

모듈 방향 결정 문제 해결을 위한 정규화된 평균장 어닐링 알고리즘

(Normalized Mean Field Annealing Algorithm for Module Orientation Problem)

정 균 락 *

(Kyun Rak Chong)

요약 각 모듈들의 위치가 배치 알고리즘에 의해 결정된 후에도 모듈들을 종축 또는 횡축을 중심으로 뒤집거나 회전시킴으로써 회로의 효율성과 연결성을 향상시킬 수 있다. 고집적 회로설계의 한 단계인 모듈 방향 결정 문제는 모듈간에 연결된 선의 길이의 합이 최소가 되도록 각 모듈의 방향을 결정하는 문제이다. 최근에 평균장 어닐링 방법이 조합적 최적화 문제에 사용되어 좋은 결과를 보여 주고 있다. 평균장 어닐링은 신경회로망의 빠른 수렴 특성과 시뮬레이티드 어닐링의 우수한 해를 생성하는 특성이 결합된 방법이다.

본 논문에서는 정규화된 평균장 어닐링을 사용해서 모듈 방향 결정 문제를 해결하였고 실험을 통해 기존의 Hopfield 네트워크 방법과 시뮬레이티드 어닐링과 그 결과를 비교하였다. 시뮬레이티드 어닐링, 정규화된 평균장 어닐링과 Hopfield 네트워크의 총 길이 감소율은 각각 19.86%, 19.85%, 19.03%였으며, 정규화된 평균장 어닐링의 실행 시간은 Hopfield 네트워크보다는 1.1배, 시뮬레이티드 어닐링보다는 11.4배 정도 빨랐다.

Abstract After modules are placed according to some placement algorithm, both circuit performance and routability can be improved while keeping the module placement fixed. Module orientation problem, an important step in VLSI design, is to determine the flip status of each module so as to minimize the total wire length. Recently the mean field annealing is used to solve combinatorial optimization problems. Mean field annealing exhibits the rapid convergence of the neural network while preserving the good solution afforded by simulated annealing.

In this paper we applied the normalized mean field annealing algorithm to module orientation problem and compared the result with those of Hopfield network and simulated annealing experimentally. Simulated annealing, normalized mean field annealing and Hopfield network reduce the total wire length by 19.86%, 19.85%, and 19.03%, respectively. Mean field annealing runs 1.1 times and 11.4 times as fast as Hopfield network and simulated annealing, respectively.

1. 서 론

모듈 방향 결정 문제는 각 모듈들의 위치가 어떤 배치 알고리즘에 의해 결정된 후, 각 모듈들의 위치는 변화시키지 않고, 모듈들을 뒤집어서(flipping) 회로의 효율성(performance)과 연결성(routability)을 향상시키는 방법으로 최근에 연구되기 시작하였다. 속도가 빨라야

하는 고성능 회로에서는 가장 긴 선(wire)의 길이가 최소가 되도록 각 모듈들의 방향을 결정하는 것이 바람직하고, 그렇지 않은 경우에는 전체 선의 길이의 합을 최소화하는 것이 바람직하다.


모듈 방향 결정 문제의 한 예가 그림 1에 나타나 있다. 그림 1 (a)는 주어진 모듈들의 처음 상태를 나타내고, (b)는 전체 선의 길이의 합이 최소가 되도록 각 모듈들의 방향이 결정된 후의 상태로 모듈 1, 2, 3, 6을 종축과 횡축에 대하여 뒤집고, 모듈 4, 5를 종축에 대하여 뒤집은 결과이다.

* 종신회원 : 홍익대학교 컴퓨터공학과 교수
chong@cs.hongik.ac.kr

논문접수 : 2000년 8월 1일

심사완료 : 2000년 11월 8일

이렇게 전체 선의 길이의 합이 감소하면, 다음 라우팅 단계에서의 결과도 좋아지고 또 필요한 면적도 줄어들게 된다.



(a) 방향 변환 전 (b) 방향 변환 후
그림 1 모듈 방향 문제에 예

전체 선의 길이의 합이 최소가 되도록 모듈의 방향을 결정하는 문제는 Yamada, Libeskind-Hadas, Chong 등이 연구한 바 있다. Yamada와 Liu는 이 문제를 해결하기 위해 여러 가지 분석적 방법과 시뮬레이티드 어닐링(simulated annealing)방법으로 실험하였으며, 실험 결과에 의하면 시뮬레이티드 어닐링 방법이 가장 좋은 결과를 나타냈다 [1]. Libeskind-Hadas와 Liu는 이 문제가 NP-hard임을 보였고, 신경 회로망을 이용한 휴리스틱(heuristic)을 개발하여 시뮬레이티드 어닐링 방법과 비교하였다 [2]. W. Do는 [8]에서 Libeskind-Hadas와 Liu가 사용한 에너지 함수보다 개선된 에너지 함수를 사용해서 그 결과를 향상시켰으며, J. Kim은 [7]에서 가장 긴 선의 길이가 최소가 되도록 모듈의 방향을 결정하는 문제에 대해 고찰하였다. Kim과 Kyung은 [18]에서 맨하탄 거리를 사용하는 문제를 기본적인 평균장 어닐링 방법을 사용해서 해결하였고, Chang과 Hsiao는 유전자 알고리즘을 사용해서 모듈 방향 결정 문제를 해결하는 방법을 제시하였으며 [17], Funabiki는 개화된 신경 회로망 (evolutionary neural network)을 사용하였다 [16]. Haockanson과 Radu는 PCB에서 모듈 방향의 효과에 대해 연구하였다 [15].

