

# 신경 회로망 구현에서의 광연결

이 렵

(서울대 공대 전기공학과 조교수)

## 1. 서 론

신경회로망은 기존의 컴퓨터의 조직이 수행하기 어려운 과제를 용이하게 처리할 수 있는 능력때문에 최근 많은 분야에서 연구되고 있다. 신경회로망은 많은 수의 뉴론과 고밀도의 연결(interconnection)로 이루어져 있다. 특히 뉴론은 매우 간단한 신호처리만을 하기 때문에 뉴론 자체만으로는 복잡한 문제를 해결할 수 없다. 그러나 많은수의 뉴론이 많은수의 연결에 의하여 이루어진 신경 회로망은 collective interaction에 의하여 기존의 컴퓨터 algorithm이 풀 수 없는 문제를 처리할 수 있다[1]. 이러한 기본적인 개념하에서 많은 종류의 신경 회로망 모델이 고안되어 컴퓨터 과학, 엔지니어링, 물리학, 생물학등 거의 모든 분야에서 사용되고 있고 특히 인간이 기존의 컴퓨터 보다 나은 분야의 문제를 해결하는데 집중적으로 이용되고 있다.

현재 연구되고 있는 신경회로망은 주로 어떤 특수한 문제(special purpose)만을 용이하게 해결할 수 있는 상황에 이용되고 있다. 예를 들면 형상인식 문제가 이 범주에 속하는 중요한 예이다. 형상인식은 보통 수백만의 pixel에 담겨진 정보를 처리하여야 하는데 이것을 보통 컴퓨터로 처리하려면 너무 많은 시간이 필요하기 때문에 매우 어렵다. 예를 들면 위에 언급한 수백만 pixel을 가장 간단한 변환인 선형 변환에 의하여 처리한다고 가정하여도 수백만의 차원을 가진 항렬이 필요하다. 즉 수백억개의 항렬원

소를 다루어야 하는데 이러한 intensive computing이 기존의 컴퓨터로는 어렵기 때문이다. 그러나 신경회로망은 2차원의 형상을 2차원의 광파(optical wave)에 변조시키고(즉 수백만의 pixel이 수백만의 뉴론에 대응하게 됨) 또 항렬은 광연결을 이용함으로써(즉 수백억의 광연결이 필요하다) 모든 처리를 병렬로 하기 때문에 기존의 컴퓨터가 가질 수 없는 신호처리 능력을 발휘하게 된다.

위에서 언급한 바와 같이 고용량의 신경회로망을 구현하기 위해서는 수백만개의 뉴론과 그에 대응하는 수백억의 연결이 필요하다. 이러한 신경회로망을 구현하는 데에는 현재 두가지 방법이 사용되고 있다. 첫째는 전자회로를 이용한 구현으로서 현재 급격히 발전되어온 VLSI 방법을 쓰고 있다. 이 방법의 장점은 기존의 잘 발달된 VLSI 방법을 사용하여 많은 수의 뉴론과 그에 필요한 processing unit을 쉽게 구현할 수 있는 것이다. 그러나 신경회로망의 다른 중요한 요소인 연결은 뉴론의 개수가 많아짐에 따라 고밀도의 microstrip을 이용한 연결이 필요하게 되어 어려워진다. 그러므로 VLSI를 이용한 신경회로망 구현은 저용량의 신경회로망을 구현하는데 사용하거나 또는 많은 수의 뉴론만을 구현하는데 주로 사용된다. 둘째 방법으로는 광파를 이용하는 구현으로써 본 논문의 주된 내용이다. 위에서 언급한 바와 같이 신경회로망의 하나의 장점은 모든 계산을 병렬로 처리하는데 있다[2]. 광파를 사용하는 시스템은 근본적으로 병렬적이기 때문에 특히 신경회로망의

구현에 적합하다. 특히 많은 수의 연결을 광파로 구현하면 연결간의 상호작용을 극소화시킬 수 있기 때문에(왜냐하면 두개의 빛이 만나도 서로 작용하지 않음)고밀도의 연결이 가능하여 VLSI를 이용한 구현으로는 불가능한 고용량의 신경회로망을 구현할 수 있다.

