

신경망 이론과 Simulated Annealing법을 이용한 노심 최적 장전모형 탐색 연구

이정훈, 장창선, 김창효

서울대학교

요 약

최적 노심장전모형을 찾기 위한 확률론적 방법중 하나인 Simulated Annealing 방법은 기존 결정론적 방법의 단점인 국부 최적해에 빠질 위험성을 줄이면서도 빠른 시간 안에 최적 노심장전모형을 찾을 수 있다. 그러나 많은 장전모형의 핵특성을 계산하기 위해서는 많은 전산시간이 소요되기 때문에 이의 해결 방법으로 신경망이론 이용한 노심해석을 통하여 시간을 극소화하고, 기존의 섭동이론 등 가속화된 방법에 비해 정확도를 높였다. 영광 3호기 평형노심에 적용한 결과 기존 설계된 장전모형에 비하여 더 보수적인 제한치를 만족하면서도 주기길이가 33EFPD 만큼 길어지는 장전모형을 1시간 이내에 찾을 수 있어 기존의 결정론적 방법이나 다른 핵특성 계산 모델을 사용한 SA법에 비해 더 적은 전산시간 동안 정확한 최적해를 탐색하는 것을 확인하였다.

1. 서론

원자력 발전소 운영상의 경제성 향상을 위하여 노심 내 최적 핵연료 배치모형을 탐색하고자 하는 연구는 꾸준히 지속되고 있다. 이 연구는 다양한 핵연료 배치형태의 핵특성을 하나하나 노심핵설계코드를 이용해 계산하는데 많은 시간과 노력이 필요하다는 단점이 있기 때문에 이의 해결을 위해 기존의 설계 경험이나 원자로 운전 경험을 바탕으로 기존의 노심핵설계 도구를 이용한 시행착오법으로 주기길이나 안전성이 보다 나은 핵연료 배치모형을 탐색하는 '경험칙에 의한 장전모형 탐색' 방법이나 섭동이론과 최적화 이론을 이용하여 수많은 핵연료 배치형태를 일일이 노심핵설계코드로 계산하지 않고도 최적 핵연료 배치형태를 예측하는 소위 '최적화이론에 의한 탐색' 방법이 널리 쓰이고 있다.

그러나 최적화이론에 의한 결정론적 방법은 국부 최적해에서 벗어날 수 없는 위험성이 있기 때문에 최근에는 위와 같은 결정론적 방법 이외에도 Simulated Annealing법(이하 SA법)이나 진화

알고리즘(Genetic Algorithm)을 이용한 확률론적 방법으로 결정론적 방법의 단점을 극복하려는 노력을 많이 하고 있지만, 확률론적 방법의 특성상 매우 많은 장전모형의 계산을 수행해야 하기 때문에 전산시간이 길어진다는 단점이 있었다.

확률론적 방법의 노심계산을 수행하기 위해 현재 일반적으로 사용될 수 있는 방법은 섭동이론이나 일반섭동이론을 통해 계산된 민감도 계수를 이용한 계산방법, 1.5군 근사를 통한 가속화 방법, 신경망이론을 통한 예측방법 등이 있다. 특히 신경망이론을 이용한 방법은 학습방법에 따라 비교적 정확한 결과를 얻을 수 있고, 전산시간도 매우 짧다는 것이 이미 연구되어 있다. 따라서 이 연구에서는 신경망이론에 의한 노심핵특성 계산을 이용해 SA법을 통한 최적 장전모형 탐색방법을 개발하고자 하였다.

2. SA법의 목적함수 설정과 냉각과정

SA법은 고온의 분자들을 천천히 냉각시켜 안정된 결정구조를 만들어 가는 메커니즘을 이용한 탐색 방법이다. 온도의 개념은 장전모형 탐색에서 허용 확률(acceptance probability)로써 구현이 된다. 허용확률 P_i 는 다음과 같이 정의된다.

$$P_i = \begin{cases} 1, & \bar{f}_i \leq \bar{f}_{i-1} \\ \exp\left(\frac{\bar{f}_{i-1} - \bar{f}_i}{c}\right), & \bar{f}_i > \bar{f}_{i-1} \end{cases} \quad (1)$$

이전 목적함수 값보다 더 작은 목적함수 값을 갖는 장전모형은 위 식에서 보듯이 모두 허용이 되게 된다. 이전 목적함수 값보다 더 큰 목적함수 값을 갖는 장전모형은 1보다 작은 허용 확률을 가지게 된다. 이때에는 random number를 뽑아서 결정을 하는데, random number가 허용 확률보다 작을 때 장전모형을 허용한다.

