

다목적 을 고려한 전력 시스템의 최적운용을 위한 S 모델 Automata의 적용 연구

論 文
49A - 4 - 6

A Study on The Application of S Model Automata for Multiple Objective Optimal Operation of Power Systems

李 丙 河* · 朴 鍾 根**
(Byung-Ha Lee · Jong-Keun Park)

Abstract - The learning automaton is an automaton to update systematically the strategy for enhancing the performance in response to the output results, and several schemes of learning automata have been presented. In this paper, S-model learning automata are applied in order to achieve the best compromise solution between an optimal solution for economic operation and an optimal solution for stable operation of the power system under the circumstance that the loads vary randomly. It is shown that learning automata are applied satisfactorily to the multiobjective optimization problem for obtaining the best tradeoff among the conflicting economy and stability objectives of power systems.

Key Words : Learning Automata, S-model Learning Automata, Multiple Objective, Power System Operation

1. 서 론

공학응용현장에서 자주 마주치는 결정과정 중의 하나가 트레이드 오프(Trade-off) 결정이다. 다목적 을 동시에 고려해야 할 때, 어느 한 목적의 최적치가 다른 목적에서는 최적치가 아닌 경우 이 목적들 사이에서 보상하기 위한 트레이드 오프 결정이 이루어져야 한다. 전력회사들의 궁극적 목표는 양질의 전기를 저렴하게 안정적으로 공급하고자 하는 것인 만큼, 경제적으로 안정적으로 전기를 공급하는 것이 아주 중요하다. 그러나, 경제적 운전과 안정적 운전은 둘 다 중요하지만 발전단가를 낮추어 경제적으로 전력을 공급하는 것과 전력을 정전 없이 안정적으로 공급하는 것은 서로 상반되는 성격의 목적이다. 발전 원가가 싼 발전만을 하려고 하다보면, 원자력 등의 주파수 경직성 발전기들로만 구성되어 주파수제어가 어렵게 되고 발전력 지역 편중화 현상으로 전력계통의 불안정성을 일으킬 수 있다. 경제적 전력생산을 위한 최적 운전점과 계통안정성을 위한 최적 운전점은 서로 일치하지 않으므로, 두개의 목적을 적정하게 달성하기 위한 최선의 보상해가 구해져야 한다. 이와 같이

두개 이상의 목적을 가지게 되면 다목적 최적화 문제가 되는데, 일반적인 하나의 목적을 갖는 모델과는 크게 다르다. 하나의 목적을 갖는 문제에서는 유일해의 개념이지만, 여러 가지 판정기준을 고려하는 다목적 문제에서는 최선의 보상해의 개념으로 바뀌게 된다.

다목적 최적화 기법은 예산계획, 수자원 관리, 수송계획 등의 여러 분야에 적용되어 왔고, 전력계통분야에도 적용되었는데 전력계통의 운용 및 계획 문제와 최적 무효전력 급전문제에 활용하였다[1][2]. 지금까지의 연구들은 주로 최소자승법 등에 의해 수치적으로 계산한 것이 많은데, 각각의 판정기준에 대한 스케일링이나 웨이팅이 수학적인 값으로서 물리적인 의미를 부여하기 어려우며, 광범위한 전력시스템에서 임의로 변화하는 부하와 발전력 등 여러 가지 구성인자들이 랜덤하게 변화하는 환경에서는 그 값이 최선의 해와는 상당한 차이가 발생하게 된다. 이러한 것들을 고려하여 새로운 시도로 S 모델 Learning Automata 기법을 적용하고자 한다.

Learning Automata는 랜덤한 값을 갖는 변수들의 프로세스인 마르코프 프로세스(Markov process)의 모델링에 기초하여, 입출력의 결과에 따라 스스로 학습해 나가는 자동장치인데, Learning Automata 의 이론과 기술이 근래에 크게 진전되었다. 이 기법은 확률이론과 마르코프 프로세스의 수학적 기법에 근거하여 발전되어 왔는데 Tsetlin에 의한 임의의 환경에서 동작하는 한정된 Automata의 연구가 이 분야의 선구자적인 연구이다[3]. 그 이래로, 비교적 적용하기가 용이한 천이행렬이 고정된 Fixed Structure Automata가 먼저 연구되었는데, 한정된 메모리의 결정 이