평균장 어닐링은 Hopfield 네트워크의 빠른 수렴 특성과 시뮬레이티드 어닐링의 우수한 해를 생성하는 특성이 결합된 방법으로, 최근에 조합적 최적화 문제에 사용되어 좋은 결과를 보여 주고 있다. D. Van Den Bout [4]는 그래프 분할 문제를 평균장 어닐링을 이용하여 해결하였고, P. Stoloz [13]는 TSP 문제를, C. Yu와 W. Lee [14]는 채널 라우팅 문제를 같은 방법을 사용해서 해결하였다. 또 K. Sohn, J. Kim과 W. E. Alexander [20]는 시각 시스템에서 코너 찾는 문제

(corner detection)를, R. Liang과 F. Kang [19]은 열 동력 시스템에서 연료 사용 비용을 최소화 하기 위해 각 유니트의 상태를 결정하는 문제를 평균장 어닐링을 이용하여 해결하였다.

본 논문에서는 정규화된(normalized) 평균장 어닐링을 사용해서 모듈 방향 결정 문제를 해결하였고, 실험을 통해 기존의 Hopfield 네트워크 방법과 시뮬레이티드 어닐링과 그 결과를 비교하였다.

2. 평균장 어닐링 알고리즘

2.1 개념

조합적 최적화 문제에서 목적 함수 혹은 해밀토니안(Hamiltonian) $H(s)$ 는 상호 작용하는 스핀(spin)들의 벡터(vector) $s = \{s_1, \dots, s_N\}$ 의 비선형적 결합으로 표현된다. 평균장 어닐링 알고리즘은 상호작용을 하는 스핀들로 구성된 Ising 해밀토니안에 기초하는데 다음 식과 같다 [4].

$$H(s) = \sum_i h_i s_i + \sum_{i \neq j} V_{ij} s_i s_j \quad (1)$$

여기서 V_{ij} 는 스핀 i 와 스핀 j 의 상호 작용하는 힘이고 $V_{ij} = V_{ji}$ 로 가정한다. 또 s_i 는 스핀 i 가 가지는 값으로 0과 1 사이의 값을 갖는다. 평균장 어닐링에서는 (1)의 평균값인 (2) 식을 이용한다 [5].

$$\begin{aligned} \langle H(s) \rangle &= \left\langle \sum_{i=1}^N \sum_{j \neq i} V_{ij} s_i s_j + \sum_{i=1}^N h_i s_i \right\rangle \\ &= \sum_{i=1}^N \sum_{j \neq i} V_{ij} \langle s_i s_j \rangle + \sum_{i=1}^N h_i \langle s_i \rangle \end{aligned} \quad (2)$$

H_0 는 $\langle H(s) \rangle |_{s_i=0}$, H_1 은 $\langle H(s) \rangle |_{s_i=1}$ 로 정의하면 볼츠만 분포 (Boltzmann distribution)에 의해 $\langle s_i \rangle$ 의 평형값(equilibrium value)은

$$\begin{aligned} \langle s_i \rangle &= \text{Pr}[s_i=0] \times 0 + \text{Pr}[s_i=1] \times 1 \\ &= \frac{\exp(-H_1/T)}{\exp(-H_0/T) + \exp(-H_1/T)} \\ &= \frac{1}{1 + \exp(-(H_0 - H_1)/T)} \end{aligned} \quad (3)$$

과 같이 계산되어질 수 있다. 이 때 $H_0 - H_1$ 을 계산하기 위해서는 $O(2^N)$ 의 시간이 소요된다. 그러나 상호 작용을 하는 스핀의 개수가 굉장히 많아서 어떤 한 스핀의 다른 스핀들에 대한 영향력이 전체적으로 보아 무시될 수 있을 만큼 작다면 (2)식은 다음과 같이 평균장 근사식을 사용할 수 있다.

$$\langle H(s) \rangle = \sum_{i=1}^N \sum_{j \neq i} V_{ij} \langle s_i \rangle \langle s_j \rangle + \sum_{i=1}^N h_i \langle s_i \rangle \quad (4)$$

$\langle H(s) \rangle$ 를 스핀 $\langle s_i \rangle$ 에 관하여 미분한 것을 Φ_i 라 하면 다음과 같다.

$$\Phi_i = h_i + 2 \sum_{j \neq i} V_{ij} \langle s_j \rangle = H |_{\langle s_i \rangle=1} - H |_{\langle s_i \rangle=0} \quad (5)$$

식 (5)는 다른 스핀들의 평균값은 상수로 고정시켜 두는 동안 $\langle s_i \rangle$ 를 0 에서 1로 바꾸어 줌으로서 얻는 헤밀토니안의 차이값($H_0 - H_1$)인 평균장 Φ_i 를 $O(N)$ 내에 구할 수 있음을 보여주고 있다.