목적함수는 최적화 방법에 따라서 달라지게 되는데, 본 연구에서는 주어진 핵연료 집합체들에 대하여 주기길이를 극대화하기 위해 주기말 수용성 봉산 농도를 목적함수로 사용하였는데, 여기에 각 제한치들은 제한치를 초과하는 결과에 대하여 penalty를 더하는 방법으로 구현되었다.

$$\bar{f} = -(\text{SBppm})^{\text{EOC}} + \sum \lambda_i \phi_i \quad (2)$$

식 (2)의 ϕ_i 에는 출력 제한치를 초과하는 집합체에 대한 출력 penalty와 주기말에 연소도 제한치를 초과하는 집합체에 대한 연소도 penalty가 사용되었다. N개의 집합체로 구성된 노심을 M개의 Burnup Step으로 계산할 때 각 penalty는 다음과 같이 표현된다.

$$P_{\text{pow}} = \sqrt{\frac{\sum_{j=0}^{M-1} \Delta(\text{Burnup})_j \sum_{i=1}^N \Delta P_{ij}^2}{\sum_{j=0}^{M-1} \Delta(\text{Burnup})_j}} \quad (3)$$

$$P_{\text{burn}} = \sqrt{\sum_{i=1}^N \Delta B_{i,\text{EOC}}^2} , \quad (4)$$

$$\sum_i \lambda_i \phi_i = \lambda_{\text{pow}} P_{\text{pow}} + \lambda_{\text{burn}} P_{\text{burn}} . \quad (5)$$

여기서

$$\Delta P_{ij}^2 = \{ \max [0, (P_{ij} - P_{\text{lim}})] \}^2 , \quad (6)$$

$$\Delta B_{i,\text{EOC}}^2 = \{ \max [0, (B_{i,\text{EOC}} - B_{\text{lim}})] \}^2 . \quad (7)$$

시작 온도는 첫 번째 Stage에서 임의로 만들어지는 장전모형의 90% 이상이 허용 되도록 초기 탐색을 통하여 설정한다. 각 Stage에서는 집합체간의 Binary Exchange 또는 Ternary Exchange로 30개의 장전모형이 허용될 때까지 최대 500개의 장전모형을 새로이 생산해 낸다. 한 Stage가 끝나면 냉각 계수 α ($0 < \alpha < 1$)를 가지고 다음 Stage의 온도와 penalty의 계수 λ_i 를 계산해 낸다.

$$c_{n+1} = \alpha c_n , \quad (8)$$

$$\lambda_{i,n+1} = \lambda_{i,n} / \alpha . \quad (9)$$

이와 같은 냉각과정을 거치게 되면 온도가 감소함에 따라 penalty 조건이 점점 까다로워져서 해가 점차 수렴하게 될 무렵에는 penalty가 거의 없는 장전모형들만이 허용되게 된다. 해가 충분히 수렴되었다고 생각되어 계산을 종료할 시점은 (i) Stage의 허용 장전모형 개수 < 2 , (ii) Stage 수 > 500 , (iii) $|\bar{f}_i - \bar{f}_{i-1}| < \epsilon$ ($\bar{f}_i = i$ 번째 Stage의 평균 목적함수 값) 중 하나 이상이 만족하는 경우로 설정하였다.

3. 신경망을 통한 노심핵특성 계산

SA법의 목적함수를 계산하기 위해서는 두 개의 신경망이 이용된다. 하나는 각 집합체의 농축도와 연소도가 주어졌을 때 수용성 붕산의 농도를 계산하는 신경망이고, 다른 하나는 각 집합체의 출력을 계산하는 신경망이다. 이 연구에서는 OLL법으로 2D NEM의 계산 결과를 가지고 학습시킨 신경망이 사용되었다. 학습 대상이 된 노심은 최적화 대상으로 선정한 영광 3호기 평형 노심이고, 주어진 핵연료 집합체들에 대하여 임의의 추출 형식으로 노심을 구성하여 학습시켰다.