* 正 會 員 : 仁川大 工大 電氣工學科 副教授 · 工博

** 正 會 員 : 서울大 工大 電氣工學部 教授 · 工博

接受日字 : 1999年 12月 28日

最終完了 : 2000年 3月 17日

론을 제시하였고[4], 학습하는 논리구조에 대하여 연구하였다[5]. 그리고, 입력에 기초해서 천이확률이나 실행확률을 개선시키기 위해 구조(Structure)가 변화하는 Variable Structure Learning Automata가 연구되어 왔는데 수학적으로 경신하는 알고리즘과 이에 관한 여러 가지 스킴(Scheme)이 제시되었다[6][7]. 회로망연계시스템에서 Learning Automata의 수렴특성이 향상되는 기법을 연구하였고[8], 시간과 함께 실행(Action)의 수가 변하는 경우에서의 최적화를 위한 Automata의 기법을 제시하였다[9]. P 모델 Learning Automata 기법을 전력시스템 운용에 적용해 보고자하는 연구가 시도되었다[10][11]. Variable Structure Learning Automata 기법들은 각각의 실행(actions)에 대해 확률이 어떻게 경신되느냐에 따라 P 모델, Q 모델, S 모델로 구분된다. P 모델은 각 실행 순간에서의 Automata 입력으로서 만족스러운 결과이면 0 그렇지 않으면 1의 두 가지 값을 가지게 되는데 반해, Q 모델에서는 0과 1사이의 한정된 개수의 값들을 갖게 된다. S 모델은 더 일반적인 표현으로 0과 1사이의 연속적인 값을 갖는다.

본 논문에서는 이러한 수학적 모델링과 확률이론에 기초한 Learning Automata 기법들 중에서 일반적인 모델인 S 모델 Learning Automata 기법을 전력시스템에 적용하고 그 결과를 검토하며, 전력시스템에 이 S 모델 Learning Automata 기법의 적용 가능성을 제시한다. 전력시스템 운용을 위한 두 가지 목적의 성능지수는 경제운전을 위한 발전비용의 최소화, 전력시스템 안정도향상을 위한 미소신호 안정도 관점에서의 모우드 성능지수(Modal Performance Measure)의 최소화이며, 간단한 전력시스템 모델을 사용하여 분석한다.

2. Learning Automata 특성

2.1 개요

스토캐스틱 프로세스는 어떤 표본공간에서 정의된 랜덤 변수 $\{X(t), t \in T\}$ 의 군들로 이루어진다. 셋트 T는 프로세스의 인덱스셋인데, 이 T가 셀 수 있는 갯수의 많은 구성요소들을 가지고 있으면 그 스토캐스틱 프로세스는 이산정수 프로세스이며, 무한히 많은 수의 요소들이 있으면 연속정수 프로세스이다. 어떤 시간의 랜덤변수의 값이 바로 직전의 값에만 종속되고 그 이전의 값에는 종속되지 않는 경우의 이산정수의 스토캐스틱 프로세스가 마르코프 프로세스(Markov process)이다. Learning Automata는 확률이론과 마르코프 프로세스의 수학적 기법에 근거하여 발전되어 왔는데, 허용할 수 있는 실행의 셋트로부터 최적의 실행을 결정하는 과정을 내포하고 있으며, 확률적으로 동작하는 시스템과 관련되어 있다. Learning Automata의 학습과정을 객관적으로 판단하기 위해서, 그 동작의 정량적인 기준치를 정하는 것이 필요하다. 학습이 평가될 수 있는 하나의 총체적인 방법은 순전한 우연으로 일어나는 상황과의 비교에 의해서 평가하는 것이다. r 개의 실행수를 가지고 있다고 가정하면, 그때 n 단계에서의 실행확률 벡터 $p(n)$ 은

$$p_i(n) = \frac{1}{r} \quad i=1, 2, \dots, r \quad (1)$$

로 된다. 그리고, r 개의 실행들이 각기 페널티확률 $\{c_1, c_2, \dots, c_r\}$ 을 가지고 있는 임의환경이 주어져 있을 때, 그 실행확률 벡터에 대한 평균 페널티인 $M(n)$ 의 양은 아래와 같이 정의되며 여러 Automata를 비교할 때 유용한 역할을 행한다.

$$M(n) = E[\beta(n)|p(n)] = \sum_{i=1}^r E[\beta(n)|\alpha(n) = \alpha_i] Pr[\alpha(n) = \alpha_i] \quad (2)$$

여기에서 E는 기대치(Expectation), $\alpha(n)$ 은 n 단계에서 수행하는 실행(Action), α_i 는 여러 실행들 중의 하나인 실행 i를 의미한다. β 는 Automaton에의 입력으로서 만족스러운 응답인 경우는 0, 불만족스러운 응답인 경우는 1의 값을 가진다.

그리고, 순전한 우연에 의한 Automaton에 의한 $M(n)$ 은 아래와 같이 상수인 M_0 로 표기된다.

$$M_0 = \frac{1}{r} \sum_{i=1}^r c_i \quad (3)$$

Automaton이 순전한 우연보다 더 잘 동작하기 위해서는 $n \rightarrow \infty$ 에 접근할 때, 그것의 평균 페널티가 적어도 M_0 보다 작아야 한다. $M(n)$ 은 랜덤 변수이므로 $E[M(n)]$ 과 M_0 를 비교해야 한다.

$$E[M(n)] = E[E[\beta(n)|p(n)]] = E[\beta(n)] \quad (4)$$

여기서 $E[M(n)]$ 은 단순히 Automaton에의 평균입력임을 알 수 있다.