평형 상태는 주어진 온도에서 방정식 (3)과 (5)의 값이 각각의 스핀에 대하여 변화 없이 유지될 때 이루어진다. 따라서 평균장 어닐링은 각 스핀의 값에 변화가 없는 고정점(fixed point)에 도달하기 쉬운 높은 온도에서부터 시작하여 온도를 낮추면서 최소 온도에 도달할 때까지 스핀의 고정 상태를 찾는 방법을 반복 수행한다.

2.2 모듈 방향 결정 문제의 적용

모듈 방향 결정 문제를 평균장 어닐링을 사용해서 풀기 위해서는 우선 각 모듈들에 대해 네 개의 스핀들을 부여하고 이들을 “클러스터”라고 정한다. 다음으로 각 스핀에 튜플 (i, h, v) 로 번호를 부여하는데, i 는 모듈 번호를, $h, v \in \{0, 1\}$ 는 각각 수평축과 수직 축에 대해 뒤집혀진 모듈의 방향을 나타낸다. 따라서, 전체 모듈의 개수가 n 이라면 전체 $4n$ 개의 스핀으로 이루어지며, 각 클러스터의 스핀들 각각은 모듈의 가능한 네 가지 방향들 중 하나를 나타내게 된다. 시스템이 평형 상태에 도달하면 클러스터 당 정확하게 하나의 스핀만이 “1”의 값을 가져야 하며 나머지 세 개의 스핀들은 “0”의 값을 가지게 된다.

에너지 함수는 다음의 두 가지 특성을 가지도록 만들어져야 한다.

(1) 에너지 함수가 지역적 최소해(local minima)에 도달했을 때 각 클러스터에는 정확히 하나의 스핀만이 “1”의 값을 가지며 나머지 스핀들은 “0”의 값을 가져야 한다.

(2) 에너지 함수의 값은 그 상태 하에서의 전체 선의 길이의 합에 비례하여야 한다.

따라서 에너지 함수 E 를 살펴보면 다음과 같다. 함수

$$E_1 = \sum_{(i,h,v)} s_{(i,h,v)}(1 - s_{(i,h,v)}) + \sum_i [\sum_{(h,v)} s_{(i,h,v)} - 1]^2 \quad (6)$$

은 각 스핀의 값이 “0” 혹은 “1”일 때, 그리고 각 클러스터가 “1”인 스핀 하나와 “0”인 스핀 3개로 이루어질 최소가 된다. 함수

$$E_2 = [(\sum_{(i,h,v)} s_{(i,h,v)}) - n]^2 \quad (7)$$

는 전체 스핀 중 총 n 개의 “1”이 있을 때 최소가 된다. 따라서 식 (6) + (7) 는 각 클러스터 당 정확하게 하나의 스핀만이 “1”의 값을 가질 때 최소가 된다.

$d_{(i,h,v)(i',h',v')}$ 를 (h, v) 방향의 모듈 i 와 (h', v') 방향의 모듈 i' 사이의 총 선의 길이라고 하면 함수

$$E_3 = \sum_i \sum_{j \neq i} \sum_{(h,v)} \sum_{(h',v')} s_{(i,h,v)} s_{(j,h',v')} d_{(i,h,v)(j,h',v')} \quad (8)$$

는 모듈 사이의 총 선의 길이의 합이 최소가 될 때 최소값을 가지게 된다. 따라서 최소화시켜야 할 에너지 함수는

$$E = \alpha E_1 + \beta E_2 + \gamma E_3 \quad (9)$$

이며, α, β, γ 는 양의 실수 값을 가지는 에너지 가중값이다 [8].

(9) 식을 (4) 식의 형태로 바꾸기 위해서는 행렬 V 와 벡터 h 의 값을 결정해야 하는데, δ_{ij} 를 $i=j$ 인 경우 $\delta_{ij}=1$, $i \neq j$ 인 경우 $\delta_{ij}=0$ 이 되는 Kronecker delta라 정의하면 다음과 같이 계산된다.

$$h_{(i,h,v)} = -2n\beta - \alpha$$

$$V_{(i,h,v)(j,h',v')} = \alpha(\delta_{ij} - \delta_{ij} \delta_{hh'} \delta_{vv'}) + \beta + \gamma(1 - \delta_{ij}) d_{(i,h,v)(j,h',v')}$$

2.3 정규화된 평균장 어닐링 알고리즘

에너지 함수에서 문제의 제약조건에 대한 가중치 α, β, γ 의 값을 정확히 결정하기는 어렵다. 그러므로 정규화 개념을 도입하여 식(9)의 제약 조건 항목(constraint term)을 제거하고자 한다. 편의상 $s_{(i,h,v)}$ 를 s_{ik} 로 나타내기로 한다. 단 k 는 0, 1, 2, 3 중 하나의 값을 갖는다.