신경회로망에서 사용되는 광연결에는 두가지의 방법이 많이 이용되고 있다. 첫째는 spatial light modulator를 이용하여 matrix-vector 계산을 하는 것이고 둘째는 체적 홀로그래를 이용하여 광 연결을 체적 홀로그래에 저장하고 또 선택적으로 변환시키는 방법이다. 이 논문에서는 2장에서 신경회로망의 두가지 주요모델인 associative memory와 학습신경회로망을 소개하고 특히 연결이 그의 중요한 요소임을 설명한다. 3장에서는 광 연결에 대한 구현으로서 spatial light modulator를 이용하는 방법과 체적 홀로그래를 사용하는 방법에 대해 구체적으로 기술한다. 4장에서는 결론으로서 광 연결을 이용한 신경회로망의 구현에 어떠한 문제가 있으며 앞으로 해결해야 할 점을 생각한다.

## 2. 신경회로망 개관

신경회로망은 연결 weight가 고정된 시스템과 연결 weight가 변하는 시스템으로 크게 구분할 수 있다. 전자의 한 예로는 associative memory로서 기억시키고 싶은 정보를 연결 weight에 저장한 다음 원하는 정보를 얻기 위해서는 입력과 연결 weight를 이용해 계산을 하는데 이때 연결 weight는 변하지 않는다. 후자의 한 예로는 학습 신경회로망이 있다. 이 시스템은 학습시키려는 정보를 연결 weight에 저장하는데 이때 연결 weight가 계속 변하여 원하는 학습이 이루어지게 된다.

### 2.1 Associative memory

기억시키고자 하는 정보가 N-bit의 binary 양을 표시된다고 하자, 즉  $V_i = -1$  or  $1$  (or  $0.1$ )  $i=1, 2, \dots, N$ . 다음 기억시키고자 하는 정보가 m개 있다고 가정하자. 그러면 이에 대응하는 신경회로망은 N개의 뉴론으로 구성되고 각 뉴론이 가질 수 있는 값은




그림 1. 입력 벡터  $U_i$ 가 광연결  $T_{ij}$ 에 의하여 출력 벡터  $W_i$ 가 된다. 다음 thresholding을 거쳐 출력 벡터  $U_1$ 가 된다. 이 벡터가 다시 입력으로 들어와 feedback 되는 과정

-1 or 1(또는 0.1)이 된다. 이때 연결 weight는 다음과 같은 항렬로 주어지게 된다.

$$T_{ij} = \sum_{k=1}^m V_i^{(k)} V_j^{(k)} \quad (1)$$

위에 저장된 정보를 뽑아내기 위해서 다음과 같은 적당한 입력 벡터  $U_i(0)$ 가 주어졌을 때 첫째 항렬 X 벡터를 계산하고,

$$W_i = \sum_j T_{ij} U_j(0) \quad (2)$$

다음  $W_i$ 가 양수이면 1, 음수이면 -1로 치환하여 (Thresholding) 새로운  $U_1(1)$ 을 구한다. 다음 새로운  $U_1(1)$ 을 입력 벡터로 하여 위의 과정을 계속 반복한다. 이때 수렴하는  $U_1(\infty)$ 가 존재하면 이것이 우리가 원하는  $T_{ij}$ 에 저장된 정보가 된다. 지금까지 설명한 방법이 그림1에 있다. 그림1에서 보인 바와 같이 Associative memory를 구현하기 위해서는  $N \times N$ 항렬  $T_{ij}$ 를 광 연결로 이루어야 한다. 예를들어  $N$ 이  $10^5$ 이면 총 광연결의 갯수는  $10^{10}$ 에 달한다.

식(1)에 의해 결정되는 신경회로망은 선형 associative memory라고 하는데 이것의 단점은 기억시킬 수 있는 memory의 수  $m$ 이 작다는 것이다. 이 문제를 풀기 위하여 최근 quadratic associative memory가 고안되어 연구 중이다[3]. 이 신경회로망은 linear associative memory와 비슷하나 연결 항렬이(1)에 의하여 주어지지 않고 다음과 같이 주어지

며,

$$Q_{ijk} = \sum_{l=1}^m V_i^{(l)} V_j^{(l)} V_k^{(l)} \quad (3)$$

$W_i$ 는

$$W_i = \sum_j \sum_k Q_{ijk} U_j U_k \quad (4)$$

로 주어진다. 식(3)을 보면 총연결 갯수는  $N^3$ 으로 주어져 linear associative memory에서의  $N^2$ 보다 훨씬 크다. 그러므로 quadratic associative memory를 구현하는데 있어서 연결이 더욱 어려워진다.

