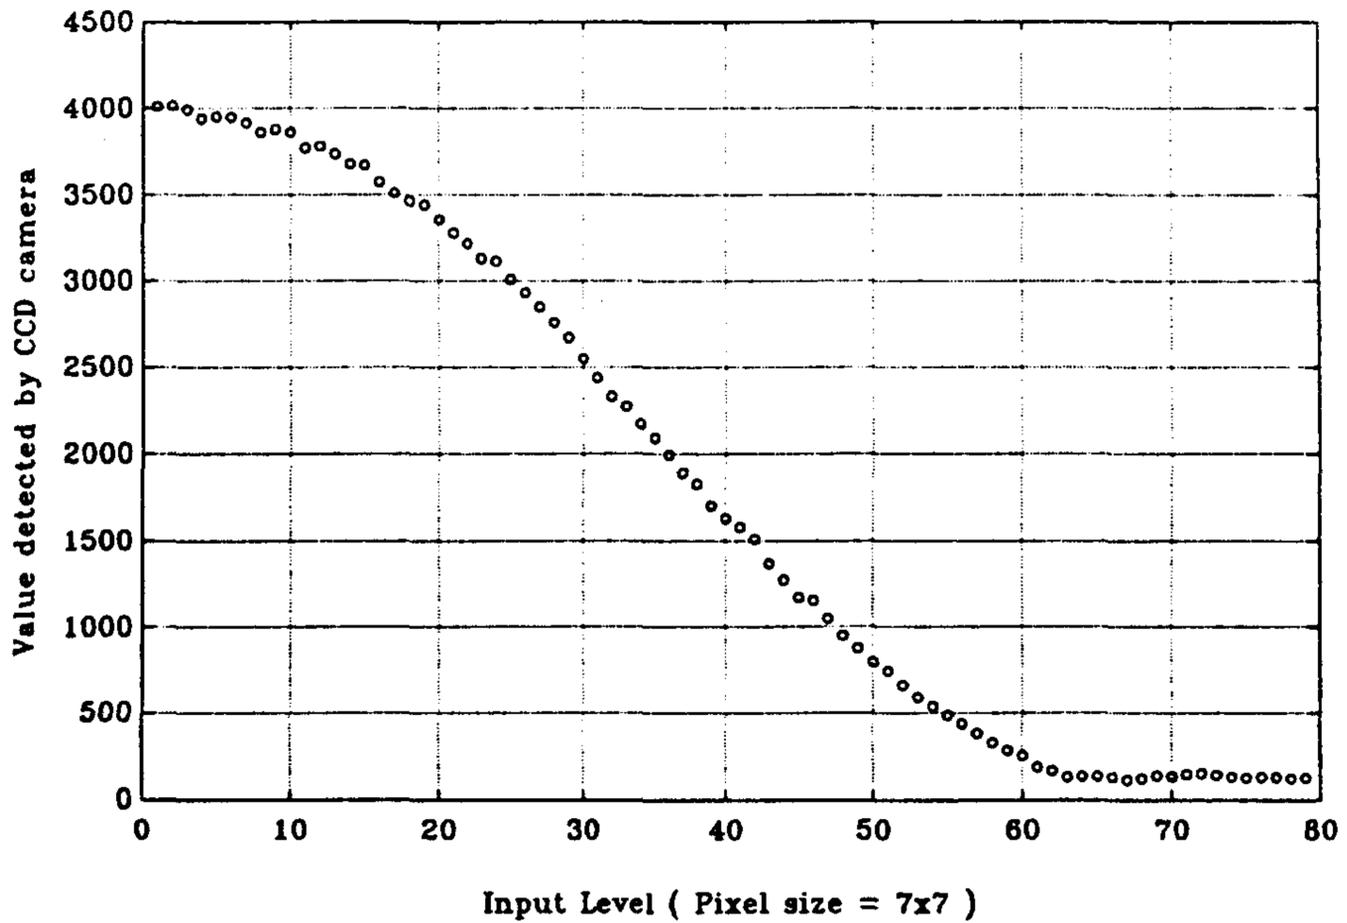


그림 3.7 LCD panel1의 전달 특성

그리고 LCD panel1은 최대로 광이 통과하도록 0를 저장하고, LCD panel2를 0에서 80까지 변화시키면서 관측되는 값을 그림 3.8에 나타냈다.

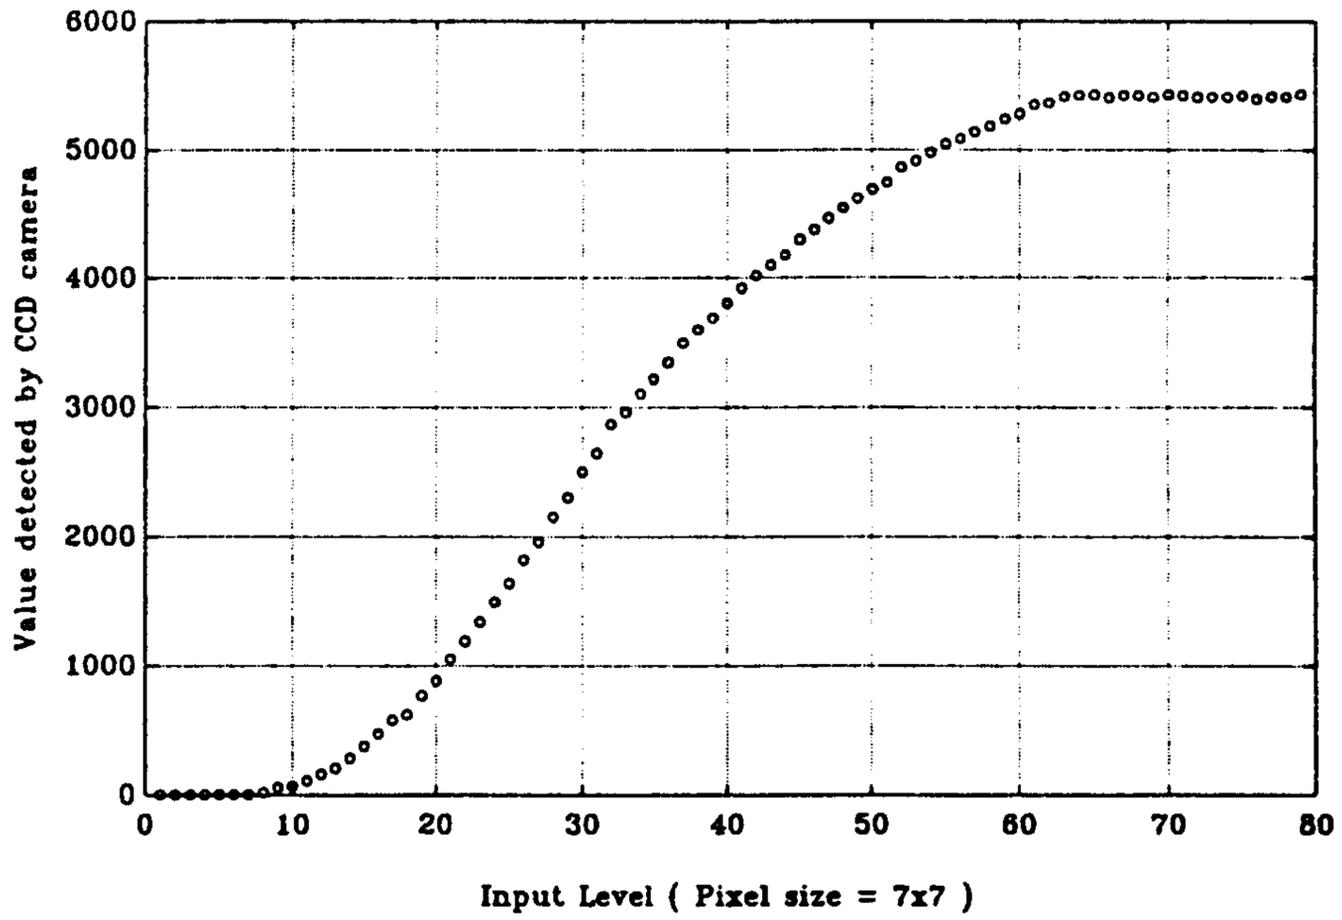
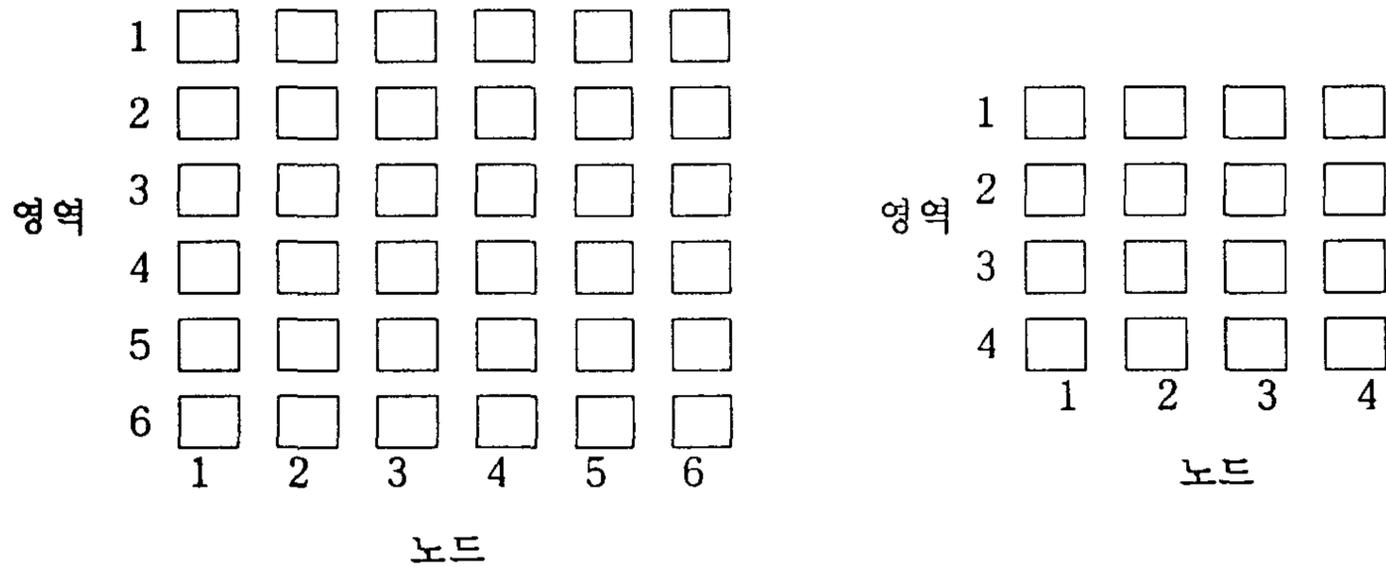


그림 3.8 LCD panel2의 전달 특성

### 3.2.2 광연결 시스템의 선형성

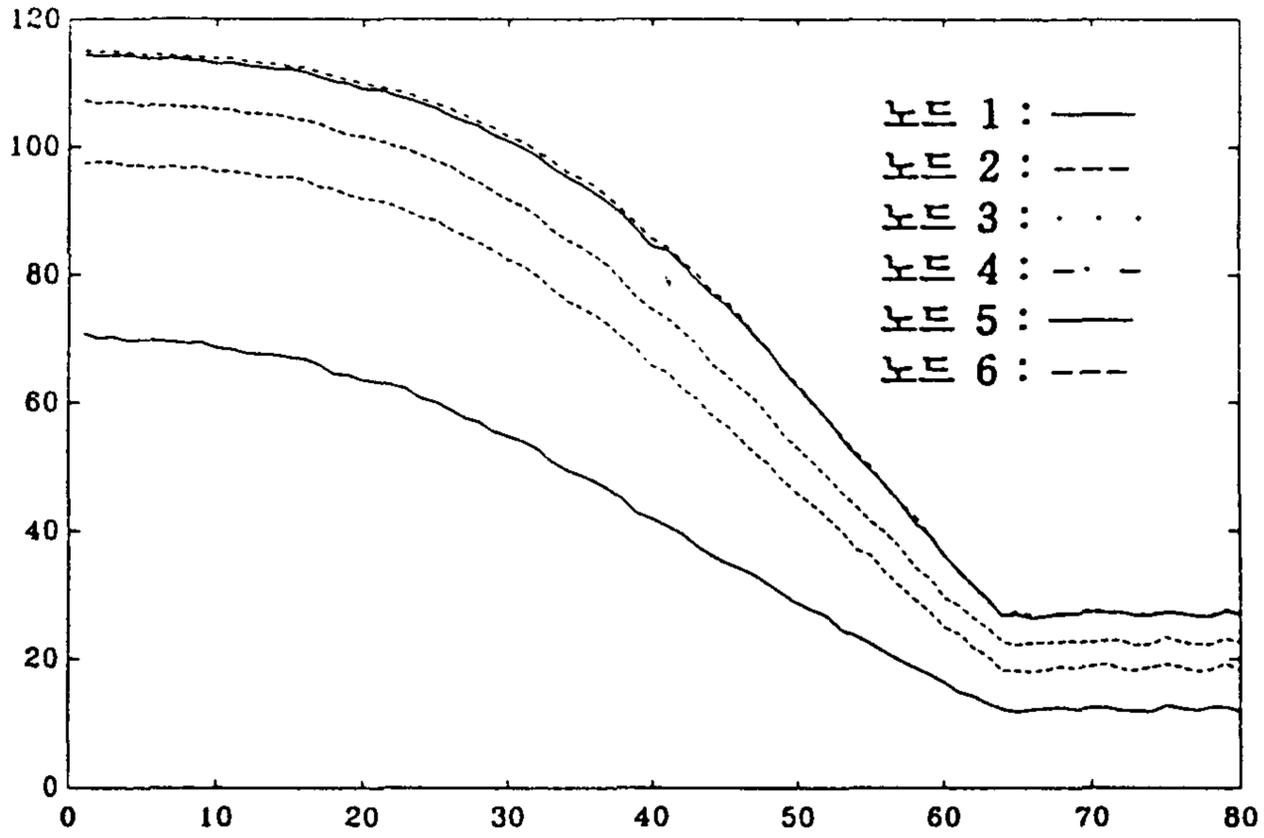
LCD panel1에 입력패턴을 나타내는 모든 pixel과, LCD panel2의 연결세기를 나타내는 모든 pixel에 0에서부터 80까지 변화시키면서 출력단의 각 영역별 선형성을 측정하였다. 은닉층의 출력을 얻을 때의 각 영역과 출력층의 출력을 얻을 때의 각 영역은 그림 3.9에 나타났다.



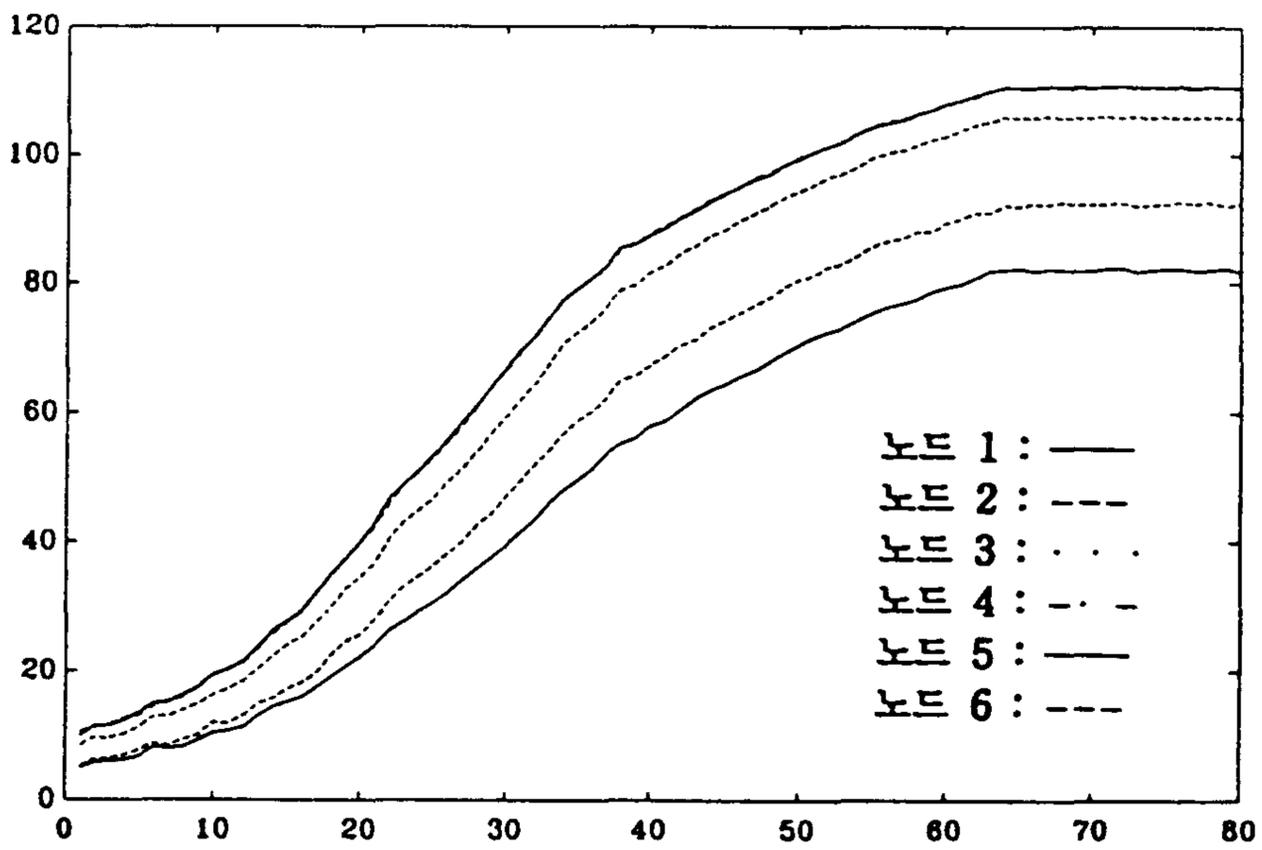
a) 3600개의 광연결에서의 출력패턴    b) 576개의 광연결에서의 출력패턴

그림 3.9 출력패턴 모양

먼저 입력층과 은닉층 사이에서 광연결의 선형성을 측정하였다. 그림 3.10은 LCD panel1을 0로 하고 LCD panel2를 0에서 80까지 변화시킬 때와 LCD panel2를 64로 하고 LCD panel1을 0에서 80까지 변화시킬 때, 각각의 경우 영역 2에서 CCD 카메라에 검출되는 값들을 나타낸다.



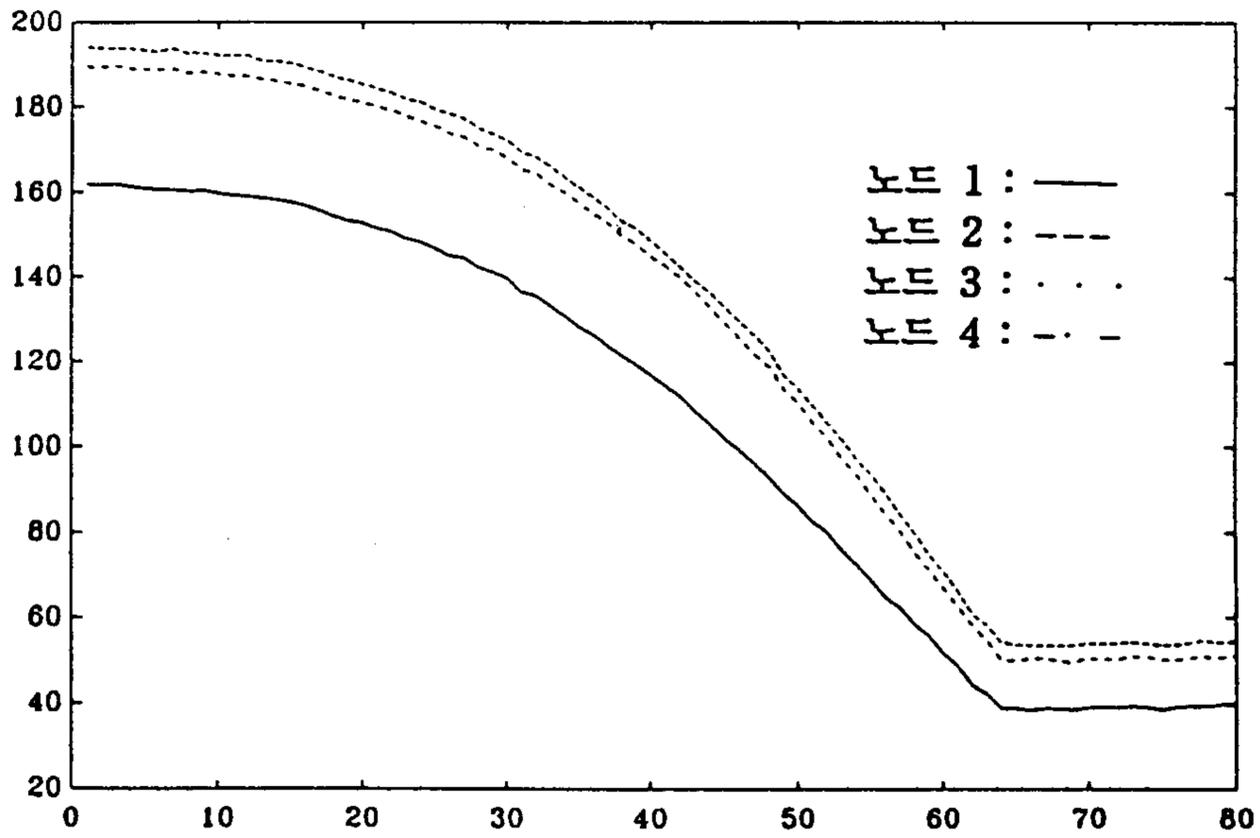
a) LCD panel2 = 64, LCD panel1 가변



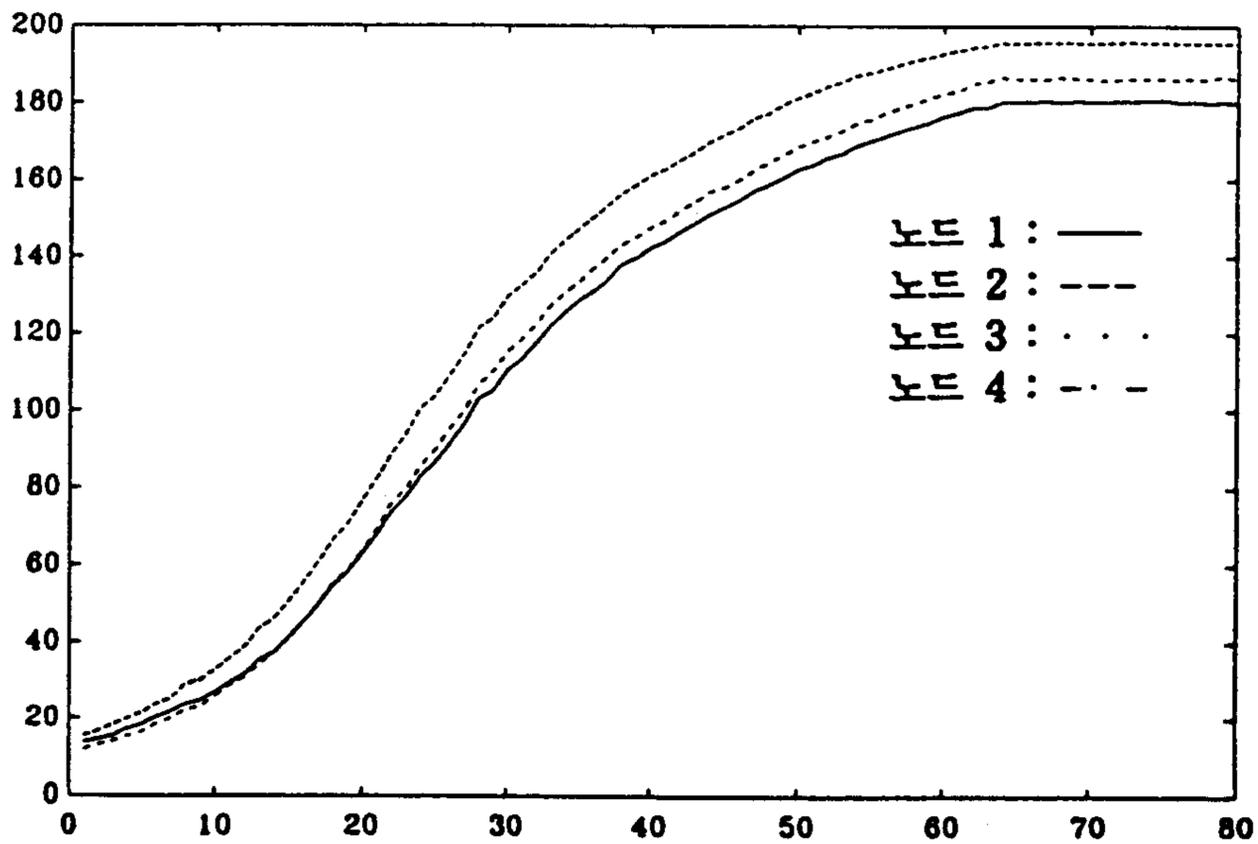
b) LCD panel1 = 0, LCD panel2 가변

그림 3.10 입력층과 은닉층 사이 광연결의 선형성

그리고 온닉층과 출력층 사이에서의 선형성을 측정하였다. 그림 3.11는 LCD panel1을 0로 하고 LCD panel2를 0에서 80까지 변화시킬 때와 LCD panel2를 64로 하고 LCD panel1을 0에서 80까지 변화시킬 때, 각각의 경우 영역 2에서 CCD 카메라에 검출되는 값들을 나타낸다.



a) LCD panel2 = 64, LCD panel1 가변



b) LCD panel1 = 0, LCD panel2 가변

그림 3.11 은닉층과 출력층 사이 광연결의 선형성

### 3.3 실험

#### 3.3.1 실험장치

다층 인식자를 구현하기 위한 실험장치를 그림 3.12에 나타냈다. LCD panel1에 입력을 넣고, LCD panel2에 상호 연결값을 넣는다. 이것은 앞 부분에서 나타냈듯이 LCD panel1은 1 또는 0로 ON/OFF만을 나타내면 되지만, LCD panel2는 0에서 64까지 상호연결 값을 나타내야 하기 때문에, 보다 선형성이 좋은 LCD panel2에 상호연결 값을 나타낸다. LCD panel1에서 입력패턴에 의해 공간적으로 amplitude 변조된 광신호가 LCD panel2의 상호연결값에 다시 곱해지고, 이 곱해진 신호를 홀로그래프 렌즈 배열과 summation 렌즈 L1에 의해서 광학적으로 합하여 4차원 상호연결의 출력을 얻는다. 출력은 CCD 카메라로 받았다. 여기에 사용된 LCD panel은 SHARP XV-100R 투사형 디스플레이의 내부에 있는 액정 패널 두개를 다른 두개의 Frame grabber DT2803으로 구동하는 방식을 사용했다. 시스템의 모든 동기신호는 CCD 카메라 동기신호에 맞춘다.

시스템의 동작순서는 다음과 같다.

- 1) 상호연결을 임의의 값으로 정한다.
- 2) LCD panel1으로 입력 패턴을 보인다.
- 3) LCD panel2의 연결세기를 모두  $OFFSET_w$  값으로 만들어 준다.
- 4) CCD camera로 은닉층의  $OFFSET^{(2)}$  값을 읽어놓는다.
- 5)  $\overline{W}_{ji}$ 를 LCD panel2에 나타내고, CCD 카메라로 은닉층의  $\overline{net_j^{(2)}}$  값을

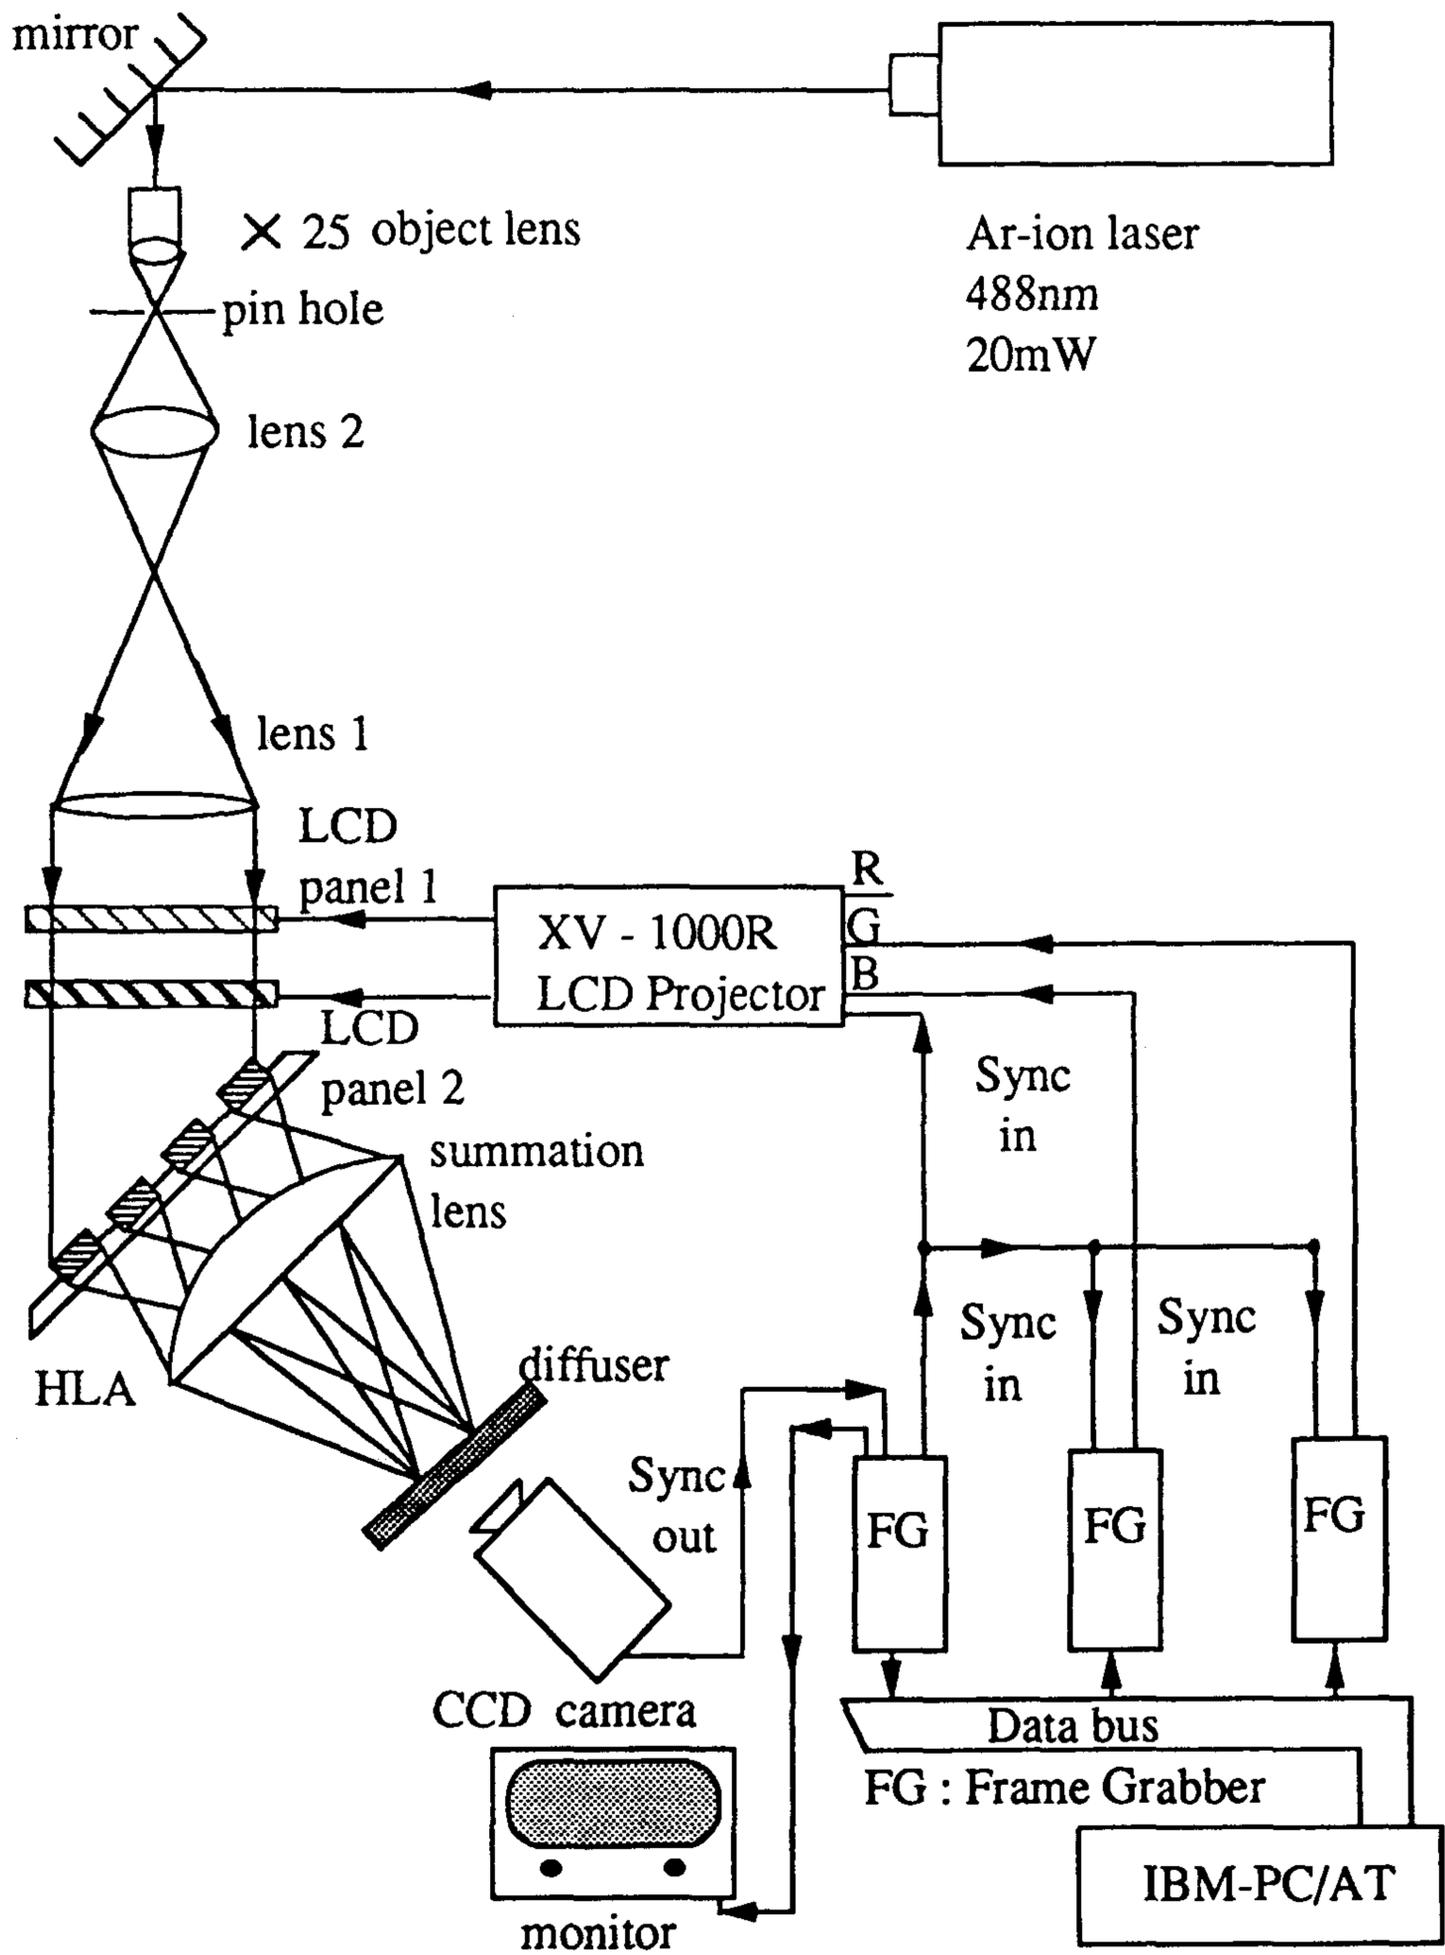


그림 3.12 실험 장치

읽어 들여 (4)에서 읽어들이는 값을 전기적으로 뺀 다음,  $f(\cdot)$ 을 취하여 은닉층 신경의 출력값을 정한다.