검증계산 결과 비교적 연소도가 적은 집합체에 대해서는 출력을 잘 예측하지만, 출력이 낮은 고연소도의 집합체에 대해서는 오차가 약간 커짐을 알 수 있다. 한편 Gd 독봉의 특성상 Gd가 모두 연소되는 시점의 출력도 오차가 약간 크다.

4. 최적화 대상 노심 및 결과

최적화 대상이 된 노심은 영광 3호기 3배치 18개월 평형 노심이다. 영광 3호기 3배치 18개월 평형 노심은 총 177개의 핵연료 집합체가 들어가고, Fresh 68개, Once Burned 68개, Twice

Burned 41개가 들어간다. 각 핵연료에 대한 정보는 표 1에 정리되어 있는데, Type에 0과 1이 들어간 것은 농축도 4.5w/o의 집합체이고, 2와 3이 들어간 것은 4.0w/o 집합체이다. 목적함수 계산에 필요한 주기말 Burnup은 440EFPD에 해당하는 16.3MWD/kgU으로 하여 10개의 노심 연소도 과정에 대하여 수용성 붕산 농도와 집합체 상대 출력을 신경망으로 계산하였다.

그림 1은 경험적으로 찾은 영광 3호기 장전모형으로서 최대 집합체 상대출력이 1.332이다. SA 계산에서는 2D 오차를 감안하여 최대 집합체 상대 출력 제한치를 좀더 보수적인 1.30으로 하고, 주기말 최대 집합체 연소도도 53MWD/kgU으로 제한하였다.

SA 계산은 269 Stage만에 수렴하였고, 생산된 총 장전모형의 개수는 66676개, 허용된 장전모형의 개수는 약 10% 가량인 6960개이다. 계산시간은 Pentium Pro-200 PC에서 약 3000초가 걸렸다. 최종 수렴된 장전모형의 노심계산 결과는 다시 2D NEM과 3D NEM으로 검증계산하여 그림 3에 정리하였다. 결과에서 보면 2D NEM과 신경망의 계산 결과는 최대 오차 6.3% 이내에서 일치하고 있고, 특히 침투출력이 발생하는 집합체의 오차는 1.2%이다. 주기초와 주기말 수용성 붕산 농도는 신경망 계산 결과가 각각 25ppm과 15ppm 정도 높게 예측하였다.

계산된 최적 노심은 최대 집합체 상대 출력이 Neural 2D, 2D NEM, 3D NEM이 각각 1.298, 1.301, 1.303이고, 3D NEM으로 계산된 주기 길이는 17.769MWD/kgU으로 비교 장전모형의 16.565MWD/kgU에 비하여 1.204MWD/kgU, 33EFPD가 길어졌다.

5. 결론 및 향후 과제

신경망을 이용한 SA법은 더 보수적인 제한치를 가지고도 핵특성이 우수한 장전모형을 빠른 시간에 찾을 수 있다는 것이 입증되었다. 특히 신경망은 빠른 시간에 노심 특성을 계산하면서도 오차가 매우 작아서 확률론적 최적화 방법에 유용하다는 것을 알 수 있다. 이 두가지를 결합하여 최적 노심을 탐색한 결과 비교적 많은 수의 장전모형을 탐색하면서도 전산시간은 별로 소모하지 않았다. SA법에서 많은 수의 장전모형을 탐색할 수 있다는 것은 다른 확률론적 방법에서와 마찬가지로 국부 최적해에 빠질 가능성이 그만큼 적어진다는 것이다. 이런 결과에서 신경망을 통한 노심해석은 SA법과 같은 확률론적 최적노심 탐색에 매우 유용한 도구임이 입증되었다.

그림 3에서 볼 수 있듯이 최적 노심 외곽에 독봉이 들어간 Fresh가 들어가 있는데, 이런 것을 막기 위해서는 최적화 코드에 또 다른 제한치가 필요하다. 이런 인공의 요소를 가미함으로써 불필요한 계산횟수를 줄이고, 좀더 현실성이 있는 결과를 얻을 수 있다. 한편, 상대출력 제한치는 집합체 출력보다는 상대봉출력을 기준으로 하기 때문에 여기에 대한 연구도 요구된다.

계산속도는 현재 만족할만한 수준이지만, 새 장전모형 생산 시에 Fresh 집합체의 위치에 대한 요구조건을 만족하고, 봉출력과 회전효과를 고려하면 다소 느려질 가능성이 있기 때문에 가속화 방법의 개발과 한 주기만이 아닌 다주기 노심의 최적화 또한 향후 해결해야 할 과제로 남아있다.