## 2.2 학습 신경회로망

학습에 쓰이는 신경회로망은 충분한 양의 학습정보를 신경회로망에 투입함으로써 학습이 끝나면 신경회로망이 어떤 클래스에 대하여 원하는 반응을 보이게 훈련된다. 이 과정에서 학습자료들이 연결 weight를 계속적으로 바꾸어 원하는 반응을 보이게 신경회로망이 변하게 만든다. 이런 형태의 신경회로망으로는 두 가지가 있는데 첫째는 (a)에서 설명한  $T_{ij}$ ,  $Q_{ijk}$ 로 주어지는 연결을 학습자료가 첨가되면 식(1)과 (3)에 따라 변화시킨다[4]. 즉 연결 weight가

$$T_{ij} = \sum_{m=1}^M x_i^{(m)} y_j^{(m)} \quad (5)$$

로 주어진다. 여기서  $x_i^{(m)}$ 은 학습 입력이고  $y_j^{(m)}$ 은 학습 입력이고  $y_j^{(m)}$ 은 그에 대응하는 원하는 반응이다. 둘째는 error를 줄이는 방법에 의한 학습 신경회로망이다. 이 회로망은 어떤 출력  $y_i^{(k)}$ 을 원하는 반응  $y_i^{(m)}$ 과 비교하여 그 차이를 측정하여 이 error를 줄이는 방향으로 연결 weight를 변화시킨다. 즉

$$\Delta T_{ij}(k) = f_{ij}[X_r^{(m)}, T_{pq}^{(k)}, y_s^{(m)}] \quad (6)$$

이 된다. 이러한 학습 신경회로망을 구현하기 위해서는 많은 수의 연결이 필요한 것은 물론 각각의 연결 weight를 변화시킬 수 있는 방법이 필요하게 된다. 이 경우에는 VLSI를 이용하는 연결은 광 연결이 필수적이다.

## 3. 광 연결

2장에서 살펴본 바와 같이 고용량의 신경회로망을 구현하기 위해서는 고밀도의 연결이 필요할 뿐 아니라 각 연결의 weight를 조절할 수 있는 방법이 필수

적이다. 이 장에서는 연결 weight를 구현하는 방법으로서 spatial light modulator를 이용하는 기술과 체적 홀로그래프를 사용하는 기술을 설명한다.

### 3.1 Spatial light modulator 기술[5, 6]

Associative memory 형태의 신경회로망에서 중요한 계산은 연결 weight와 입력 벡터와의 곱이다. 이러한 항렬 X벡터의 계산을 광으로 달성하는 시스템이 그림 2에 있다. 이 그림에서 보는 것과 같이 입력 뉴런의 상태 벡터가 빛의 강도에 의하여 주어지고 이 빛들은 y방향으로 퍼진다. 이때 2차원의 spatial light modulator를 지나면 빛의 강도가  $T_{ij}U_j$ 가 된다. 여기에서 항렬  $T_{ij}$ 는 2차원의 spatial light modulator의 광 투과율에 의하여 주어진다. 다음 출력 뉴런에 도달하는 빛의 강도는 x방향으로 합한 양이 되므로  $\sum_j T_{ij}U_j$ 이 된다. 이 양들은 바로 우리가 원하는 항렬 X벡터 계산의 결과가 된다.

Spatial light modulator는 2차원의 면으로 이루어져 있다. 그러므로 2차원 평면에서 한개의 pixel에 필요한 최소 면적은  $\lambda^2$ 보다 크다. ( $\lambda$ 는 광의 파장이다) 왜냐하면 광의 파장이 정보를 실을 수 있는 최소 길이이기 때문이다. 그러므로 spatial light modulator의 크기가  $L^2$ 이면 가능한 연결의 총수는  $(L/\lambda)^2$ 으로 주어진다. 예를들면  $L$ 이 1cm이고  $\lambda$ 가 1  $\mu\text{m}$ 이면  $10^8$ 이 된다. 이 숫자는 최대의 연결 갯수이