6) LCD panel1으로 은닉층의 값을 출력한다.

7) LCD panel2의 연결세기를 모두  $OFFSET_w$ 값으로 만들어 준다.

8) CCD camera로 출력층의  $OFFSET^{(3)}$ 값을 읽어놓는다.

9) LCD panel2에  $\overline{W_k}$ 를 나타내고 카메라로 출력층의  $\overline{net_k^{(3)}}$ 값을 읽어들이 (8)에서 읽어들이는 값을 전기적으로 뺀 다음,  $f(\cdot)$ 을 취하여 출력값을 얻는다.

10) 전기적으로 오차를 계산하여 연결세기를 바꾸어 준다. 일정한 수준의 에너지로 줄어들 때까지 (2)에서부터 다시 반복한다.

### 3.3.2 패턴학습 결과

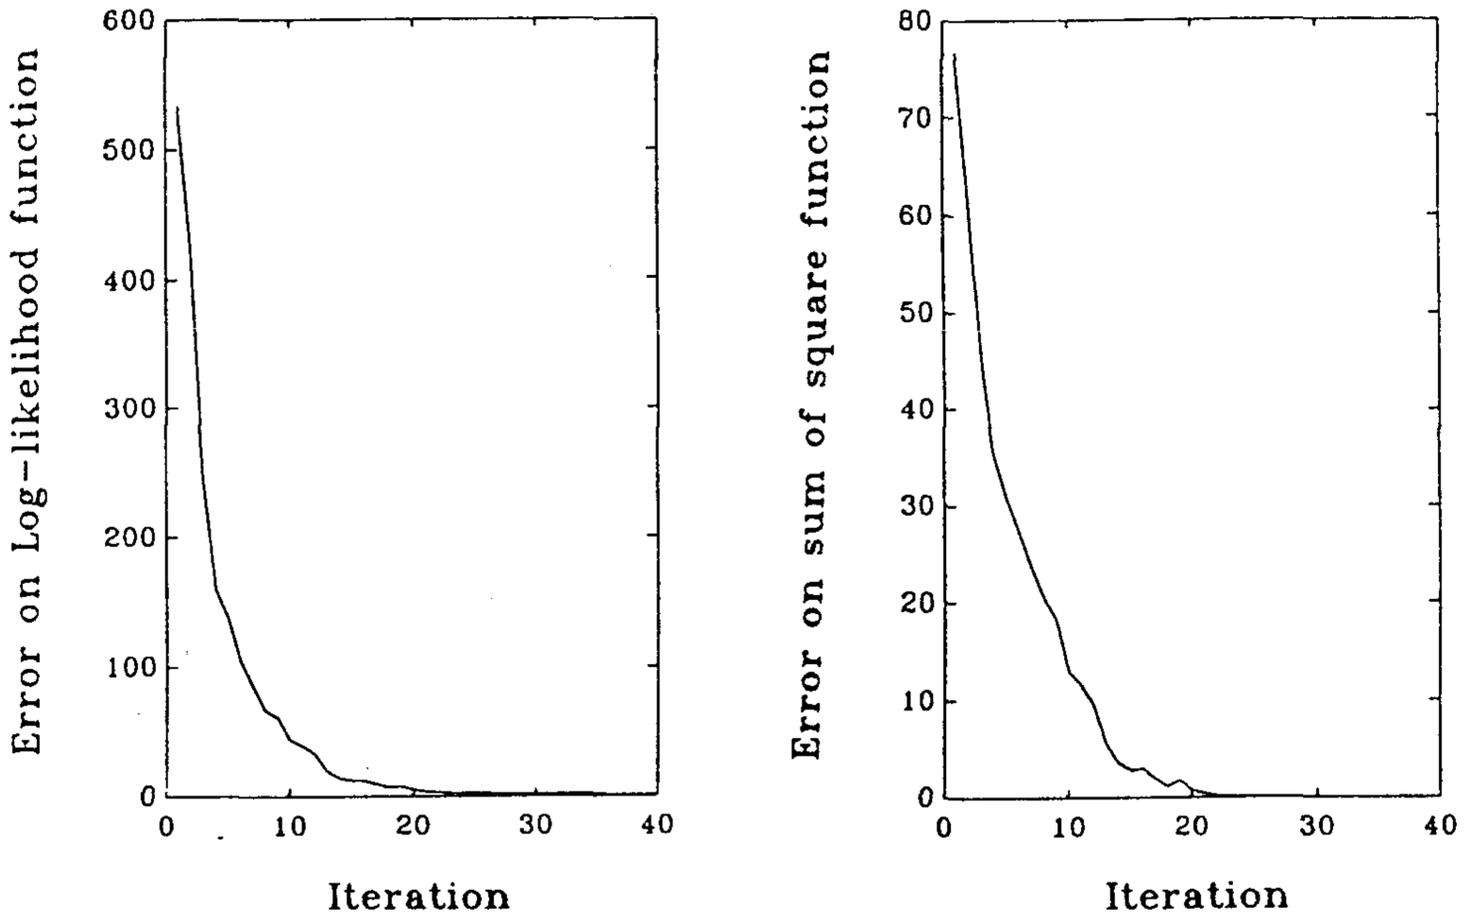
실험에 사용된 입력패턴과 target 패턴은 그림 3.13에 나타낸다. 입력패턴 중에 3과 8은 서로 상관관계가 크기 때문에 시스템이 다르게 인식하지 못한다. 그래서 전체패턴을 상하로 한 비트씩 이동한 패턴모양으로 만들어 실험하였다. 전체 오차가 수렴하는 과정을 그림 3.14에 시뮬레이션 결과와 함께 나타냈다. 이때 사용된 학습률과 관성률은 시뮬레이션을 통해서 산출되었다. 그림에 나타난 것처럼 시뮬레이션에서 40번의 반복학습[약 30분]으로 0.1이하의 수렴정도를 보였다. 그리고 실험에서는 40번의 반복[약 1시간]학습으로 1.5이하의 수렴, 60번의 반복학습[약 1시간 30분]으로 0.5이하의 수렴정도를 보였다. 앞의 모든 시간 계산은 PC 286으로 수행했을 때의 값이다.

Input pattern	Target pattern	Input pattern	Target pattern

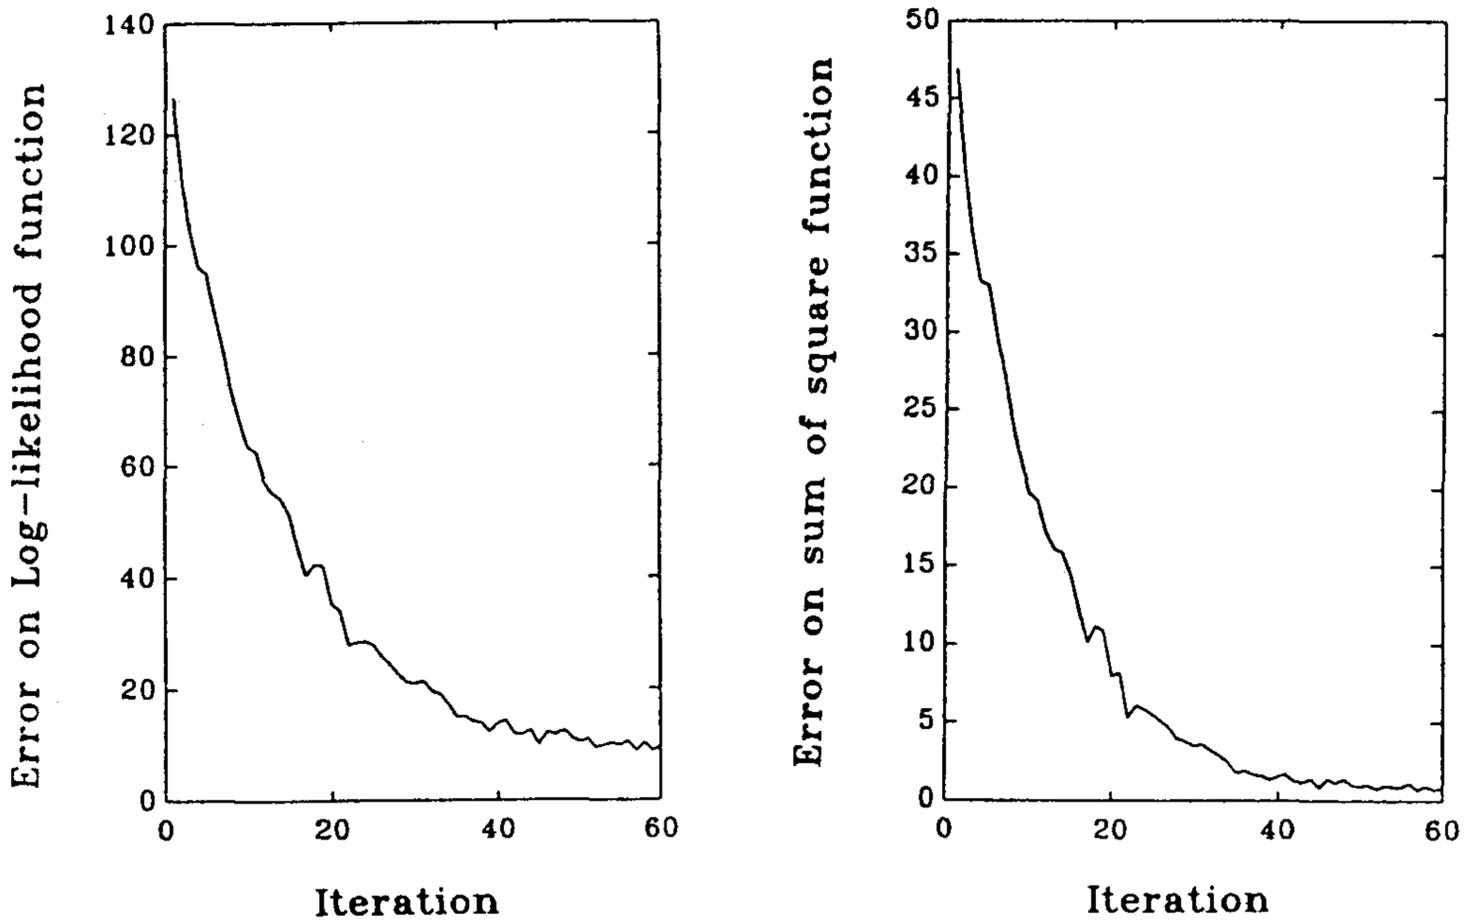
: 1  
 : 0

그림 3.13 실험에 사용된 패턴

각 출력단이 수렴하는 과정과 출력영상을 그림 3.15에서부터 그림 3.24에 나타냈다. 오른쪽 열은 시뮬레이션 결과이며 왼쪽 열은 실험결과이다.



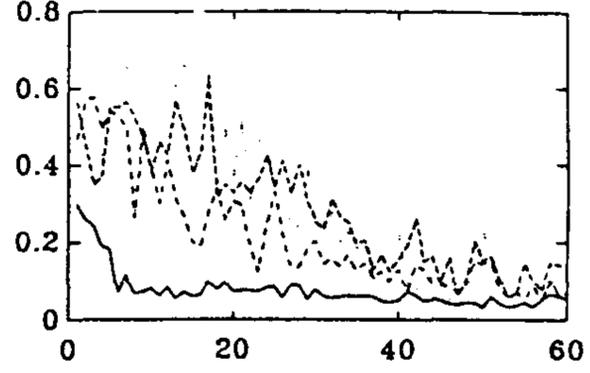
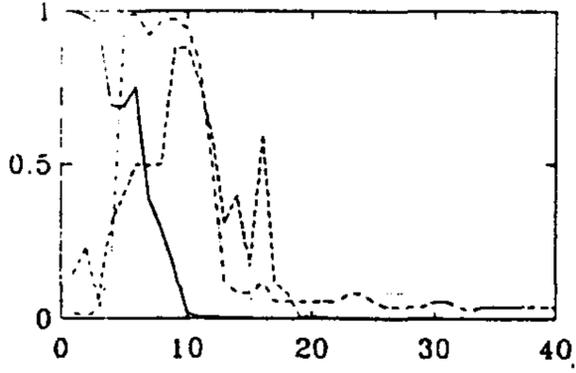
a) 시뮬레이션에서의 수렴곡선



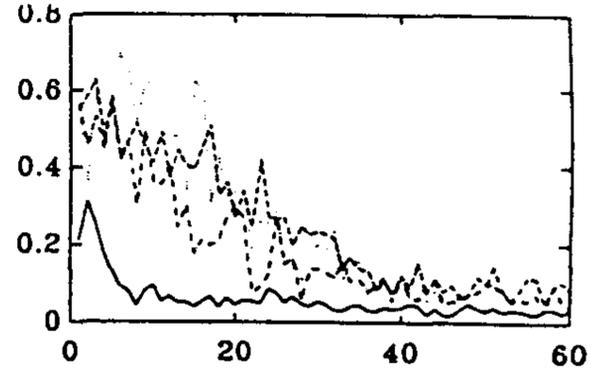
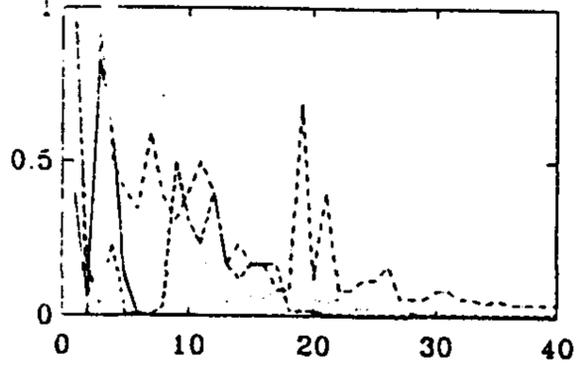
b) 실험에서의 수렴곡선

그림 3.14 수렴곡선

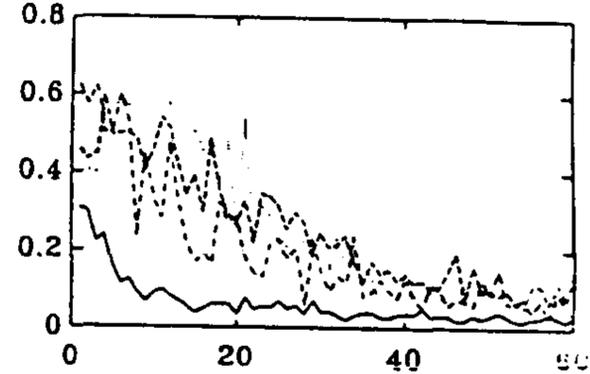
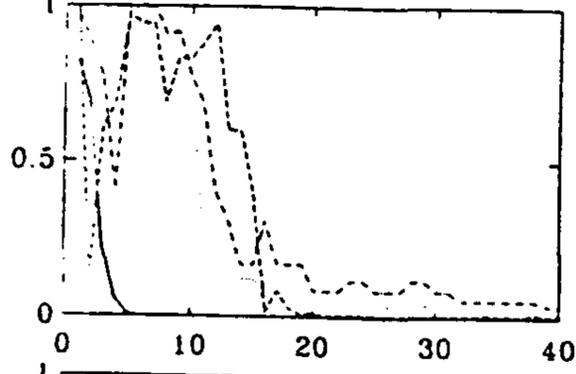
영역 1



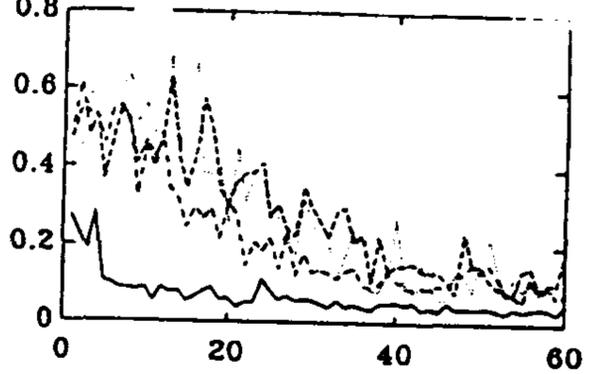
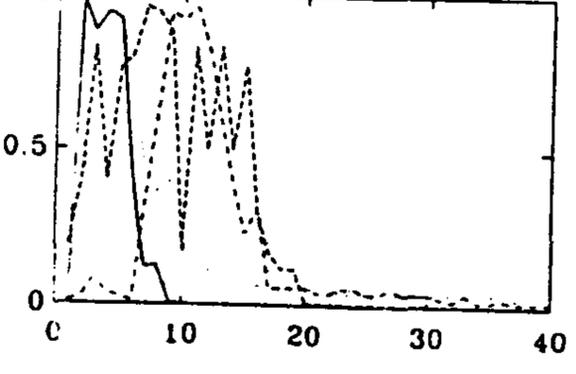
영역 2



영역 3



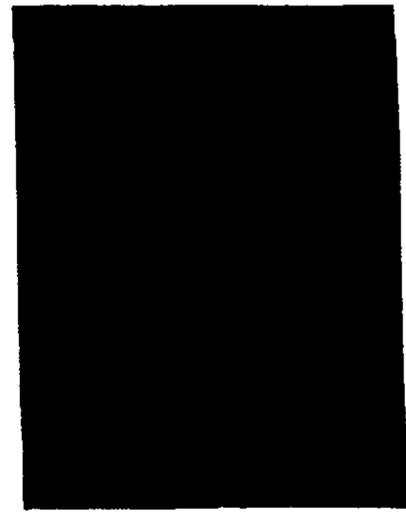
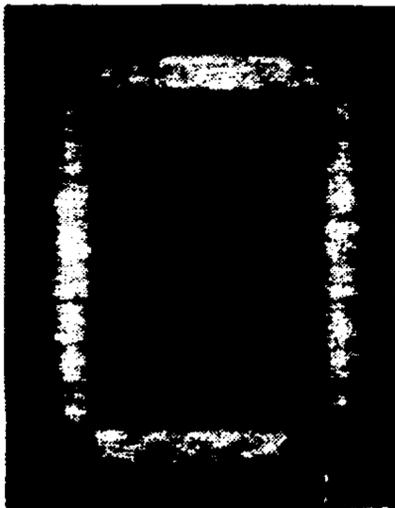
영역 4



시뮬레이션결과

실험결과

a) 각 영역별 출력노드에서의 iteration에 대한 학습과정  
 ( 노드 1 : —, 노드 2 : ---, 노드 3 : ···, 노드 4 : -·-· )



b) 입력패턴

c) 최종 offset 패턴

d) 최종 출력패턴

그림 3.15 패턴 0에 대한 출력단의 각 노드의 학습과정과 결과



















### 3.3.3 인식률 측정

다층인식자 시스템이 완전히 학습되었을 때, 그때의 연결세기를 가지고 인식률 측정을 하였다. 각 패턴에 대하여 20번 error 패턴을 만들어서 인식한 패턴의 퍼센트를 그림 3.25에 나타냈다. 입력영상에 5%의 error가 발생할 때까지 90%이상을 인식하고 있다.

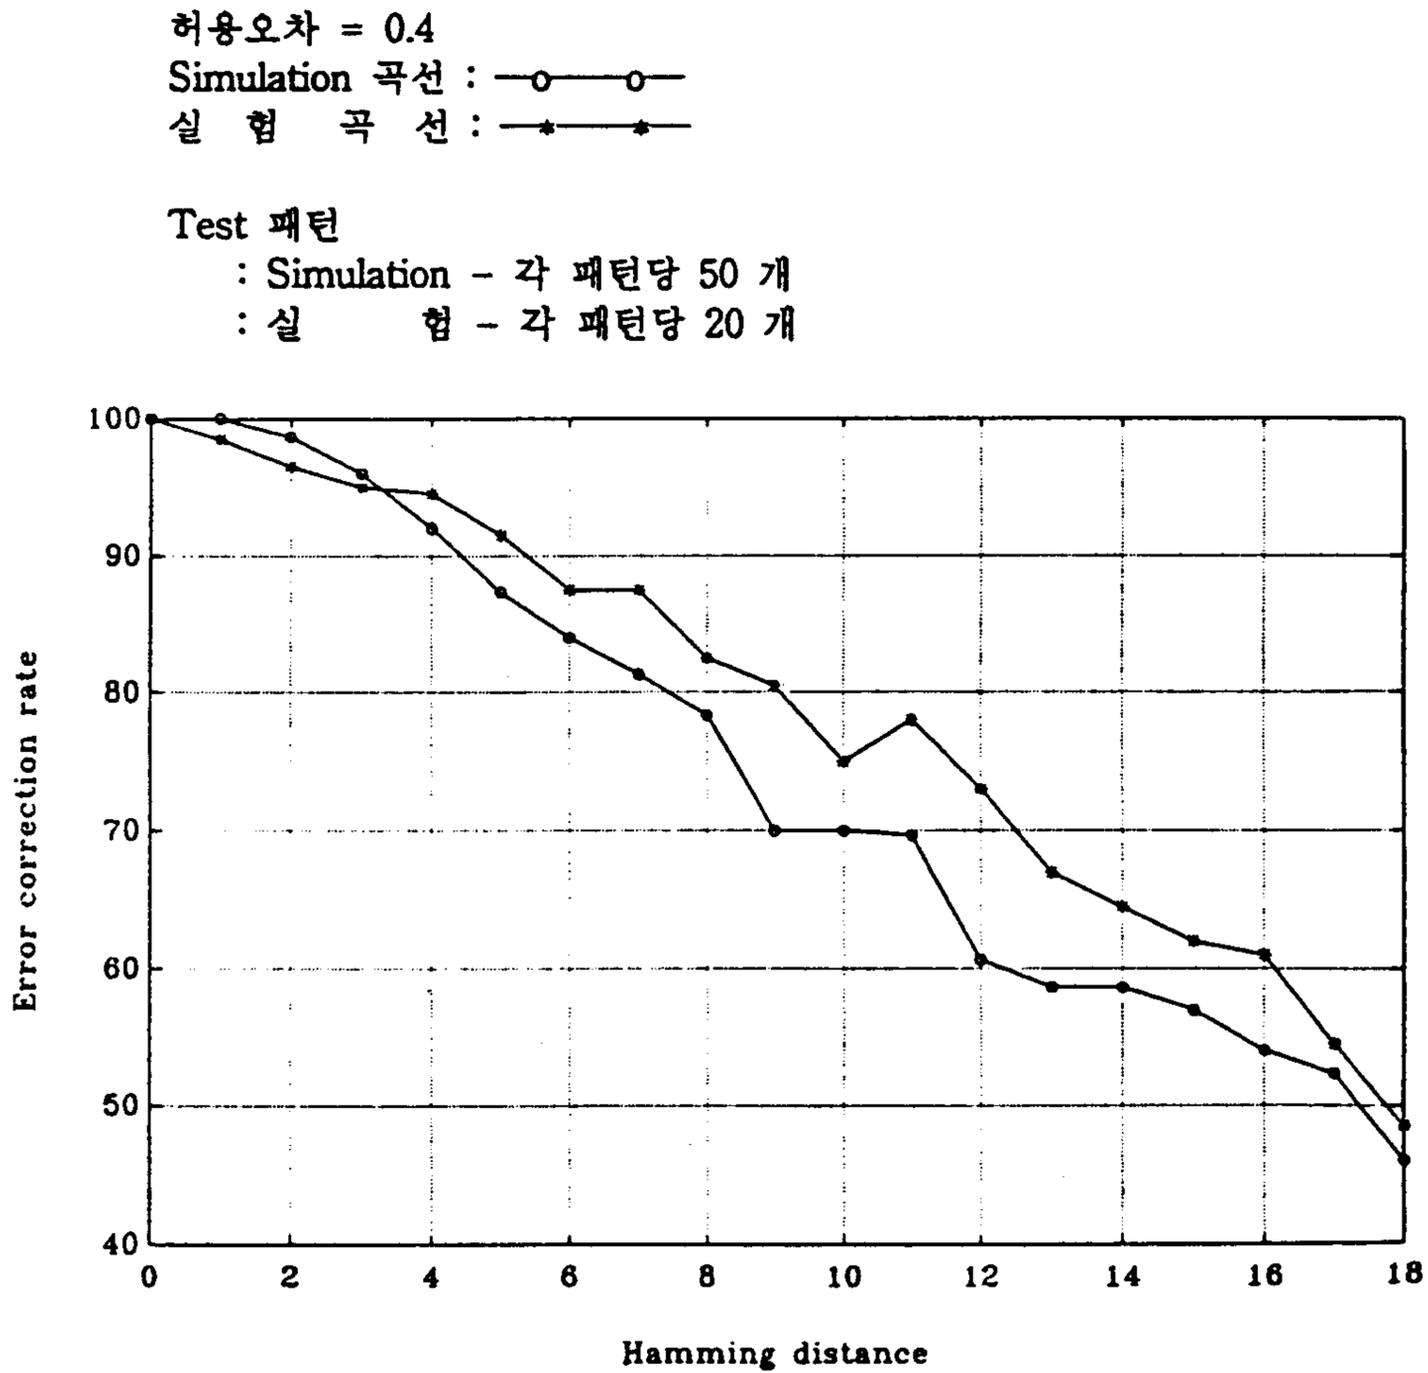


그림 3.25 인식률 곡선

## 4) 결론

본 보고서에서는 홀로그램 렌즈 배열과 LCD panel를 사용하여 3600개의 가변 광연결을 구현하였다. 이 실험에서 사용된 LCD panel은 기존의 LCTV와 같은 구조로 가로 세로  $256 \times 256$  pixel을 가진다. 실험에서는  $207 \times 207$  pixel을 사용하여 광연결을 구현하고, 더 많은 광연결 구현에 따른 제한요소들을 고찰하였다. 이와 같이 구현된 가변 광연결 구조를 이용하여 입력층  $10 \times 10$ , 은닉층  $6 \times 6$ , 그리고  $4 \times 4$  개의 출력층 신경수를 가지는 다층 인식자를 구현하였다. 입력에 따른 출력의 문턱화를 도입하여 다층인식자가 양의 상호연결의 세기만을 갖도록 하였다. 에너지 함수로 log-likelihood 함수를 도입하였다. 이렇게 구현된 다층 인식자는 학습을 통하여 10개의 숫자를 2진수 코드패턴으로 정확히 mapping해냈다.

## 참 고 문 헌

- [1] L. Shasfri, "Massive parallelism in artificial intelligence," *Appl. Opt.* Vol. 26, p. 1829 (1987)
- [2] T. H. Hildebrandt, "Optimal training of thresholded linear correlation classifiers," *IEEE trans. on neural network*, Vol 2, p. 577 (1991)
- [3] P. D. Wasserman, *Neural computing*, Van Nostrand Reinhold, New York, 1989
- [4] Y. H. Pao, *Adaptive pattern recognition and neural networks*, Addison Wisley Publishing, Inc., 1989
- [5] N. H. Farhat, D. Psaltis, A. Prata, and E. Paek., "Optical implementation of the Hopfield model," *Appl. Opt.*, Vol. 24, p. 1469 (1985)
- [6] J. W. Goodman, F. I. Leonberger, S. Y. Kung, and R. A. Athale, "Optical interconnections for VLSI systems," *Proc. IEEE*, Vol. 72, p. 850 (1984)
- [7] I. Glaser, "Lenslet array processors," *Appl. Opt.* Vol. 21, p. 1271 (1982)
- [8] J. S. Jang, S. Y. Shin, and S. Y. Lee, "Parallel  $N^4$  weighed optical interconnects : comments," *Appl. Opt.* Vol. 27, p. 4364 (1988)
- [9] H. J. Caulfield, "Parallel  $N^4$  weighted optical interconnection," *Appl. Opt.* Vol. 26, p. 4039 (1987)
- [10] K. Wagner, and D. Psaltis, "Multilayer optical learning networks," *Appl. Opt.* Vol. 26, p. 5061 (1987)

- [11] G. E. Lohman, and A. W. Lohmann, "Optical interconnection network utilizing diffraction gratings," *Opt. Eng.* Vol. 27, p. 893 (1988)
- [12] M. Kranzdorf, B. J. Bigner, L. Zhang, and K. M. Johnson, "Optical connectionist machine with polarization-based bipolar weight values," *Opt. Eng.* Vol. 28, p. 844 (1989)
- [13] H. J. Lee, S. Y. Lee, and S. Y. Shin, "TAG : a neural network model for large-scale optical implementation," *Neural Computation* Vol. 3, p. 135 (1991)
- [14] 이혁재, "TAG 모델의 전기 광학적 구현," 한국과학기술원 전기및 전자공학과 석사학위논문, (1991)
- [15] D. E. Rumelhart and J.L. McClelland, Eds., *Parallel Distributed Processing*, Vol. 1, MIT Press, 1986
- [16] M. J. J. Holt, and S. Semnani, "Convergence of back-propagation in neural networks using a log-likelihood cost function," *Electronics letter* Vol.26, No. 23,pp. 1964 (1990).
- [17] 육성원, "숫자 인식을 위한 다층인식자의 전기 광학적 구현," 한국과학기술원 전기및 전자공학과 석사학위논문, (1992)
- [18] 장주석, "홀로그램을 이용한 신경회로망의 광학적 구현," 한국과학기술원 전기및 전자공학과 박사학위논문,(1989)
- [19] H. K. Liu, and T. H. Chao, "Liquid crystal television spatisl light modulators," *Appl. Opt.* Vol. 28, p. 4772 (1989)
- [20] E. N. Leith, and J. Upatnieks, "Wavefront reconstruction with diffused illumination and three-dimensional objects," *J. Opt. Soc. Am.* Vol. 54, p. 1295 (1964)

- [21] F. G. Kaspar, R. L. Lamberts, and C. D. Edgett, "Comparison of experimental and theoretical holographic image radiance, " J. Opt. Soc. Am. Vol. 58, p. 1289
- [22] H. W. Lorber, "A theory of granularity and bleaching for holographic information recording," IBM J. Res. Develop., p. 521 (1969)
- [23] W. R. Graver, J. W. Gladden, and J. W. Eastes, "Phase holograms formed by silver halide (sensitized) gelatin processing," Appl. Opt. Vol. 19, p. 1529 (1980)
- [24] 김 남, 길상근, 박한규, "은염에 형성된 위상형 회절격자의 고효율에 관한 연구," 전자공학회논문지, 제 26권, 제 3호, p.452 (1989)
- [25] 신상길, "홀로그램 렌즈 배열을 이용한 단층인식자의 광학적 구현," 한국과학기술원 전기및 전자공학과 석사학위논문,(1989)
- [26] P. Hariharan, *Optical Holography*, Cambridge University Press, New York, 1985
- [27] D. G. Falconer, "Noise and distortion in photographic data storage," IBM J. Res. Develop., p. 521 (1970)

여 백

## 제 4 장 능동형 광학 연산 소자

### (1) 연구 배경

빛을 이용하면 대규모 병렬 신호 처리(Fourier transform, Convolution)가 가능하기 때문에 이전부터 이에 대한 많은 연구가 진행되어 왔다. 그러나 신호처리를 전적으로 광학적으로만 하는 것보다는 기존에 개발되어있는 전기적 신호처리 시스템과 연결 시킬 수 있다면 좀더 융통성 있는 시스템을 구성할 수 있기 때문에 전기 광학적 신호 처리 시스템이 연구되어왔다.

그러나 최근까지 병렬형 광 연산의 주요 장애물 중의 하나는 간단한 능동형 광 연산 소자 (Optical Logic Device)가 없었다는 점이다. 물론 Edge Emitting Laser를 기초로 한 광 논리소자가 구현되었었지만 광 교환기(Optical Switching)나 광 연산(Optical Computing)에서는 대부분 광 논리소자의 2차원 배열을 요구하므로 그 응용에는 많은 제한이 따른다. 때문에 최근에는 VCSEL과 HPT를 결합한 광 논리소자의 연구가 진행되고 있다. 이러한 형태의 논리소자가 가지는 장점은 결정성장 과정에서 두 소자를 결합시킬 수 있기 때문에 제작공정상 유리하며, 높은 구동전류를 요구하지 않으므로 한 chip 상에서 동작이 가능하다는 점이다.

능동형 광학소자의 기본적인 개념은 입사광이 HPT의 Base와 Collector 일부에서 흡수되고, 증폭된 Collector 전류는 VCSEL을 발진시키게 된다. 다음의 그림 1-1은 입사 광이 들어올 때마다 VCSEL이 발진하는 회로이며 그림 1-2는 그 반대의 경우를 보여주고있다.

이와 같은 기본적인 회로를 변형하면 모든 논리소자를 구성할 수 있으며 이는 광컴퓨터(optical computer)나 광교환기(optical switch) 등에 사용될 수 있다.

또한 HPT는 base band gap보다 높은 에너지를 가지는 입사광(GaAs의 경우 < 870nm)에 대해서는 넓은 범위에서 안정되게 동작하므로 실제의 여러 상황에서 사

용될 때 소자내의 VCSEL의 파장이 조금씩 변화가 있더라도 안정된 동작특성을 보이게 된다. 이는 SEED(self electro-optic effect device)등이 온도에 민감하며 수동형 광변조기임을 감안하면 상당한 강점으로 나타난다.