그리고,

$$\lim_{n \rightarrow \infty} E[M(n)] < M_0 \quad (5)$$

이면 이 Learning Automaton은 적당하다(Expedient).

$E[M(n)]$ 이 최소값이 되도록 하는 것이 자주 요구된다. r 개의 실행들이 각기 페널티확률 $\{c_1, c_2, \dots, c_r\}$ 을 가지고 있는 임의환경이 주어져 있을 때,

$$\inf M(n) = \inf_{p(n)} \left\{ \sum_{i=1}^r c_i p_i(n) \right\} = \min \{c_i\} \equiv c_i \quad (6)$$

이면, 이 Automaton은 최적이다. 또, 모든 n과 모든 $p_i(n) \in [0, 1]$ 와 모든 가능한 셋트 $\{c_i\}$ 에 대해서

$$E[M(n+1)|p(n)] < M(n) \quad (7)$$

가 성립하면 절대적으로 적당하며(Absolutely Expedient), 임의의 환경과 임의의 초기조건에 대해서도 바람직한 동작 특성을 갖게 된다.

Learning Automaton은 환경과의 상호작용에 기초하여 실행의 시퀀스를 발생시킨다. Variable Structure Learning Automata의 경우 확률적인 정보에 근거해서 실행을 선택하

여 행하고 만족스러운 결과나 아니냐에 따라서 천이확률을 경신하여 최선의 해를 찾아가도록 하는데, 여러 가지 알고리즘의 스킴(Scheme)으로서 $R-P$ 스킴, $R-\epsilon P$ 스킴, $R-I$ 스킴 등이 있다. 실행확률은 천이확률행렬의 표현으로 변환이 가능하므로 실행확률 경신과 천이확률 경신은 같은 의미이다. 그리고, Variable Structure Learning Automata 기법 중에서 수행한 실행(actions)의 결과에 일치하여 확률이 어떻게 경신되느냐에 따라 P 모델, Q 모델 및 S 모델 Learning Automata로 나누어 진다[7].

2. 2 S 모델 Learning Automata

P 모델 Learning Automata에서는 각 실행에 대해 만족스러운 결과이면 0, 그렇지 않으면 1인 두가지의 값만을 그것의 응답으로 가지는데, 그 시스템의 출력 평가를 너무 극단적으로 하는 셈이다. 따라서 각 입력의 응답에 따라서 좀더 세분화된 값들을 지정하는 Q 모델과 S 모델이 제시되게 되었다. Q 모델에서는 그 Automaton의 실행 α_i 에 일치해서 2개 이상의 이산된 출력 값들을 갖는다. 이 출력 값을 양자화하고 정규화함으로써 [0,1]사이의 간격 안에서 한정된 개수의 값들을 갖게 된다. S 모델에서는 그 Automaton의 실행 α_i 에 일치해서 정규화 함으로써 만족과 불만족의 중간 임계점에서 0.5의 값을 갖고 [0,1]사이의 간격 안에서 연속적인 값들을 가질 수 있다. 이 P, Q, S 모델은 주어진 실행 α_i 에 대해서 β^i 에 따른 확률밀도함수의 특성으로 구분될 수 있다. 이 것이 그림 2-3에 보여져 있는데, 가로축이 만족도를 나타내는 β^i 의 값이고 세로 축이 그의 발생확률이다. P 모델에서는 $\beta^i=1$ 이 될, 즉 만족스럽지 않은 응답이 나타날 확률이 c_i 이고, $\beta^i=0$ 이 될, 즉 만족스러운 응답이 나타날 확률이 $1-c_i$ 로서 이 두가지 값밖에 없으므로 그림의 P 모델에 이것이 그려져 있다. Q 모델에서는 β^i 가 [0,1]사이의 간격 안에서 여러 가지의 값들을 가지게 되고, S 모델에서는 β^i 가 [0,1]사이에서 연속적인 값들을 가지는 것이 그림 1에 개념적으로 그려져 있다.




그림 1 P, Q, S 모델의 β^i 에 따른 확률 밀도 함수 비교
Fig. 1 Comparison of probability density functions of β^i in P, Q, S models

r 개의 실행을 가지는 S 모델에서 평균 페널티 $M(n)$ 은 아래와 같이 표현될 수 있다.

$$M(n) = E[\beta(n)|p(n)] = \sum_{i=1}^r E[\beta(n)|p(n), \alpha(n) = \alpha_i] Pr[\alpha(n) = \alpha_i] = \sum_{i=1}^r s_i p_i \quad (8)$$

여기서 $s_i = E[\beta(n)|\alpha(n) = \alpha_i]$ 이다.

