

- $H_i = \sum T_{ij}V_j + I_i > \text{threshold} : V_i \rightarrow V_i^1$
- $H_i = \sum T_{ij}V_j + I_i < \text{threshold} : V_i \rightarrow V_i^0$
- $H_i = dU_i/dt$: 뉴우런(i)에 대한 입력
- T_{ij} : 뉴우런(j)에서 뉴우런(i)로의 연결강도
- I_i : 뉴우런(i)의 외부입력
- $V_i = g_i(U_i)$: 뉴우런(i)의 출력값
- g_i : 뉴우런(i)의 입출력함수(그림.2)




그림.2 시그모이드함수

그리고 홉필드 신경회로망의 에너지함수는 다음과 같이 정의된다.

$$E = -1/2 \sum \sum T_{ij}V_iV_j - \sum I_iV_i \quad (1)$$

이것의 시간에 대한 미분은 다음과 같다.

$$dE/dt = -\sum g_i'(U_i)(dU_i/dt)^2 \leq 0 \quad (2)$$

여기에서 g_i 는 단조증가함수이므로 dE/dt 는 항상 0보다 적음을 알 수 있다. 따라서 홉필드 신경회로망은 항상 local minima로 간다는 것을 알 수 있다.

III. 전력경제급전의 뉴우런망에서의 맵핑

1) 목적함수

경제전력급전은 주어진 발전량에 대하여 전체비용이 가장 최소가 되도록하는 개별 발전소의 발전량의 조합을 찾아내는 최적화 방법중의 하나이다. 본 논문에서는 다음과 같은 비용함수를 사용하기로 한다.

$$C = aP^2 + bP + c \quad (3)$$

C : 비용

a, b, c : 개별 발전소에 의해서 제약받는 상수

P : 발전량

따라서 경제전력급전은 C(비용)를 최소화시키는 문제로 귀착된다.

2) 제약조건

비용을 최소화시키는데 있어서 다음과 같은 제약조건을 만족시켜야 한다.

① 전체 발전량의 합

$$D + L = \sum P_i \quad (4)$$

D : 주어진 발전량의 합(total load)

L : 전송손실

$$\text{여기서 } L = \sum \alpha_i P_i^2 \quad (5)$$

α_i : 손실을 결정하는 상수

② 발전량의 최대, 최소 한계

개별 발전소에서 발전되는 발전량은 최소발전량과 최대발전량 사이에 존재해야 한다. 즉,

$$l_i \leq P_i \leq u_i \quad (6)$$

l_i : 최소발전량 u_i : 최대발전량

3) 홉필드 신경회로망과 전력경제급전의 맵핑
전력경제급전문제를 해결하기 위해서 목적함수와 제한조건을 결합한 다음과 같은 에너지함수를 설정한다.

$$E = A(D+L - \sum P_i)^2 + B \sum (\alpha_i V_i^2 + b_i V_i + c_i) \quad (7)$$

여기서 A, B(≥ 0)는 weighting parameter 전력경제급전 문제의 해결에 있어서 결정적인 역할을 하는 상수이다.

위의 에너지함수를 홉필드 신경회로망의 에너지함수와 맵핑시키면 다음과 같은 연결강도와 외부바이어스를 얻는다.

$$T_{ii} = -A - B\alpha_i$$

$$T_{ij} = -A \quad (8)$$

$$I_i = A(D+L) - Bb_i/2$$

또한 신경회로망으로 큰 수를 나타내기 위해서는 보통의 2진방식으로는 아주 많은 뉴우런을 필요로 하는 것은 시스템을 구성하는데 큰 제약조건으로 작용한다. 따라서 본 논문에서는 하나의 뉴우런으로 큰 수를 나타내기 위해서 다음과 같은 시그모이드함수(그림.3)를 사용한다.

$$V_i = g_i(U_i) = (u_i - l_i)(1 + \tanh(U_i/u_0))/2 + l_i \quad (9)$$




그림3. 큰 수를 나타내는 시그모이드함수

즉, 이 함수는 최대, 최소 발전량의 한계를 만족시키면서 시그모이드함수 역할을 해낸다.