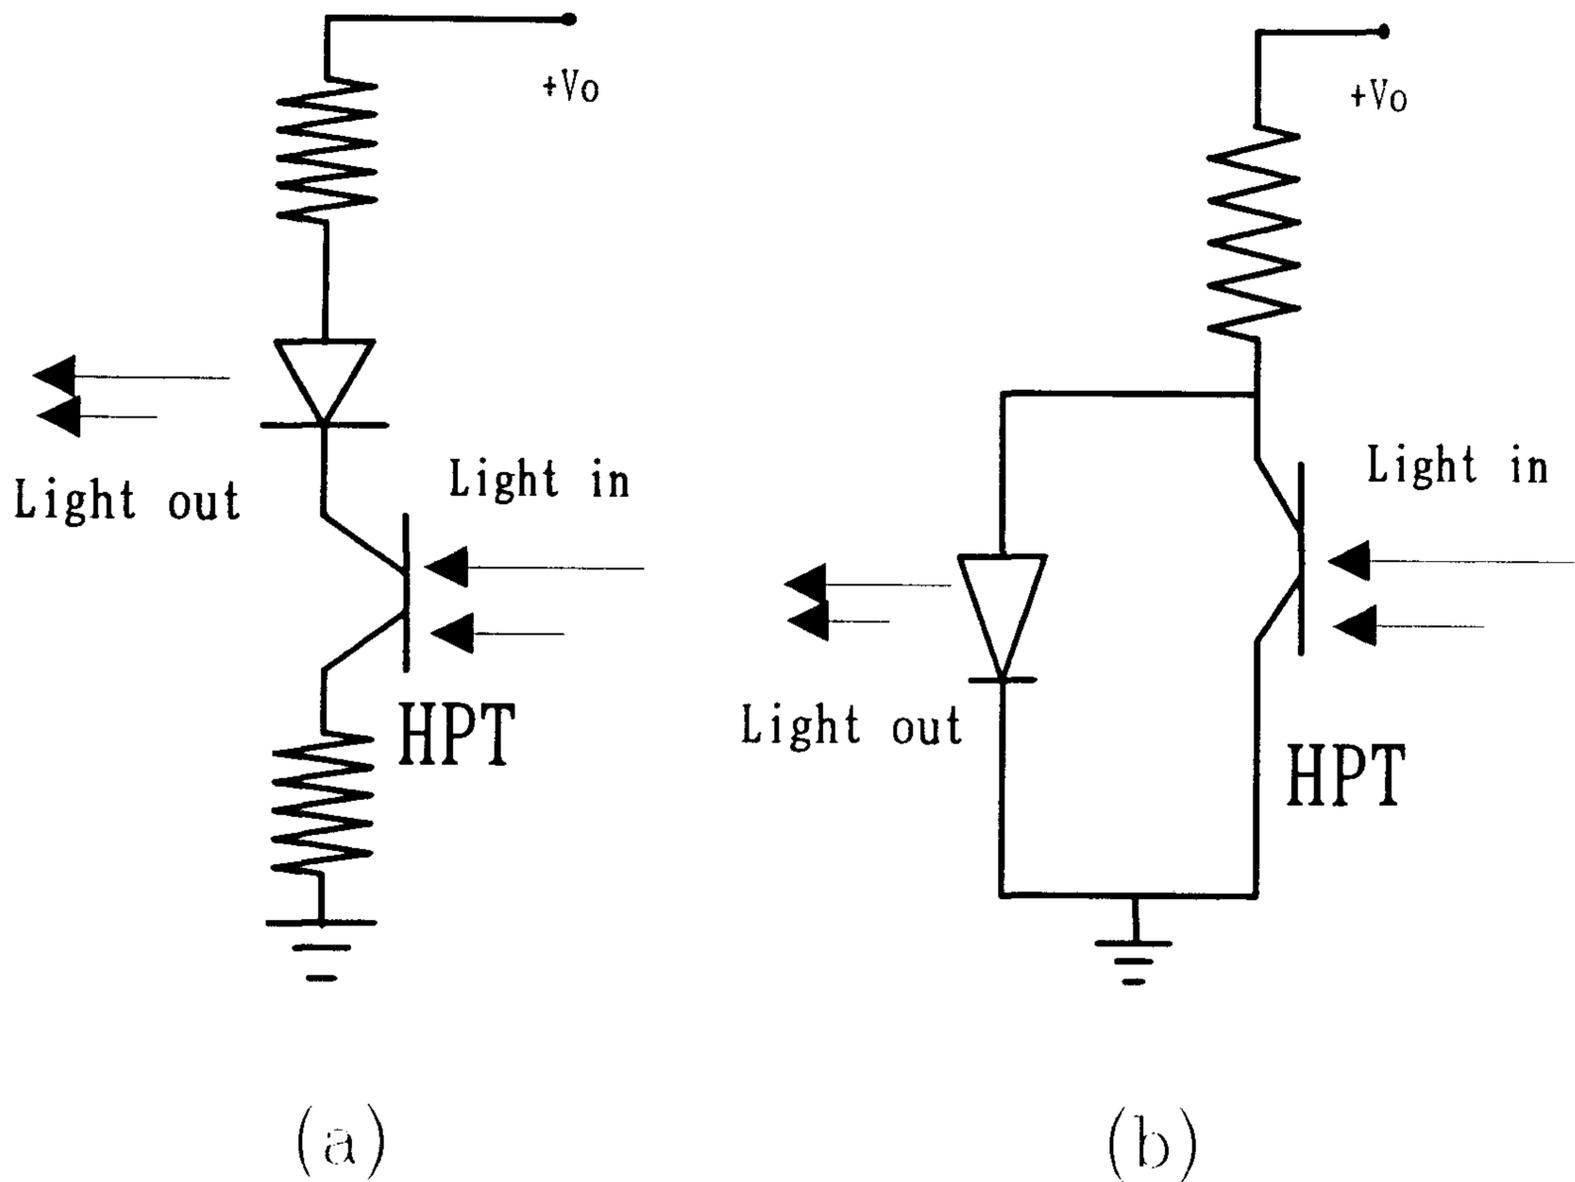


그림 1. VCSEL과 HPT를 이용한 논리 회로의 예

근래까지 HPT 는 큰 이득을 얻기 위해 heterojunction wide band gap emitter 를 사용 하여왔다. heterojunction과 homojunction의 차이는 heterojunction의 경우 접합면을 형성하는 두 물질의 energy gap 차이로 인해 전도대, 가전자대에 불연속이 생긴다는 점이다.

이  $\Delta E_g$ 와  $\Delta E_v$  때문에 HPT의 base에서 emitter로의 정공에 의한 전류가 homojunction보다 크게 억제되어 transistor의 gain에 기여한다.

수식적으로 살펴보기위해 다음과 같은 간단한 model을 살펴보자.

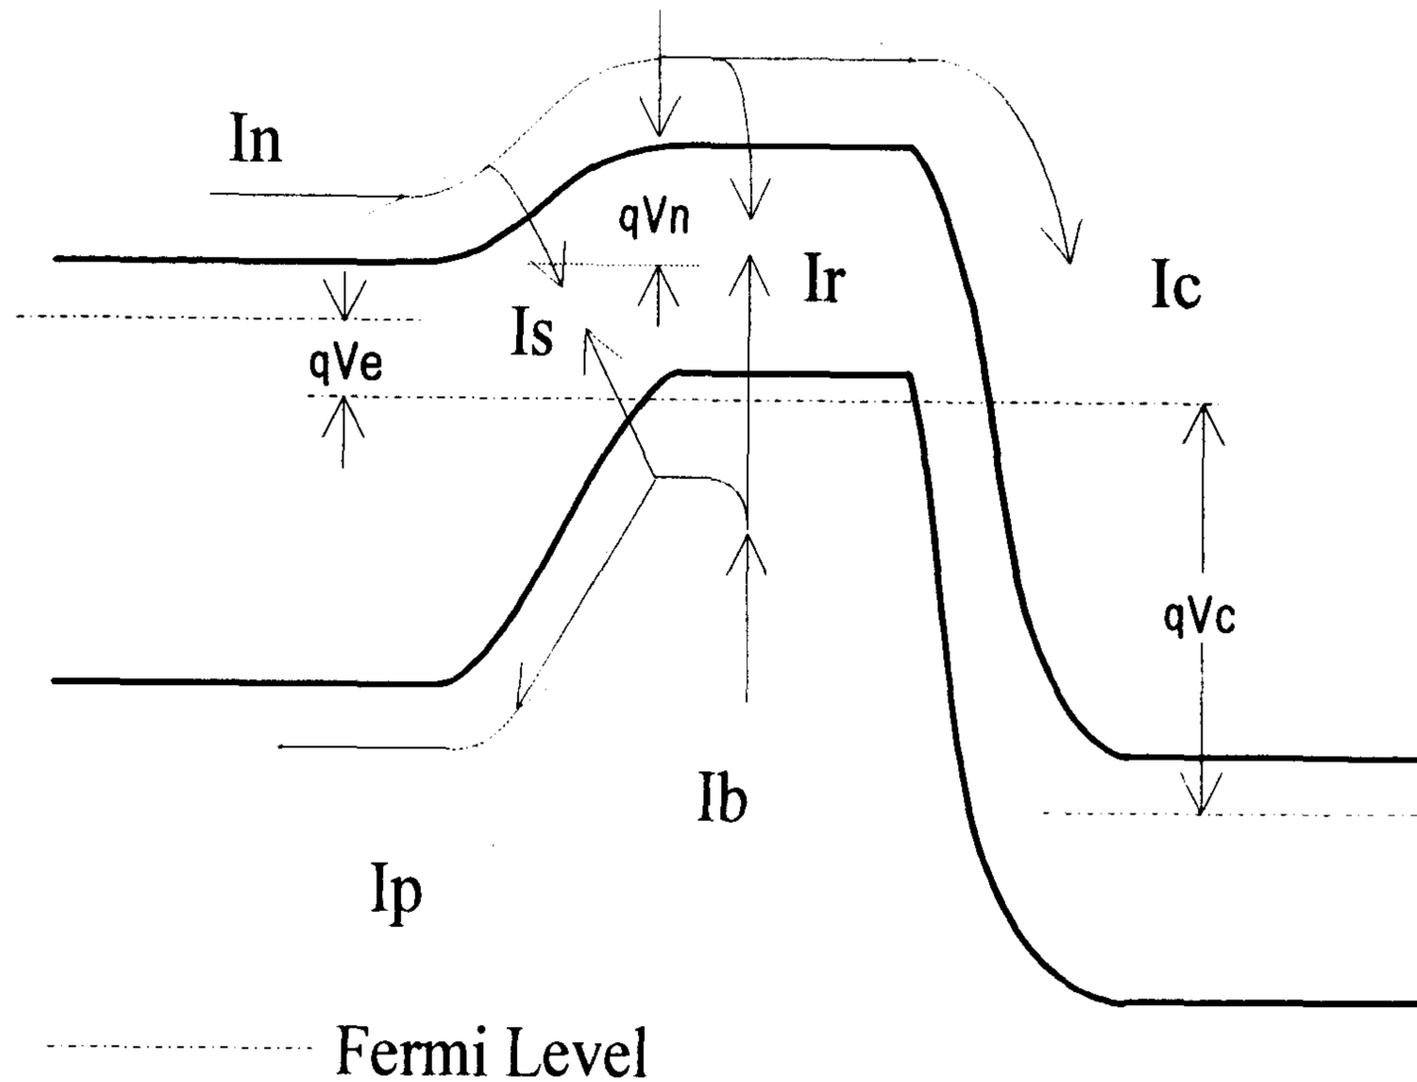


그림 2. N-p-n Transistor의 Energy Band Diagram

먼저 각 전류요소를 정리하면

$I_n$  : emitter에서 base로 inject되는 전자에 의한 전류.

$I_p$  : base에서 emitter로 inject되는 전공에 의한 전류.

$I_s$  : 순방향으로 bias가 걸려진 emitter-base space charge layer에서 재결합되는 전자와 전공에 의한 전류.

$I_r$  : emitter에서 inject된  $I_n$  중에서 bulk 재결합에 의해 사라지는 전류.

이 전류 요소로 각 terminal에서의 순 전류를 표현해보면

$$\text{Emitter 전류 : } I_e = I_n + I_p + I_s$$

$$\text{Base 전류 : } I_b = I_p + I_r + I_s$$

$$\text{Collector 전류 : } I_c = I_n - I_r$$

이 된다.

이 성분으로 gain을 표현하면  $\text{gain } \beta = \frac{I_c}{I_b} = \frac{I_n - I_r}{I_p + I_r + I_s} < \frac{I_n}{I_p} \equiv \beta_{\max}$ 이며 여기서

$\beta$ 의 최대치인  $\beta_{\max}$ 의 개선은 wide band gap emitter를 씬으로써 가능해진다.

emitter와 base 사이의 전자와 전공에 대한 energy 차를  $qV_n, qV_p$ 라 하면 전자와 전공에 대한 injection current density는

$$J_n = N_e v_{nb} \exp(-qV_n/kT) \quad N_e : \text{emitter doping level}$$

$$J_p = P_b v_{pe} \exp(-qV_p/kT) \quad P_b : \text{emitter doping level}$$

이며, 여기서  $v_{nb}$ 는 전자의 base에서의 drift velocity,  $v_{pe}$ 는 전공의 emitter에서의 drift velocity이다. emitter의 energy gap이 base보다  $\Delta E_g$ 만큼 크다고 하면  $q(V_p - V_n) = \Delta E_g$ 라 할 수 있으므로

$$\beta_{\max} = \frac{I_n}{I_p} = \frac{N_e}{P_b} \frac{v_{nb}}{v_{pe}} \exp(\Delta E_g/kT) \text{ 가 된다.}$$

이 식이 가지는 물리적인 의미는 전공에 의해 base서 emitter로 흐르는 전류흐름에 비해 전자에 의해 emitter에서 base로 흐르는 전류가 얼마나 큰가하는 것이다.

여기서 전공에 의한 전류흐름은 전위장벽  $\Delta E_g$ 의 존재로 인해 emitter로 넘어가는데 큰 제약을 받게 된다.

homojunction인 경우  $\Delta E_g = 0$  이므로 HPT의 gain은 doping 농도에 크게 의존한다.  $N_e$ 를 크게하면 emitter junction에서의 capacitance가 문제가 되고  $P_b$ 를 작게하면 HBT의 경우 base resistance가 크게 늘어난다.

그러나 wide band gap emitter를 쓰면 doping level에 구애받지 않고 충분히 큰 gain을 얻을 수 있다. 만일  $\Delta E_g = 0.2$  eV인 물질을 emitter로 쓴다면 homojunction보다 2300 배 정도 큰 gain을 얻을 수 있다.

또한 wide band gap emitter를 쓰면 emitter doping과 base doping에 여러 가지 가능성을 주므로 고속 동작 소자의 설계에 많은 도움을 준다.

앞의 식에서 gain은  $\Delta E_g$ 에 의존하지만 더 정확히는  $\Delta E_v$ 에 의존하며 다음은 그에 대한 설명이다.

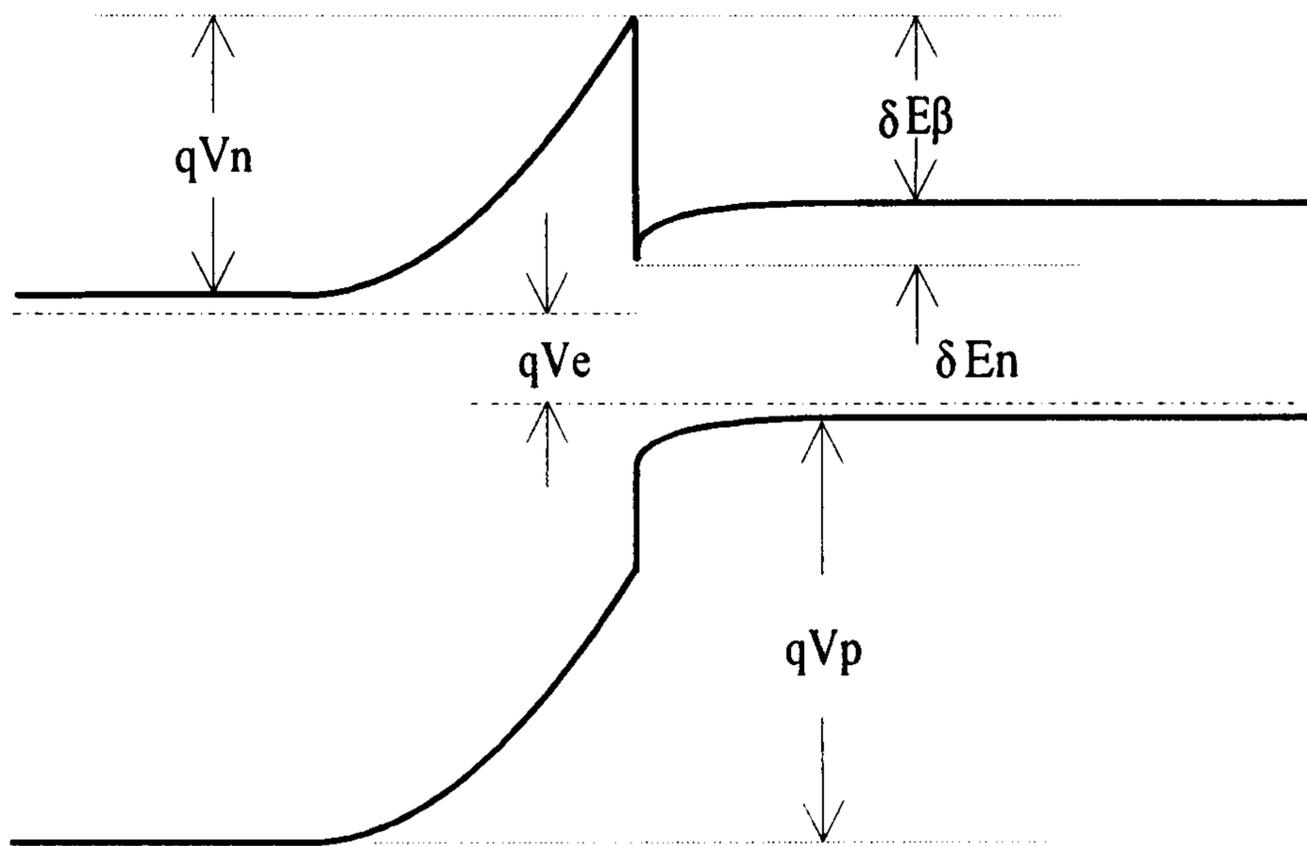


그림 3. Abrupt Wide-gap Emitter의 Band 구조

그림에서처럼  $\Delta E_g$ 가  $I_p$ 에 대해  $I_n$ 의 흐름을 개선하지만 전위 장벽  $\Delta E_B$ 는 그 흐름을 막는 역할을 한다. 따라서 앞의 식은  $\Delta E_g \rightarrow \Delta E_g - \Delta E_B = \Delta E_g - (\Delta E_C - \Delta E_v) \sim E_g - \Delta E_C = \Delta E_v$ 로 표현되어야 한다.

따라서 같은 band gap 크기를 가지는 물질이라고 하더라도  $\Delta E_C$ 와  $\Delta E_v$ 의 비에 따라 gain과 소자의 동작특성이 크게 달라질 수 있다.

실험에 쓰인  $\text{Al}_{0.35}\text{Ga}_{0.65}\text{As}$ 와  $\text{In}_{0.49}\text{Ga}_{0.51}\text{P}$ 는 거의 같은 크기의 band gap을 가지지만  $\text{Al}_{0.35}\text{Ga}_{0.65}\text{As}$ 의 경우 6 : 4 로  $\Delta E_c$ 가 큰데 비해  $\text{In}_{0.49}\text{Ga}_{0.51}\text{P}$ 는 4.9 : 5.1로  $\Delta E_v$ 가 조금 더 크다. 따라서 같은 band gap일 때  $\text{Al}_{0.35}\text{Ga}_{0.65}\text{As}$ 보다  $\text{In}_{0.49}\text{Ga}_{0.51}\text{P}$ 가 gain이 크며 전기 광학적 특성과 n-type doping 특성이 좋다.

실험에 사용된 3 종류의 HPT 중에서 STR-A는  $\text{Al}_{0.35}\text{Ga}_{0.65}\text{As}$ 를 emitter로 사용하였고 STR-B와 STR-C는  $\text{In}_{0.49}\text{Ga}_{0.51}\text{P}$ 를 emitter로 사용하였다.

$\text{Al}_{0.35}\text{Ga}_{0.65}\text{As}$ 와  $\text{In}_{0.49}\text{Ga}_{0.51}\text{P}$ 를 emitter로 사용함에 따른 energy band diagram의 차이가 다음에 보여진다.

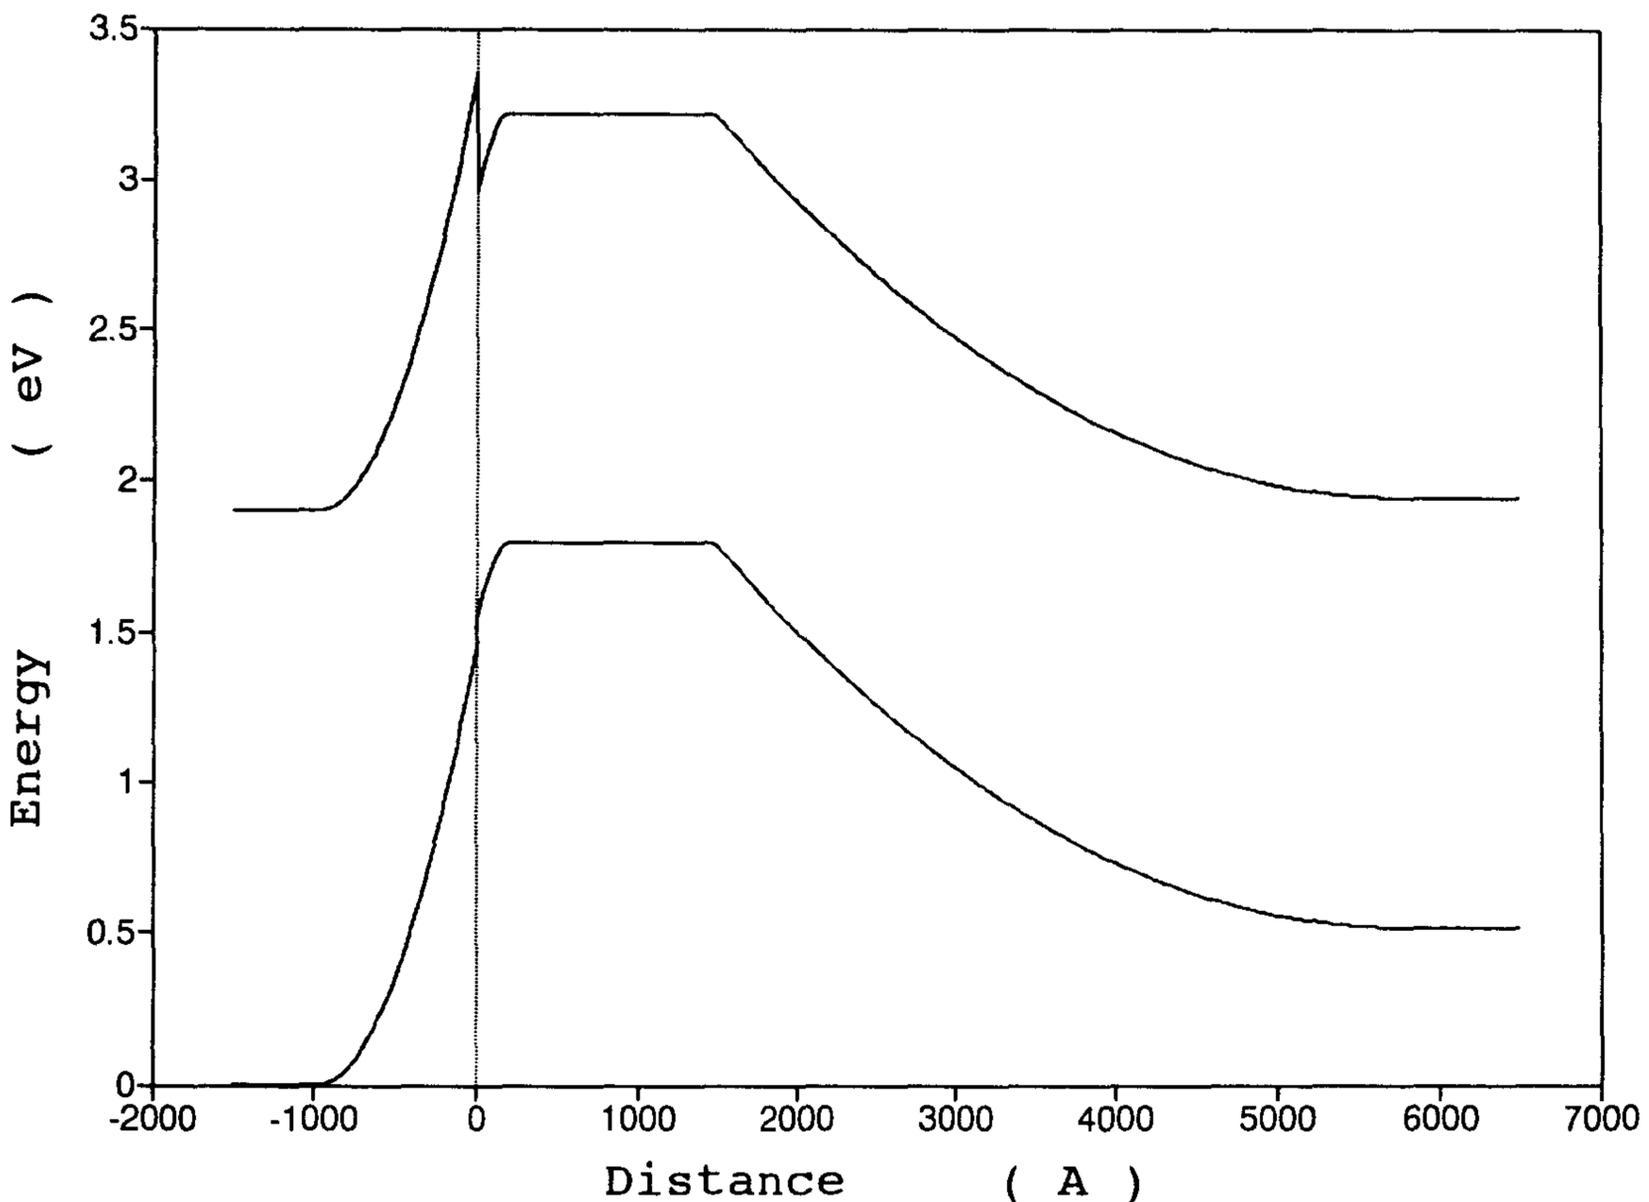


그림 4-1.  $\text{Al}_{0.35}\text{Ga}_{0.65}\text{As}$ 를 Emitter로 쓴 HPT의 Energy Band Diagram

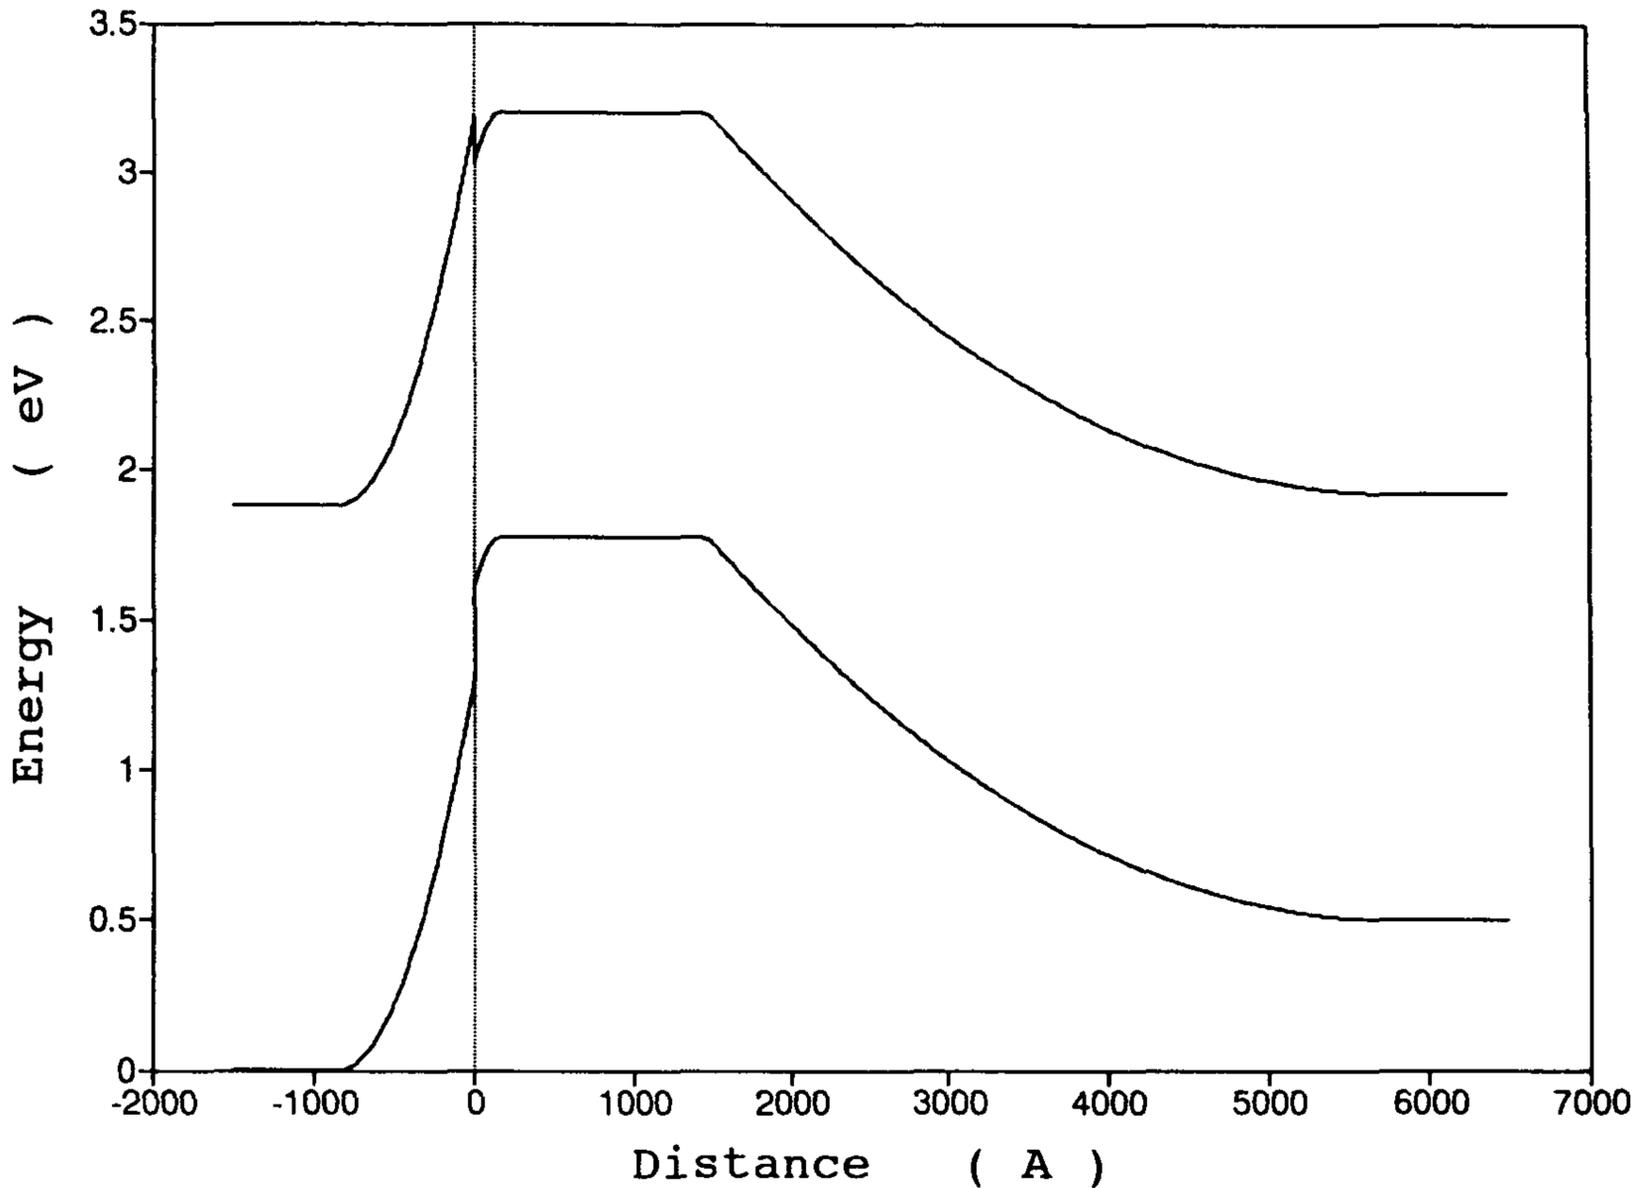


그림 4-2.  $\text{In}_{0.49}\text{Ga}_{0.51}\text{P}$ 를 Emitter로 쓴 HPT의 Energy Band Diagram

band diagram을 사용하는데 사용한 data는 STR-A와 STR-B에 대한 값을 사용하였다. 그림에서  $\text{Al}_{0.35}\text{Ga}_{0.65}\text{As}$ 와  $\text{In}_{0.49}\text{Ga}_{0.51}\text{P}$ 는  $\Delta E_g$ 는 거의 같으나  $\text{In}_{0.49}\text{Ga}_{0.51}\text{P}$ 의 경우 더 많은 부분이  $\Delta E_v$ 로 주어지므로 base로부터 emitter로의 전공의 흐름을  $\text{Al}_{0.35}\text{Ga}_{0.65}\text{As}$ 보다 효과적으로 막아준다. 따라서  $\text{Al}_{0.35}\text{Ga}_{0.65}\text{As}$ 보다 gain과 고속 동작특성이 우수하리라고 예측된다.

VCSEL은 상당히 빠른 응답특성을 보이는데 비해 HPT는 상대적으로 느린 편이므로 HPT의 High Speed 특성을 알고, 개선하는 것이 논리 소자의 처리 속도 향상에 주요 관건이 된다. 따라서 본 실험에서는 DC gain, Gain-Bandwidth Product, Cut-off Frequency의 측정을 통해서  $\text{In}_{0.49}\text{Ga}_{0.51}\text{P}$ 와  $\text{Al}_{0.35}\text{Ga}_{0.65}\text{As}$ 를 emitter로 쓴 HPT를 서로 비교 분석하였다.