볼츠만 분포(Boltzmann distribution)에 의하면 모듈 i 의 클러스터 내 k 번째 스핀 평균은 $\langle s_{ik} \rangle \propto \exp(-H_{ik} / T)$ 로 표현할 수 있다. 여기서 H_{ik} 는 모듈 i 에 대한 클러스터내의 모든 스핀 값을 ‘0’으로 한 다음 k 번째 스핀을 ‘1’로 하여 계산되어진 헤밀토니안 값을 나타낸다.

```

T = starting temperature
for i=1 to N do
begin
for k=1 to B do
< sik > = 1/B + δ;
end;
while ( T > Tmin ) do
do until ( a fixed-point is found )
begin
select a node i at random;
for k=1 to B do

```

```

< sik > = 0;
sum = 0;
for k=1 to B do
begin
  Hik = H(< s > ) | < sid > = 1;
  sum = sum + exp(-Hik/T);
end;
for k=1 to B do
  < sik > = exp(-Hik/T) / sum;
end;
T ← aT
    
```

그림 2 정규화된 평균장 어닐링 알고리즘

클러스터 내에 반드시 하나의 1이 존재해야 한다는 제약조건은 모듈 i 에 대한 각각의 스핀 평균을

$$\langle s_{ik} \rangle = \frac{\exp(-H_{ik}/T)}{\sum_j \exp(-H_{ij}/T)} \quad (10)$$

으로 정규화(normalize) 시킴으로써 만족되어진다 (실제로는 각 클러스터 안에 있는 네 개의 스핀들의 합이 1이 된다). 그러므로 식 (9)에서 E_1 과 E_2 항목은 생략되고 에너지 함수는 $E = E_3$ 가 된다. 정규화된 평균장 알고리즘이 그림 2에 나타나 있다[4]. 여기서 B는 클러스터내의 스핀의 개수를 나타낸다.

2.4 임계 온도의 결정

평균장 어닐링 방법에서 중요한 변수의 하나는 임계 온도(critical temperature)를 추정하는 것이다. 임계 온도가 너무 높게 추정되면 수렴하는 데 시간이 오래 걸리게 되며, 너무 낮게 추정되면 수렴은 빨리 하지만 결과가 나빠지게 된다. 본 논문에서는 [4]에서 사용한 방법과 유사하게 임계 온도를 추정하였다. 먼저 다음을 가정한다.

(1) 모듈 i 의 방향이 k 를 향하여 변하면, 즉 Δs_{ik} 가 증가하면 클러스터 i 에 있는 $(B-1)$ 개의 스핀은 그 크기가 $\Delta s_{im} = -\Delta s_{ik}/(B-1)$ 만큼씩 변한다. 여기서 m 은 k 를 제외한 나머지 방향을 의미한다.

(2) 클러스터 i 에 연결된 ϵ 개의 모듈의 집합을 $\Lambda(i)$ 라 하면, $\Lambda(i)$ 에 있는 모든 모듈은 동일하게 반응한다. 스핀의 변화는 클러스터 i 와 $\Lambda(i)$ 에 있는 스핀들에서만 일어난다.

(3) 임계 온도 근처에서 스핀의 변화는 충분히 작아서 모든 스핀은 각각의 높은 온도 근처에서 평균 $1/B$ 을 유지하고 있다.

이런 가정 하에서 스핀들에 대한 유효한 평균장 변화

는 식 (10)으로부터 다음과 같이 된다.

$$\frac{\partial s_{ik}}{\partial \Phi_{ik}} = s_{ik}(s_{ik-1})/T = (1-B)B^2T$$

$$\frac{\partial s_{im}}{\partial \Phi_{ik}} = s_{ik}s_{im}/T = 1/B^2T \quad \forall m \neq k$$

식 (8)로부터 스핀 s_{ik} 에 의한 평균장 변화는

$$\Phi_{ik} = \frac{\partial H}{\partial s_{ik}} = 2 \sum_{j \neq i} \sum_l s_{jk} d_{ijkl}$$

가 되고, 다른 스핀들의 변화로 인한 이 스핀의 평균장 변화는

$$\frac{\partial \Phi_{ik}}{\partial s_{jm}} = \begin{cases} 0 & i=j \\ 2d_{ijkm} = 2d & i \neq j \end{cases}$$

가 된다. 여기서 d 는 모든 모듈간의 선의 길이의 평균이다. 만약 클러스터 i 가 Δs_{ik} 만큼 변하면, $\Lambda(i)$ 에 있는 각 클러스터 j 의 스핀들의 평균장 변화는

$$\Delta \Phi_{jk} = \frac{\partial \Phi_{jk}}{\partial s_{ik}} \Delta s_{ik} = 2d \Delta s_{ik}$$

$$\Delta \Phi_{jm} = \frac{\partial \Phi_{jm}}{\partial s_{im}} \Delta s_{im} = \frac{-2d \Delta s_{ik}}{B-1}$$