IV. Numerical Experiment

본 연구에서는 3개의 뉴우런으로 세가지 경우(①손실이 없는 경우, ②손실이 없으면서 최대, 최소 발전한계를 만족 하지 못하는 경우, ③손실이 있는 경우)에 대하여 시뮬레이션을 하였다. 그리고 뉴우런의 입력에 대해서는 아래와 같은 differential synchronous transition mode[9]를 사용하였다. 즉,

$$U_i(k) - U_i(k-1) = \sum T_{ij}V_j(k) + I_i \quad (10)$$

$$V_i(k+1) = g(U_i(k)) \quad (11)$$

문제는 아래와 같이 설정 되었다.

< 문제설정 >

① node(1) $150 \leq P_1 \leq 600$

$$C_1 = 0.001562P_1^2 + 7.92P_1 + 561.0$$

node(2) $100 \leq P_2 \leq 400$

$$C_2 = 0.00194P_2^2 + 7.85P_2 + 310.0$$

node(3) $50 \leq P_3 \leq 200$

$$C_3 = 0.00482P_3^2 + 7.97P_3 + 78.0$$

② node(1) $150 \leq P_1 \leq 600$

$$C_1 = 0.001278P_1^2 + 6.48P_1 + 459.0$$

node(2)와 node(3)은 ①의 경우와 동일하다.

③ ①의 경우와 모두 동일하며 다음과 같은 손실함수가 주어진다.

$$L = 0.00003P_1^2 + 0.00009P_2^2 + 0.00012P_3^2 \quad (12)$$

그리고 전체적으로 total load($D=P_1+P_2+P_3$)는 850.0으로 주어진다.

1) 초기조건

일반적으로 local minima로 수렴 할 수 있는 초기 조건의 집합이 존재한다^[11]고 알려져 있으나, 무엇이 그 집합의 한계를 결정하는지에 대해서는 알려져 있지 않다. 본 연구에서의 초기조건은 절대값이 같지 않으면서 symmetry를 형성시키지 못하도록 하였다. 그리고 phase state의 중간값($P_1=225.0, P_2=150.0, P_3=75.0$)을 선택하였다.^[8]

그러나 본 시뮬레이션에서는 초기조건의 변화가 아무런 영향을 미치지 못하였는데, 그 이유는 수렴 가능한 초기조건의 집합이 아주 넓기 때문이라고 생각된다.

2) Weighting parameter(A,B)

최적화문제에서 weighting parameter의 결정이 아주 어려운 경우가 많다. 본 연구에서는 약간의 시행착오를 거쳐서 $A=0.4, B=0.05$ 로 택하였다.

A는 제한조건에 주어지고 B는 목적함수에 주어지는 파라메타인데, A가 B보다 큰 이유는 total load를 보다 정확하게 만족시키기 위해서이다. A가 B보다 커질수록 결과는 total load에 가까와 지는데, A가 너무 커지면 B의 역할이 거의 무시되어 최소화 시키려는 목적함수에 영향을 주지 못하게 된다. 즉, A를 B의 10배 정도로 두는 것이 적당하다. 그리고 자기제한이 있는 경우($T_{11} \neq 0$)에는 oscillation하는 경우가 발생하는데^[9], 본 연구에서는 A가 0.4보다 커질 때 oscillation이 발생하였다. (그림.4)

또한 A와 B를 똑같은 비율로 증가시키는 것은 홉필드 신경회로망에서는 불합리한데^[12], 그 이유는 홉필드 신경회로망이 nonlinear한 구조를 가지기 때문이다. A와 B는 다른 조건이 바뀔 경우(예를들어, sigmoid함수의 변화, discrete time간격의 변화 등) 증가 또는 감소될 수 있다.




그림.4 Oscillation (A=1.0, B=1.0)

3) 결과

에너지함수는 그림.5와 같이 시간에 대하여 항상 감소함을 볼 수 있다.