## (2) 능동형 광학 연산 소자의 특성

### 1. HPT 구조

STR-A(EC91115)	두께(A)	Doping( $\text{cm}^{-3}$ )
n-GaAs	300	$3 \times 10^{18}$
n-AlGaAs(.35)	3000	$2 \times 10^{17}$
p-GaAs	1500	$1 \times 10^{18}$
n-GaAs	5000	$1 \times 10^{16}$
n-AlGaAs	100	$3 \times 10^{18}$
n-GaAs	2000	$1 \times 10^{18}$

STR-B(TSII92900)	두께(A)	Doping( $\text{cm}^{-3}$ )
n-GaAs	500	$> 5 \times 10^{18}$
n-InGaP	3000	$2 \times 10^{17}$
p-GaAs	1500	$1 \times 10^{18}$
n-GaAs	5000	$1 \times 10^{16}$
n-GaAs	5000	$> 5 \times 10^{18}$

STR-C(TSII92901)	두께(A)	Doping( $\text{cm}^{-3}$ )
$n^{++}$ -GaAs	500	$> 5 \times 10^{18}$
$n^{++}$ -InGaP	2200	$> 5 \times 10^{18}$
n-InGaP	800	$2 \times 10^{17}$
p-GaAs	800	$1 \times 10^{18}$
n-GaAs	5000	$1 \times 10^{16}$
n-GaAs	5000	$> 5 \times 10^{18}$

그림 5. 본 실험에 사용된 HPT의 Epi 구조

본 실험에 사용된 HPT는 위와 같은 epi 구조에 동작 속도 향상을 위하여 (capacitance 감소) 원형으로 emitter부터 base 영역까지 mesa etching이 되어 있다.

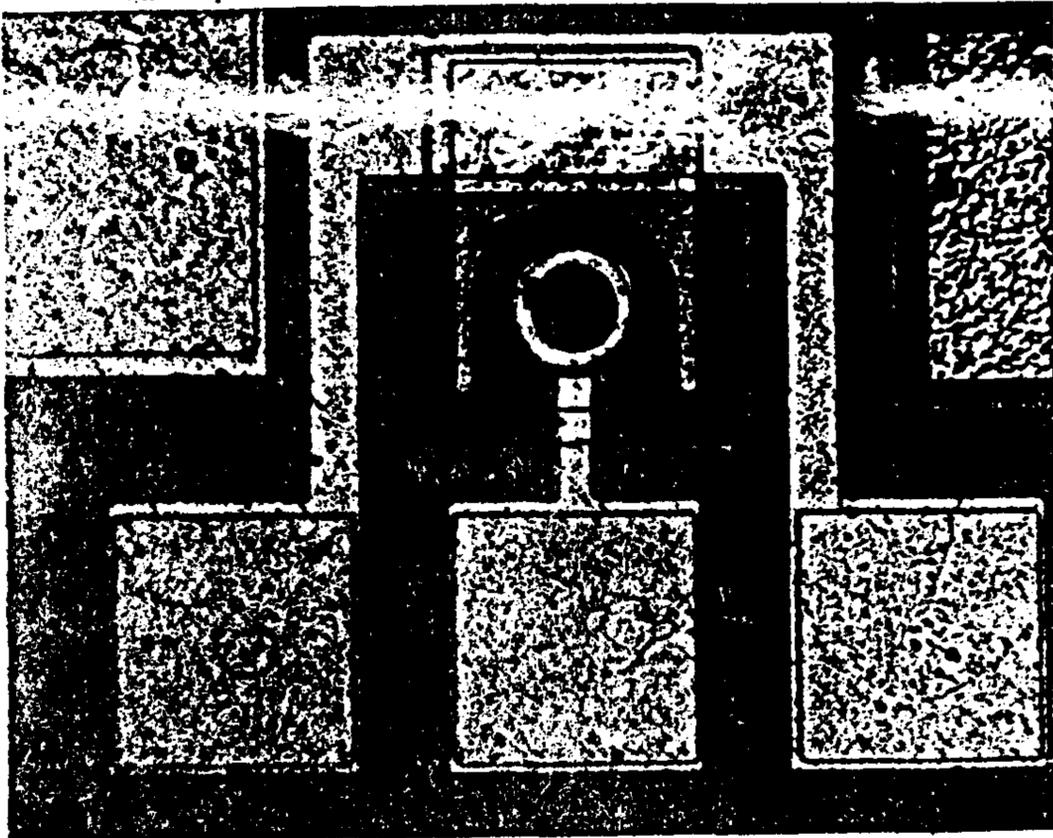


그림 6. 실험에 사용된 HPT의 모습

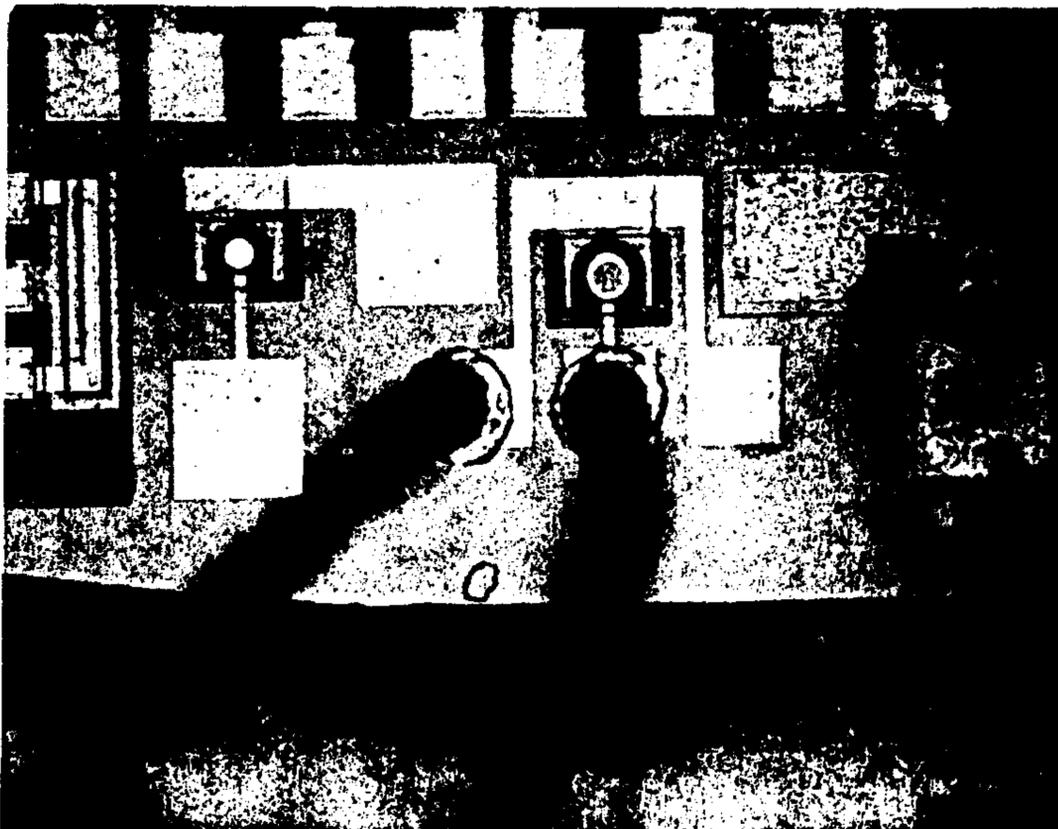


그림 7. 실험에 사용된 HPT의 wiring된 모습

mesa etching을 통한 소자의 면적은 약  $1256\mu\text{m}^2$  (반경  $20\mu\text{m}$ ) 정도이며 emitter에 빛이 입사되는 수광 면적은 주위의 전극 때문에 소자 면적보다 작은  $490\mu\text{m}^2$  (반경  $12.5\mu\text{m}$ ) 정도이다.

또한 표면에 노출되는 p-n 접합면에서의 누설 전류를 줄이기 위해 polyimide가 사용되었으며 bonding pad는 반절연 기판위에 놓여져 있다.

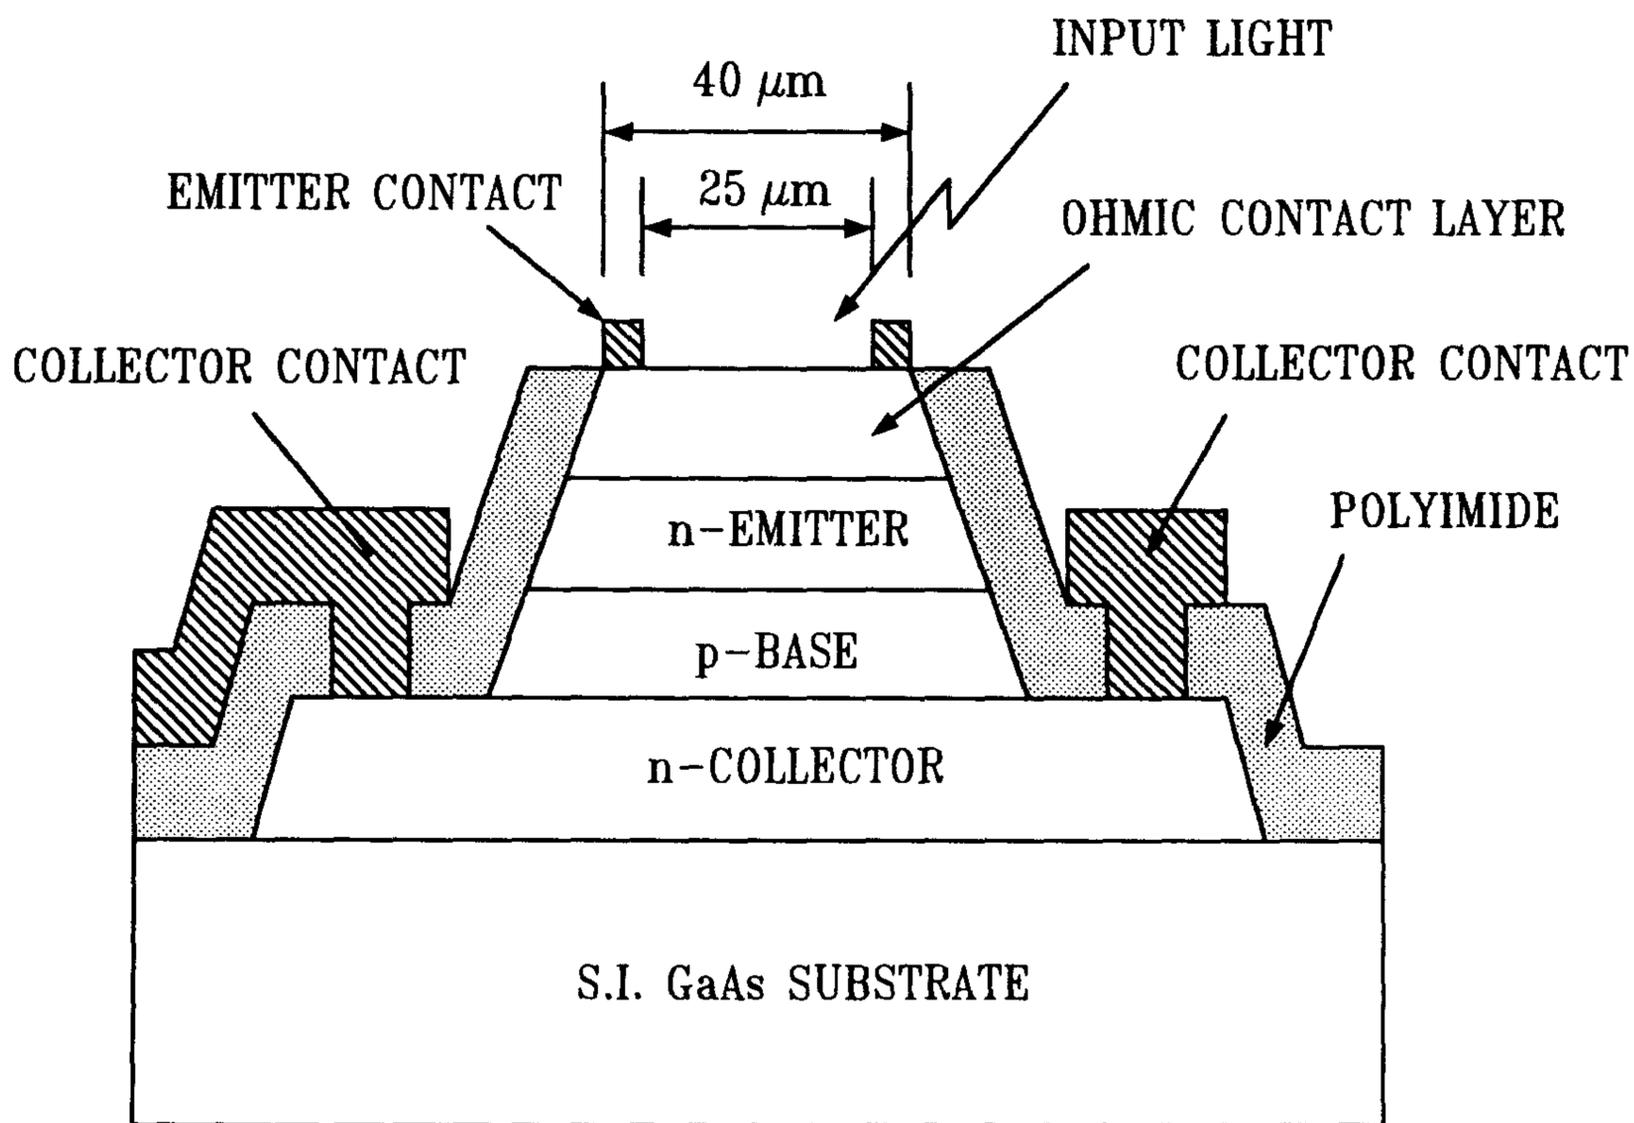


그림 8. 사용된 HPT의 단면모습

HPT 기판의 전체적인 모습이 다음에 나타나 있다.

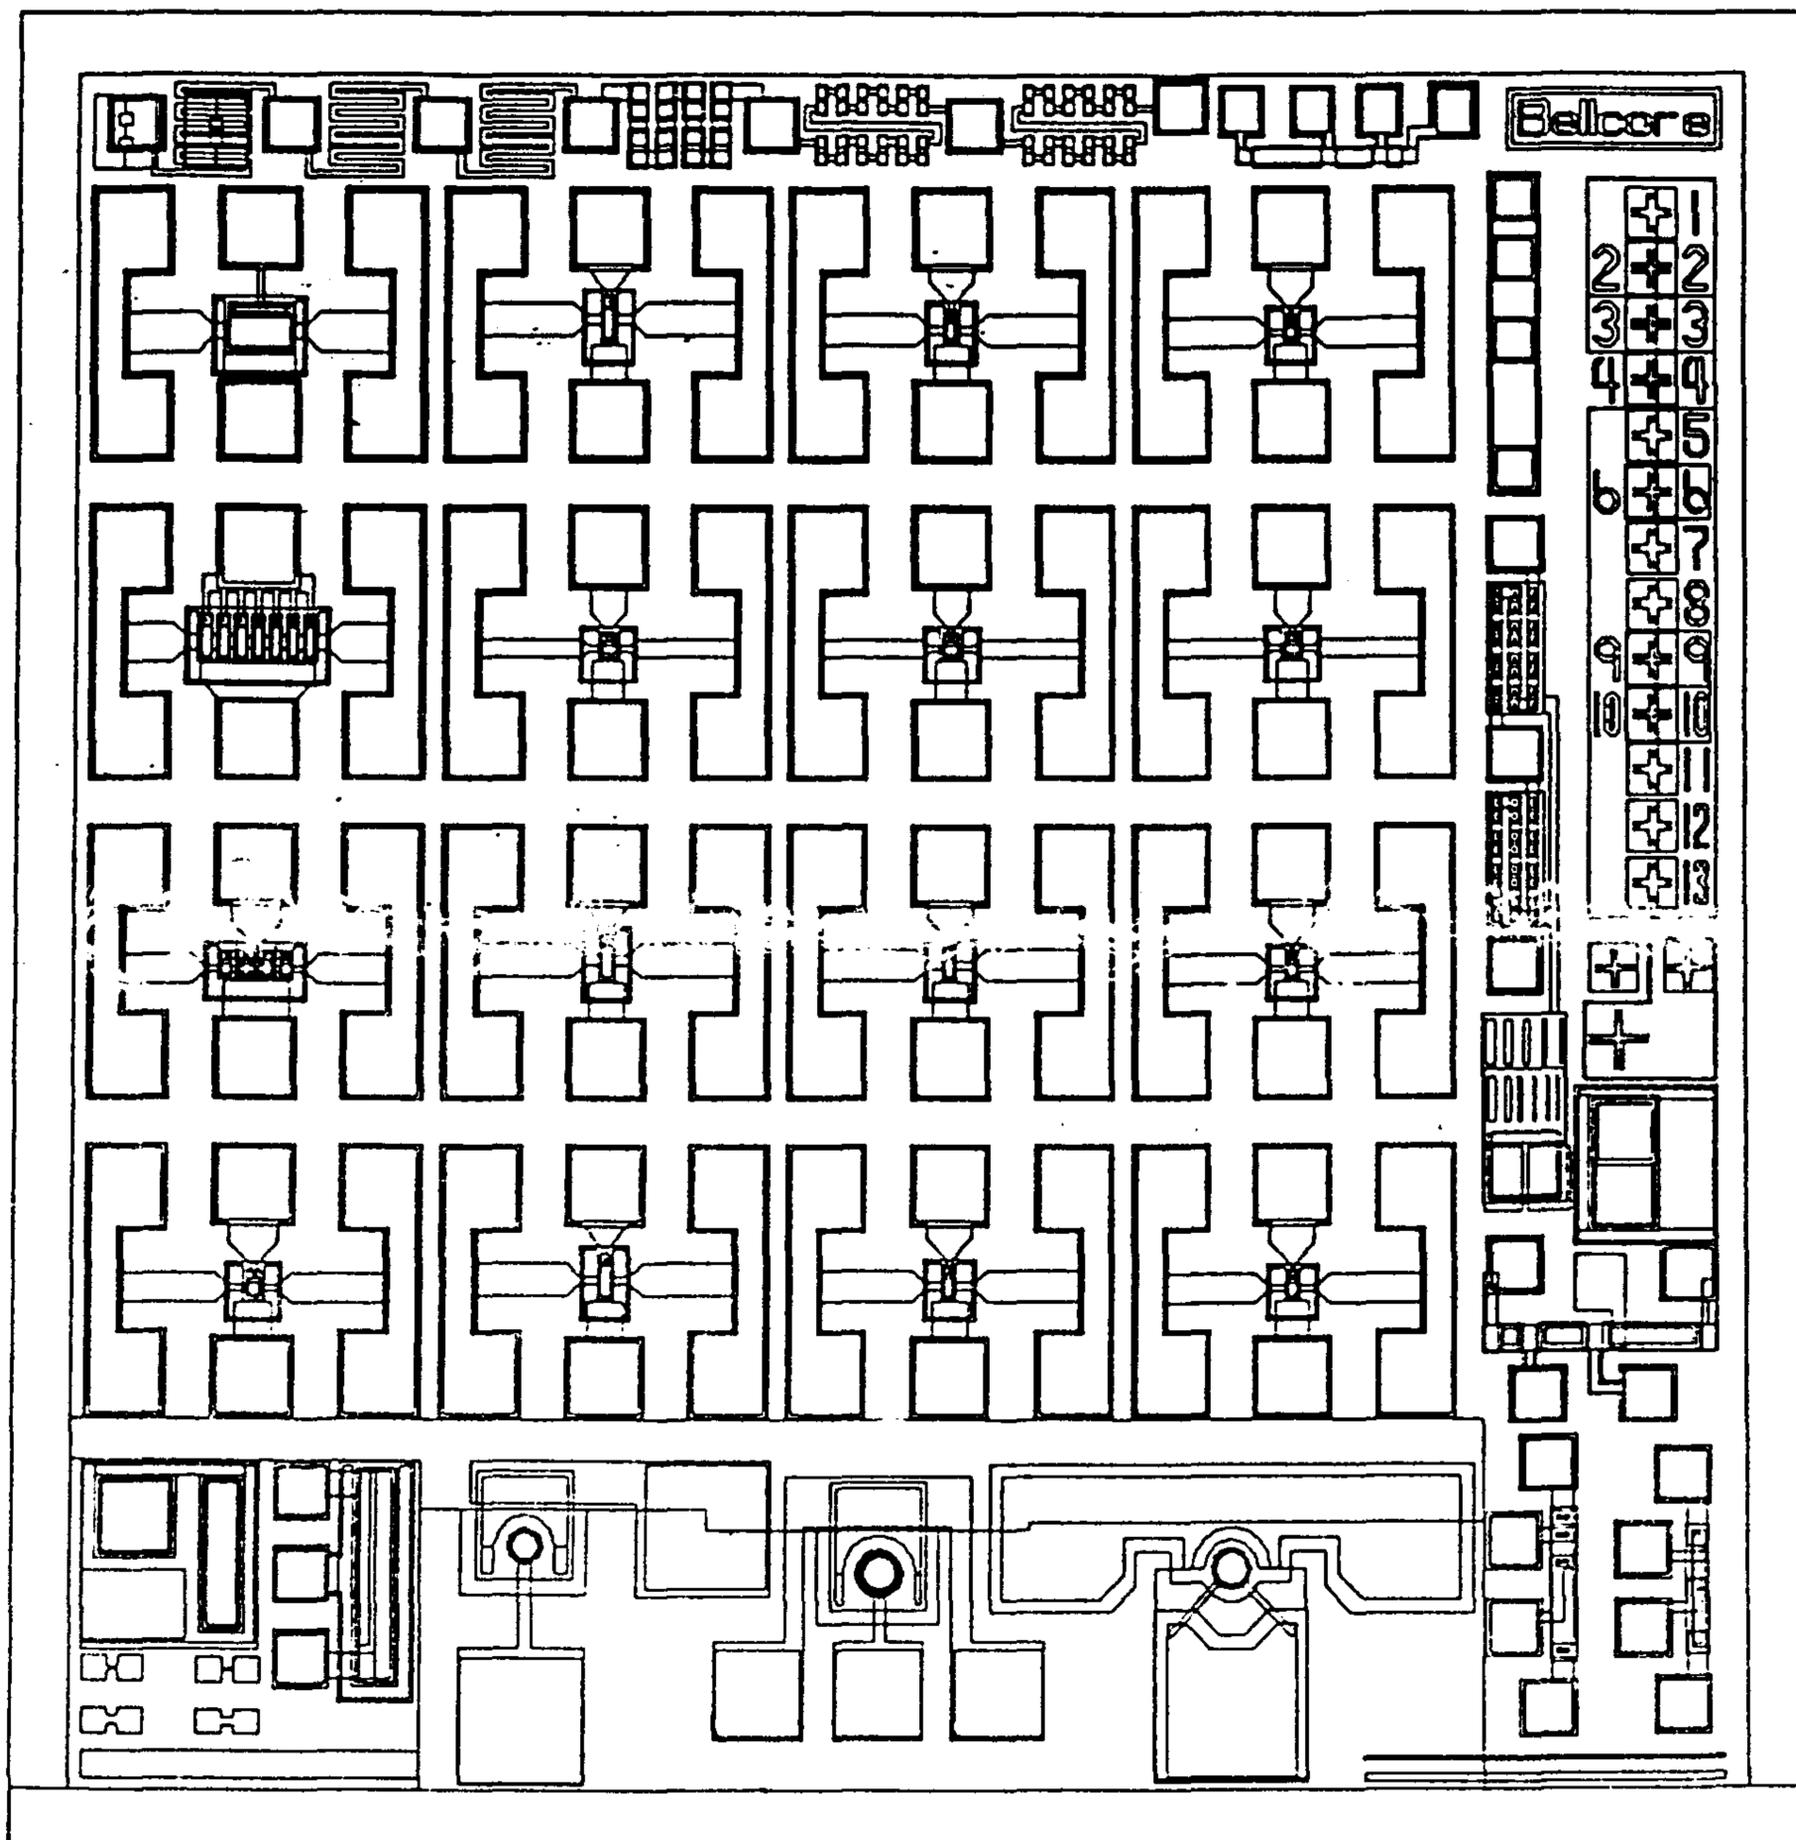


그림 9. HPT와 HBT를 포함한 웨이퍼의 전체적인 모습

## 2. 실험 방법

### i) DC 특성 측정

다음 그림은 DC Gain을 측정하기 위한 실험 장치이다.

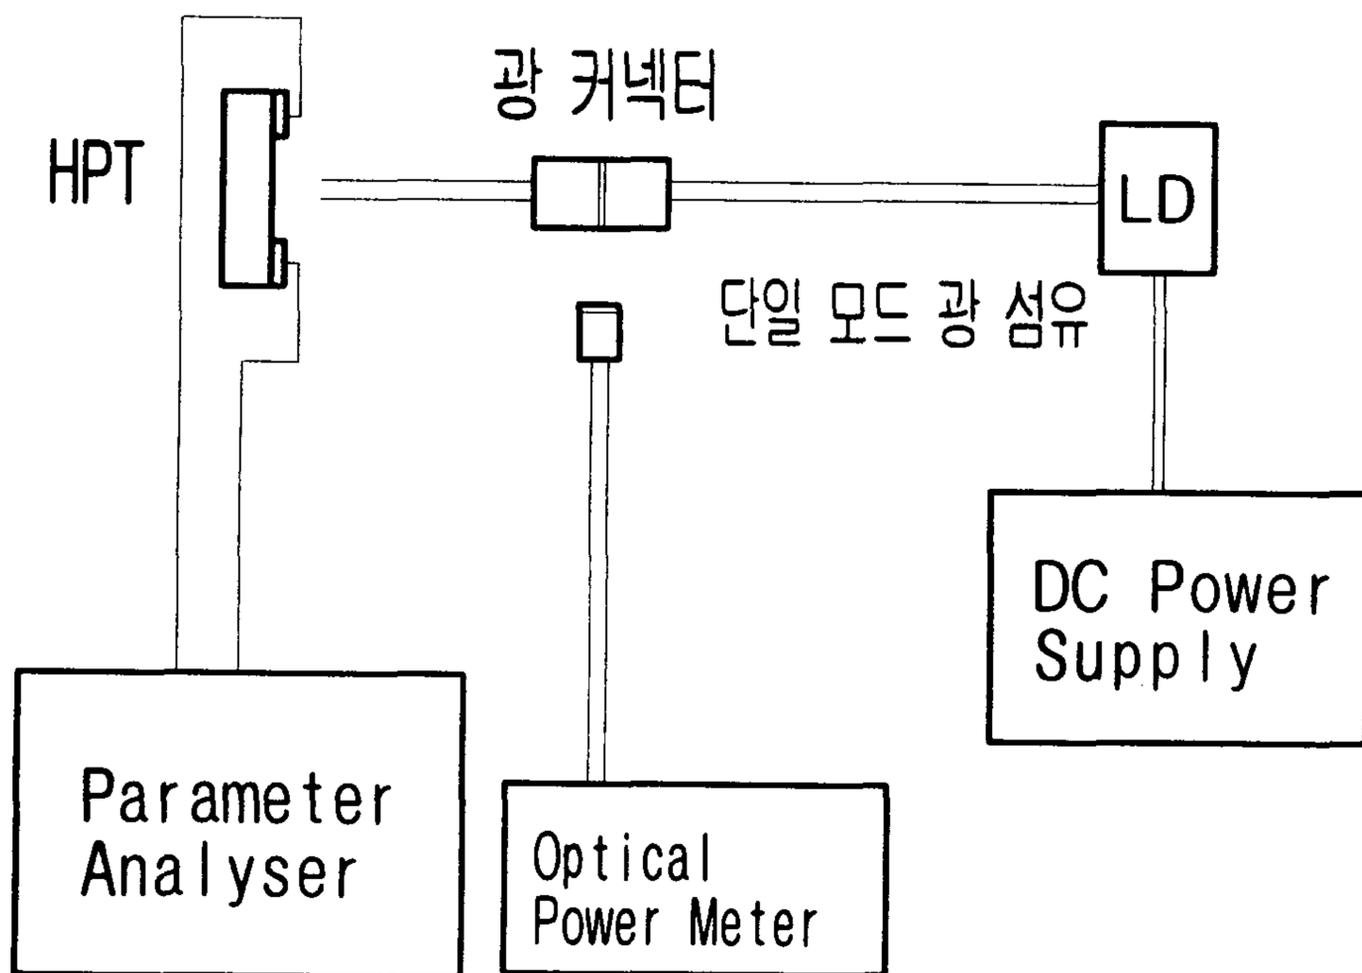


그림 10. HPT의 DC gain을 측정하기 위한 장치

소자의 수광 면적이 작기 때문에 ( $490\mu\text{m}^2$ ) 단일 모드 광섬유를 이용하여 빛을 소자에 입사시켰다. 입사광의 power를 정확히 얻기 위해 광섬유 중간에 coupler를 장치하여 HPT에 입사되는 빛의 세기를 monitor 하였다.

이 실험과 AC 특성 측정에 사용된 LD Light Source의 구성이 다음에 보여진다.

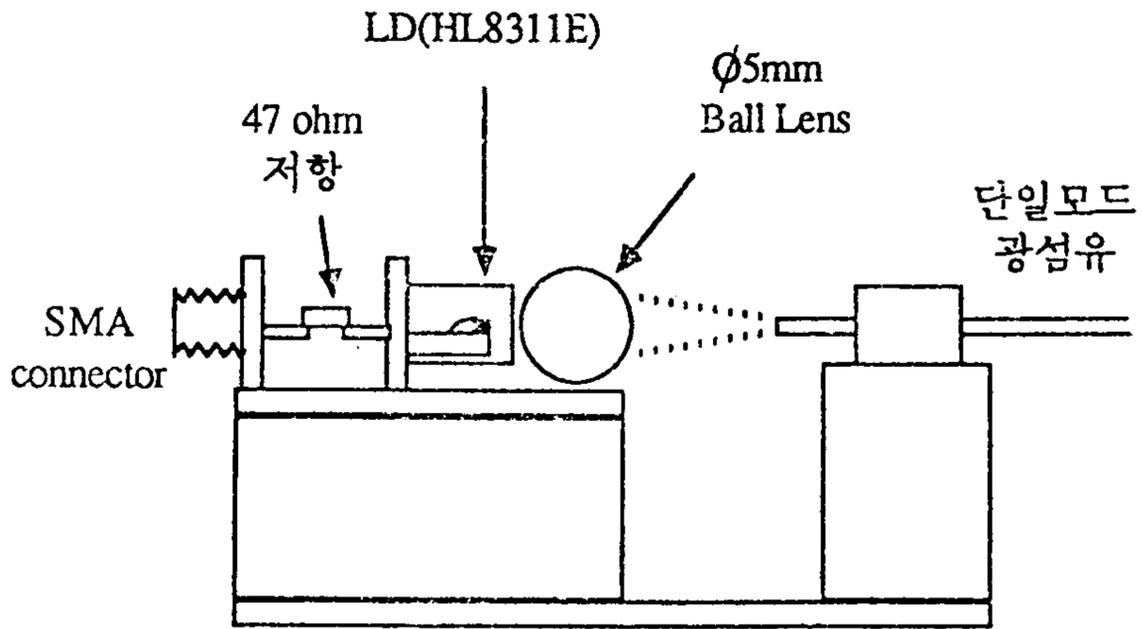


그림 11. LD Light Source의 구성

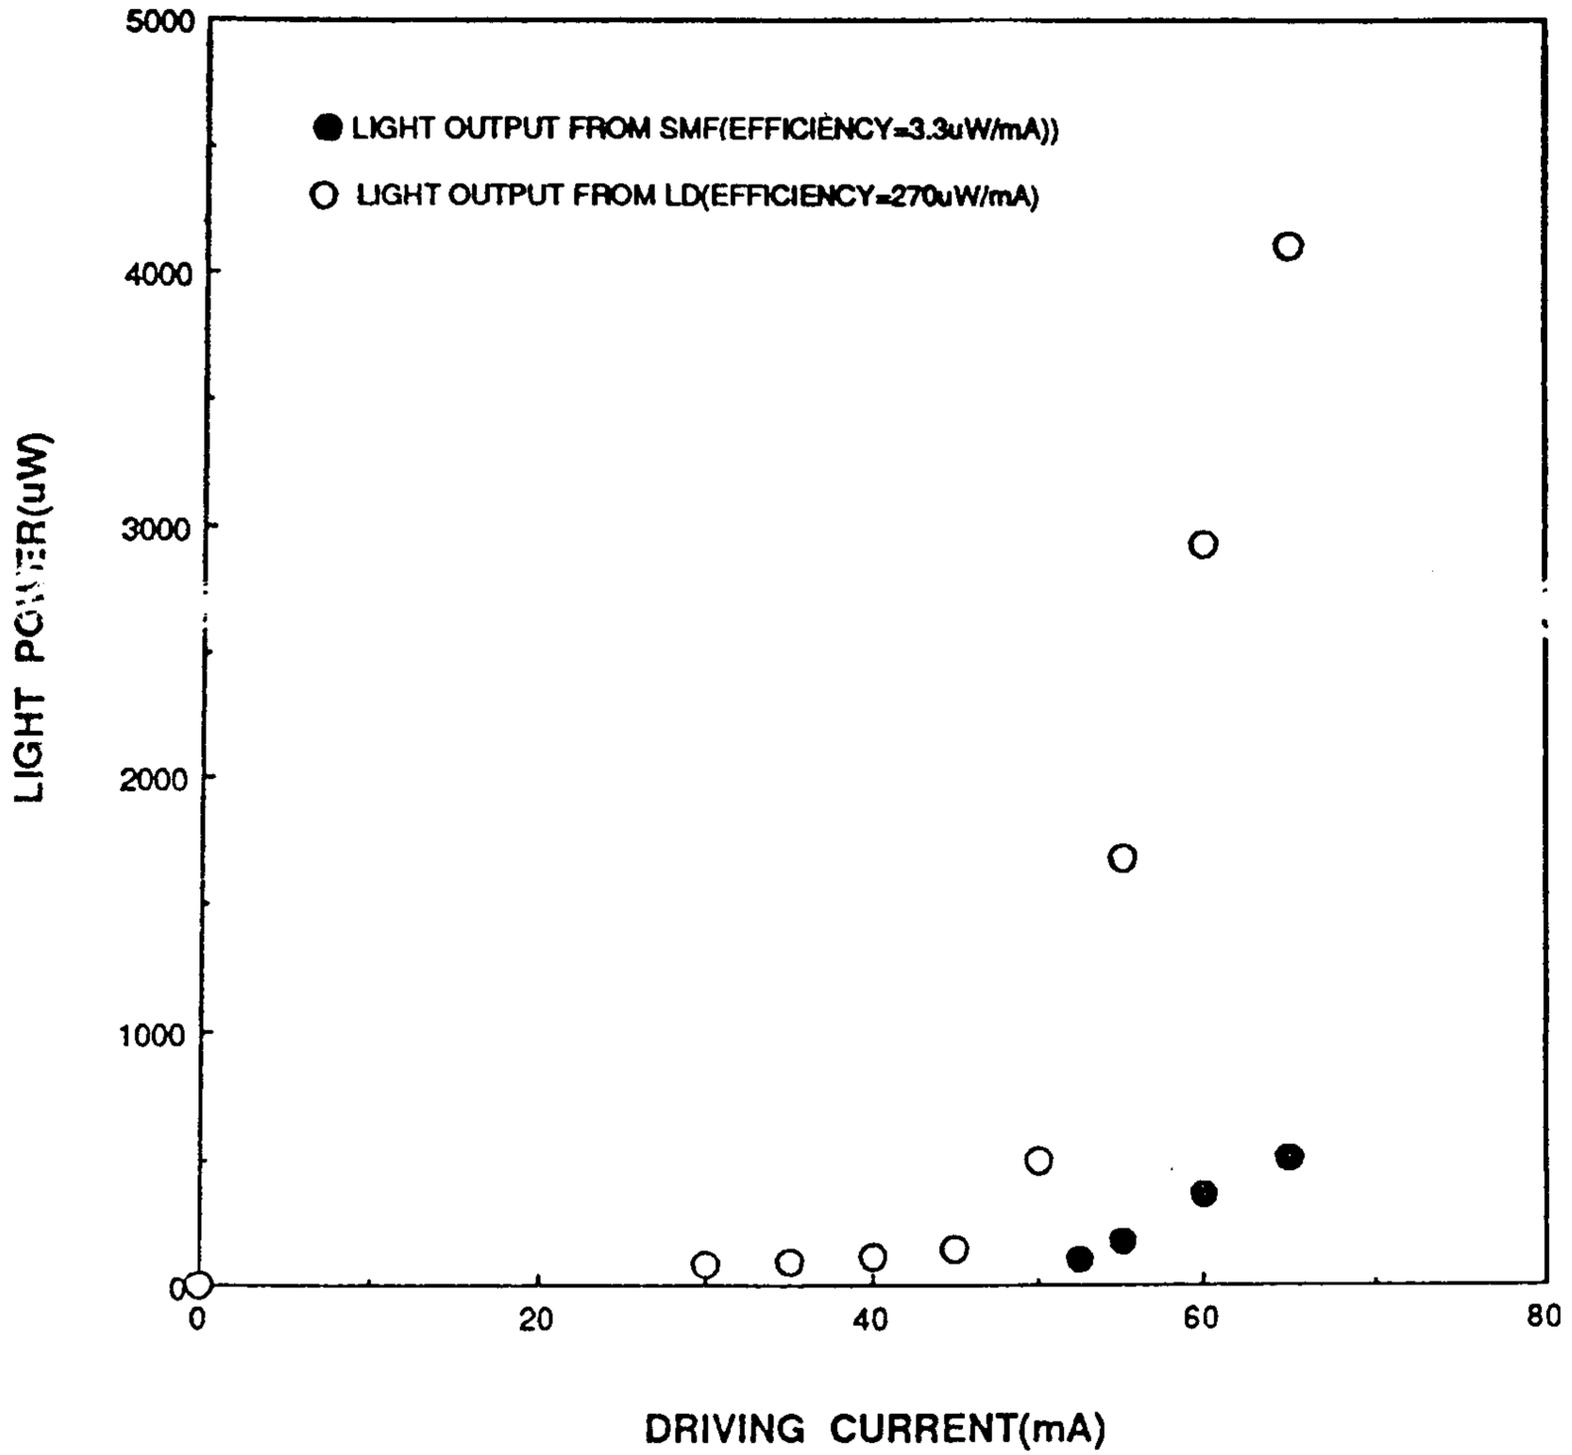


그림 12. 광원의 L-I 특성

Source 구성에 사용된 LD는 Hitachi 사의 HL8311E로 발진 파장이 827.5 nm이고 발진 임계 전류는 50 mA이다.