가 된다. $\Lambda(i)$ 에 있는 각 클러스터 j 의 스핀들의 평균장 변화는 스핀들의 크기를 변화시키는데

$$\begin{aligned} \Delta s_{jk} &= \frac{\partial s_{jk}}{\partial \Phi_{jk}} \Delta \Phi_{jk} + \sum_{m \neq k} \frac{\partial s_{jk}}{\partial \Phi_{jm}} \Delta \Phi_{jm} \\ &= \frac{1-B}{B^2T} (2d \Delta s_{ik}) + \frac{B-1}{B^2T} \left(\frac{-2d \Delta s_{ik}}{B-1} \right) \\ &= -\frac{2d \Delta s_{ik}}{BT} \end{aligned}$$

$$\begin{aligned} \Delta s_{jm} &= \frac{\partial s_{jm}}{\partial \Phi_{jm}} \Delta \Phi_{jm} + \frac{\partial s_{jm}}{\partial \Phi_{jk}} \Delta \Phi_{jk} + \sum_{l \neq m, k} \frac{\partial s_{jm}}{\partial \Phi_{jl}} \Delta \Phi_{jl} \\ &= \frac{2d \Delta s_{ik}}{B(B-1)T} \end{aligned}$$

가 된다. 또 이 변화는 다시 클러스터 i 의 평균장을 변화시킨다.

$$\Delta \Phi_{ik} = 2d \epsilon \Delta s_{\Lambda(i)k}$$

$$\Delta \Phi_{im} = 2d \epsilon \Delta s_{\Lambda(i)m}$$

이 변화는 스핀의 크기를 변화시키게 되는데

$$\begin{aligned} \Delta s_{ik}' &= \frac{1-B}{B^2T} 2d \epsilon \left(\frac{-2d \Delta s_{ik}}{BT} - \frac{2d \Delta s_{ik}}{B(B-1)T} \right) \\ &= \frac{1-B}{B^2T} 2d \epsilon \frac{-2d \Delta s_{ik}}{BT} \left(\frac{-B}{B-1} \right) \\ &= \frac{2^2 d^2 \epsilon^2}{B^2 T^2} \Delta s_{ik} \end{aligned}$$

가 된다. 임계 온도에서는 스핀의 변화가 존속되어야 하므로

$$\Delta s_{ik} = \frac{1}{B^2 T^2} 2^2 d^2 \varepsilon \Delta s_{ik}$$

가 되고 따라서

$$T = \frac{2d}{B} \sqrt{\varepsilon} = \frac{1}{2} d \sqrt{\varepsilon}$$

가 된다. 여기서 ε 는 각 모듈들에 연결된 선의 평균 개수라 하면 $T = \frac{1}{2} d \sqrt{2E/N}$ 가 된다 여기서 N 은 모듈의 개수이고 E 는 선의 개수이다. 표 1에 본 논문에서 표 1 초기 온도에 따른 결과

초기온도	선의 길이의 합	실행시간
5 * T _c	759052	3768
2 * T _c	759052	2994
1 * T _c	759052	2316
0.5 * T _c	759052	1999
0.25 * T _c	759082	1682

추정된 임계 온도를 사용해서 초기 온도를 결정하였을 때의 실행 시간과 선의 길이의 합이 나타나 있다. 초기 온도가 0.5 * T_c 일 때 선의 길이의 합이 제일 적으면서 실행시간이 작게 걸리는 것으로 나타나 있고, 초기 온도가 그 보다 높을 때는 시간이 낭비되고 그 보다 낮을 때는 결과가 나빠지는 것으로 나타나 있다.

2.5 실험 변수들의 선택

스핀의 평균값 $\langle s_i \rangle$ 의 초기 값을 어떻게 정하느냐에 따라 평형 상태로의 수렴 속도와 해가 달라질 수 있다. 본 논문에서는 클러스터 내의 각 스핀들에게 균등한 상태 가중값을 주기 위하여 1/4의 값에 noise를 더해 주는 다음의 방식을 택하였다.

$$\langle s_i \rangle = 0.25 + \delta \times (\text{RAND} - 0.5)$$

이 때 RAND에 의해 발생하는 난수는 0과 1사이에서 균일하게 분포한다. δ 은 1보다 작은 수를 사용하게 되는데 본 논문에서는 10^{-2} 의 값을 사용하였다.

어닐링 스케줄은 초기 온도가 $T = T_0$ 에서 시작해서 각 단계마다 온도를 $T = \alpha T$ 로 낮추면서 $T < T_{min}$ 에 도달할 때까지 반복한다.

여기서 T_0 는 초기 온도, T_{min} 은 어닐링 단계에서의 마지막 온도, α 는 1보다 작은 상수로 0.75, 0.8, 0.85, 0.9 등을 사용하여 실험하였다. T_{min} 은 $T_0/12$ 로 실험적으로

정하였다.