그림.5 시간에 따른 에너지함수의 변화

① 손실이 없는 경우 (TL : total load)

고전적인 결과 : $P_1 = 393.2 \quad C_1 = 3916.6$

$P_2 = 334.6 \quad C_2 = 3153.8$

$P_3 = 122.2 \quad C_3 = 1123.9$

TL = 850.0 전체비용 = 8194.3

시뮬레이션 결과 : $P_1 = 393.8 \quad C_1 = 3922.1$

$P_2 = 333.1 \quad C_2 = 3140.1$

$P_3 = 122.3 \quad C_3 = 1124.8$

TL = 849.2 전체비용 = 8187.0

각 값들의 변화는 그림.6에 나타내었다

Total load에서 생기는 조급의 오차는 비용으로 환산되어 질 수 있는데, 어느 경우(P_1, P_2, P_3)에 대하여 보상을 하여도 최소값을 넘지는 않는다. 그리고 초기에 조급의 변동이 있는 후에 아주 완만하게 변화하기 때문에 수렴시간이 길어지는 단점(IBM PC-386으로 6-7분 정도)이 발견되었다.




그림.6 개별전력의 시간에 따른 변화 (손실이 없는 경우)

P1, P2, P3의 변화의 추이로 보아서는 시뮬레이션의 결과는 충분한 시간이 경과한 후에는 고전적인 값과 완전히 일치하게 될것 이라는 것을 예측할 수 있다. 즉, P1은 감소하고, P2는 증가하고, P3는 감소하고 있기 때문이다.

② 손실이 없고 최대 또는 최소한계를 만족시키지 못하는 경우

고전적인 결과 : P₁ = 600.0 C₁ = 4807.1
 P₂ = 187.1 C₂ = 1846.6
 P₃ = 62.9 C₃ = 598.4
 TL = 850.0 전체비용 = 7252.1

시뮬레이션 결과 : P₁ = 600.0 C₁ = 4807.1
 P₂ = 186.6 C₂ = 1842.4
 P₃ = 62.9 C₃ = 598.4
 TL = 849.5 전체비용 = 7247.9

각 값들의 변화는 그림.7에 나타내었다.




그림7 개별전력의 시간에 따른 변화 (최대, 최소한계를 만족 못시키는 경우)

이 경우는 P1이 최대한계(600)을 넘기 때문에 고전적인 경우에는 최대한계를 넘지 못하도록 하는 제약조건이 설정되어야 한다. 그러나 홉필드 신경회로망을 사용한 경우는 아무런 조건의 첨가없이 똑 같은 결과를 찾아낼 수 있는 잇점이 있다. 나머지 경우는 손실만 없는 경우와 동일하다.

③ 손실이 있는 경우

고전적인 결과 : P₁ = 435.1 C₁ = 4302.7
 P₂ = 300.0 C₂ = 2839.6
 P₃ = 130.7 C₃ = 1202.0
 TL = 865.8 전체비용 = 8344.3
 Loss = 15.8

시뮬레이션 결과 : P₁ = 432.4 C₁ = 4277.7
 P₂ = 288.5 C₂ = 2736.2
 P₃ = 144.1 C₃ = 1326.6
 TL = 865.0 전체비용 = 8340.5
 Loss = 15.6

각 값들의 변화는 그림.8에 나타내었다.

손실이 있는 경우는 앞의 두 경우와 다른점이 몇 개 있는데, 이것은 고전적인 결과와 시뮬레이션결과를 비교해 보면 곧 알 수 있다. 즉, 개별 전력의 값들이 조그도 일치하지 않는다. 그러나 전체비용으로 따져보면 큰 차이가 나지 않는다. Total load의 오차가 0.6




그림.8 개별전력의 시간에 따른 변화 (손실이 있는 경우)

인데, 이것을 각 전력에 보상하여 보면 오차는 0.02% 정도 밖에 증가하지 않는다. 고전적인 경우에도 어느 값이 절대적인 최적해인지 파악할 수 없기 때문에, 위의 세가지의 문제를 하나의 시스템으로 처리할 수 있는 홉필드 신경회로망이 더 유용하다고 본다.