이 light source는 후에 AC 특성 실험에도 사용할 수 있게 하기 위하여 LD 전극을 impedance 정합용  $47\Omega$  저항을 거쳐 SMA connector에 접속하여 고속 변조가 가능하도록 제작하였다. 또한 LD로 부터 나오는 광 출력은 효율적으로 단일모드 광섬유에 접속 시키기 위해 직경 5mm의 ball lens가 사용되었다.

그림 12에서 ○ 는 LD로 부터 나온 출력광의 세기를 LD 바로 앞에서 Optical power meter로 측정한 결과를 보여주고 있으며, ● 는 출력광이 LD에서 나온후 단일모드 광섬유에 coupling된 후 측정된 값을 보여준다.

그 결과 LD로 부터 직접 측정된 경우는  $270\mu\text{W}/\text{mA}$ 의 효율을 보이는 반면, 단일모드 광섬유를 거치는 경우는  $33\mu\text{W}/\text{mA}$ 의 효율을 보인다. 이는 LD-광섬유간의 결합 효율이 12.2 %임을 말한다.

이렇게 낮은 coupling 효율 때문에 DC Gain 측정시 높은 Power level 에서의 Data를 얻을 수 없었다.

### — 측정 방법 —

DC power supply의 power를 조절하여 HPT에 입사되는 빛의 세기를 100, 80, 60, 40, 20, 10 등으로 바꾸어 가면서 각 power level에 대한 HPT 의 I-V curve를 얻는다. 이때 광의 세기는 광섬유 중간에 연결된 광 connector를 통하여 optical power meter로 monitor 하게 된다.

실제로 고속 동작에 필요한 형태는 STR-A보다는 STR-B나 STR-C가 될 것이므로 주로 STR-B와 STR-C에 대해서 측정하였다.

ii) AC 특성 측정

다음은 HPT의 AC 특성 측정을 위해 구성된 장치도이다.

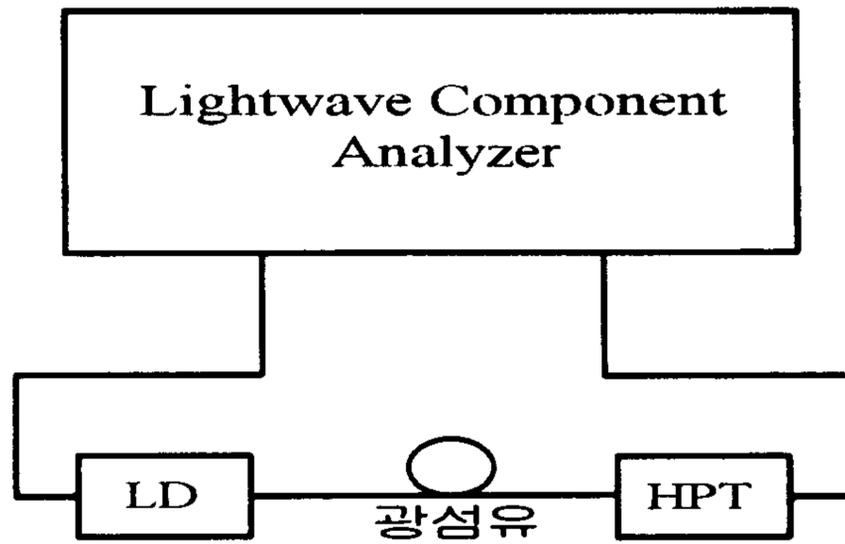


그림 13. HPT 소신호 특성 측정을 위한 실험장치

그림과 같이 HPT의 AC 응답 특성을 측정하기 위해 그림 13에서 처럼 55Ω의 부하 저항을 부착한 형태로 제작하였다. 이때 광신호는 외부로부터 단일모드 광섬유를 통해 HPT chip의 수광영역으로 정렬되어 입사한다. HPT의 소신호 응답특성은 앞에서 제작된 고속변조 광원을 송신기로 사용하여 HP Lightwave Component Analyzer로 측정하였는데 장치구성도는 그림 13에 보였다. 이때 그림의 Lightwave Component Analyzer는 Electric Network Analyzer 기능을 수행하며 광원과 HPT 결합 구성의 변조주파수에 따른 전/광->광/전 변환효율을 측정한다.

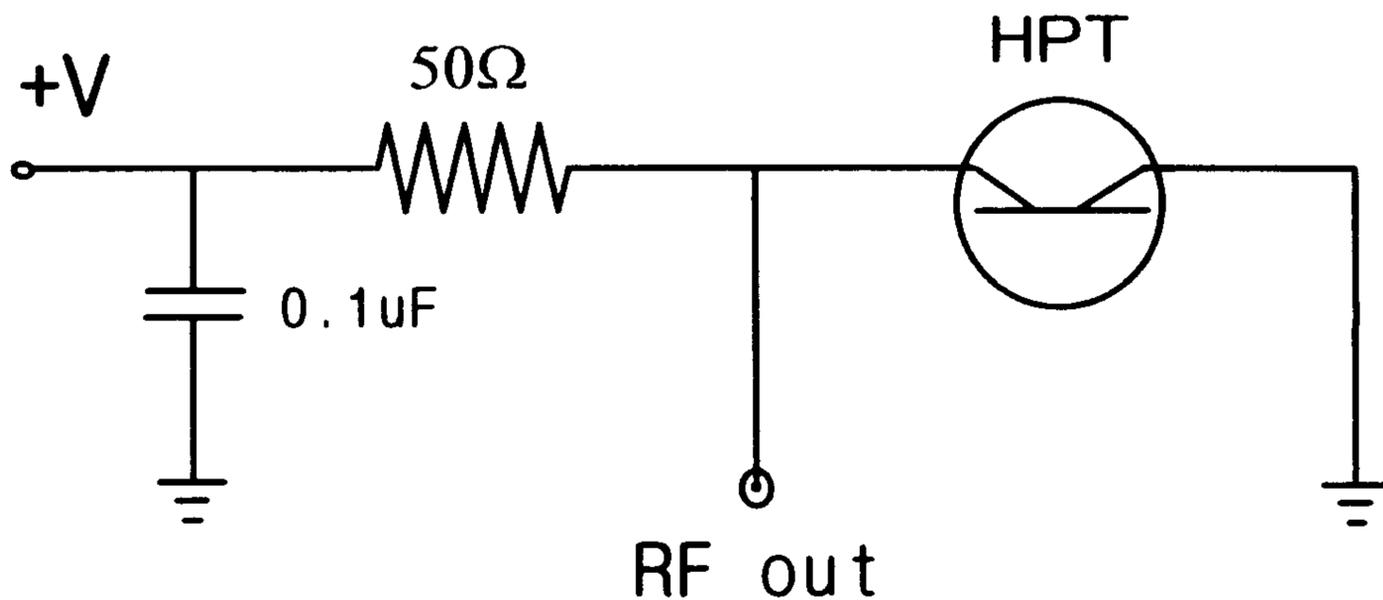


그림 14. HPT의 소신호 특성 측정을 위한 회로 구성

iii) Impulse 측정 실험

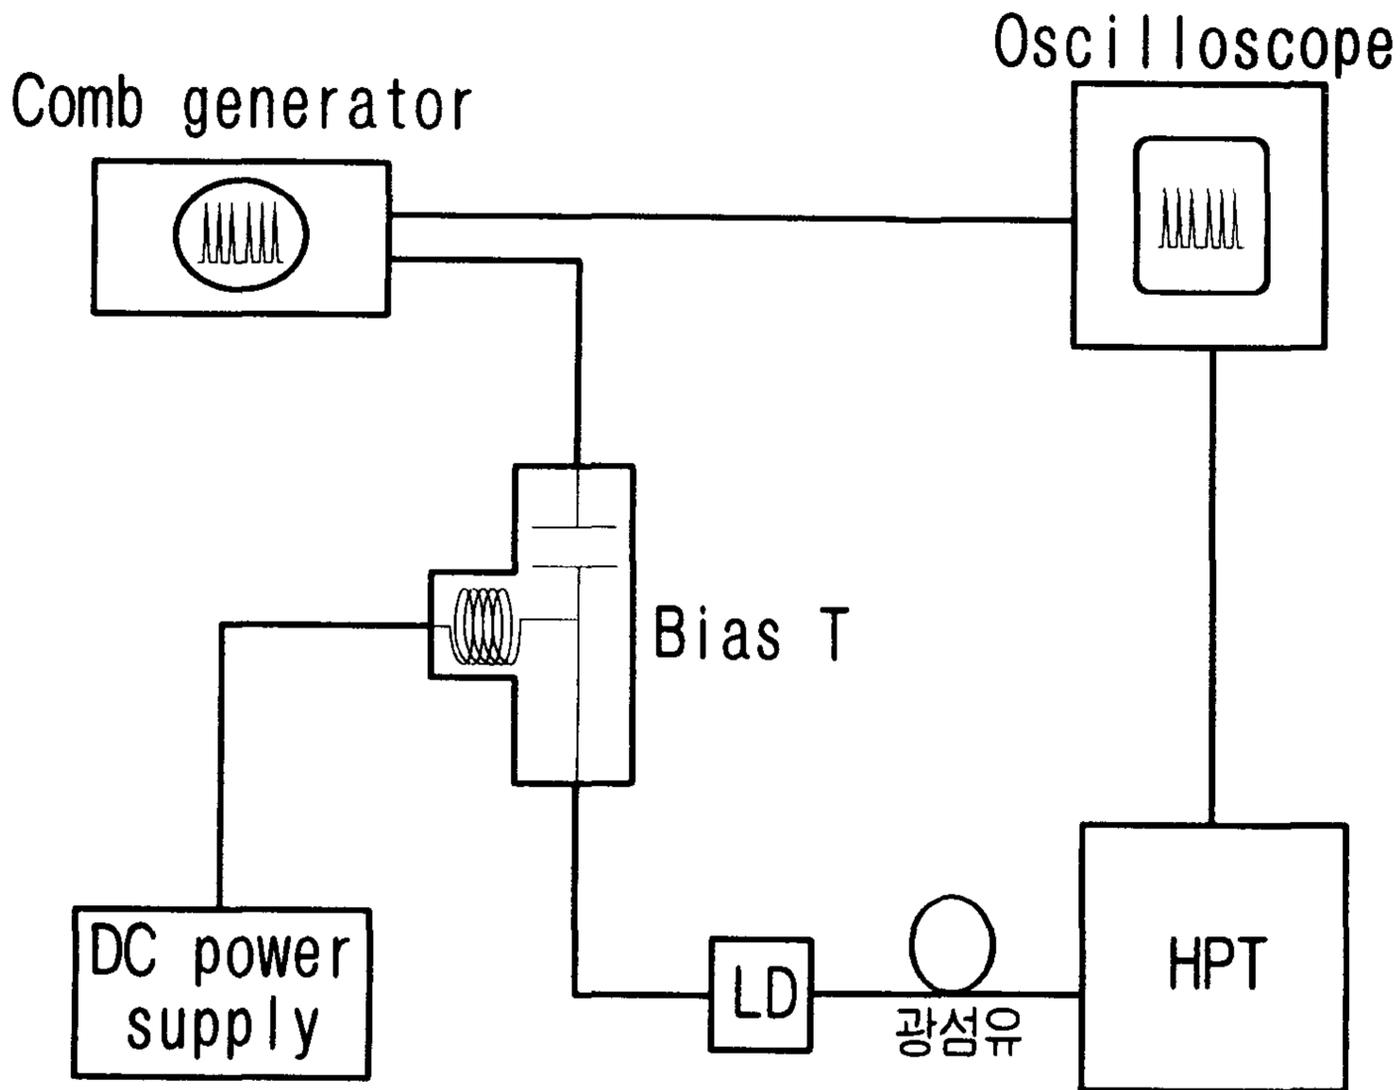


그림 15. HPT의 대 신호 응답특성을 측정하기 위한 실험장치 구성도

그림 15 에 HPT의 대 신호 응답특성을 측정하기 위한 실험장치 구성도를 보인다. Comb-generator를 이용하여 electrical pulse를 만든후 bias T를 통해 앞에서 제작한 광원을 구동시킴으로서 광 pulse를 얻어 이를 HPT에 입사시켰다.

LD로부터 short optical pulse를 얻기 위해 LD에 가해지는 dc pre-bias 전류를 65mA 인가함으로써 고속변조가 가능하도록 하였다.

### 3. 측정 결과

#### i) DC 특성 측정

다음 그림은 STR-A, STR-B, STR-C의 각 광 power level에 따른 I-V curve를 나타낸다.

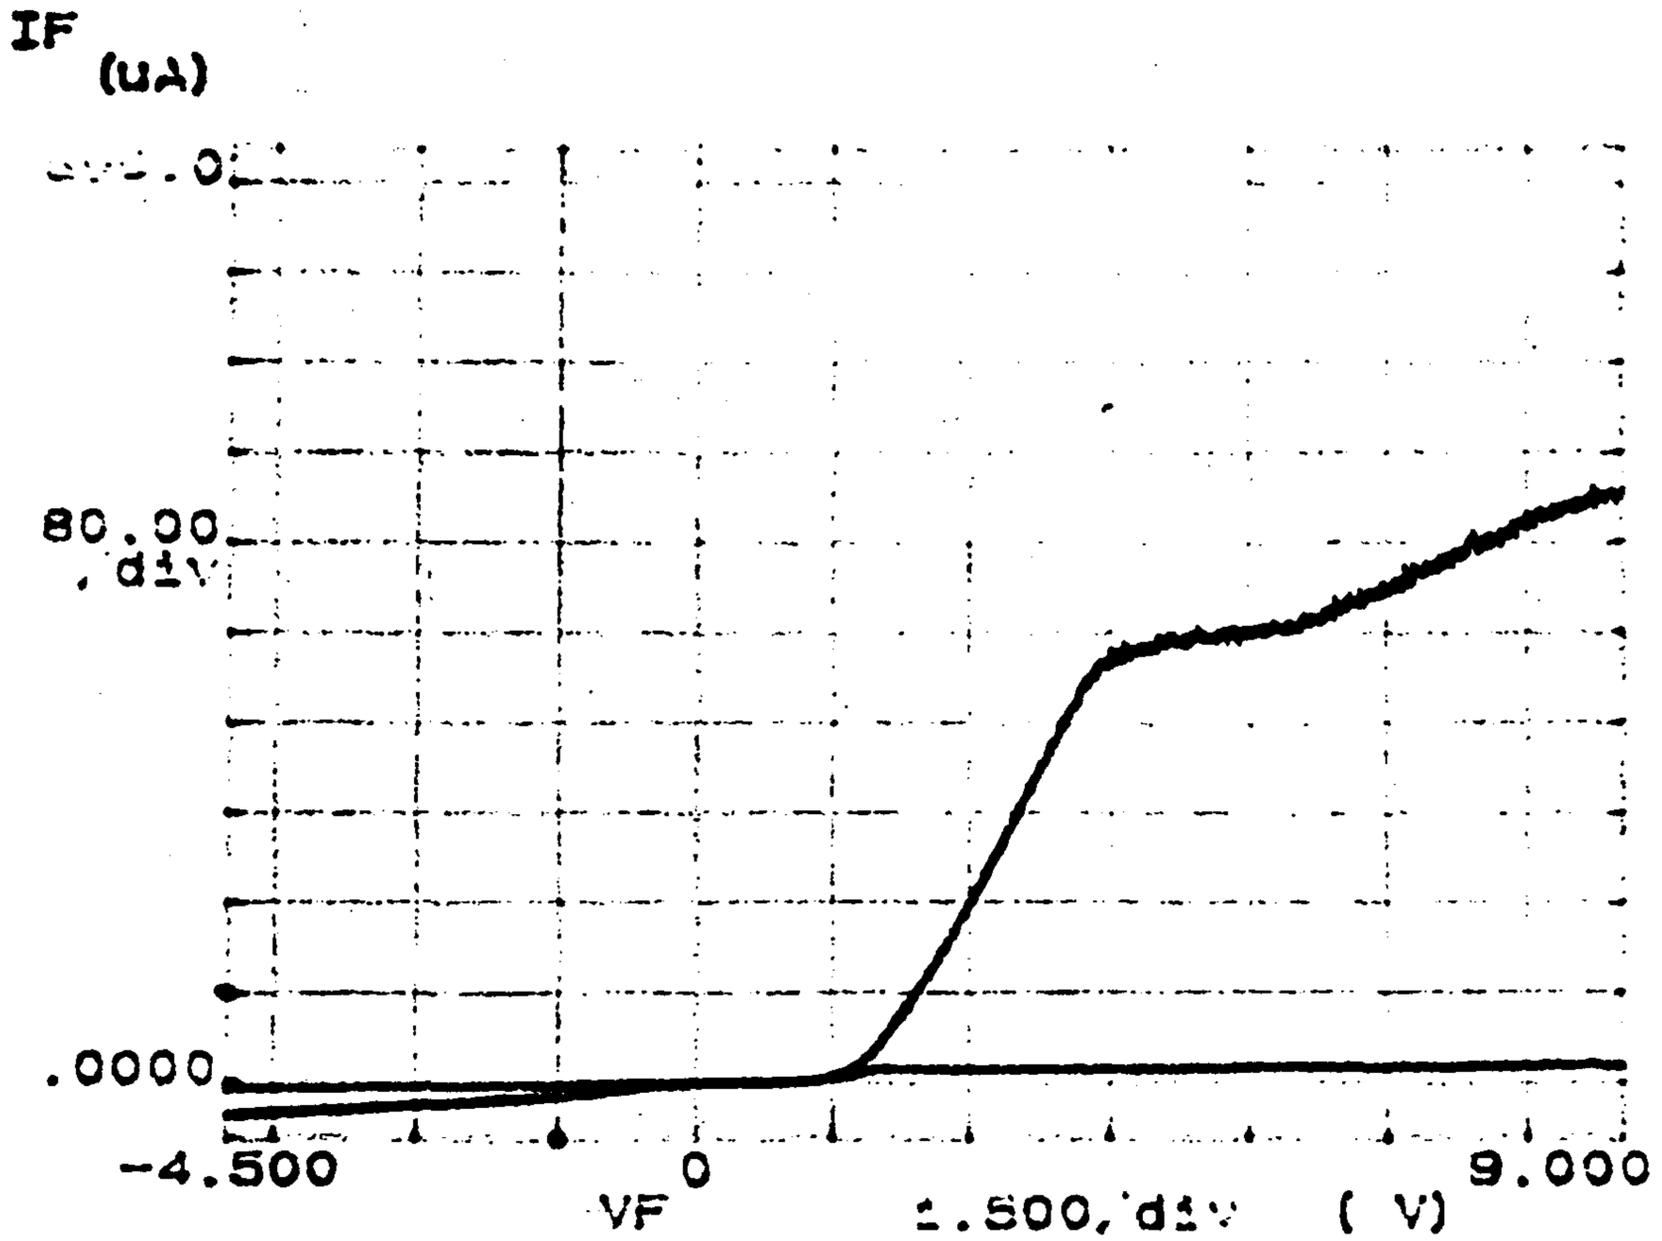


그림 16 STR-A의 120 μW에 대한 DC 특성

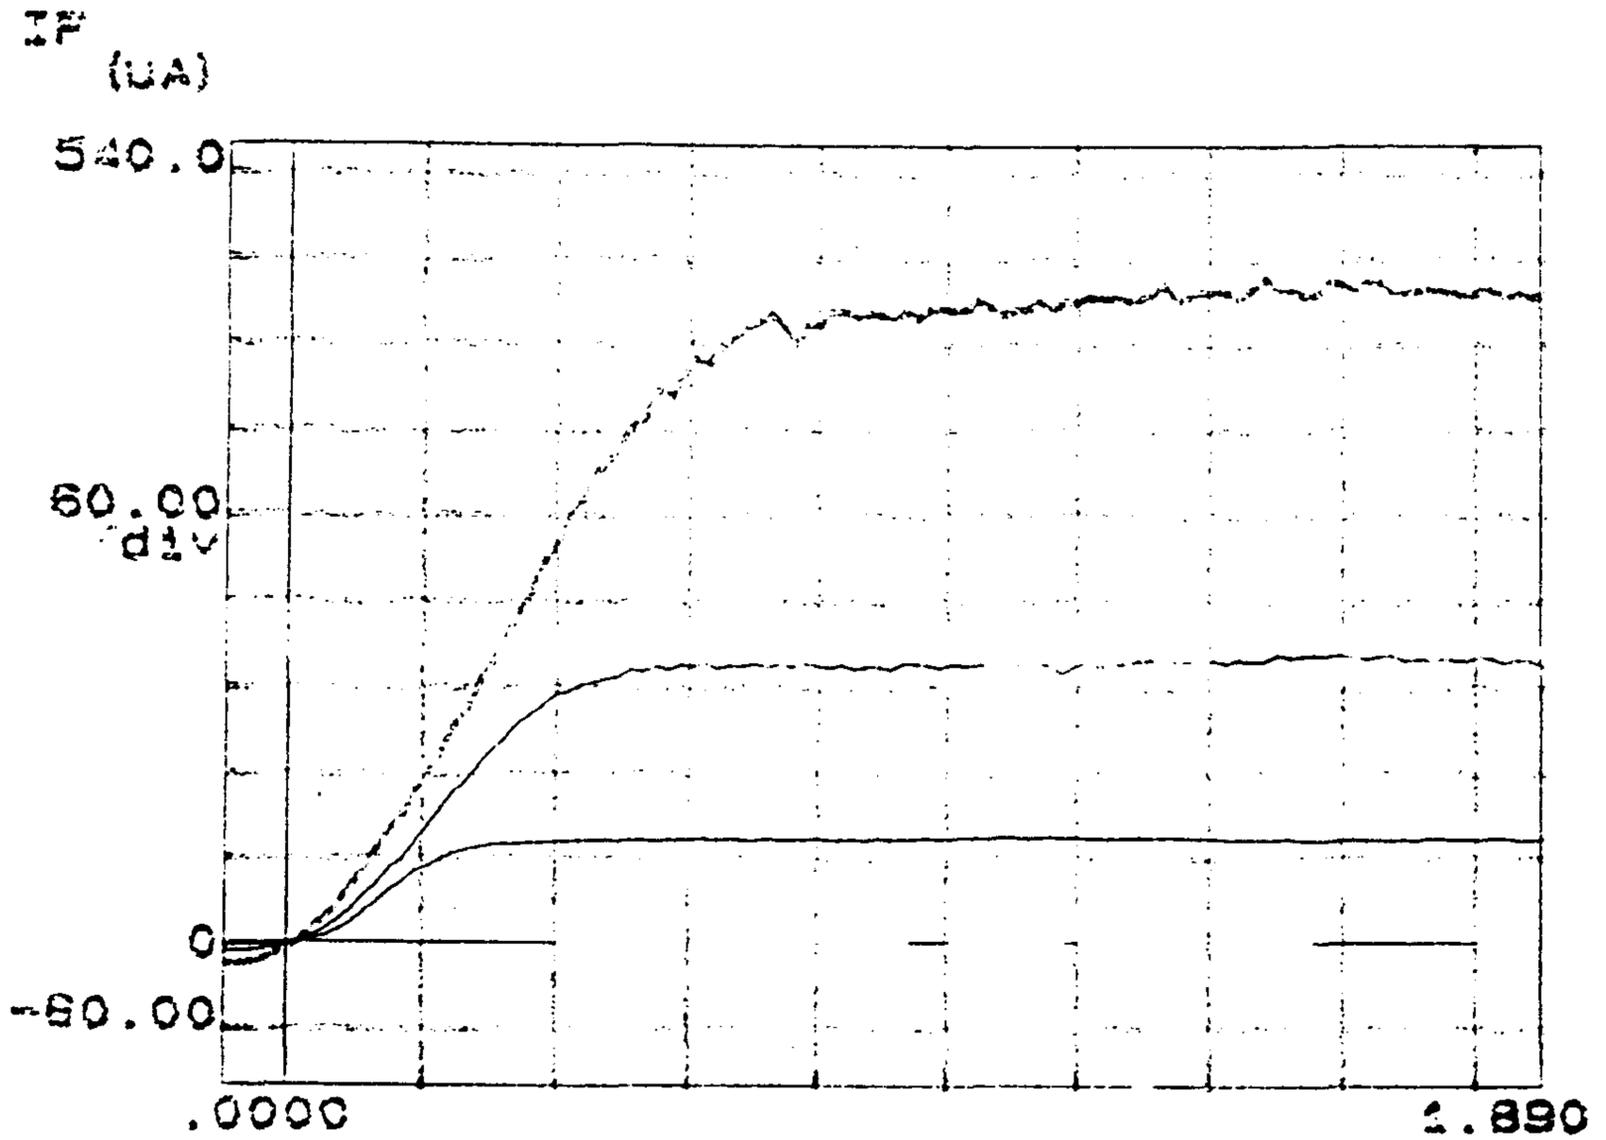


그림 17. STR-B의 145, 100, 50  $\mu\text{W}$ 의 광 세기에 대한 I-V curve

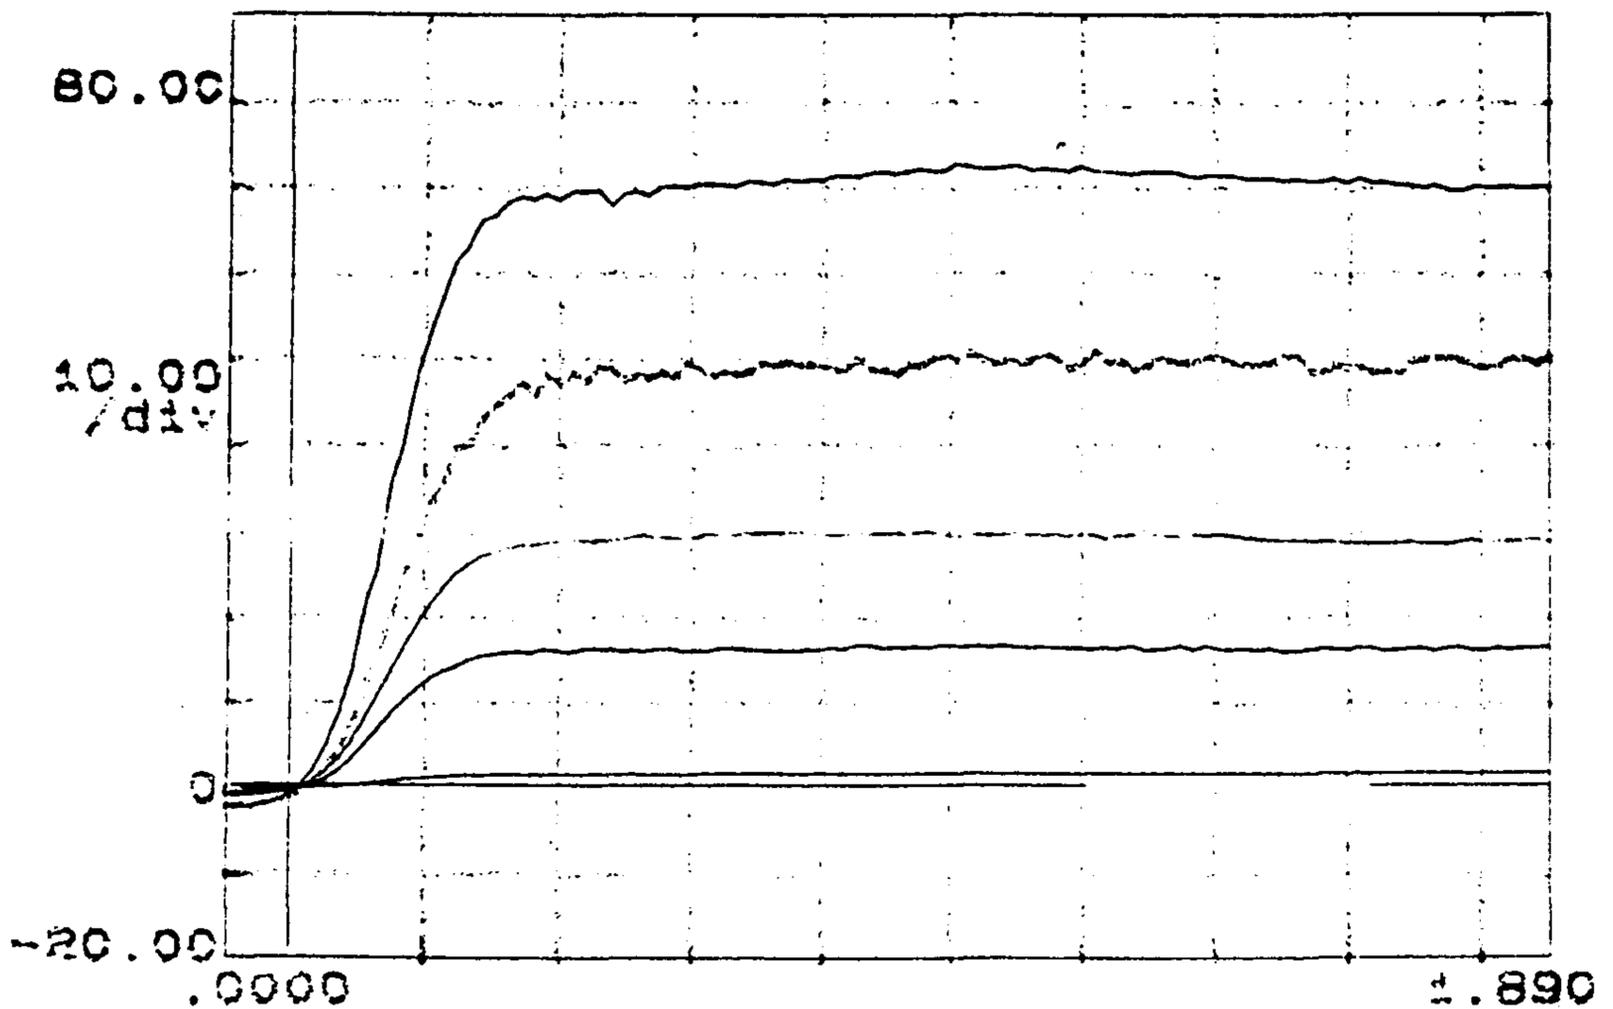


그림 18 STR-B의 55, 40, 30, 20, 5  $\mu\text{W}$ 의 광 세기에 대한 I-V curve  
위의 curve에서 saturation 부분이 상당히 안정되게 나타나는데 이는 소자를 넓은 범위에서 구동 시킬 수 있음을 말한다.