실험을 통하여 수렴의 성격을 관찰해 보면 0.2 이하로 수렴된 스핀이 0.5 이상으로 변하거나, 0.5 이상으로 수렴된 스핀이 0.2 이하로 변하는 경우는 발견되지 않았으므로 수렴 조건은 스핀들이 0.2 이하, 0.5 이상의 값을 갖는 경우로 정해 주었다.

3. Hopfield 네트워크

Hopfield 네트워크에 대한 설명은 [3][6][9][10] 등에 자세히 기술되어 있으므로 여기서는 실험에 관한 부분만 간단히 언급하고자 한다. 신경회로망을 통해 최적화 문제를 풀기 위해서는 다음과 같은 형태로 에너지 함수가 표현되어야 한다.

$$E = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n T_{ij} v_i v_j - \sum_{i=1}^n I_i v_i$$

여기서 v_i 는 뉴런들의 값이고 T_{ij} 는 뉴런 i 와 뉴런 j 의 연결 강도이고 I_i 는 외부 입력 벡터이다. 에너지 함수는 2장에서 정의한 E_1 , E_2 , E_3 를 사용하였고 이 경우

$$T_{(m,h,v)(m',h',v')} = -\alpha(\delta_{mm'} - \delta_{mm'} \delta_{hh'} \delta_{vv'}) - \beta - \gamma(1 - \delta_{mm'}) d_{(m,h,v)(m',h',v')}$$

$$I_{(m,h,v)} = \frac{1}{2} \alpha + \beta \times n$$

로 표현된다.

```
do {
for every i
vi = g(ui)
for every i {
Δ ui = Δ t ( ∑j Tij vj - ui / R + Ii )
ui = ui + Δ ui
}
} while (network not converged);
```

그림 3 Hopfield 네트워크 방법

Hopfield 네트워크 알고리즘이 그림 3에 나타나 있다 [10]. 여기서 g 는 sigmoid 함수로서 $g(u) = \frac{1}{2}(1 + \tanh(\lambda u))$ 를 사용하였고 저항에 관련된 R 은 1을 사용하였다. 입력 벡터 v 의 초기 값을 어떻게 정하느냐에 따라 평형 상태로의 수렴 속도와 해가 달라질 수 있다. 평균 수렴 속도를 높이기 위하여 본 논문에서는 $4n$ 차 hypercube를 가정하고 v 의 초기 값이 이 hypercube의 중심 근처에 있도록 다음과 같이 주었다.

$$v_i = 0.5 + \delta \times (\text{RAND} - 0.5)$$

여기서 RAND에 의해 발생하는 난수는 0과 1사이에서

서 균일하게 분포한다. δ 은 1보다 작은 수를 사용하게 되는데 본 논문에서는 10^{-2} 의 값을 사용하였다.

신경 회로망을 사용했을 때 해의 정확성과 수렴 속도는 에너지 함수, Δt 와 λ 에 밀접한 관계를 가지고 있다. Δt 가 작을수록 일반적으로 좀더 정확한 해를 구할 수 있으나 수렴하는데 걸리는 시간이 길어지므로 본 연구에서는 Δt 의 값을 0.0001로 고정시켰다. λ 의 값은 1.5, 2.0, 2.5 등을 사용하였고 서서히 $\Delta \lambda = 0.005$ 만큼 변화시켰다.

4. 시뮬레이티드 어닐링

시뮬레이티드 어닐링 방법은 최적화 문제를 해결하는데 사용되는 일반적인 방법으로 [11][12] 등에 자세히 언급되어 있으므로 실험 설명에 필요한 정도만 간단히 언급하기로 한다. SA의 알고리즘이 그림 4에 나타나 있다. [12].

```

i = initial configuration;
Y = initial temperature;
while (stopping criterion is not satisfied) do
begin
while (not yet in equilibrium) do
begin
j = perturbation of i;
 $\Delta = E(j) - E(i)$ ;
prob =  $\min(1, e^{-\Delta/Y})$ ;
if random(0, 1)  $\leq$  prob then j = i;
end;
update Y;
end;
    
```

그림 4 시뮬레이티드 어닐링

SA를 사용하기 위해서는 초기온도, 반복 횟수, 온도의 감소 순서 등을 결정하여야 한다. 초기온도 Y_0 값이 작으면 $e^{-(E(j) - E(i)) / Y_0}$ 값을 작게 하여 수행 시간은 빨라지지만 지역해에서 빠져 나올 확률이 적어지고, Y_0 가 커지면 수행 시간이 길어진다. 보통 초기 온도 Y_0 는 정해진 수만큼의 퍼터베이션을 수행하여 구하여진 목적 함수의 변화율을 정한다. 온도의 감소 단계는 일반적으로 다음과 같이 표시할 수 있다.

$$Y_i = bY_{i-1}, \quad i = 1, 2, \dots, k$$

온도 감소율 b 는 보통 0.5부터 0.99사이의 값으로 고정되거나 또는 온도의 감소 단계에 따라 변하기도 한다 [12]. 여기서 k 는 보통 6과 50사이의 정수로 고정된다. 본 논문에서는 b 값은 0.95와 0.90을 사용하고 k 는 같은

결과 값이 10번 반복될 때까지로 정해 주었다.

i 번째 Markov 체인의 길이(안쪽 while loop의 반복회수)를 L_i 라 할 때, 본 논문에서는 $L_i = s * n$ 을 사용하였는데 n 은 모듈의 수이고 s 는 20, 40, 60을 사용하였다.