모든 실행 확률이 같고 순전히 우연으로 동작하는 Automaton의 평균 페널티는 아래와 같이 표현된다.

$$M_0 = \frac{1}{r} \sum_{i=1}^r s_i \quad (9)$$

앞에서와 유사하게

$$\lim_{n \rightarrow \infty} E[M(n)] < \frac{1}{r} \sum_{i=1}^r s_i \quad (10)$$

이면 이 Learning Automaton은 적당하다(Expedient). 또,

$$\lim_{n \rightarrow \infty} E[M(n)] = \min_i \{s_i\} = s_i \quad (11)$$

이면, 이 Automaton은 최적이다[7].

S 모델에서 실행확률을 경신하기 위한 일반적인 스킴은 아래와 같다.

$$p_j(n+1) = p_j(n) + \beta(n) [b/(r-1) - b p_j(n) - [1 - \beta(n)] a p_j(n)] \quad \text{for } \alpha(n) \neq \alpha_j \quad (12)$$

$$p_j(n+1) = p_j(n) - \beta(n) b p_j(n) + [1 - \beta(n)] a (1 - p_j(n)) \quad \text{for } \alpha(n) = \alpha_j \quad (13)$$

여기서 a는 상 정수(Reward parameter)이고, b는 페널티 정수(Penalty parameter)이다. 바람직한 실행이 된 경우에 그 실행을 유도하는 상 정수를, 그리고 바람직하지 못한 경우에는 그 실행을 억제하는 페널티 정수를 선형적으로 적용하게 된다. 상벌이 같은 크기인 a=b 일 때, S 모델을 의미하는 S와 선형을 의미하는 L을 덧붙여서 SL_{R-P} 스킴(Scheme)이라 부르고, 상 정수의 값은 주되 벌은 가하지 않는 b=0 일 때, SL_{R-I} 스킴이라 부른다. 그리고, 페널티 정수 b를 a보다 작게 하는 $SL_{R-\epsilon P}$ 스킴이 있다. 일반적으로 SL_{R-I} 스킴이 SL_{R-P} 스킴보다 수렴 특성이 빠르나, 확률 1의 값으로 흡인 상태(Absorbing state)로 수렴하게 되어 최적값으로 수렴하지 않을 가능성이 존재한다. $SL_{R-\epsilon P}$ 스킴은 이점들을 보완한다.

위의 벡터 $p(n)$ 은 랜덤벡터이다. 주어진 시스템 환경의 페널티 확률이 상수의 값이고 g와 h가 단계의 수 n에 무관하면, 확률 $p(n+1)$ 은 확률 $p(n)$ 에 의해 완전히 결정되며, 여기서 $\{p(n)\}$ 은 이산시간의 제차 마르코프 프로세스가 된다.

S 모델에서도 P 모델에서의 수식과 이론들이 그대로 유사하게 적용되는데, 수식과 실행확률 경신 알고리즘의 표현에서 약간의 차이가 있다. S 모델은 P 모델 보다 $\beta(n)$ 의 값을 결정하는 과정이 추가되므로 약간 더 복잡하고 약간 더 시간이 걸리지만, 지정된 함수로부터 값을 읽어오는 것

이기 때문에 계산 시간 면에서 조금 더 소요되는 정도이다. P 모델, Q 모델, S 모델들은 적용 이론이 유사하지만, 만족·불만족의 정도가 주어진 임계점을 한계로 딱 구분되는 것이 아니라 그 정도가 다양하고 다 다를 것이기 때문에 S 모델이 제일 실제에 부합되는 모델에 가깝다고 할 수 있다.

3. 전력시스템의 안정적 운용

동적 전력시스템의 수학적 모델은 동적 기기 및 제어장치의 미분방정식, 발전기 고정자의 대수방정식, 회로망의 대수방정식 등으로 구성되며, 아래와 같이 비선형 미분대수방정식 형태로 나타낼 수 있다.

$$\frac{dX}{dt} = f(X, Y), \quad 0 = g(X, Y) \quad (14)$$

여기서 X는 상태변수들을 나타내고 Y는 모션전압, 위상각 등의 회로변수들을 나타낸다. 평형점 부근에서 작은 외란 발생시 위의 미분대수 방정식을 선형화하여 정리하면,

$$\frac{d\Delta X}{dt} = (A - BD^{-1}C)\Delta X = \tilde{A}\Delta X \quad (15)$$

$$\Delta Y = -D^{-1}C\Delta X = \tilde{C}\Delta X \quad (16)$$

여기서, A, B, C, D는 평형점에서 선형화된 적합한 차수를 가지고 있는 계수 행렬들이고, $\Delta X = X(t) - X_s$, $\Delta Y = Y(t) - Y_s$, 그리고 X_s 와 Y_s 는 각각 $X(t)$ 와 $Y(t)$ 의 정상상태의 값이다.