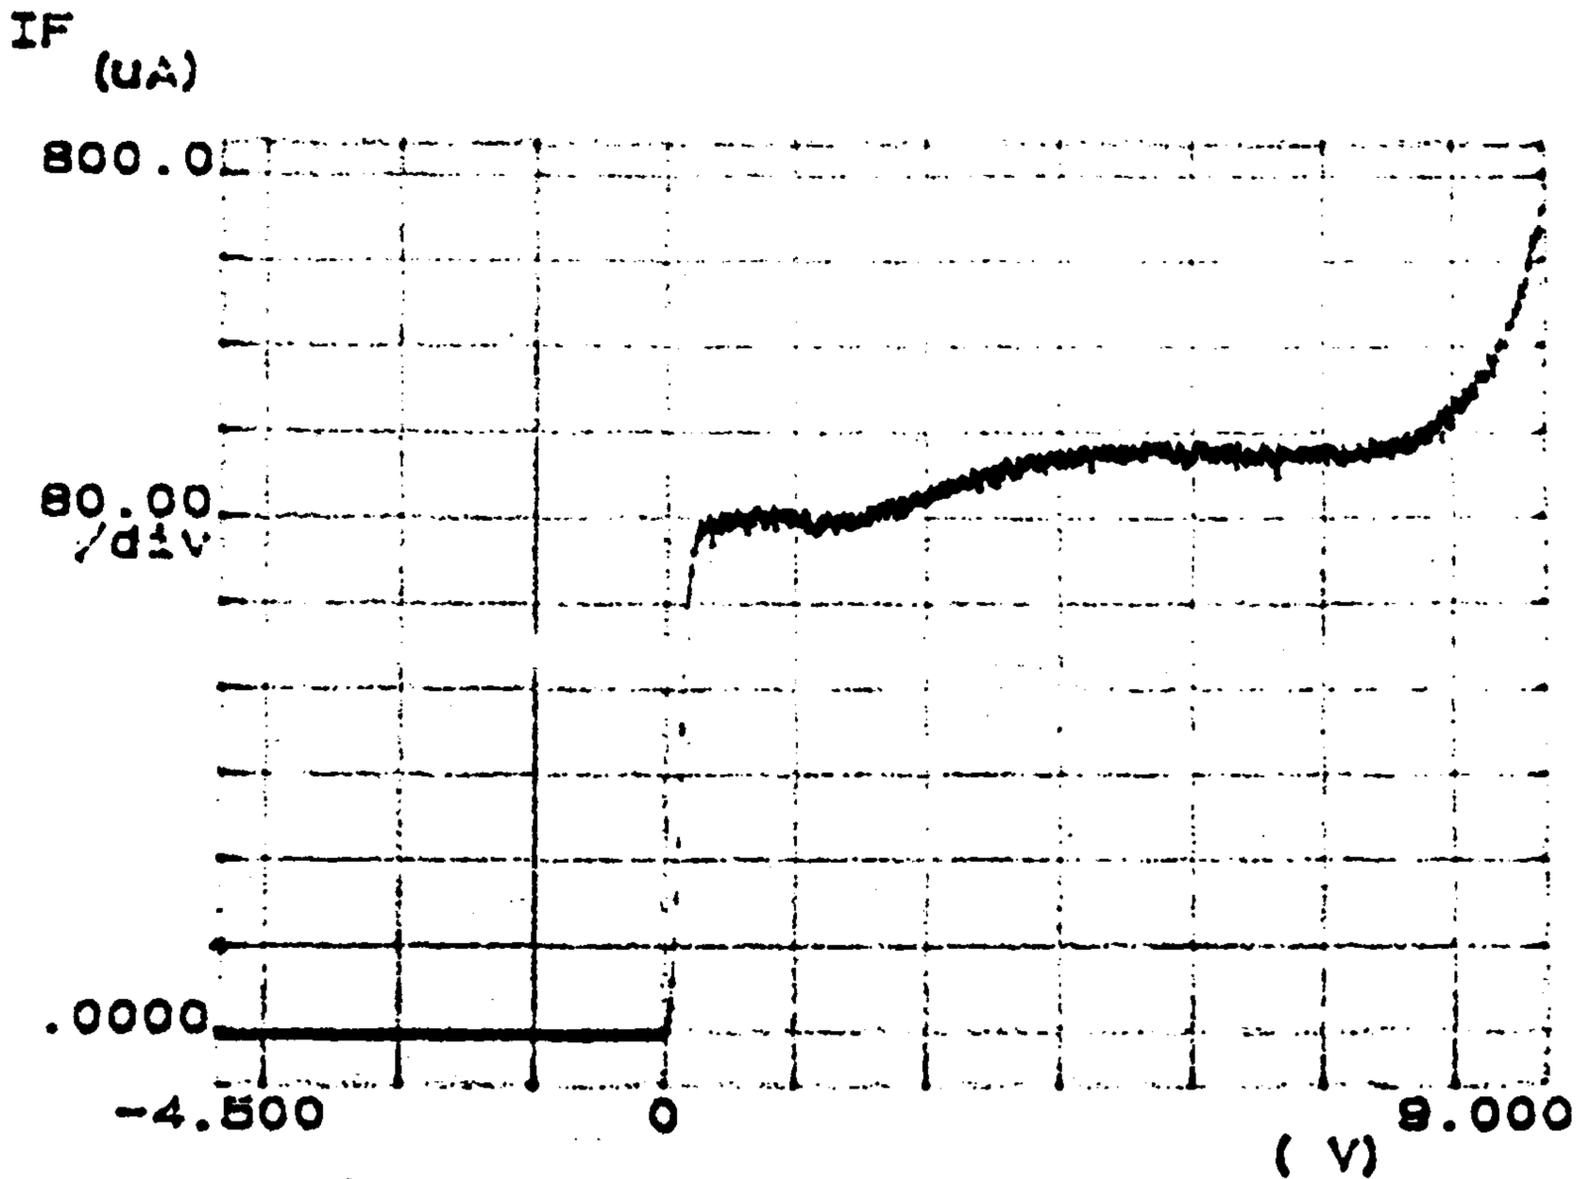


그림 19. STR-C의  $120\mu\text{W}$ 의 광 세기에 대한 I-V curve

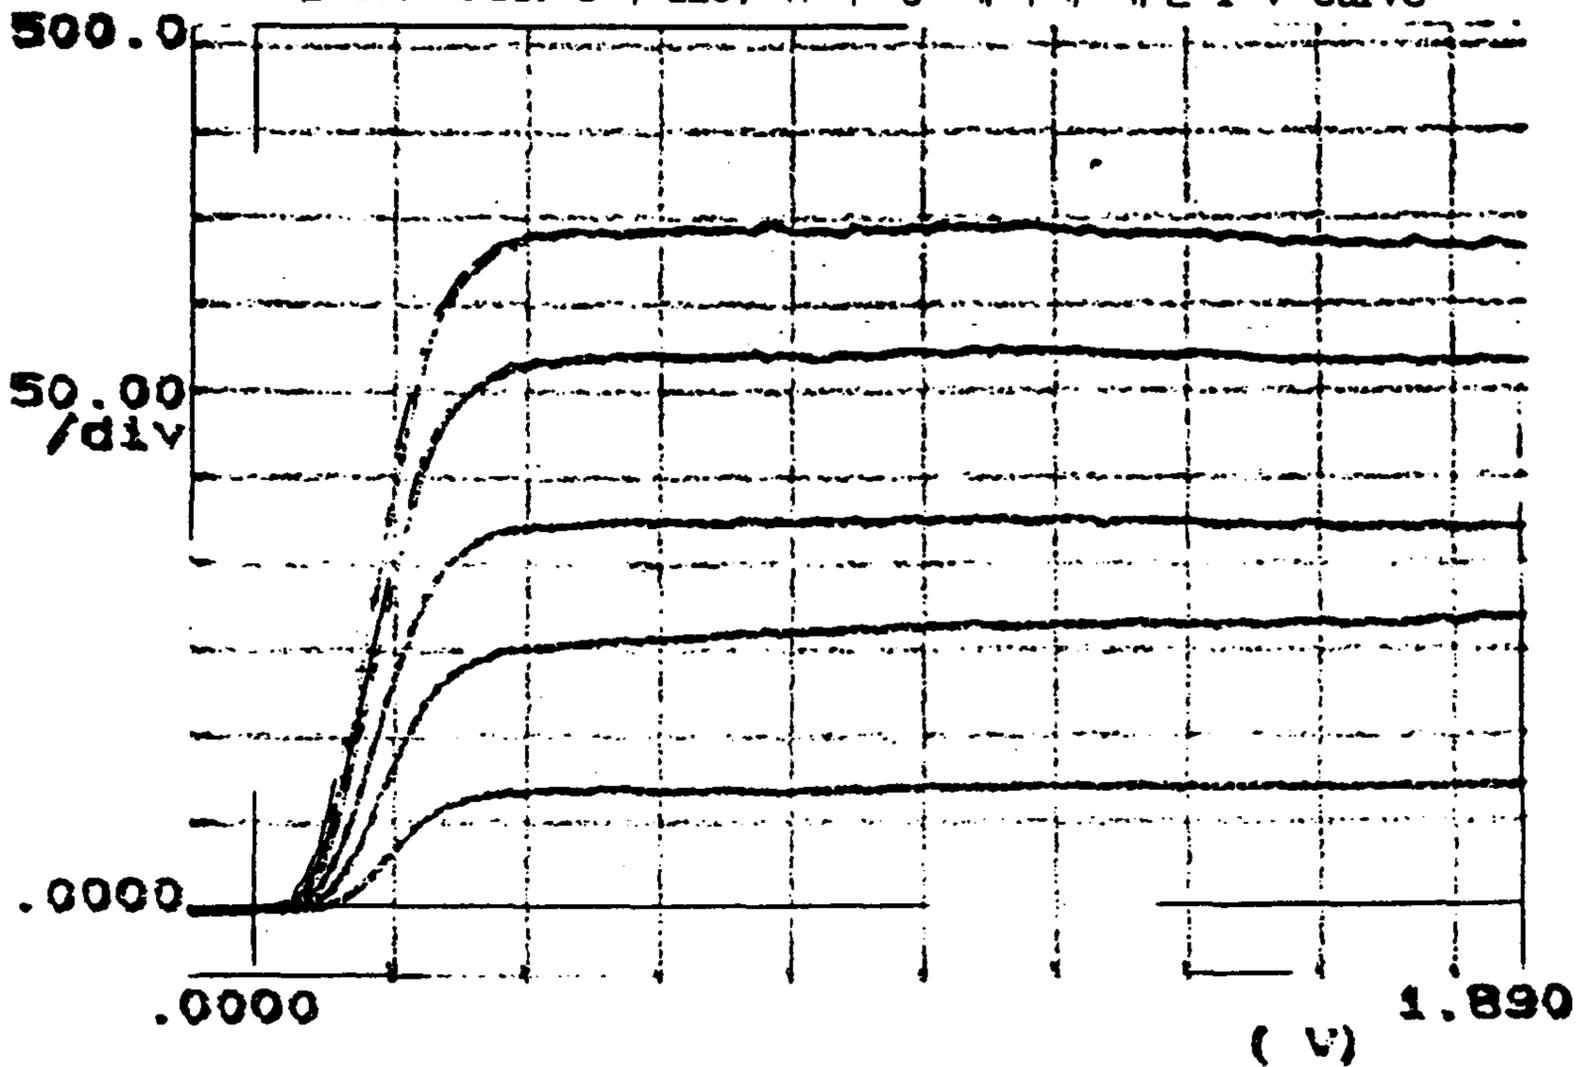


그림 20. STR-C의  $100, 80, 60, 40, 20\mu\text{W}$ 의 광 세기에 대한 I-V curve  
STR-C의 경우 9V 정도에서 avalanche effect가 보이기 시작한다.

이들 I-V curve로 부터 각 power level에서의 gain을 구할 수 있다.

gain에 대한 식은  $G = (\frac{I}{q}) / (\frac{P}{h\nu})$ 이며, 여기서 입사되는 빛의 정확한 세기는

광섬유와 HPT 사이의 광 결합 효율 및 HPT 표면에서의 반사 계수 등을 정확히 알으로써 구해진다.

광섬유의 출력이 HPT에 입사되는 비율은 다음과 같이 구할 수 있다.

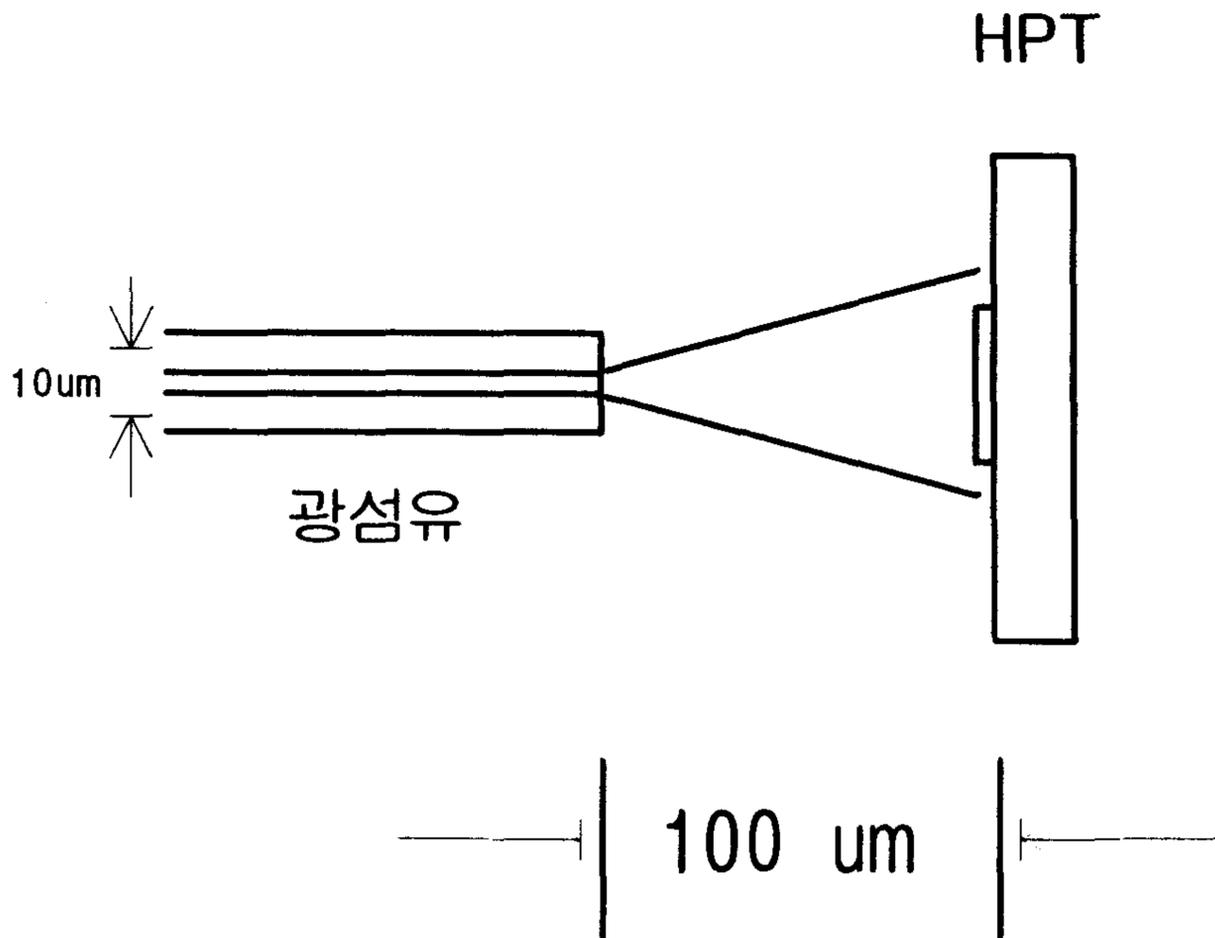


그림 21. 광섬유로부터 HPT에 입사되는 beam의 모습

광섬유의 반경이  $5\mu\text{m}$ 이고 광섬유에서 HPT 면까지의 거리가 약  $100\mu\text{m}$ , 빛이 광섬유에서 퍼져가는 각도를 약  $7^\circ$  정도라 하면 HPT 면에 입사되는 빛의 반경은  $R = 5 + 100 \text{ Tan } (7^\circ) (\mu\text{m})$  이고 입사광의 면적은  $938\mu\text{m}^2$ 이 된다.

HPT의 수광 면적은  $490\mu\text{m}^2$  이므로 입사광의 약 52 % 가 HPT에 입사된다고 보여지지만 단일 모드 광섬유에서 나온 빛은 Gaussian이므로 실제로는 더 많은 빛이 입사하게 된다. 또한 HPT의 표면은 GaAs이므로 표면을 통하여 71 %의 빛이 base와 collector에 입사하게 된다.

따라서 광 connector를 통해 power meter로 측정한 빛의 약 60% 이상이 HPT의 흡수층에 흡수됨을 알 수 있다.

이를 고려하여 DC gain을 계산하면 다음과 같다.

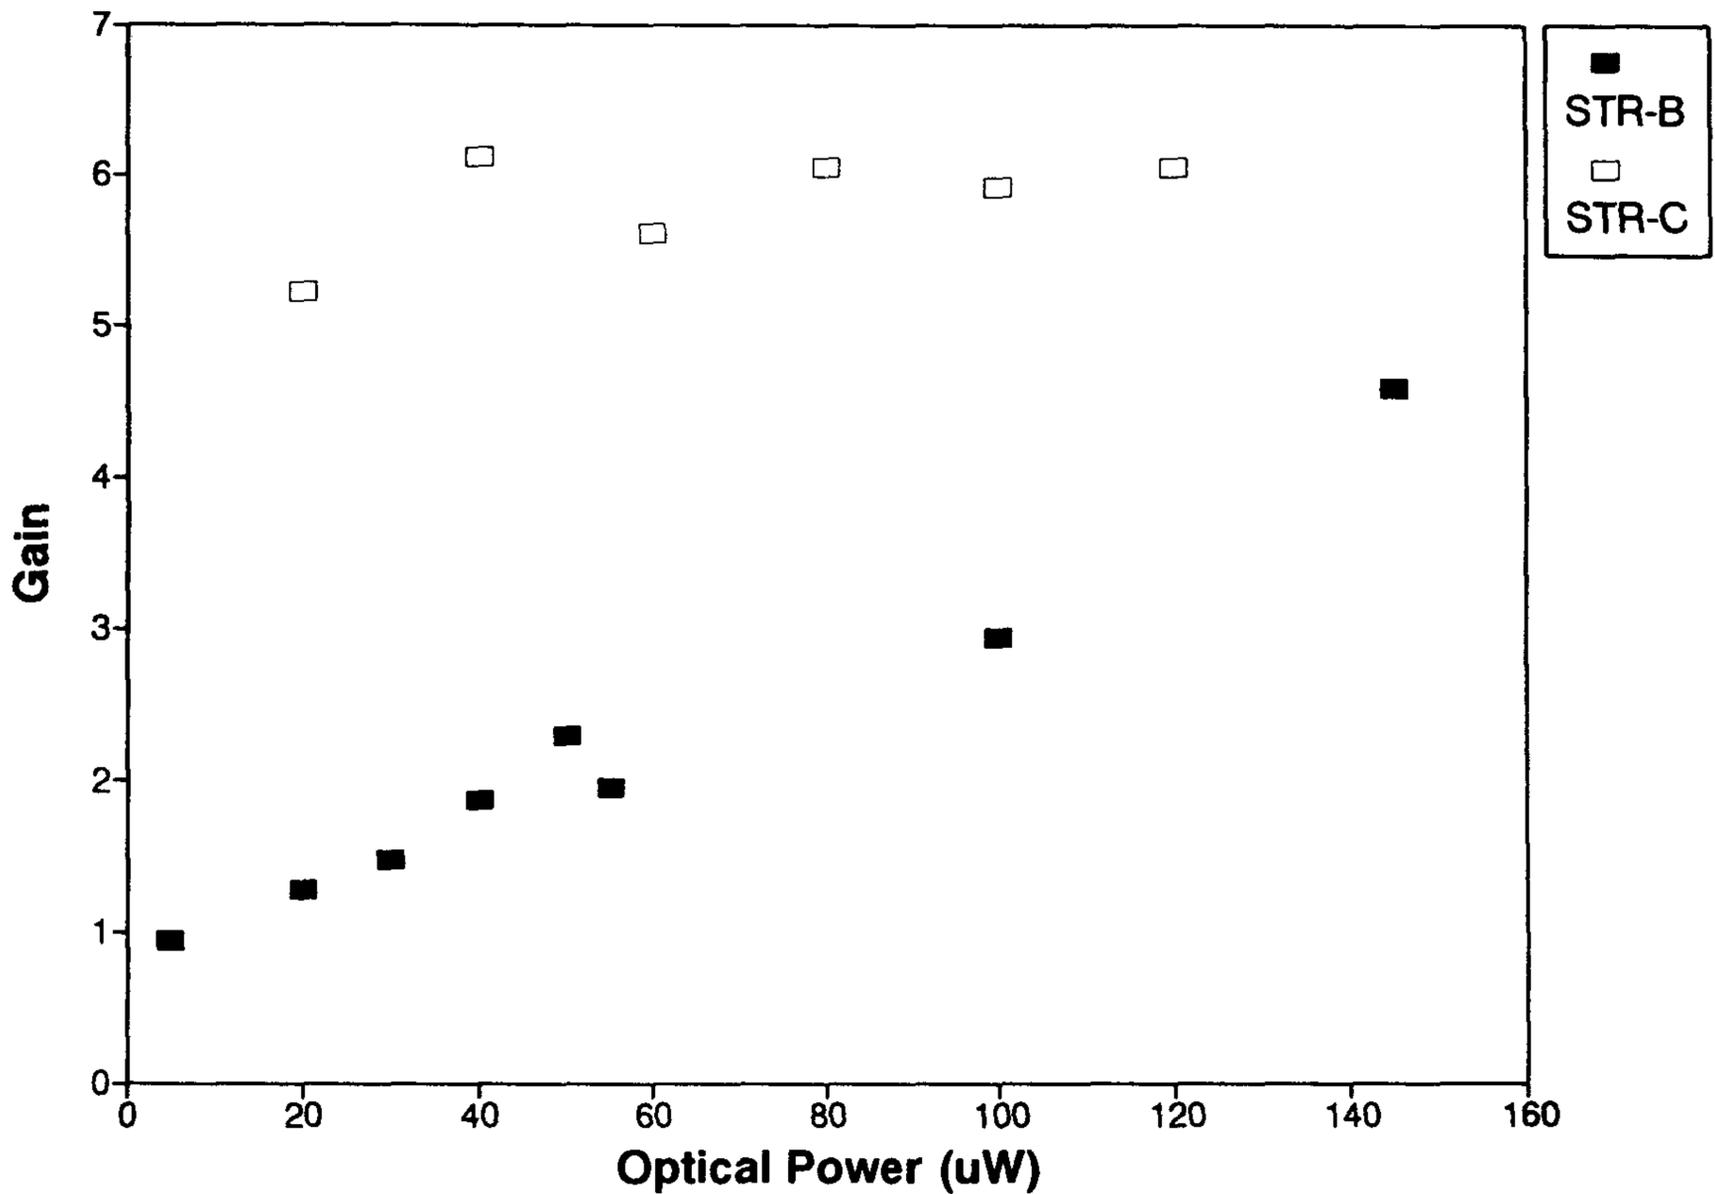


그림 22. 입사광 세기에 따른 gain의 변화

STR-B의 경우 100uW의 입사광에 대하여 약 200uA의 collector 전류가 측정되었으며, STR-C의 경우 같은 크기의 빛에 대해 약 400uA의 전류가 측정되었다. 따라서 dc gain은 STR-B, STR-C가 각각 약 5A/W, 10A/W 정도로 추정된다.

STR-B의 경우 낮은 광 강도에서는 gain이 STR-C보다 작으나 광 강도가 커질수록 STR-C와 점점 같아짐을 볼 수 있다.

이와는 별도로 lens를 써서 HPT 수광 영역의 작은 점에 집중 시켜본 결과 그 차이는 더욱 자세히 보인다. 다음 그림에 그 결과가 나타나있다.

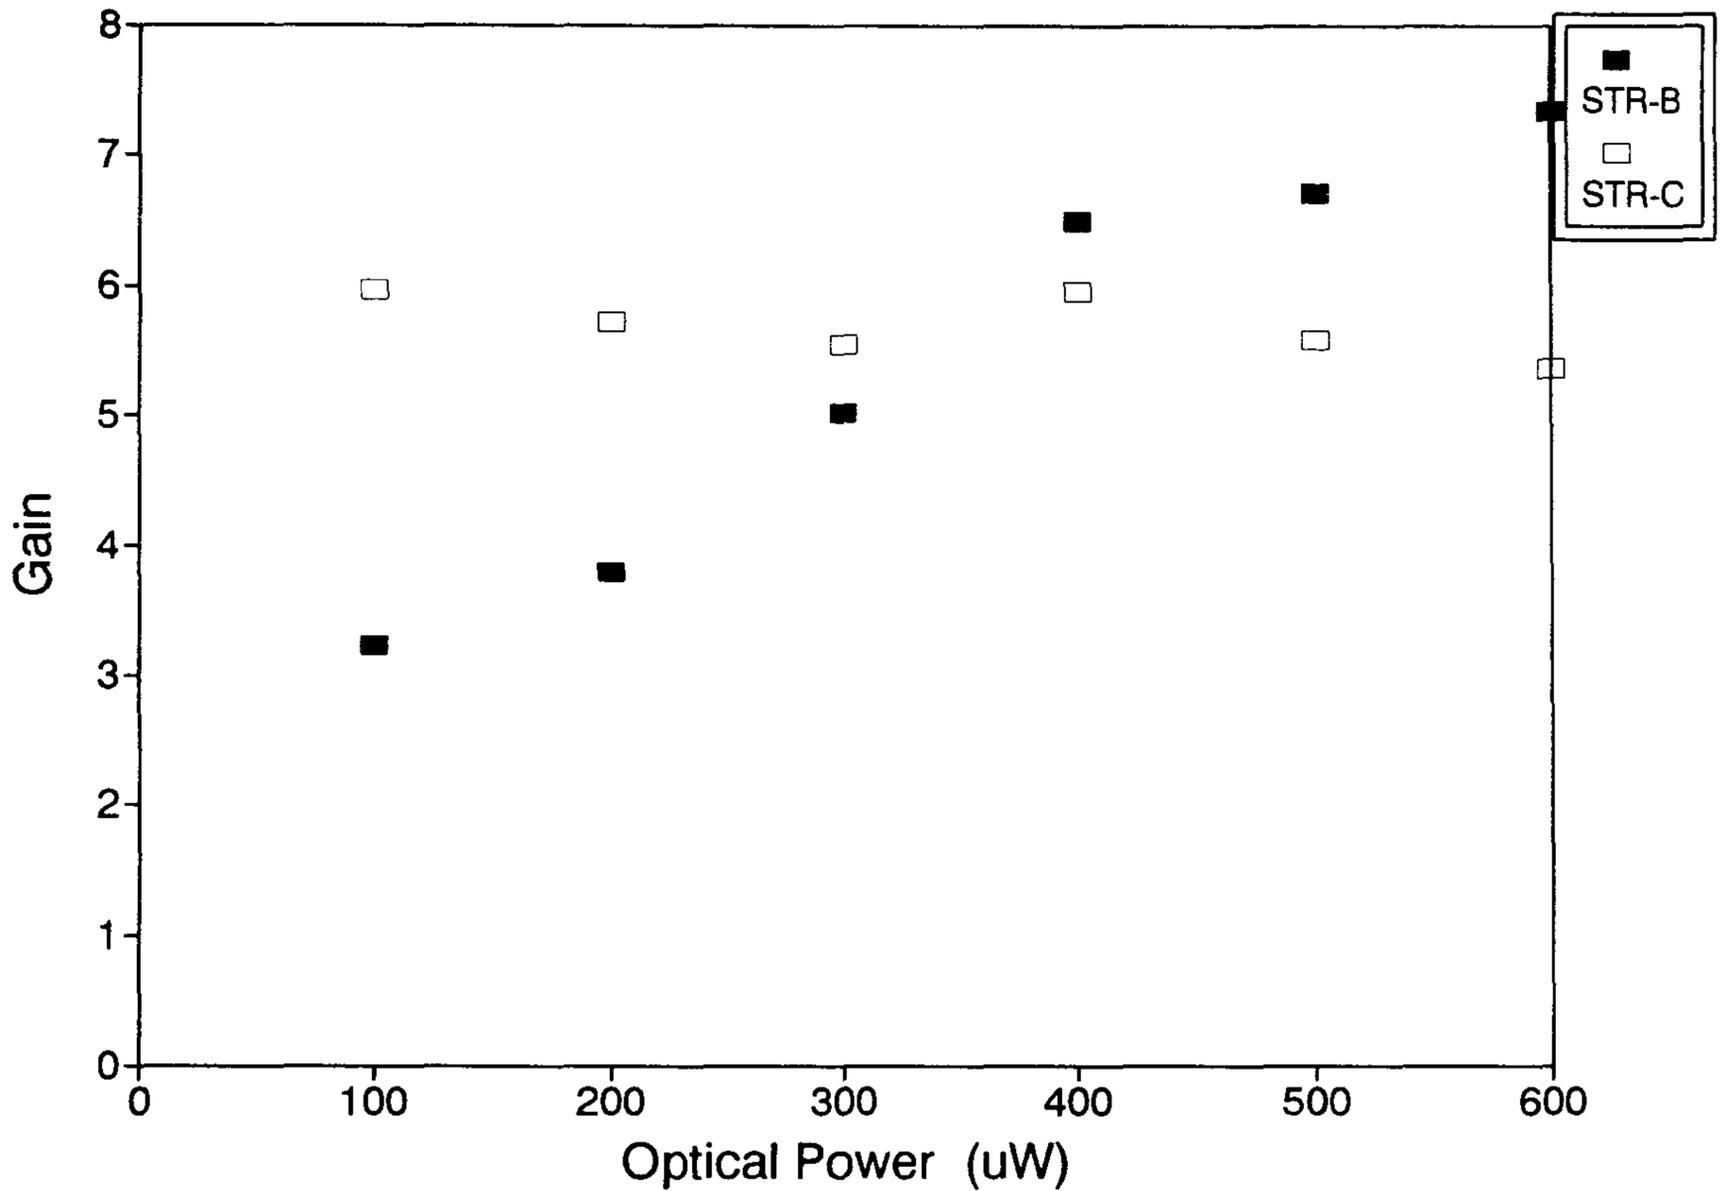


그림 23. 입사광 세기에 따른 gain의 변화

이는 광섬유를 사용하지 않고 빛을 직접 HPT에 입사시킴으로써 더 높은 광 강도에서 I-V 특성을 구할 수 있었다.

여기서 높은 광 강도로 가면 갈수록 STR-B의 gain이 오히려 더욱 커짐을 볼 수 있다. 이는 STR-B의 gain 은 STR-C 보다 높지만 낮은 광 강도에서는 표면 재결합 효과에 의해 gain이 작게 나온 것으로 추정된다.

즉 base에 file-up된 정공이 메사(mesa) 에칭된 표면에 많이 존재하는 표면 재결합 center에서 재결합하여 사라짐으로서 전류의 증폭에 기여하지 못하는 결과를 초래하기 때문에 이러한 현상이 발생한다.

이러한 현상은 정공의 diffusion time보다 빠른 속도로 변조된 광신호에 대해서는 발생하지 않으며, 따라서 조금 더 큰 gain을 얻을 수 있다. 대체적으로 정공의 diffusion time은 수 ns로서 50 - 200MHz의 광신호에 대해 큰 gain을 얻을 것으로 추정된다. STR-B는 base의 두께가 1500A으로 STR-C의 800A보다 두껍고, 따라서 상대적으로 2배나 많은 표면 재결합 center를 메사 주위에 갖고 있다.

STR-C의 dc gain이 STR-C의 dc gain보다 2배 가량 큰 것으로 보아 앞에서 논의한 생성-재결합 중심이 dc gain을 감소시킨다는 가정이 타당한 것으로 생각된다. 다음은 I 와 gain에 대한 fitting 결과이다.