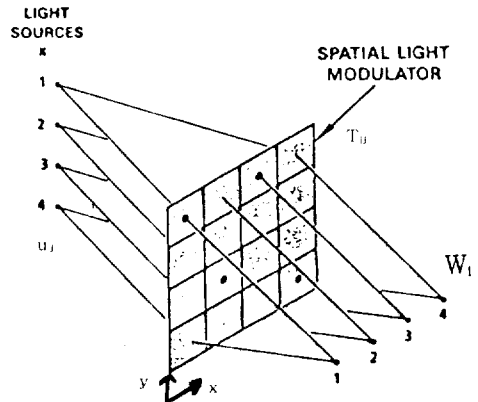


그림 2. 항렬  $T_{ij}$ 와 벡터  $U_j$ 의 항렬 X벡터 계산을 spatial light modulator를 이용하여 구하는 방법

고 실제로는 최소 pixel사이즈가  $10\mu\text{m} \times 10\mu\text{m}$ 정도 이므로  $10^6$ 정도의 연결이 가능하다. 하지만 서론에서 언급한 바와 같이 형상인식을 위한 신경회로망의 연결갯수는  $10^{12}$  정도가 필요하다. 그러므로 spatial light modulator를 사용하는 신경회로망의 구현은 저 용량의 시스템에만 사용할 수 있다.

### 3.2 체적 홀로그램 기술

위에서 논의한 spatial light modulator는 평면으로 이루어져 있기 때문에 연결 용량이 부족하다. 이러한 문제점을 해결하기 위해 3차원의 정보저장 물질을 [7] 이용하는 체적 홀로그램을 이용하는 광 연결이 고안되었다 [8]. 이 방법은 그림3에 표시되어 있다. 입력 뉴런과 출력 뉴런에 해당하는 N개의 입력 pixel과 N개의 출력 pixel이 입력 평면과 출력 평면에 배열되어 있다. 입력 구면 렌즈를 이용하여 pixel에서 나온 빛을 평면파로 바꾸어 준다. 한편 출력 구면 렌즈는 체적 홀로그램을 통과한 평면파를 집속하여 출력 pixel에 빛을 전달한다. 이때 하나의 입력 pixel i와 하나의 출력 pixel p에 대응하는 하나의 광 연결은 체적 홀로그램안에 있는 하나의 격자에 의하여 이루어진다. 이 격자는 그림3에서와 같이 p의 conjugate pixel인 p(training plane)에서 나온 빛을 i에서 나온 빛과 간섭을 일으켜 얻어진다. 다음 N개의 입력 pixel이 N개의 모든 출력 pixel과 연결되어 있다고 가정하면 우리는  $N^2$ 개의 서로 다른 격자를 체적 홀로그램에 저장해야 한다.

체적 홀로그램으로 많이 쓰이는 물질은 photorefractive 물질이다. photorefractive 효과는 그림4에 설명되어 있다. 빛의 간섭 무늬가 물질에 입사하면




그림 3. 체적 홀로그램을 이용하여 광 연결을 구현하는 방법

빛의 강도에 따라 전자가 conduction band로 여기된다. 다음 이 전자들은 drift와 diffusion에 의하여 공간에서 움직이고 어느 시간이 지난 후 다시 안정된 준위로 떨어지게 된다. 이때 공간의 전하 분포로 달라지게 되고 선형 electro-optic 효과에 의해 물질의 굴절율이 바뀌게 된다. 이러한 굴절율의 변화는 입사한 빛의 간섭 무늬에 비례하게 되어 격자를 만들어 준다 [9].

체적 홀로그램을 사용한 광 연결 기술에 있어서 생각하여야 할 점들은 다음과 같다.

- (1) 물질의 주어진 체적하에서 최대의 연결 갯수는 얼마일까?
- (2) 이때 광 연결 상호간의 간섭은 어떻게 발생하며 또 중요한 지표인 signal-to-noise ratio는 얼마인가?
- (3) 광 연결의 갯수가 많아질수록 광 연결 하나에 대한 photorefractive 효과가 감소하는데 과연 출력이 충분한가?
- (4) 광 연결을 연속적으로 변화시키는 것이 가능한가?