Y_r 을 Y의 기준값이라 할 때, $Z(t) = Y(t) - Y_r$ 이라 두면, 제어의 목적은 시스템 파라미터에 대한 여러 $Z(t)$ 를 최소화하는 것으로 귀결된다.

이때 $Z(t)$ 는 아래와 같이 표현될 수 있다.

$$\begin{aligned} Z(t) &= \tilde{C}\Delta X + Y_s - Y_r \\ &= \sum_{j=1}^n \tilde{C}_j \Delta X_j(t) + Z_0 \\ &= \sum_{j=1}^n Z_j(t) + Z_0 \end{aligned} \quad (17)$$

여기서,

$$\begin{aligned} Z_j(t) &= \sum_{i=1}^n Z_{j,i}(t) \\ &= \tilde{C}_j \sum_{i=1}^n (V_i \Delta X_0) U_{j,i} \cdot \exp(s_i t), \end{aligned} \quad (18)$$

Y_s 는 $Y(t)$ 의 정상상태 값, $Z_0 = Y_s - Y_r$, Z_j 는 ΔX 의 j 번째 상태에 종속하는 Z의 성분이고, $Z_{j,i}$ 는 Z_j 의 i 번째 모우드이다. U와 V는 각각 우, 좌 고유벡터들이고, $U_{j,i}$ 는 i 번째 우 고유벡터 U_i 의 j 번째 성분이다. 각 모우드의 포락선(envelope)의 감쇠를 극대화 하도록 하기 위한 모우드 성능 지수를 아래와 같이 표현할 수 있다.

$$J(P) = \sum_{j=0}^n J_j \quad (19)$$

여기서,

$$J_j = \int_0^T \sum_{i=1}^n Z_{j,i}' W_j Z_{j,i} dt \quad \text{for } j\text{th state}, \quad (20)$$

여기서 W_j 는 j 번째 상태에 대한 가중치 행렬이고, t와 *는 각각 전치와 공액복소수를 뜻한다.

위의 식 (19)-(20)으로 표현되는 모우드 성능 지수 $J(P)$ 는 파라미터 벡터 P에 관한 감도를 이용하여 최소화 될 수 있다. J의 구배(Gradient) ∇J 는 연쇄법칙(chain rule)을 사용하여 아래와 같이 표현된다.

$$\begin{aligned} \nabla J &= \frac{\partial J}{\partial P} = \sum_{j=0}^n \frac{\partial J_j}{\partial P} \\ &= \sum_{j=0}^n \sum_{k=1}^n \sum_{l=1}^n \left(\frac{\partial J_j}{\partial \tilde{A}} \right)_{k,l} \left(\frac{\partial \tilde{a}_{k,l}}{\partial P} \right) \end{aligned} \quad (21)$$

여기서, $\left(\frac{\partial J_j}{\partial \tilde{A}} \right)_{k,l}$ 은 행렬 $\left(\frac{\partial J_j}{\partial \tilde{A}} \right)$ 의 (k,l)성분이고, $\tilde{a}_{k,l}$ 은 \tilde{A} 의 (k,l)성분이다. 위 식 (17)과 식 (19)로부터

$$\begin{aligned} J_m &= \sum_{i=1}^n \left(\tilde{C}_m' W_m \tilde{C}_m^* \right) (V_i \Delta X_0)' (V_i \Delta X_0)^* \\ &\quad \cdot (U_{m,i}) (U_{m,i})^* \cdot f(\sigma_i) \end{aligned} \quad (22)$$

여기서 $f(\sigma_i) = \frac{1}{2\sigma_i} (\exp(2\sigma_i T) - 1)$, σ_i 는 고유치 s_i 의 실수부이다.

[12]에서와 같은 방식으로 진행하면,

$\Delta J_m = J_m(\tilde{A} + \Delta \tilde{A}) - J_m(\tilde{A})$ 와 [13]에서의 고유치 감도 식으로부터 ΔJ_m 은 아래 식으로 표현된다.

$$\begin{aligned} \Delta J_m &= \sum_{i=1}^n \left(\tilde{C}_m' W_m \tilde{C}_m^* \right) \\ &\quad \cdot \{ f(\sigma_i) V_i \Delta X_0 V_i' \Delta X_0^* 2 \operatorname{Re} (U_{m,i}' D_i V_i \Delta \tilde{A} U_i U_{m,i}^*) \\ &\quad + f(\sigma_i) U_{m,i} U_{m,i}^* 2 \operatorname{Re} (V_i \Delta \tilde{A} U_i V_i' \Delta X_0^*) \\ &\quad + f'(\sigma_i) \operatorname{Re} (V_i \Delta \tilde{A} U_i V_i' \Delta X_0^* U_{m,i} U_{m,i}^*) \} \end{aligned} \quad (23)$$