5. 실험 결과 비교 및 분석

정규화된 평균장 알고리즘, 시뮬레이티드 어닐링, 알고리즘 Hopfield 네트워크 알고리즘들은 Enterprise 3000에서 C언어를 사용하여 구현하였으며, 데이터는 [7]에서 사용한 데이터를 사용하였다. [7]에서 생성된 데이터는 모듈의 개수 n 가 10, 20, 30, 40, 50의 다섯 가지 경우이고 각 모듈의 수 n 에 대하여 4개의 데이터씩 총 20개가 있다.

실험은 매개 변수들의 값을 변화시켜 가면서 조합적으로 수행하였는데 표 2에 각 방법에서 최선의 결과에 대한 비교가 나타나 있다. 각 경우에 사용된 매개 변수를 보면 정규화된 평균장 어닐링의 경우 시작 온도는 2장 4절에서 설명한 임계 온도를 사용하였고 온도 감소율 α 를 0.75로 사용하였다. 시뮬레이티드 어닐링의 경우는 시작 온도를 평균장 어닐링과 같은 임계온도로 사용하였고, 온도 감소율은 $\alpha=0.95$ 를, Markov 체인의 길이는 $60n$ 으로 제한하였다. Hopfield 네트워크에서는 sigmoid 함수의 λ 값으로 2.5를 사용하였고 시간의 변화량 Δt 의 값을 0.0001로 사용하였다.

표 2 각 알고리즘의 최선의 결과 비교

	초기 길이	Hopfield	SAM	정규 MFA
mod1000	3186	1918	1764	1764
mod1001	2994	1620	1462	1462
mod1002	2800	2026	1972	1972
mod1003	3116	2134	2104	2108
mod2000	10306	6446	6164	6164
mod2001	10438	6576	6454	6458
mod2002	10978	7956	7784	7784
mod2003	11384	8848	8674	8674
mod3000	54298	40990	40240	40240
mod3001	53864	39708	38878	38912
mod3002	39464	29882	29564	29564
mod3003	40246	33308	32782	32782
mod4000	70894	55238	54896	54896
mod4001	71836	55866	55242	55242
mod4002	67780	57098	56380	56380
mod4003	69992	57948	57698	57730
mod5000	111756	95014	94660	94660
mod5001	110140	92846	92250	92250
mod5002	98270	85756	85268	85268
mod5003	103316	85690	84732	84732
길이의 합	947058	766,868	758,978	759,052
실행시간의 합	-	2580	26340	2316

표 3 수행 시간이 2000ms 근처일 때의 결과 비교

	Hopfield	SAM	정규 MFA
길이의 합	767,612	781,846	759,058
실행 시간	1,945	1,902	1,999

선의 길이의 합이 감소된 결과를 보면 시뮬레이티드 어닐링 방법이 758,978로 19.86% 감소하였고, 근소한 차이로 정규화된 평균장 어닐링이 759,052로 19.85% 감소하였으며, Hopfield 네트워크가 766,868로 19.03% 감소하였다. 그러나 각 데이터를 보면 Hopfield 네트워크는 다른 방법보다 더 우수한 경우가 없었고, mod1001의 경우는 감소율의 차이가 5.28%나 되었다.

실행시간을 보면 평균장 어닐링이 2316ms(micro second), Hopfield 네트워크가 2580ms, 시뮬레이티드 어닐링 방법이 26,340ms로 평균장 어닐링보다 11.37배 더 걸렸다. 그러나 Hopfield 네트워크에서는 mod5000 데이터만 제외한 나머지 데이터에 대해서는 모두 첫 번째 온도(단계)에서 수렴하여 결과가 더 이상 향상되지 않았고, 이 경우 선의 길이의 합은 767,612였고 실행시간은 794ms로 수렴시간이 매우 빨랐다.

표 3에 2,000ms 대의 시간 제한을 주었을 경우의 각 알고리즘의 결과가 나타나 있다. 이 경우 정규화된 평균장 어닐링이 선의 길이의 합이 759,058로 가장 우수하게 나타났고, 시뮬레이티드 어닐링이 781,846으로 결과의 개선 속도가 가장 느린 것으로 나타났다.