Acknowledgement

본 연구는 한국전력공사 지원에 의해 기초전력공학공동연구소 주관으로 수행되었음.

참고문헌

1. J. G. Stevens, K. S. Smith, and K. R. Rempe, "Optimization of Pressurized Water Reactor Shuffling by Simulated Annealing with Heuristics," *Nucl. Sci. Eng.*, **121**, 67-88 (1995).
2. D. J. Kropaczek and P. J. Turinsky, "In-Core Nuclear Fuel Management Optimization for Pressurized Water Reactors Utilizing Simulated Annealing," *Nucl. Technol.*, **95**, 9 (1991).
3. "FORMOSA-P Version 3.4.1 Release Notes," North Carolina University (1996).
4. T. K. KIM and CHANG HYO KIM, "Determination of Optimized PWR Fuel Loading Pattern by Mixed Integer Programming," *Proc. International Conference on the Physics of Reactors*, Mito, Japan, Vol.3, p.I-76. (1996).
5. S. ERGEZINGER and E. THOMPSON, "An Accelerated Learning Algorithm for Multilayer Perceptrons: Optimization Layer by Layer", *IEEE*, Vol.6, 31 (1995).
6. E. Aarts and J. Korst, "Simulated Annealing and Boltzmann Machines," John Wiley & Sons (1989).
7. "Nuclear Design Report for YGN 3 Cycle 1," KAERI (1994).

표 1. 영광 3호기 평형주기 사용 핵연료 집합체의 사양

Type	No. Available	No. BA	Burnup (MWD/kgU)	Type	No. Available	No. BA	Burnup (MWD/kgU)		
Fresh	C0	16	0	0.000	Once-Burned	B0	8	0	13.108
	C1	20	8	0.000		B0	8	0	16.044
	C2	12	8	0.000		B1	8	8	16.544
	C3	20	12	0.000		B1	8	8	18.632
Twice-Burned	A1	8	8	25.718		B1	4	8	18.967
	A0	8	0	32.111		B2	8	8	20.418
	A3	4	12	27.982		B2	4	8	20.934
	A0	8	0	35.241		B3	8	12	21.079
	A2	4	8	31.247		B3	4	12	21.200
	A1	4	8	36.484		B3	8	12	21.526
	A1	4	8	38.455					
	A1	1	8	37.674					

Burned 41개가 들어간다. 각 핵연료에 대한 정보는 표 1에 정리되어 있는데, Type에 0과 1이 들어간 것은 농축도 4.5w/o의 집합체이고, 2와 3이 들어간 것은 4.0w/o 집합체이다. 목적함수 계산에 필요한 주기말 Burnup은 440EFPD에 해당하는 16.3MWD/kgU으로 하여 10개의 노심 연소도 과정에 대하여 수용성 붕산 농도와 집합체 상대 출력을 신경망으로 계산하였다.

그림 1은 경험적으로 찾은 영광 3호기 장전모형으로서 최대 집합체 상대출력이 1.332이다. SA 계산에서는 2D 오차를 감안하여 최대 집합체 상대 출력 제한치를 좀더 보수적인 1.30으로 하고, 주기말 최대 집합체 연소도도 53MWD/kgU으로 제한하였다.

SA 계산은 269 Stage만에 수렴하였고, 생산된 총 장전모형의 개수는 66676개, 허용된 장전모형의 개수는 약 10% 가량인 6960개이다. 계산시간은 Pentium Pro-200 PC에서 약 3000초가 걸렸다. 최종 수렴된 장전모형의 노심계산 결과는 다시 2D NEM과 3D NEM으로 검증계산하여 그림 3에 정리하였다. 결과에서 보면 2D NEM과 신경망의 계산 결과는 최대 오차 6.3% 이내에서 일치하고 있고, 특히 첨두출력이 발생하는 집합체의 오차는 1.2%이다. 주기초와 주기말 수용성 붕산 농도는 신경망 계산 결과가 각각 25ppm과 15ppm 정도 높게 예측하였다.

계산된 최적 노심은 최대 집합체 상대 출력이 Neural 2D, 2D NEM, 3D NEM이 각각 1.298, 1.301, 1.303이고, 3D NEM으로 계산된 주기 길이는 17.769MWD/kgU으로 비교 장전모형의 16.565MWD/kgU에 비하여 1.204MWD/kgU, 33EFPD가 길어졌다.