여기서, $f'(\sigma_i) = \frac{\partial f(\sigma_i)}{\partial \sigma_i}$,

$$D_i = \operatorname{diag} [1/(s_i - s_1), \dots, 1/(s_i - s_{i-1}), 0, 1/(s_i - s_{i+1}), \dots, 1/(s_i - s_n)]$$

$$\begin{aligned} U &= [U_1 \ U_2 \ \dots \ U_n] \\ V &= [V_1' \ V_2' \ \dots \ V_n']' \\ U &= [U_1 \ U_2 \ \dots \ U_n] = U^t \end{aligned}$$

σ_i 는 고유치 s_i 의 실수부, Re 는 그 항의 실수부를 의미한다.

행렬에는 아래와 같은 대각합(trace) 특성이 있다.

$$\operatorname{Tr}(BC) = \operatorname{Tr}(CB) = CB$$

여기서 B는 (N × 1)행렬이고 C는 (1 × N)행렬이고 Tr 은 대각합(trace)을 의미한다. 또, $\Delta J = \operatorname{Tr}(M \Delta A)$ 이면

$$\frac{\partial J}{\partial A} = M^t \text{ 으로 된다. 이 특성들을 사용하면,}$$

$$\frac{\partial J_m}{\partial \lambda} = \sum_{i=1}^n (C_m' W_m C_m^*) \cdot \{f(\sigma_i) |V_i \Delta X_0|^2 2Re([U_i \ U_m' D_i V]' U_{m,i}^*) + f(\sigma_j) |U_{m,i}|^2 2Re([UD; V \Delta X_0 V_i]' V_i^* \Delta X_0^*) + f(\sigma_i) |V_i \Delta X_0|^2 |U_{m,i}|^2 Re([U_i V_i]')\}$$

으로 표현된다.

위 식 (24)를 식 (21)에 대입하면, 파라미터 P에 대한 모우드 성능 지수의 구배를 구할 수 있다. 미소신호 안정도의 관점에서 동적안정도를 개선시키기 위해서는 앞에서 제시된 모우드 성능지수가 최소화되도록 해야한다. 최급강하법을 적용하면 쉽게 그 해를 구할 수 있다. 본 논문에서는 여자기로서 [12], [14]에서와 같은 IEEE type 1 여자기를 사용하였고 사용된 동적모델의 수식도 [12]에서와 같다.

4. 전력시스템의 경제적 운용

전력시스템의 경제운용의 목적은 수화력 발전소의 조합 및 부하배분을 적절히 실시해서 발전비용을 최소로 하는데 있다. 전력시스템을 경제적으로 운용한다는 것은 그 에너지 비용이 연간 약 3조 5천억원에 이르는 엄청난 비용이며, 그 비용의 대부분을 차지하는 연료를 전적으로 외국으로부터의 수입에 의존하고 있는 우리나라 형편으로 볼 때 극히 중요한 문제이다. 전력시스템은 높은 신뢰도를 가진 양질의 전력을 경제적으로 공급함을 목적으로 해서 운용되지 않으면 안되는데, 수화력 병용시스템의 경제적 발전계획, 발전설비의 정기보수계획 등의 장기운용계획과 수화력 병용시스템의 경제운용계획, 발전기의 경제적 기동정지계획 등의 단기운용계획을 수립하고 이들의 운용계획에 의거해서 최적의 경제운용을 위한 순시적인 운용제어가 수행된다.

본 논문에서는 문제를 보다 단순화하여 분석을 용이하게 하기 위해, 경제운용을 위한 비용함수가 발전출력의 2차 함수로 표현되는 발전비용의 전체 합으로써 주어진다 가정한다. 그 때 발전비용은 아래와 같이 표현될 수 있다.

$$C(P_{sg}) = \sum_{k \in G} (a_k + b_k P_{gk} + c_k P_{gk}^2) \tag{25}$$

여기서 G: 스윙 모선을 포함한 발전기 모선의 집합

C: 발전기 함수

a_k, b_k, c_k : 발전기의 비용계수

P_{gk} : 발전기 모선 k의 발전출력

P_{sg} : 스윙 모선을 포함한 발전기 모선의 발전출력

위 수식에서 선로손실을 포함하고 있는 스윙 모선의 발전 비용이 함께 계산되므로 전력시스템의 선로손실도 반영되게 된다.