한편, 식(8)에서 I_i는 P의 함수임을 알 수 있다. 즉,

$$I_i = A(D+L) - Bb_i/2 = A(D + \sum \alpha_i P_i^2) - Bb_i/2 \quad (12)$$

그러므로 궁극적으로 따져보면 이 연구에서 신경회로망의 급전전력배분의 맵핑은 부정확하다고 볼 수 있다. 위의 논의를 에너지함수와 연관시켜보면 다음과 같다.

$$E = -1/2 \sum_i \sum_j T_{ij} V_i V_j - \sum_i I_i V_i \quad (1)$$

$$\begin{aligned} dE/dt &= -1/2 \sum_i \sum_j T_{ij} (V_j (dV_i/dt) + V_i (dV_j/dt)) \\ &\quad - \sum_i (I_i (dV_i/dt) + V_i (dI_i/dt)) \\ &= -1/2 \sum_i (dV_i/dt) \{ (\sum_j T_{ij} V_j + T_{ii} V_i) + 2I_i \\ &\quad + 2(dI_i/dV_i) \} \\ &= -1/2 \sum_i (dV_i/dt) (2 \sum_j T_{ij} V_j + 2I_i + 2(dI_i/dV_i)) \\ &= -\sum_i (dV_i/dt) (\sum_j T_{ij} V_j + I_i) - \sum_i (dV_i/dt) (dI_i/dV_i) \\ &= -\sum_i (dV_i/dt) (dU_i/dt) - \sum_i (dV_i/dt) (dI_i/dV_i) \\ &= -\sum_i (dV_i/dt) \{ (dU_i/dt) + (dI_i/dV_i) \} \\ &= -\sum_i g_i'(U_i) (dU_i/dt)^2 - \sum_i (dV_i/dt) (dI_i/dV_i) \end{aligned} \quad (13)$$

여기서 B_i=(dV_i-dt)(dI_i/dV_i)=dI_i-dt 로 두면, B_i=0 일 때 또는 (dU_i/dt)에 비해서 (dI_i/dV_i)가 거의 무시될 수 있는 경우에 dE/dt ≤ 0가 된다. 따라서 본 연구의 검토결과 I_i의 시간에 대한 변화가 아주 미소하기 때문에 일정한 한계(0.01이상)내에서는 I_i가 거의 상수(constant)로 취급되어 질 수 있다.

본 연구에서 손실이 있는 경우에 대해서는 시간의 변화에 대한 외부입력(I_i)의 변화가 거의 무시될 수 있도록 수렴한계를 0.01로 두었다. 그리고 수렴한계를 0.01이하로 두었을 때에는 시간에 대한 에너지의 변화가 0보다 적어진다는 근거가 없기 때문에 좋은 결과를 얻지 못하였다.

V. 결과 및 전망

본 연구의 수행결과 다음과 같은 몇가지 결론을 얻게 되었다.

첫째, 홉필드 신경회로망은 초기조건에 많은 영향을 받는다. 특히 TSP에서는 초기조건이 아주 중요하다. 그러나 본 연구에서 다루어진 전력경제급전의 경우에는 초기조건에 영향이 거의 없었다. 따라서 전력경제급전의 경우에는, $P_i P_j$ 같은 방곡선 함수가 많아 복잡함에도 불구하고 에너지함수가 smooth하고 simple한 특성이 있어 보인다. 이러한 최적화문제의 경우에는 보다 많은 뉴런을 사용하더라도 수렴이 쉬울 것이라고 생각된다.

둘째, 고전적인 방법을 사용하는 최적화문제에 있어서 weighting의 결정은 일정한 규칙이 없고 매우 까다로운 작업이다. 이것은 홉필드 신경회로망에 있어서도 마찬가지인데, 다만 일정한 trend를 찾을 뿐이다. (11) 본 연구에서는 weighting parameter(A,B)를 결정할 때, A(제한조건)와 B(목적함수 penalty)의 비율이 어느 정도 클 때 제한조건을 만족함을 알고, 그 비율을 어느 정도 구한 후 정확한 A와 B의 값을 구하였다.