이제 위에서 제기된 4가지 문제에 대하여 논의한다

주어진 체적하에서 최대의 연결 갯수를 제한하는 요소는 세가지가 있다. 첫째는 입력 평면, 출력 평면, 또 체적홀로그램의 크기가 한정되어 있기 때문에 구면 렌즈에 의하여 집속되는 pixel의 크기가 유한하




그림 4. 빛의 간섭무늬 강도가 photorefractive 물질 안에서 굴절율의 변화로 나타나는 과정




그림 5. 최대 광연결 갯수를 얻기 위하여 제거해야 할 특별한 광연결의 개략

다. 둘째, 체적 홀로그래ムの Z축(그림3)방향의 크기가 한정되어 있으므로 빛과 체적 홀로그래ム이 소작용하는 길이가 한정되어 있다. 그러므로 최소한의 angular sensitivity 즉 pixel 사이의 간격이 체적의 Z방향 크기에 의존한다. 셋째, 두개의 입력 pixel과 두개의 출력 pixel이 특별한 두개의 연결에 의하여 이루어진 경우가 그림5에 있다. 두 연결은 i-p와 j-1로 표시된다. 이때 두개의 격자  $K_{ip}$ 와  $K_{ji}$ 은 동일하다고 가정한다. 그러면 이 연결은 결국 하나의 광연결로 이루어진 셈이다. 따라서 우리가 원하는 두개의 개별적인 연결인 i-p와 j-1이 불가능하다. 그러므로 이러한 특별한 경우를 모두 제외하여야 한다. 위의 세가지 요소를 고려하면 최대의 연결 갯수  $N_T$ 는 체적이 정육면체일 때에 주어지고 그 갯수는,

$$N_T = (W/\lambda)^3 \quad (7)$$

에 의하여 결정된다. 여기서  $\lambda$ 는 광의 파장이고 W는 체적의 한변의 길이이다. 예를 들어  $W=1\text{cm}$ ,  $\lambda=1\mu\text{m}$ 이면 총 갯수는  $10^{12}$ 에 달한다. 이러한 갯수는 서론에서 논의한 신경회로망에 필요한 연결 갯수를 만족한다. 그러므로 고용량의 신경회로망을 구현하기 위해서는 spatial light modulator 보다는 체적 홀로그래ム을 이용하여야 한다. 다음 그림5의 경우를 제외하는 방법이 그림6에 표시되어 있다. 이 그림에서 보는 바와 같이 위의 첫째와 둘째 조건에 의하여 결정된 입력, 출력 pixel중에서 다만 그림6에서 굵은 점들로 표시된 pixel만을 사용하여야 그림 5의 경우를 제거할 수 있다.

광 연결 상호간의 간섭은 예를 들면 그림7에서 보




그림 6. 최대 광연결 갯수를 얻기 위하여 입력 pixel과 출력 pixel이 만족해야 할 분포




그림 7. 체적 홀로그래ム을 이용한 광 연결에서 SNR을 구하는데 필요한 기본 원리

는 바와 같이 pixel i에서 나온 빛이 세개의 서로 다른 광 연결과 작용하여 pixel p로 들어감으로써 발생한다. 이때 signal-to-noise ratio는

$$\text{SNR} \approx \frac{36}{N_T^{4/3} \eta^2} \quad (8)$$

로 주어진다. 여기에서  $\eta$ 는 하나의 광연결의 평균 굴절효율이다.

많은 수의 광 연결이 photorefractive 물질안에 저장되어 있을 때 광 연결 하나에 의한 출력은 photorefractive 효과를 결정하는 여기된 전자를 발생시킬 수 있는 총 불순물의 갯수에 의하여 제한된다. 즉 총 연결 갯수가  $N_T$ 이면 각 연결이 가질 수

있는 굴절 효율은

$$\eta \approx \frac{2\eta_0}{N_T} \quad (9)$$

로 주어진다. 여기서  $\eta_0$ 는 연결하면 저장할 때의 최대 굴절 효율이고 보통  $\eta_0 \leq 1$ 이다. 예를 들면  $N_T = 10^{10}$ 이면  $\eta \sim 10^{-10}$  정도이고 이것은 매우 작은 값이다. 하지만 하나의 출력 pixel  $p$ 를 생각하면 일반적으로  $p$ 가 모든 입력 pixel (즉  $10^5$ 개)와 연결되어 있으므로 실제의  $p$  pixel에 대한 굴절 효율은  $10^{-10}$ 보다 훨씬 커진다. 출력 강도  $I_0$ 와 입력 강도  $I_i$ 의 비를 구하면 coherent system에서는

$$I_0 = 2\eta_0 I_i \quad (10)$$

이고 incoherent system에서는

$$I_0 = \frac{2\eta_0}{\sqrt{N_T}} I_i \quad (11)$$

이다. 그러므로 coherent system에서는 증폭이 필요 없지만 incoherent system에서는  $\sqrt{N_T}$ 만큼의 증폭이 필요하다.