5. 전력시스템에의 적용 및 시뮬레이션 결과

5. 1 Learning Automata 기법 적용을 위한 전력시스템 모델

분석계통으로는 그림 2에 보여져 있는 6모선 계통을 사용하였으며, 모선 1이 스윙모선이다. 선로와 모선 데이터는 표 1과 표 2에 보여져 있다. 발전기의 비용계수는 1MW 당 $a_1=52.0, b_1=1.12, c_1=0.0021, a_2=88.0, b_2=1.91, c_2=0.0035$ 으로 하여, 스윙모선 1의 발전기가 모선 2의 발전기보다 좀더 발전 비용이 싼 것으로 하였다. 이 전력시스템에서 발전기 2의 발전량이 결정되면 스윙모선 1의 발전기의 발전량은 자동적으로 결정되기 때문에 최적 경제운용 문제는 최적이 되는 발전기 2의 발전량을 결정하는 것으로 된다. 발전비용을 최소화하는 발전기 2의 발전량을 구하면 $P_{GE}^* = 0.072$ p.u.이고, 계통안정도를 위해 제시된 모우드 성능지수를 최소화하도록 하는 발전기 2의 발전량을 구하면, $P_{GS}^* = 0.417$ p.u.이다. 부하는 표준오차 3%의 가우스 정규분포로서 랜덤하게 변한다고 가정하였으며, 각 모선의 부하변화율은 같고 부하 역률은 일정하게 유지된다고 가정하였다. 또, 미소신호 안정도에서의 동적안정도 분석을 위해서 각 부하가 1%의 순시 변동이 발생한 것으로 가정하고 모의하였다.




그림 2 6모선 전력 시스템
Fig. 2 6 bus power system

표 1 선로 데이터

Table 1 Line data

Line number	From bus number	To bus number	Line impedance (p.u.)	
			R	X
1	1	6	0.135	0.962
2	1	4	0.10	0.756
3	4	6	0.12	0.795
4	5	6	0.11	0.873
5	2	5	0.142	0.983
6	2	3	0.181	1.21
7	3	4	0.05	0.41

표 2 모선 전압 및 발전/부하 초기 데이터
Table 2 Initial data of bus voltage, generation and load
(단위; p.u.)

Bus number	Voltage magnitude	Voltage angle	P	Q
1	1.0	0.0		
2	1.0		0.32	
3			-0.27	-0.06
4			0.0	0.0
5			-0.19	-0.05
6			-0.28	-0.03

5. 2 S 모델 Learning Automata 적용시의 시뮬레이션 결과

여기에서 사용하는 전력시스템에서 최적 경제운영 문제는 최적이 되는 발전기 2의 발전량을 결정하는 것이 되므로, 발전기 2의 경제적운영 최적치와 안정적운영 최적치 사이의 간격을 등간격으로 10등분하여 양단의 경제적운영 최적치와 안정적운영 최적치를 포함한 11개의 실행들(actions)을 보상해의 후보로 선택하였다. 11개의 실행들의 P_{G2} 값은 표 3에 보여져 있다. 본 연구의 간단한 전력시스템에서의 경제운영 문제는 이들 실행들 중에서 주어진 기준을 가장 높게 만족하는 보상해, 곧 발전기 2의 발전량을 구하는 것이 된다.

경제적운영과 안정적운영을 위한 최선의 보상해를 구하기 위해 만족스러운 값이나 아니냐의 기준이 되는 임계값은 경영목표와 여러 조건들을 종합적으로 고려하여 결정되어야 한다. 여기에서는 경제적운영과 안정적운영을 위한 각각의 최적치에 대해서 각각에 해당하는 값으로 나눈 값이 경제적운영으로는 최적치의 90%, 안정적운영으로는 최적치의 50%로 정하여 이 기준을 넘으면 만족하는 쪽으로 되도록 하였는데, 이 값을 기준으로 시그모이드 함수를 적용하여 S 모델에 적용하였다.

표 3 실행들의 P_{G2} 값(단위 p.u.)

Table 3 P_{G2} values of actions

실행	실행1	실행2	실행3	실행4	실행5	실행6
P_{G2}	0.072	0.106	0.141	0.175	0.210	0.244
실행	실행7	실행8	실행9	실행10	실행11	
P_{G2}	0.279	0.313	0.348	0.382	0.417	

상정수와 페널티 정수의 값은 시행착오법으로 적절한 값을 선택하게 된다. 상정수의 값이 증가 해 감에 따라 수렴속도가 빨라지는데 반해 진동하는 폭이 점차 증대되어 가는데 너무 커지면 오히려 수렴이 어렵게 된다. 본 연구에서 상정수는 $a=0.02$, 페널티 정수는 SL_{R-P} 스킴에서 $b=0.02$, SL_{R-EP} 스킴에서 $b=0.002$ 를 적용하였다. 시뮬레이션결과로서 가장 높은 확률로 수렴하는 해(p_5)와 그렇지 않은 다른

해(p_{10})의 400회의 시도횟수(n)에 따른 확률계적들과 평균 페널티의 양 $M(n)$ 의 궤적들이 각 스킴별로 보여져 있다.