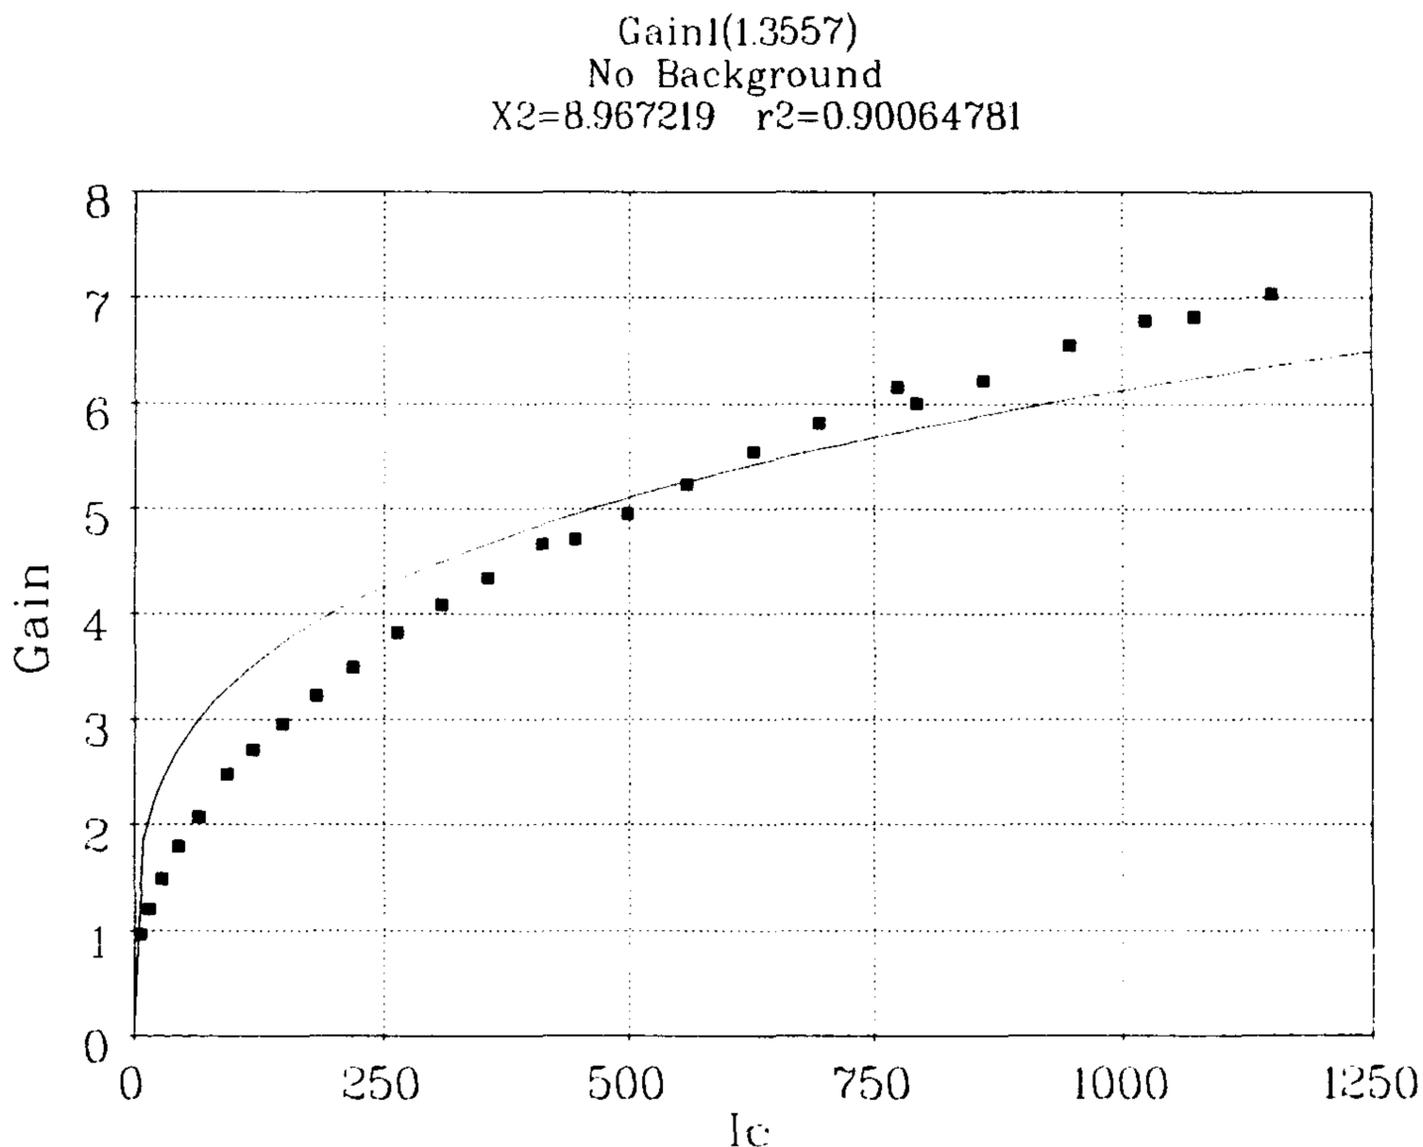


그림 24. STR-B에 대한 fitting 결과

Gain1(1.18703)  
 No Background  
 X2=3.9121415 r2=0.95028457

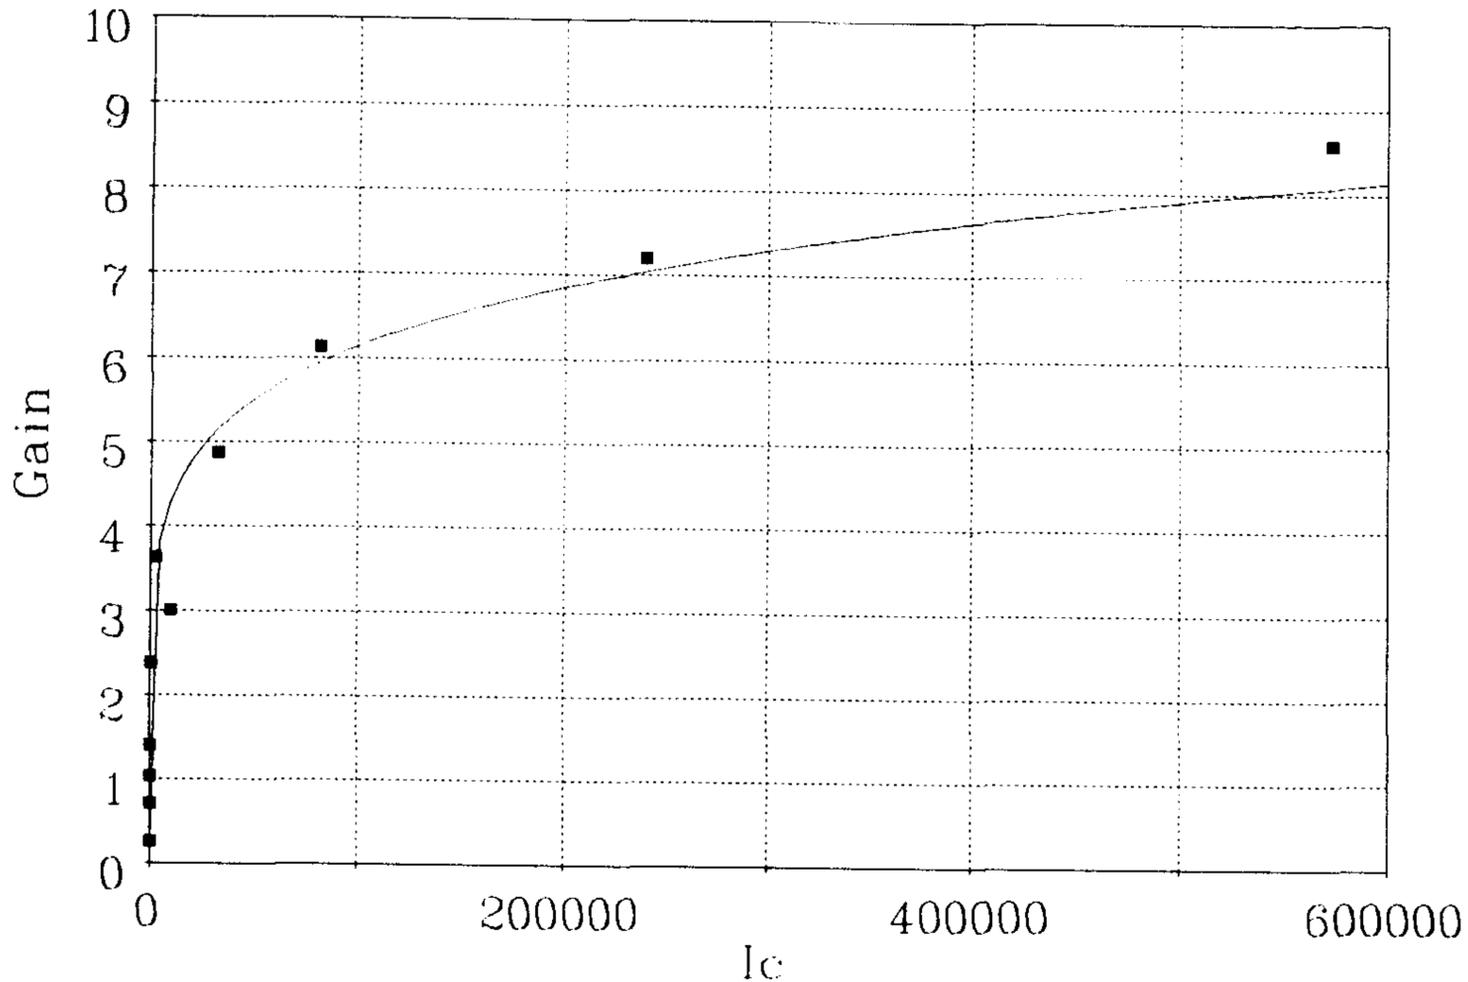


그림 25. STR-C에 대한 fitting 결과

이 fitting은 gain이 전류 세기에 따라  $G \propto I_c^{1-\frac{1}{n}}$ 의 관계를 가짐을 이용한 것이다.

여기서 n은 ideality factor로  $n \rightarrow 1$  일수록 diffusion에 의한 전류가 지배적이며  $n \rightarrow 2$  일수록 표면 재결합에 의한 누설 전류가 더 지배적이라는 의미를 가진다.

참고로 fitting에 사용된 data는 서로 다른 조건하에서 STR-B와 STR-C를 측정 한 것으로 절대적인 비교에는 무리가 있다. fitting 결과 STR-B의 경우  $n \sim 1.35$ 이고 STR-C의 경우  $n \sim 1.18$ 로, STR-B가 표면 재결합에 의한 누설전류가 더 많음을 알 수 있다. 이 사실은 낮은 광 강도에서 두 소자의 DC gain 차이를 설명한 앞의 가정을 뒷 받침 해준다.

ii) AC 특성 측정

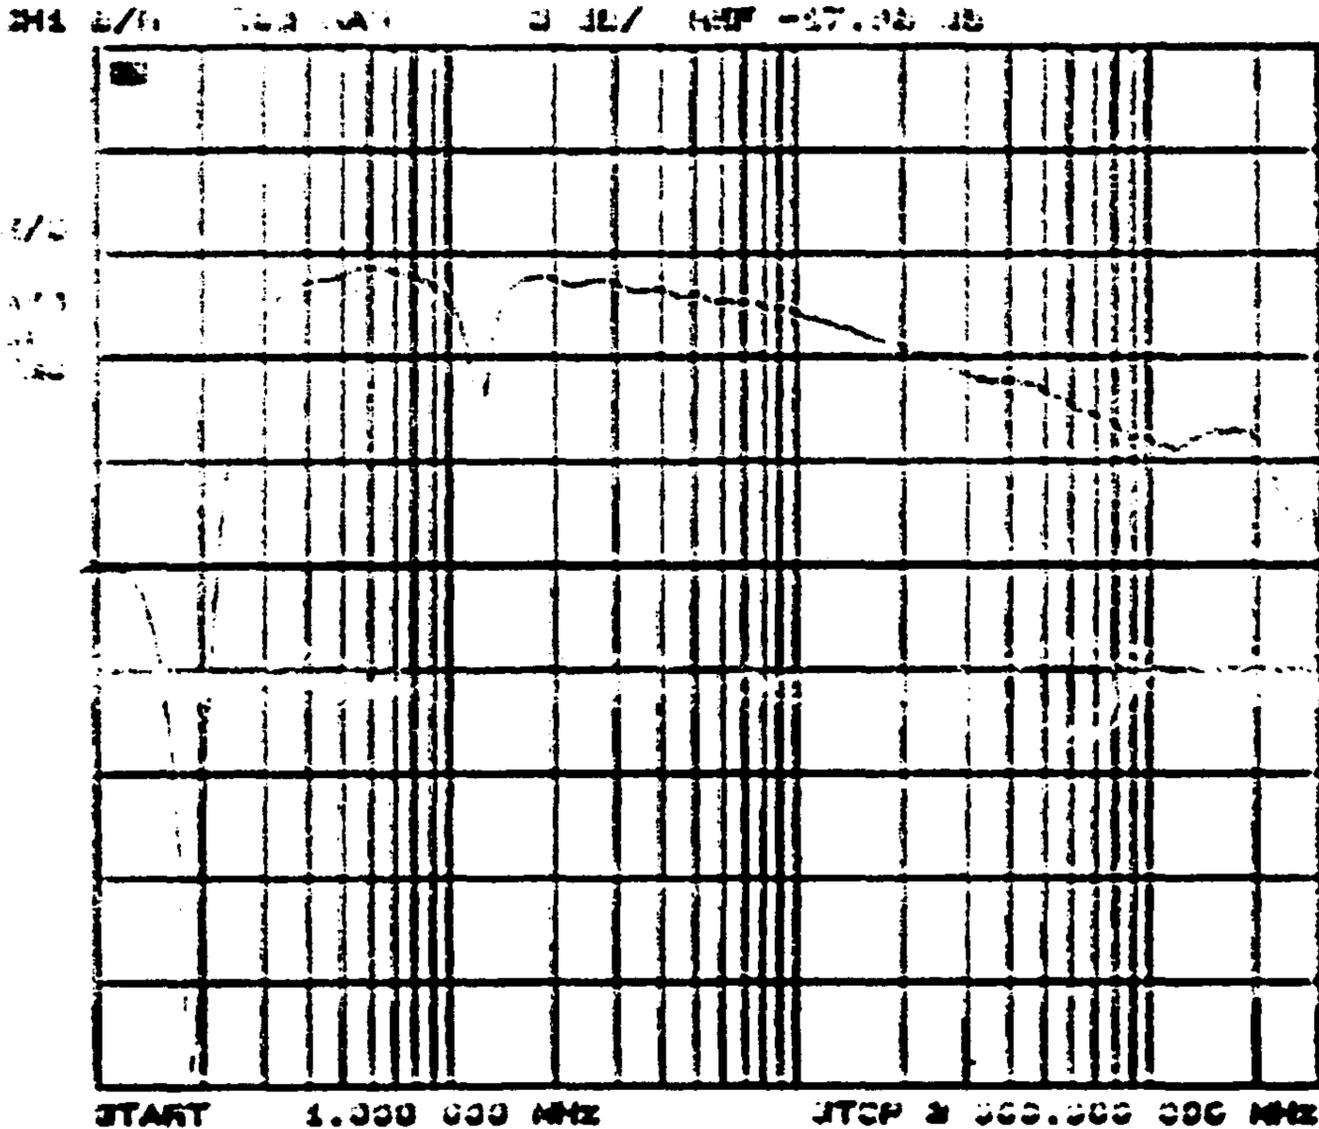


그림 26. 광원의 소신호 응답 특성

그림 26는 제작된 광원의 소신호 변조 대역폭을 HP Lightwave Component Analyzer를 이용하여 측정한 결과이다. 측정조건은 LD에 pre-bias 65mA, RF 변조폭 0dBm을 bias-T를 통해 인가하였으며 기준 수신기는 3GHz 대역폭을 가지는 InGaAs 광수신기를 사용하였다.

그림으로부터 2MHz 및 12MHz 부근에서 강한 dip이 있으며 100MHz까지 과장된 변조특성을 보이고 있음을 알 수 있는데 이것은 실험에 사용된 bias-T(유효주파수 대역:45MHz - 12GHz)에 의한 영향으로 분석된다.

전기 에너지가 LD로 들어가서 광섬유를 통해 끝단에서 출력될 때 그 변환 효율은 12.2 % 즉, -15 dB가 된다. 중앙의 기준선이 -17 dB를 말하고 1 division 당 3 dB가 되므로 이 광원은 3GHz 이상의 -3dB 변조대역폭을 가짐을 알 수 있다.

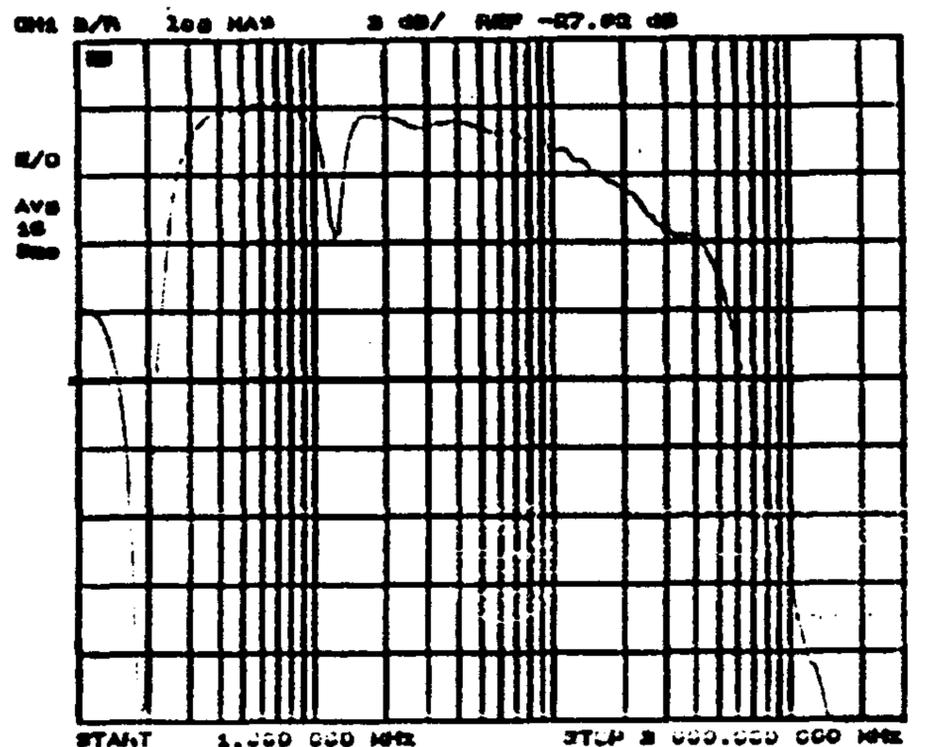
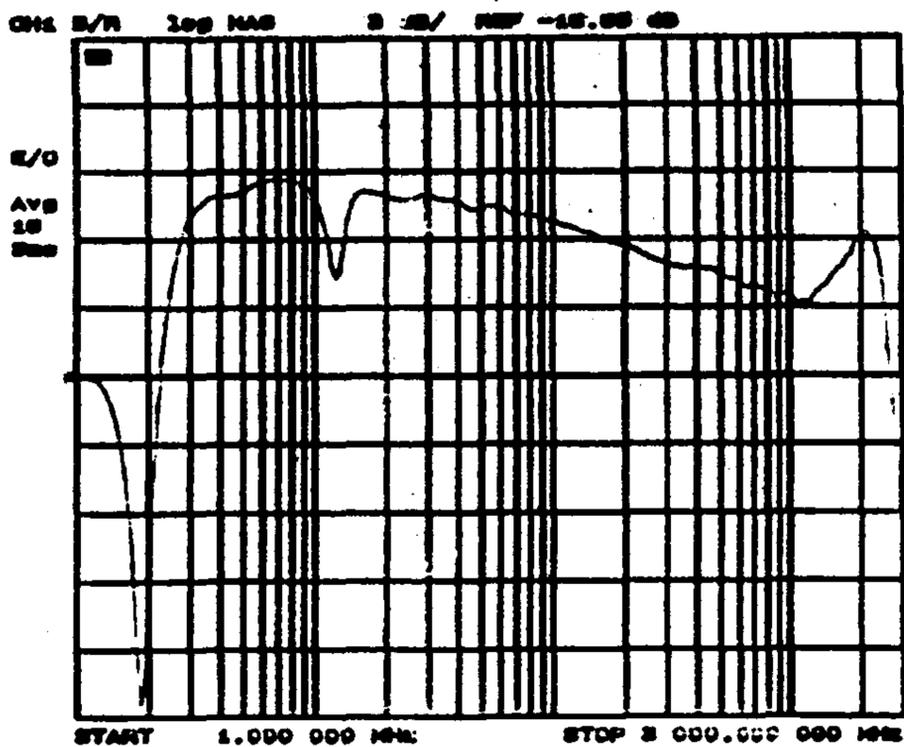
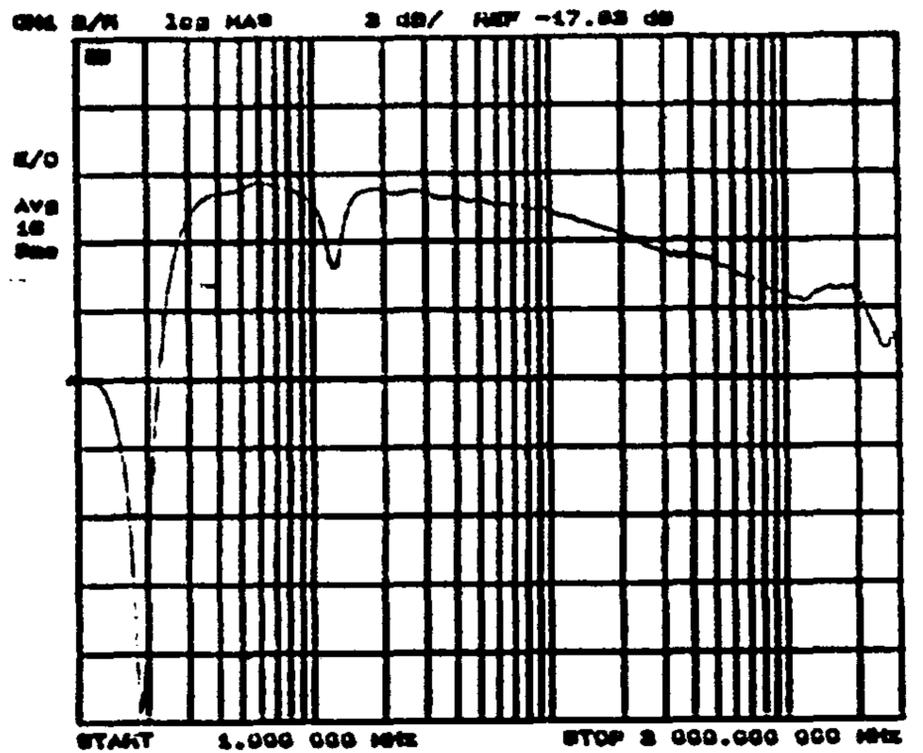
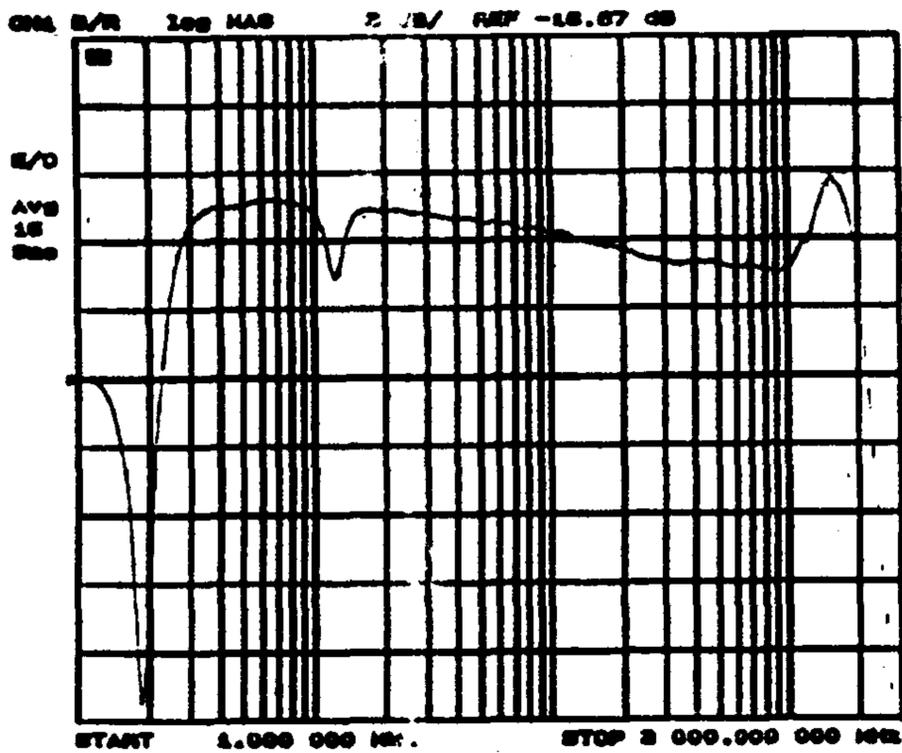


그림 27. 55, 65, 60, 50mA에 대한 광원의 소신호 응답 특성 (좌상부터)

위의 그림은 LD에 pre-bias 50, 55, 60, 65 mA를 pre-bias로 주면서 측정한 결과이며, 고속 동작에서는 65 mA 일 때가 가장 안정된 특성을 보이기 때문에 앞에서처럼 광원의 pre-bias 로 65 mA를 선택하였다. 그러나 이 경우 광 섬유 끝에서 나오는 빛의 세기는 약  $508 \mu\text{W}$ 가 되며 DC gain은 STR-B가 STR-C 보다 크므로 다음의 결과에서처럼 STR-B와 STR-C가 차이 나는 원인이 되었다고 생각된다.

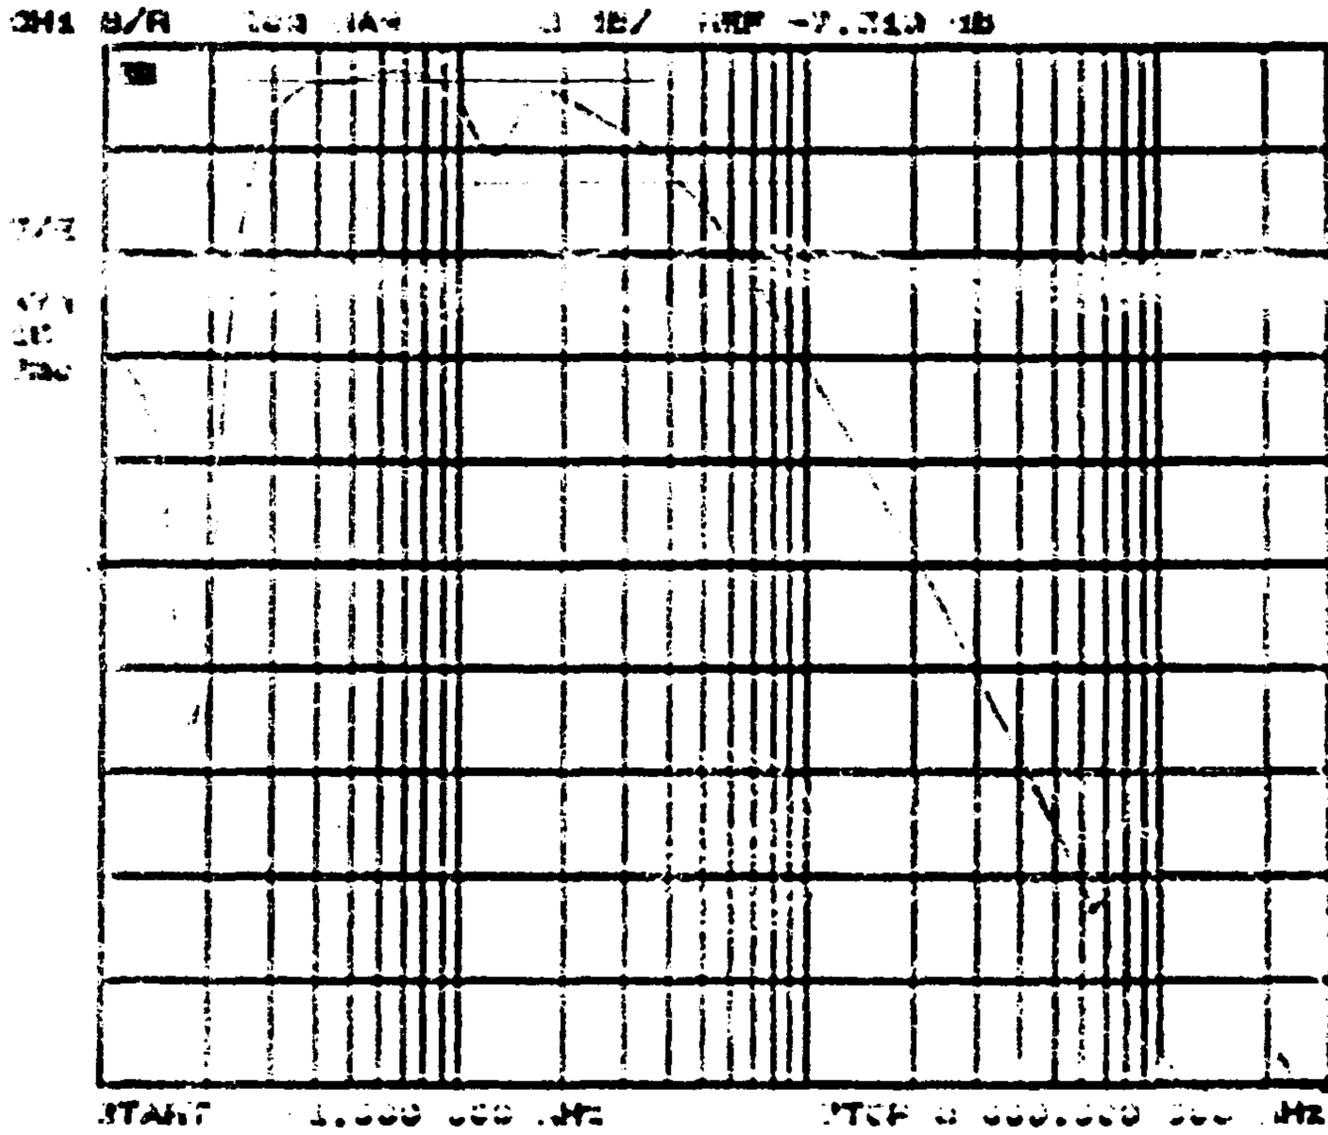


그림 28. STR-B의 소신호 응답특성

그림 28에서 보는 것처럼 STR-B 최대 주파수 응답대역은 약 3 - 20 MHz이며, 최대 응답으로부터 3dB 감쇄가 일어나는  $f(-3dB)$ 는 42 MHz이다. 이때 STR-B 자체의 응답특성은 그림 26에서 측정된 광원의 변조특성으로 STR-B의 응답특성을 나눔으로써 정확히 구해진다.

$f(-3dB)$  점에서의 gain을 먼저 살펴보자. 최대 주파수 응답대역에서 전→광→전의 변화율은 +6.5dB 이므로, 전기 에너지가 LD로 들어가 광섬유를 통해 끝단에서 출력될 때 그 변환 효율은 3.294 % 즉, -14.8 dB가 됨을 고려하면 이 대역에서 STR-B의 gain은 21.3 dB(11.64 배)가 됨을 알 수 있다.

따라서 Gain-Bandwidth product는 489 MHz가 되며, cutt-off frequency는 gain이 1 이 되는 점이므로 그래프에서 약 500 MHz 정도가 됨을 알 수 있다.

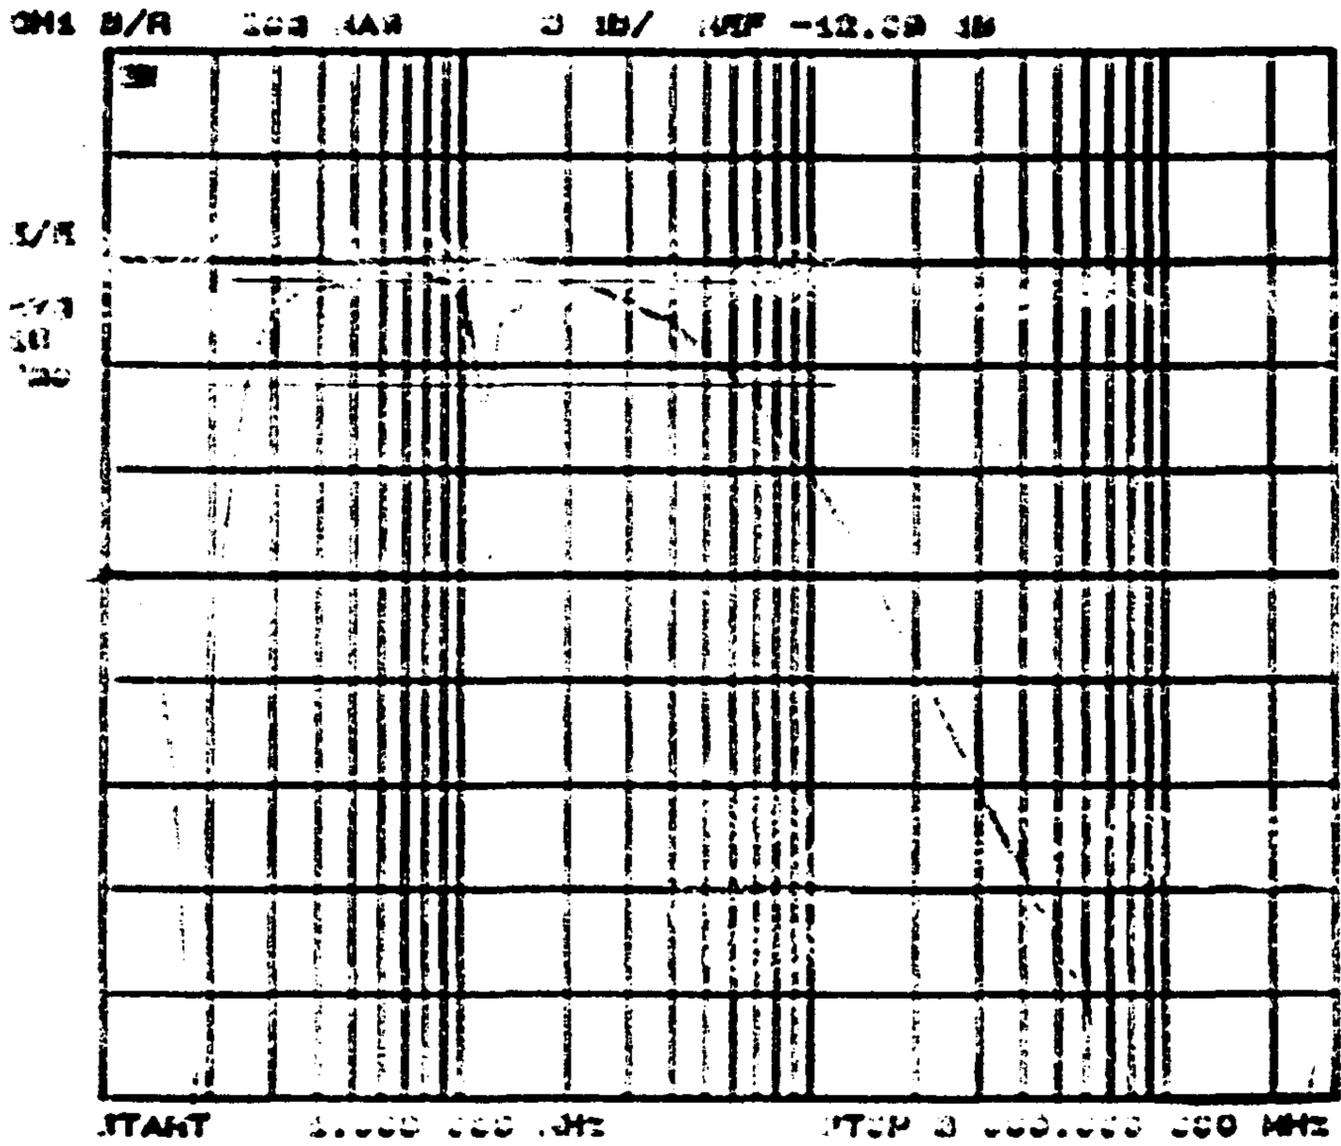


그림 29. STR-C의 소신호 응답특성

그림 29에서처럼 STR-C 최대 주파수 응답대역은 약 3 - 30 MHz이며, 최대 응답으로부터 3dB 감쇄가 일어나는  $f(-3dB)$ 는 65 MHz이다.

이때 STR-C자체의 응답특성 역시 그림 26에서 측정된 광원의 변조특성으로 STR-C의 응답특성을 나눔으로써 정확히 구해진다.

$f(-3dB)$  점에서의 gain 은 최대 주파수 응답대역에서 전→광→전 의 변화율이 -4 dB이므로, 광원의 전→광 효율 -14.8 dB를 고려하면 이 대역에서 STR-C의 gain 은 10.8 dB(3.467 배)가 됨을 알 수 있다.

따라서 Gain-Bandwidth product는 225 MHz가 되며, cutt-off frequency는 gain 이 1이 되는 점이므로 그래프에서 약 220 MHz 정도가 됨을 알 수 있다.