5. 결론 및 향후 과제

신경망을 이용한 SA법은 더 보수적인 제한치를 가지고도 핵특성이 우수한 장전모형을 빠른 시간에 찾을 수 있다는 것이 입증되었다. 특히 신경망은 빠른 시간에 노심 특성을 계산하면서도 오차가 매우 작아서 확률론적 최적화 방법에 유용하다는 것을 알 수 있다. 이 두가지를 결합하여 최적 노심을 탐색한 결과 비교적 많은 수의 장전모형을 탐색하면서도 전산시간은 별로 소모하지 않았다. SA법에서 많은 수의 장전모형을 탐색할 수 있다는 것은 다른 확률론적 방법에서와 마찬가지로 국부 최적해에 빠질 가능성이 그만큼 적어진다는 것이다. 이런 결과에서 신경망을 통한 노심해석은 SA법과 같은 확률론적 최적노심 탐색에 매우 유용한 도구임이 입증되었다.

그림 3에서 볼 수 있듯이 최적 노심 외곽에 독봉이 들어간 Fresh가 들어가 있는데, 이런 것을 막기 위해서는 최적화 코드에 또 다른 제한치가 필요하다. 이런 인공의 요소를 가미함으로써 불필요한 계산횟수를 줄이고, 좀더 현실성이 있는 결과를 얻을 수 있다. 한편, 상대출력 제한치는 집합체 출력보다는 상대봉출력을 기준으로 하기 때문에 여기에 대한 연구도 요구된다.

계산속도는 현재 만족할만한 수준이지만, 새 장전모형 생산 시에 Fresh 집합체의 위치에 대한 요구조건을 만족하고, 봉출력과 회전효과를 고려하면 다소 느려질 가능성이 있기 때문에 가속화 방법의 개발과 한 주기만이 아닌 다주기 노심의 최적화 또한 향후 해결해야 할 과제로 남아있다.

Acknowledgement

본 연구는 한국전력공사 지원에 의해 기초전력공학공동연구소 주관으로 수행되었음.

참고문헌

1. J. G. Stevens, K. S. Smith, and K. R. Rempe, "Optimization of Pressurized Water Reactor Shuffling by Simulated Annealing with Heuristics," *Nucl. Sci. Eng.*, **121**, 67-88 (1995).
2. D. J. Kropaczek and P. J. Turinsky, "In-Core Nuclear Fuel Management Optimization for Pressurized Water Reactors Utilizing Simulated Annealing," *Nucl. Technol.*, **95**, 9 (1991).
3. "FORMOSA-P Version 3.4.1 Release Notes," North Carolina University (1996).
4. T. K. KIM and CHANG HYO KIM, "Determination of Optimized PWR Fuel Loading Pattern by Mixed Integer Programming," *Proc. International Conference on the Physics of Reactors*, Mito, Japan, Vol.3, p.I-76. (1996).
5. S. ERGEZINGER and E. THOMPSON, "An Accelerated Learning Algorithm for Multilayer Perceptrons: Optimization Layer by Layer", *IEEE*, Vol.6, 31 (1995).
6. E. Aarts and J. Korst, "Simulated Annealing and Boltzmann Machines," John Wiley & Sons (1989).
7. "Nuclear Design Report for YGN 3 Cycle 1," KAERI (1994).

표 1. 영광 3호기 평형주기 사용 핵연료 집합체의 사양

Type	No. Available	No. BA	Burnup (MWD/kgU)	Type	No. Available	No. BA	Burnup (MWD/kgU)		
Fresh	C0	16	0	0.000	Once-Burned	B0	8	0	13.108
	C1	20	8	0.000		B0	8	0	16.044
	C2	12	8	0.000		B1	8	8	16.544
	C3	20	12	0.000		B1	8	8	18.632
Twice-Burned	A1	8	8	25.718	B1	4	8	18.967	
	A0	8	0	32.111	B2	8	8	20.418	
	A3	4	12	27.982	B2	4	8	20.934	
	A0	8	0	35.241	B3	8	12	21.079	
	A2	4	8	31.247	B3	4	12	21.200	
	A1	4	8	36.484	B3	8	12	21.526	
	A1	4	8	38.455					
	A1	1	8	37.674					