셋째, 손실이 있는 경우, 손실함(L)은 뉴런 출력 상태(V_i)의 함수이고 동시에 외부입력에 포함된다. 따라서 (dI_i/dV_i) 또는 (dI_i/dt) 가 존재하므로 $(dE/dt) \leq 0$ 을 보장할 수가 없어 전력경제급전의 뉴런망에의 열평은 성공적이지 못하였다. 그러나 (dI_i/dV_i) 또는 (dI_i/dt) 가 적으면 수렴한계를 조정하여 함수를 smoothing시키는 효과를 얻어 수렴에 도달할 수 있다. 그리고 (dI_i/dV_i) 또는 (dI_i/dt) 가 클 때, iterative method를 써서 I_i 를 상수(constant)로 만들어 수렴시킬 수 있다고 생각된다.

넷째, 자기궤환(T_{ii})이 아니므로 oscillation하는 경우와 수렴이 느릴 경우가 발생한다. (9) 본 연구에서는 transition mode를 differential synchronous mode를 사용하였는데, oscillation을 줄이는 효과가 커다고 알려진 direct asynchronous transition mode 나 differential asynchronous transition mode를 사용한다면 더 좋은 결과를 얻을 수 있으리라 생각된다.

마지막으로, 본 연구결과를 토대로 발전소가 여러 개일 경우 즉, 뉴런의 수가 많을 경우에 홉필드 모델을 적용할 것이고 나아가 전력경제급전의 뉴런망 하드웨어 구현에 대한 연구를 계속하고자 한다.

참고 문헌

[1] W.S.McCulloch and W.Pitts, "A logical calculus of the idea immanent in nervous activity", Bull. Math. Biophys. vol.5, 1943, pp.115-133.

[2] J.J.Hopfield, "Neural networks and physical systems with emergent collective computational abilities", Proceedings of the National Academy of Science USA, vol.79, 1982, pp.2554-2558.

[3] J.J.Hopfield, "Neurons with graded response have collective computational properties like those of two-state neuron", proceedings of National Academy of Science USA, vol.81, 1984, pp.3088-3092.

[4] J.J.Hopfield and D.Tank, "Neural computation of decisions in optimization problems", Biological Cybernetics, vol.52, 1985, pp.141-152.

[5] J.J.Hopfield and D.W. Tank, "Collective computation with continuous variables", in Distorted System and Biological organization, E. Blenstock, F.Fogelman, and G.Weisbuch Eds. Berlin Germany : Springer Verlag 1985.

[6] David W.Tank and J.J.Hopfield, "Simple 'neural' optimization networks : an A/D converter, signal decision circuit, and a linear programming circuit", IEEE vol. CAS-33, no.5, May, 1986, pp.533-541.

[7] Yoon-Pin Simon Foo and Yoshiyasu Takefuji, "Stochastic neural networks for solving Job-shop scheduling part.1, problem representation", IEEE ICNN vol.2, 1988, pp.275-282.

[8] Shigeo Abe, "Theories of the Hopfield neural networks", ICNN-88, vol.1, pp.557-564, 1988.

[9] M.Takeda and J.W.Goodman, "Neural networks for computation : number representations and programming complexity", Applied Optics, vol.25, no.18, 1986, pp.3033-3046.

[10] Satoshi Matuda and Yoshiakira Akimoto, "The representation of large numbers in neural networks and its application to economical load dispatching of electric power", Icnn-89, vol.1, pp.587-592, June, 1989.

[11] S.Amari and K.Maginu, "Statistical neurodynamics of associative memory", Neural Networks, vol.1, pp.63-67, 1988.

[12] S.U. Hegde, J.L.Sweet and W.B. Levy, "Determination in a Hopfield/Tank computational network", International conference on Neural Net, vol.12, 1988.

[13] 林泰弘, 岩本伸一, 松田聖, 古本能彬, "電力潮流計算問題へのニューラルネットワーク理論導入に関する考察", 日本電気学会 電力技術研究会 1990. 7.

[14] 森啓之, 氣谷直樹, 都築旋二, "最適潮流計算へのHopfield型ニューラルネットの適用について", 日本電気学会 電力技術研究会 1990. 8