### iii) 대신호 응답 특성

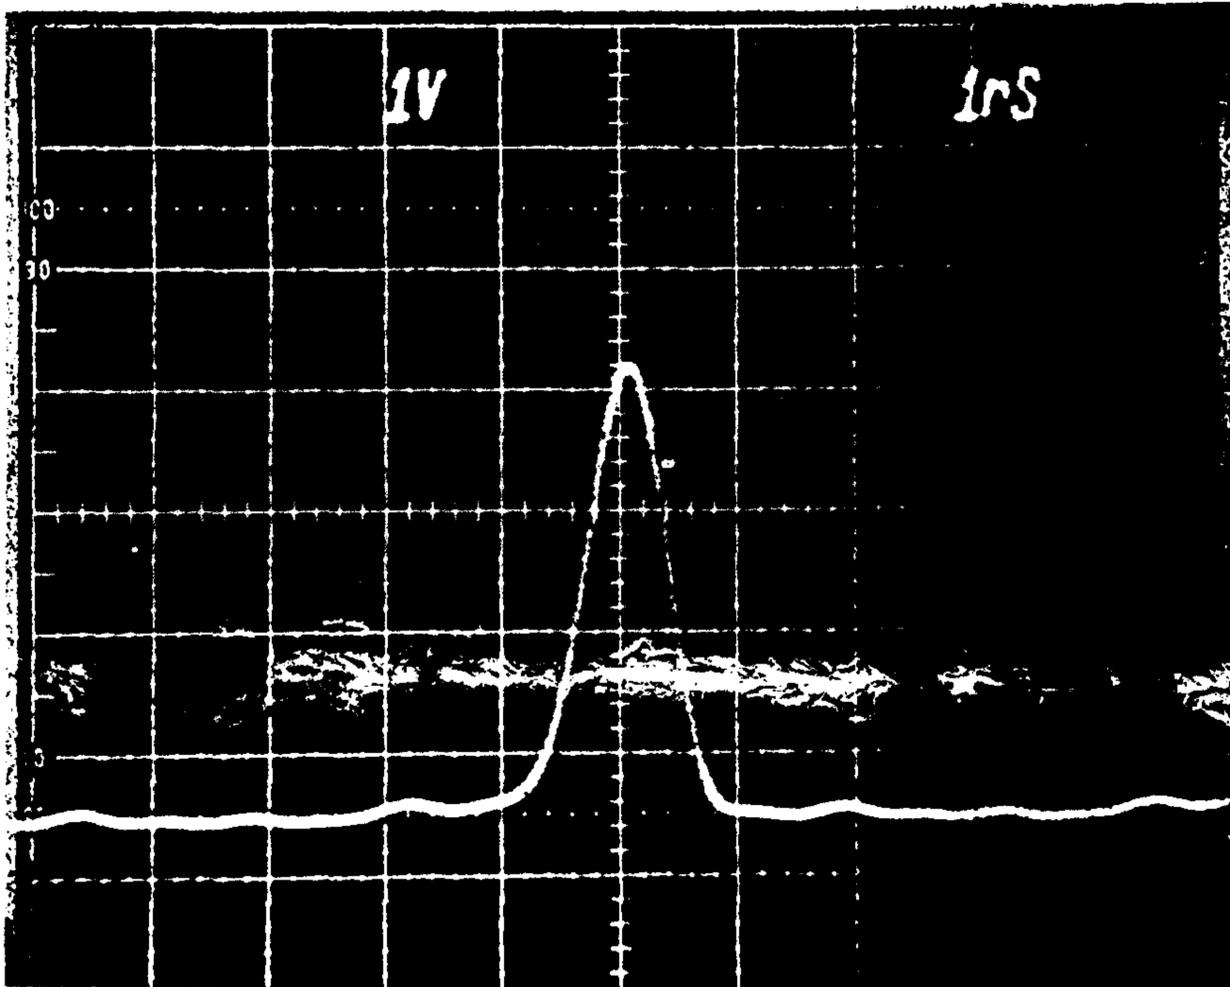


그림 30. Comb Generator에서 생성된 전기 펄스

그림 30은 LD를 구동시키기 위하여 Comb Generator에서 생성시킨 FWHM 800 ps, pulse 주기 100 MHz인 전기 pulse를 보여주고있다.

Comb Generator로 만들어진 이 pulse로 LD를 구동시키는데, short optical pulse를 얻기 위해 DC pre-bias 65 mA를 가하여 고속변조가 가능하게 하였다.

이 pulse로 구동할 때 LD가 잘 따라가고 있는지를 보기위해 LD에서 나온 pulse의 형태를 측정해 보았다.

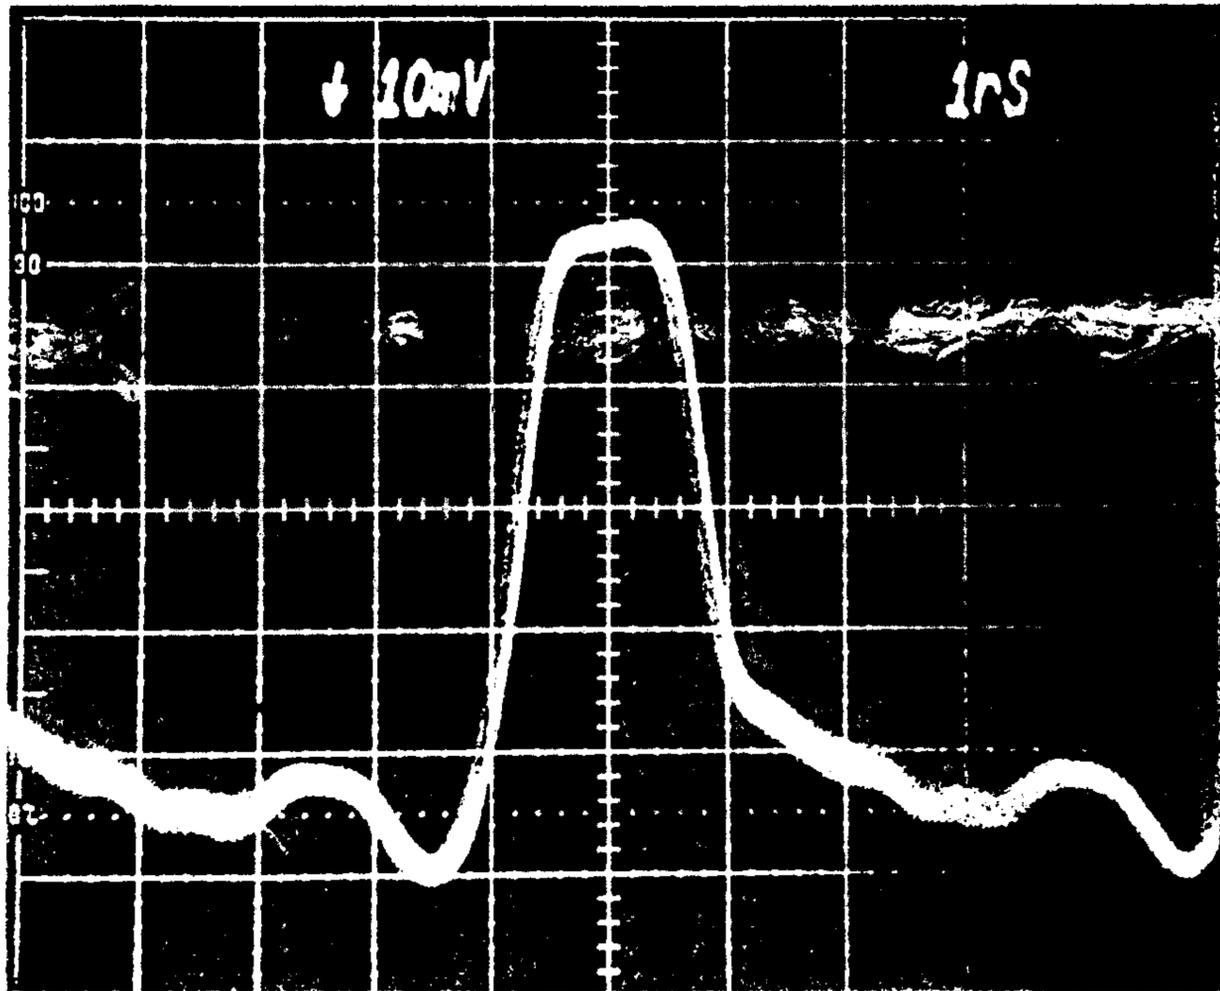


그림 31. 전기 펄스에 대한 광 펄스 응답특성

그림 31은 Comb Generator로 생성시킨 전기 펄스로 LD를 구동시킨 후 LD로부터 얻어진 광 펄스를 3 GHz 이상의 응답 대역폭을 가지는 광 수신기(HP lightwave component analyser에 부착된 것)로 측정된 것이다.

그림에서 광 펄스의 peak의 상단 부분이 잘려져있는데 이것은 광 수신기가 소 신호 응답 특성 측정용이므로 dynamic range를 제한시켜 놓았기 때문인 것으로 생각된다. 그림에서 광 수신기의 dynamic range가 제한되지 않았다고 가정하면, optical pulse의 FWHM은 약 1ns로 평가되므로 제작된 광원은 구동하는 전기 펄스를 충분히 따라가고 있음을 알 수 있다. 또한 이 펄스의 rise time 과 fall time 이 거의 1 nS이므로 약 300 MHz 미만의 구동 속도를 가진 소자를 평가하는데 충분히 사용될 수 있음을 알수있다. 그러나 STR-B와 STR-C 모두 250 MHz 이상의 cutt-off frequency를 가지므로 모두 충분히 따라갈 것으로 기대된다.

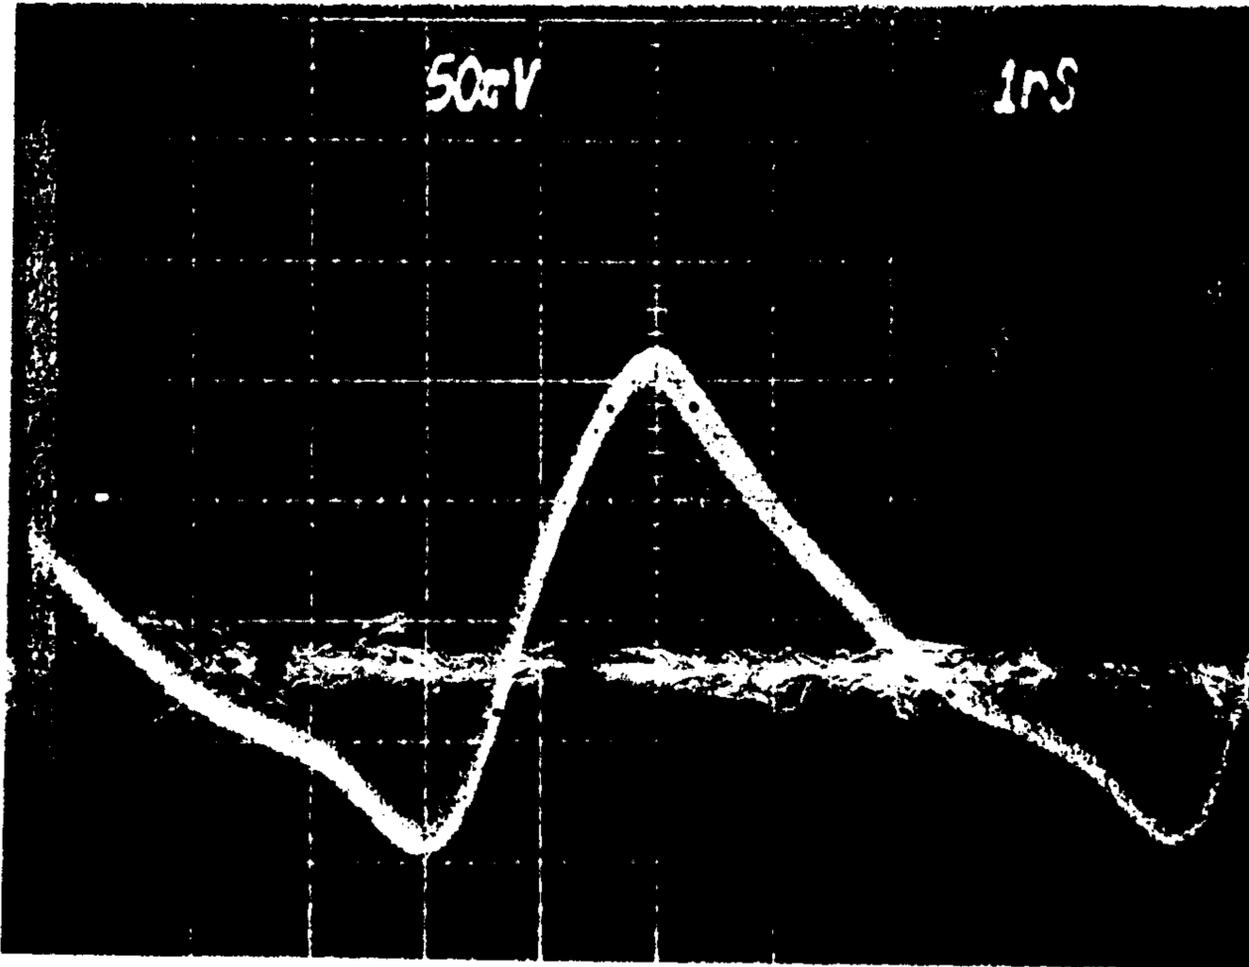


그림 32. STR-B의 대 신호 응답 특성

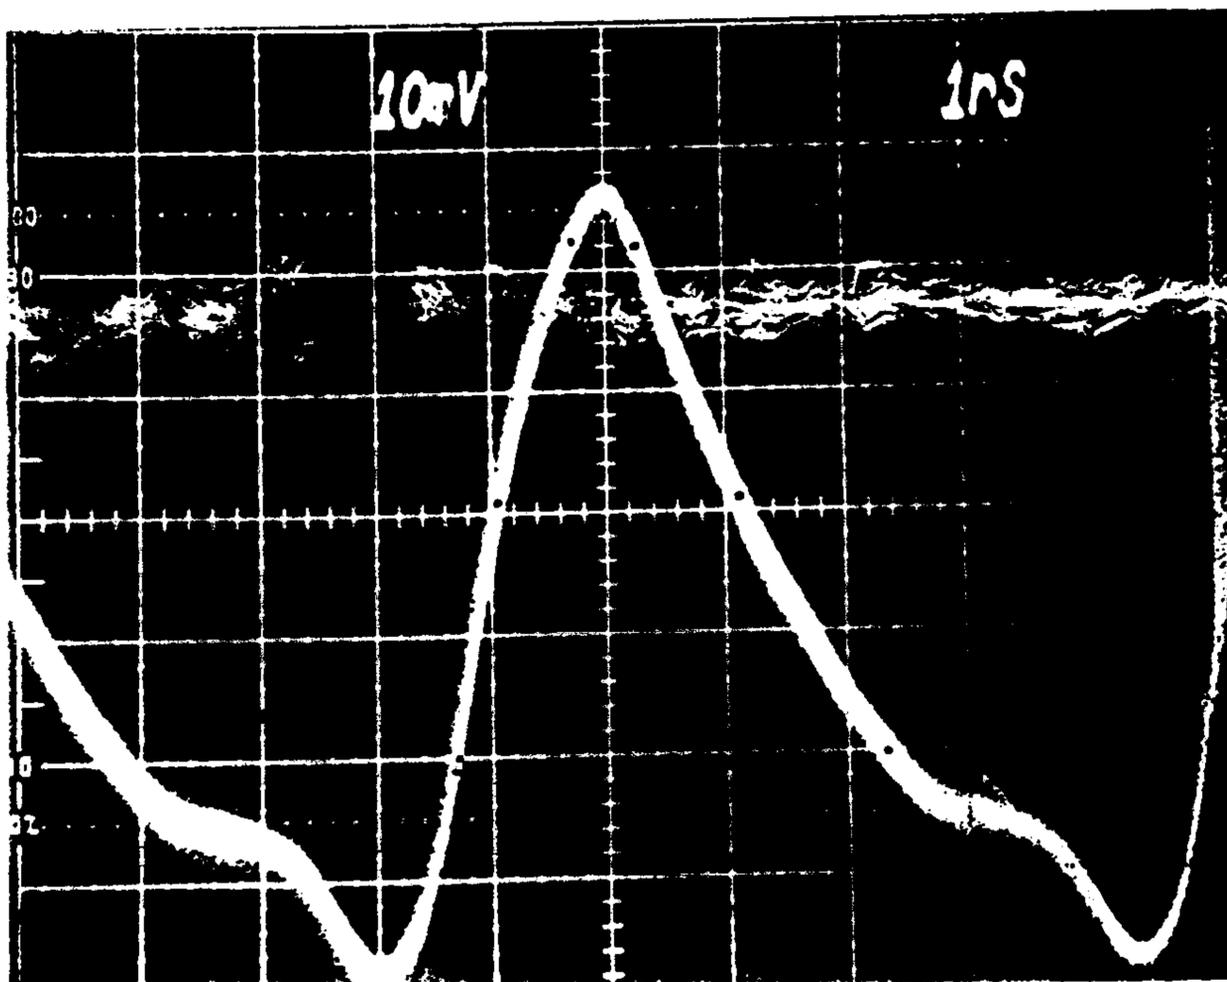


그림 33. STR-C의 대 신호 응답 특성

그림 32는 STR-B에 대한 광 펄스의 응답특성을 보이고 있다. 여기서도 STR-A는 입사 광 펄스에 대하여 응답을 하지 않음으로써 결과를 얻을 수 없었다.

그림 32에서 펄스의 rise time(10%→90%)은 1.6 ns, fall time(90%→10%)은 3.3 ns 및 FWHM 3 ns를 보였다.

그림 33은 STR-C에 대한 광 펄스의 응답특성을 보이고 있는데 펄스의 rise time(10%→90%)은 1.2 ns, fall time(90%→10%)은 3.6 ns 및 FWHM 3 ns를 보였다. STR-B와 STR-C의 측정 결과가 모두 동일한 시간적 pulse 응답특성을 보이고 있는데 이것은 앞에서 측정한 소 신호 응답특성에서 알 수 있듯이 고속 응답특성을 결정하는 수백 MHz - 수 GHz대역에서의 소 신호 응답특성이 동일한 slope로 roll-off하기 때문인 것으로 판단된다. 여기서 STR-B와 STR-C의 Gain Bandwidth 값의 차이는 광 펄스 응답진폭에 영향을 미쳐 STR-B가 STR-C에 대해 약 3배의 진폭을 갖는 것으로 나타났다.

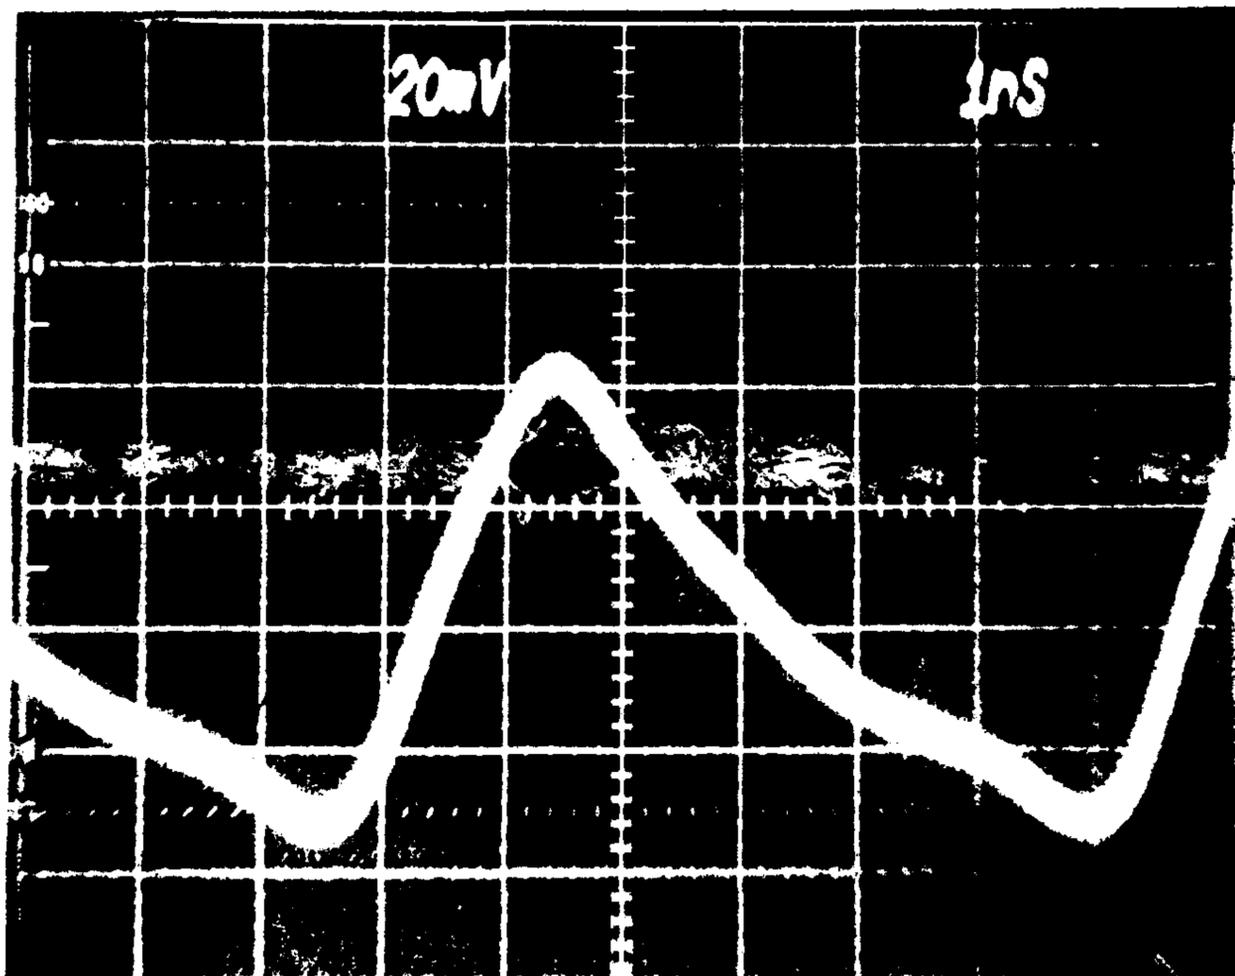


그림 34. STR-B 의 대 신호 응답 특성

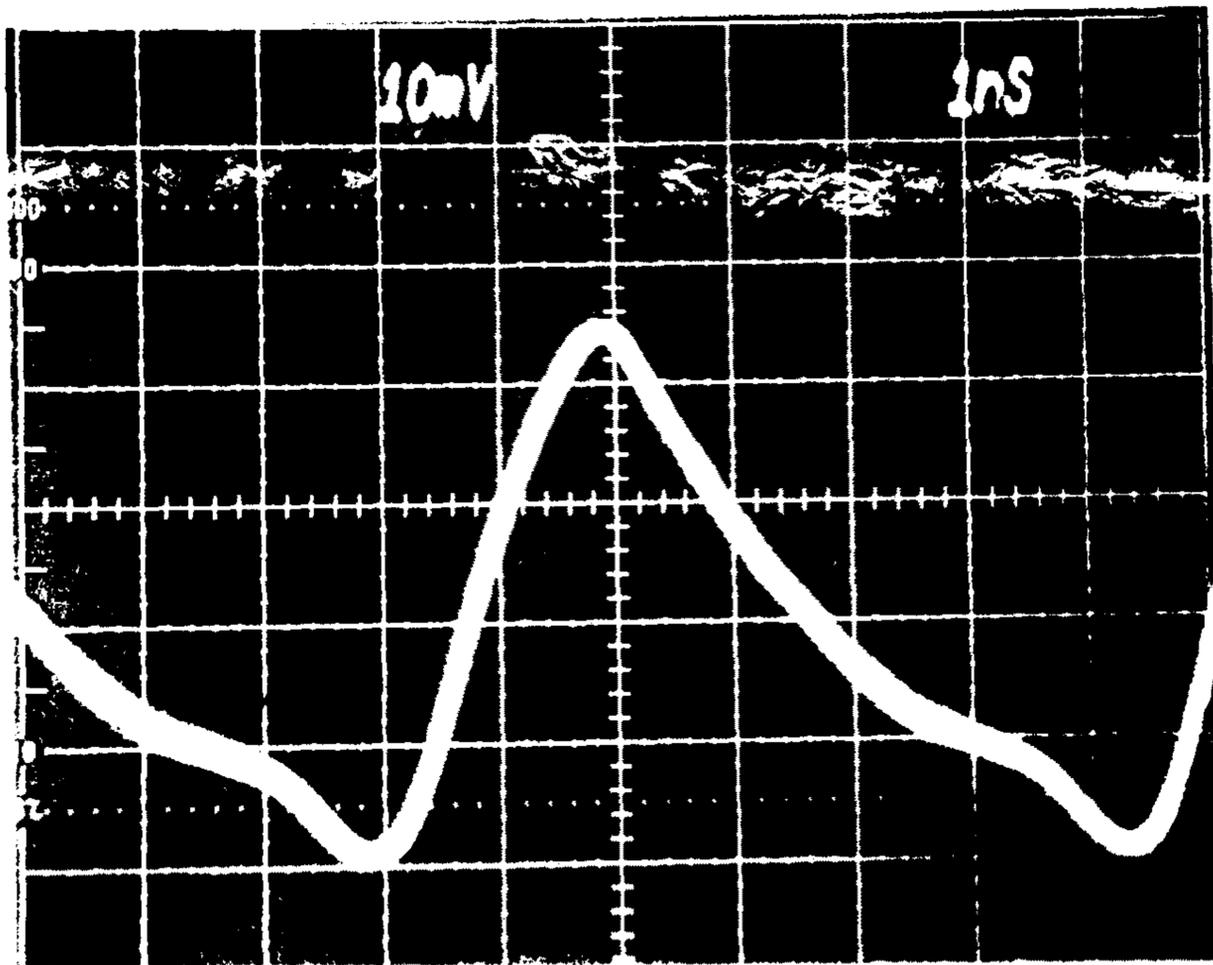


그림 35. STR-C 의 대 신호 응답 특성

그림 32와 33의 측정결과는 HPT에 5V의 bias전압을 가한 경우에 대한 것이며, bias전압을 낮추어도 HPT가 동작하는 0.5V 이상에서는 동일한 pulse 응답특성을 얻을 수 있었다. 이는 HPT의 DC 특성에서도 볼 수 있듯이 0.3 V 이상이면 saturation되기 때문이다. 그림 34와 35는 HPT에 0.5V의 bias전압을 가한 경우의 대 신호 응답특성이다.

### (3) 개선 방향

앞의 결과에서처럼 HPT는 VCSEL에 비해 상대적으로 느린 동작 특성을 보이고 있으므로, VCSEL과 HPT를 이용한 논리소자의 동작속도는 HPT에 의해 제한된다.

따라서 현재 HPT의 gain 증가와 동작속도 개선을 위한 많은 노력이 진행되고 있는데 그 예로 emitter와 base 사이의 capacitance를 줄이는 방법이나 base에 contact을 연결하는 방법 등을 들 수 있다.

#### 1. capacitance 감소

capacitance는 HPT의 주위를 etching하여 접합면적을 줄이거나 doping level을 달리함으로써 줄일 수 있다. 실제로 STR-B와 STR-C는 작은 접합면적(약  $1256 \mu\text{m}^2$ )을 가지고 있어서 capacitance를 줄이는 데에는 효과적이다.

그러나 이 작은 면적으로 인해 큰 비중을 차지하게 될 표면 재결합 center의 발생 방지가 어려움으로 등장한다. STR-B와 STR-C 모두 passivation을 위해 polyimide를 사용하였는데 결과에서도 보여지듯이 표면 재결합 center의 발생 방지에는 크게 기여하지 못한 것으로 생각된다.

이는 낮은 광 강도일 때 gain의 감소에 직접적인 원인도 되므로 소자의 면적 감소에 따른 적절한 passivation이 매우 중요하다.

#### 2. Base Contact

그림 32와 33에서 보는 바와 같이 Response의 falling time이 rising time보다 상당히 큼을 볼 수 있는데, 이는 입력 신호가 끝난 후에도 base에 아직 살아남아 있는 잉여 전공들에 의해 emitter-base 장벽이 낮추어져 있기 때문이다. 따라서 전공들이 재결합되어 사라지기 전까지는 이러한 잉여 잡음이 계속된다. 이에 반해 HBT는 입력 신호가 끝난후 전공들이 base contact을 통해 외부로 빠져나가기 때문에 HPT처럼 긴 falling time는 가지지 않는다.

base 두께를 줄이고, capacitance를 줄여서 rising time를 줄여주는 것도 중요하지만, 빠른 신호 처리의 문제에 대해서는 한 신호가 입력되고 끝이어서 얼마나 빨리 다음 신호가 입력될 수 있는가가 중요하므로 falling time을 줄이는 것이 고속 동작 소자의 설계에서는 중요하다. 따라서 고속 동작을 위한 형태로 HBT처럼 base에 contact을 만드는 것도 좋은 방법이다.

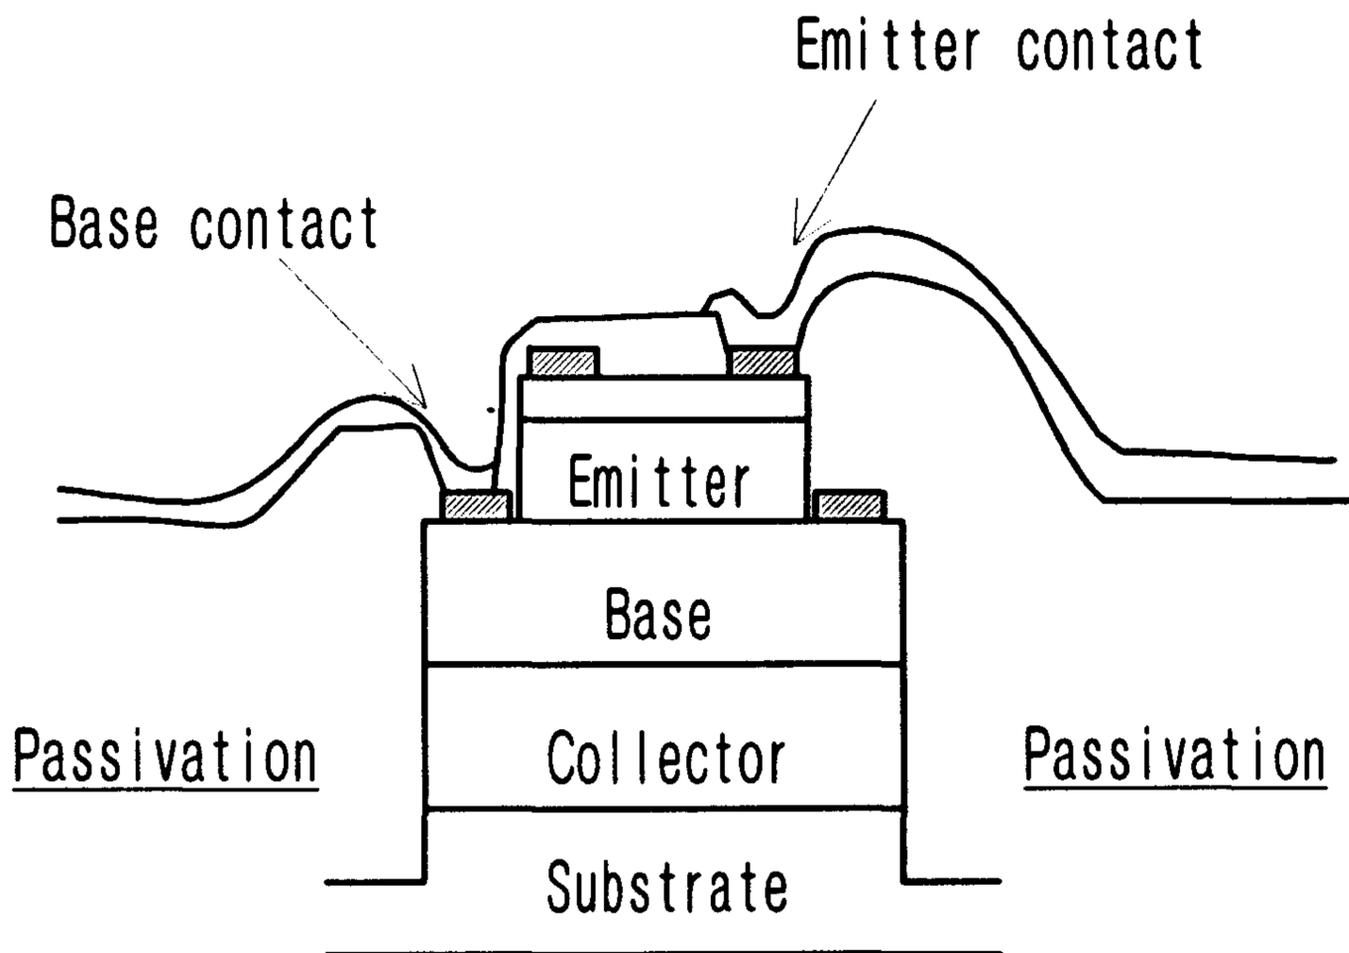


그림 36. Base contact이 있는 HPT

## - REFERENCES -

1. J.C.Campbell, "Semiconductors and Semimetals," vol. 22, part D, Chap. 5, Academic Press, (1985)
2. J.C.Campbell, "InP/InGaAs Heterojunction Phototransistors," IEEE J. Quantum Electronics, vol. QE-17, pp. 264-269 (1981)
3. 이 용희, "표면광 마이크로레이저 및 능동형 광학연산소자의 특성," 한국 광학회, vol. 2, pp. 233 (1991)
4. Y.H.Lee, J.I.Song, M.S.Kim, C.S.Shim, B.Tell, and R.E.Leibenguth, "Active Optical NOR Logic Devices Using Surface-Emitting Lasers," IEEE Photonics Technology Letters, vol. 4, pp.479-482
5. H.Kroemer, "Heterostructure Bipolar Transistors and Integrated Circuits," Proc. IRE, vol. 70, pp. 13-25 (1982)
6. H.Kroemer, "Theory of a wide-gap emitter for transistors," Proc. IRE, vol. 45, pp. 1535-1537 (1957)
7. H.Kroemer, "Heterostructure Bipolar Transistors : What should we build?" J. Vac. Sci. Technol. B, vol. 1, pp. 126-130 (1983)
8. H.H.Lin, S.C.Lee, "Super-gain AlGaAs/GaAs Heterojunction Bipolar Transistors Using an Emitter Edge-thinning Design," Appl. Phys. Lett. vol. 47, pp.839-841 (1985)
9. Y.Zho, Y.Komatsu, S.Noda, Y.Takeda, "Fabrication and Characteristics of  $\text{Al}_x\text{Ga}_{1-x}\text{As}$  Heterojunction Phototransistors with Wide-gap Window," IEEE Trans. Electron Devices, vol. 38, pp. 1310-1315 (1991)
10. J.K.Twynam, P.A.Claxton, R.C.Woods, "High-gain GaInP/GaAs Heterojunction Phototransistors Utilising Guard-ring Structure," Electronics Letters vol. 25, pp. 85-86 (1989)
11. A.G.Milnes and D.L.Feucht, "Heterojunctions and Metal Semiconductor Junctions," Academic Press (1972)
12. B.L.Sharma and R.K.Purohit, "Semiconductor Heterojunctions," Pergamon Press

## 제 5 장      결 론

본연구에서 개발된 SOFFA 모델은, 문자 인식에서 가장 많이 쓰이는 신경회로망 모델인 Neocognitron의 국부특징(local feature) 추출과 다층 구조 인식자(multi-layer perceptron)의 강한 인식력을 접합시킨 것으로, 양 모델의 장점을 보유한다. 특히, 독창적인 Fuzzy 축약 변환은 정보의 양을 줄여 고속 계산이 가능하게 함과 동시에, 이동및 크기에 둔감한 특성을 준다.

본과제에서는 SOFFA 신경회로망 모델의 전기 광학적 구현 시스템의 설계가 이루어 졌으며, 다층 인식자의 광학적 구현을 수행하였다. 또한 소형 광 신경회로망 구현을 위한 전기 광학 소자의 특성이 연구되었다.