6. 결론

모듈 방향 결정 문제는 각 모듈들의 위치를 배치 알고리즘에 의하여 결정 한 후, 위치를 고정시킨 상태에서 종축 또는 횡축을 중심으로 뒤집어 회로의 효율성과 연결성을 향상시키는 방법이다. 최근에 평균장 어닐링 방법이 조합적 최적화 문제에 사용되어 좋은 결과를 보여 주고 있다. 평균장 어닐링은 신경회로망의 빠른 수렴 특성과 시뮬레이티드 어닐링의 우수한 해를 생성하는 특성이 결합된 방법이다.

본 연구에서는 전체선의 길이가 최소가 되도록 모듈들의 방향을 결정하는 문제를 Hopfield 네트워크, 시뮬레이티드 어닐링, 정규화된 평균장 어닐링 알고리즘을 사용하여 해결하고 그 결과를 실험을 통해 비교하였다. 실험 결과 정규화된 평균장 어닐링 알고리즘이 총 선의 길이의 감소율과 실행 시간을 고려할 때 가장 우수한 것으로 나타났다.

참고 문헌

- [1] M. Yamada and C. L. Liu, "An Analytical Method for Optimal Module Orientation," Proc. 1988 International Symp. on Circuits and Systems, pp 1679-1682
- [2] R. Libeskind-Hadas and C. L. Liu, "Solution to the Module Orientation and Rotation Problem by Neural Computation Network," Proc. 26th Design Automation Conference, pp400-405, 1989
- [3] Shigeo Abe, "Theories on the Hopfield Neural Networks," Proc. of IJCNN-89, Vol. 1, Jun.
- [4] David E. Van Den Bout, "Graph partitioning Using Annealed Neural Networks," IEEE Trans. on Neural Networks, Vol. 1, No. 2, June, pp 192-203, 1990
- [5] Griff Billbro, Reinhold Mann, Thomas K. Miller, "Optimization by Mean Field Annealing,"
- [6] Shiego Abe, "Global Convergence and Suppression of Spurious States of the Hopfield Neural Networks," Proc. IJCNN-91, Vol. 2, Nov. 1991.
- [7] 김재범, 정균락, "최장 전선의 길이를 최소화하기 위한 모듈의 방향 결정에 관한 휴리스틱 연구", 정보과학회 논문지(A), 제 23 권, 제 1 호, pp. 34-44, 1996
- [8] 도 원철, 정균락, "Hopfield 네트워크를 이용한 모듈의 방향 결정", 정보과학회 논문지, 제 21 권, 제 3 호, 3 월, pp. 481-488, 1994.
- [9] J. J. Hopfield and D. W. Tank, "Neural computation of decision in optimization problems," Biol. Cybern., Vol. 52, 1985.
- [10] J. Freeman and D. Skapura, "Neural networks," Addison-Wesley Publishing Company, 1991
- [11] S. Kirkpatrick, C. Gelatt, Jr., and M. Vecchi, "Optimization by Simulated Annealing," Science, Vol.220, No. 4598, pp 671-680, 1983
- [12] P.J.M. van Laarhoven and E.H.L. Arts, "Simulated Annealing : Theory and Applications," Kluwer Academic Publishers, 1987
- [13] P. Stolorz, "Merging constrained optimization with deterministic annealing to solve combinatorially hard problems," Tech. Report, LA-UR-91_3593, Los Alamos National Lab, 1991
- [14] C. Yu and W. Lee, "A parallel Mean Field Neural Net Approach to an Unrestricted Channel Routing Problem," KISS Proc. of Info Science 93, 1993
- [15] D. Haockanson and S. Radu, "An investigation of the effects of PCB-module orientation on radiated EMI," 1999 IEEE Intl. Symp. on Electromagnetic Compatibility, vol. 1, pp 399-404, 1999
- [16] N. Funabiki, J. Kitamichi, and S. Nishikawa, "An evolutionary neural network approach for module

orientation problems," IEEE Transaction on Systems, Man and Cybernetics, Part B, vol. 28, pp 849-855, 1998

- [17] R. Chang and P. Hisiao, "Genetic algorithm for module orientation problem," Electronic Letters, vol 30, issue 15, pp 1199-1200, 1994
- [18] S. S. Kim and C. M. Kyung, "Module orientation algorithm using reconstruction of nets and mean field annealing," Electronic Letters, vol 27, issue 13, 1991
- [19] R. Liang and F.C. Kang, "Thermal generating unit commitment using an extended mean field annealing neural network," IEE Proceedings, Generation, Transmission and Distribution, vol 14, pp 15-22, 2000
- [20] K. Sohn, J. Kim, and W.E. Alexander, "A mean field annealing approach to robust corner detection," IEEE Transaction on Systems, Man and Cybernetics, Part B, vol 28, pp 82-90, 1998



정 균 락

1978년 서울대학교 계산통계학과 학사.
 1980년 한국과학기술원 전산학과 석사.
 1991년 미네소타대학 박사. 1980년 ~
 1984년 한국과학기술원 연구원. 1998년
 플로리다대학 방문교수. 1991년 ~ 현재
 홍익대학교 컴퓨터공학과 부교수. 관심분

야는 알고리즘, 고집적회로 설계 알고리즘, 병렬 알고리즘.