네째, 학습 회로망을 구현하기 위해서는 광 연결을 계속 변화시킬 수 있어야 한다[10, 11]. 이때 photorefractive 물질을 사용하면 하나의 광 연결을 변화시키고자 할 때 일반적으로 다른 모든 광 연결의 크기가 감소한다. 이것은 빛의 간섭에서 bias항이 있고 이 항이 모든 광 연결을 전체적으로 감소시키는 것이다. 그러므로 긴 시간 동안 연속적으로 광 연결을 변화시키면 처음에 저장한 광 연결은 점점 감소하여 문제가 발생한다. 이 점을 해결하는 것은 쉽지 않으나 지금 알려진 방법은 시간에 따라 다른 비율의 exposure 양을 정함으로써 달성할 수 있다.

#### 4. 결 론

본문에서 신경회로망의 특징을 설명하였고 그 중에서 연결을 구현하는 방법을 논의하였다. 3장에서 본바와같이 고용량의 신경회로망을 구현하기 위해서는 spatial light modulator 보다는 체적 홀로그래램을 이용한 광 연결이 필수적이다. 그러나 체적 홀로그래램을 이용한 광 연결은 아직 초보단계로 앞에서 해결해야 할 문제점들이 많다.

첫째, 광학적 질이 좋고 photorefractive 효과가 큰 물질을 개발하여야 한다.

둘째, 학습 신경회로망에 필요한 sequential exposure의 경우 체적 홀로그래램의 점진적 소멸을 해결해야 한다.

세째, 위에서 언급한 최대 연결 개수를 주는 입력, 출력 모양의 실험적 증명 및 SNR의 실험적 측정 등 체적 홀로그래램에서의 광의 전파를 자세하게 분석해야 한다[12].

네째, 다양한 광 파장에 민감한 photorefractive 물질을 개발하여야 한다.

이러한 여러가지 연구가 필요함에도 불구하고 광 연결은 앞으로 신경회로망을 구현하는데 중요한 역할을 수행할 것이다.

#### 참 고 문 헌

- [1] J.J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities", Proc. Natl. Acad. Sci. USA vol. 79, 2554, 2982.
- [2] J.W. Goodman, "Fan-in and fan-out with optical interconnections", Opt. Acta, vol. 32, 1489, 1985.
- [3] D. Psaltis, and C.H. Park, "Nonlinear discriminant function and associative memories", Neural Networks for computing, J.S. Denker, ed A.I.P., New York, NY, 370, 1986.
- [4] D. Psaltis, D. Brady, and K. Wagner, "Adaptive optical networks using photorefractive crystals", Appl. Opt. vol. 27, 1752, 1988.
- [5] A.D. McAulay, "Spatial-light-modulator interconnected computers", IEEE computer, 45, October, 1987.
- [6] J.S. Jang, S.J. Shin, and S.Y. Lee. "Adaptive two-dimensional quadratic associative memory using holographic lenslet arrays", Optical Computing, 1989 Technical Digest Series, vol. 9(OSA, Washington, D.C. 1989), 40.
- [7] P.J. van Heerden, "Theory of optical information storage in solids", Appl. Opt. vol. 2, 393, 1963.
- [8] H. Lee, X-G Gu, and D. Psaltis, "Volume holographic interconnections with maximal capacity and minimal crosstalk", J. Appl. Phys. vol. 65, 2191, 1989.
- [9] W.S. Baek, and H. Lee, "Inter-mode photorefractive space-charge fields in volume holographic interconnections", J. Appl. Phys. vol. 67, 1194, 1990.

- 
- [10] P. Yeh, A. Chiou, and J. Hong, "Optical interconnection using photorefractive dynamic holograms", *Appl. Opt.* vol. 27, 2093, 1988.
- [11] A. Marrakchi, and J.S. Patel, "Implementaion of dynamic holographic interconnects with variable weight in photorefractive crystals", *Optical Computing, 1989 Technical Digest Series*, vol. 9 (OSA, Washington, D.C. 1989), 124.
- [12] K.Y. Tu, T. Tamir, and H. Lee, "Multiple-scattering theory of wave diffraction by superposed volume gratings", *J. Opt. Soc. Am. A* vol. 7, 1421, 1990.