• SL_{R-P} 스킴의 분석

S 모델의 SL_{R-P} 스킴에서, 가장 높은 확률로 수렴하는 해인 실행 5를 수행할 확률(p_5)의 궤적이 그림 3에 보여져 있다. 처음에는 순전히 우연에 의한 확률과 같은 0.09 정도의 확률에서 시도횟수가 증가함에 따라 스스로 학습해 가며 0.9 정도의 1에 가까운 확률로 잘 수렴해 감을 알 수 있고 Q 모델과 유사한 결과를 보여주는데, SL_{R-EP} , SL_{R-I} 스킴들에 비해서는 확률궤적이 상대적으로 크게 진동하면서 증가 해 감을 알 수 있다. 그림 4에서는 해가 아닌 다른 실행, 여기서는 실행 10의 수행확률(p_{10})의 궤적을 보여주는데, 처음에는 순전히 우연에 의한 확률과 같은 0.09 정도의 확률에서 시작하여 시도횟수가 증가함에 따라 확률 0으로 떨어져 가고 있음을 보여준다. 모든 실행들의 수행확률의 합이 1이어야 하므로, 어느 한 실행의 확률이 1로 접근해 가면 다른 실행들의 확률은 0으로 접근할 수밖에 없다. 그림 5에서는 평균 페널티의 양 $M(n)$ 이 시도횟수가 증가함에 따라 변해 가는 궤적을 보여준다. 초기의 0.414의 값에서 시작하여 0.05의 값으로 수렴하여 가는 것을 보여 주는데, 평균 페널티의 양이 작을수록 양호한 것이므로, 만족한 성능을 보여줌을 알 수 있다.

• SL_{R-EP} 스킴의 분석

S 모델의 SL_{R-EP} 스킴에서는, 상정수는 $a=0.02$, 페널티 정수는 $b=0.002$ 를 적용하였는데, 가장 높은 확률로 수렴하는 해인 실행 5를 수행할 확률의 궤적이 그림 6에 보여져 있다. 처음에는 순전히 우연에 의한 확률과 같은 값에서 시작하여 시도횟수가 증가함에 따라 스스로 학습해 가며 SL_{R-P} 스킴보다 더 신속하게 덜 진동하며 1에 가까운 확률로 잘 수렴해 감을 보여준다.

그림 7과 그림 8에서는 해가 아닌 실행 10의 수행확률(p_{10})의 궤적과 평균 페널티의 양 $M(n)$ 의 궤적을 보여주는데, SL_{R-P} 스킴보다 더 신속하게 덜 진동하며 잘 수렴해 감을 보여준다.

• SL_{R-I} 스킴의 분석

S 모델의 SL_{R-I} 스킴에서도 상정수는 $a=0.02$, 페널티 정수는 $b=0.0$ 을 적용하였는데, 가장 높은 확률로 수렴하는 해인 실행 5를 수행할 확률의 궤적이 그림 9에 보여져 있다. 앞에서의 분석과 유사하지만 SL_{R-P} , SL_{R-EP} 스킴보다 좀 더 신속히 덜 진동하면서 1에 가까운 확률로 잘 수렴해 감을 알 수 있다.

그림 10에서는 해가 아닌 실행 10의 수행확률(p_{10})의 궤적을 보여주는데, 처음에는 순전히 우연에 의한 확률에서 시

작하여 시도횟수가 증가함에 따라 확률 0으로 잘 떨어져 가고 있음을 보여준다.

그림 11에서는 평균 페널티의 양 $M(n)$ 이 시도횟수가 증가함에 따라 변해가는 궤적을 보여준다. SL_{R-P} , SL_{R-EP} 스킴들보다 더 신속히 떨어져 감을 보여 주는데, 수렴 특성에서 좋은 성능을 보여줌을 알 수 있다.

• SL_{R-P} 스킴과 SL_{R-I} 스킴의 비교

S 모델의 지금까지의 결과들을 비교하면 SL_{R-EP} 스킴은 SL_{R-I} 스킴과 상당히 유사하면서 SL_{R-P} 스킴과 SL_{R-I} 스킴의 중간 정도의 특성을 나타내므로 이것은 생략하고, SL_{R-P} 스킴과 SL_{R-I} 스킴들의 동작 특성을 비교해 본다. 그림 12~14에서 실행 5를 수행할 확률, 실행 10을 수행할 확률, 평균페널티의 양들의 궤적들이 각기 나타나 있다. 그림 12에서 보면, SL_{R-I} 스킴이 가장 빨리 1 가까이로 수렴하고, 수렴시의 진동도 제일 적다는 것을 알 수 있다. 반면에 SL_{R-P} 스킴은 수렴속도가 제일 느리고, 수렴시 진동 폭도 제일 큼을 보여준다. 그림 13, 그림 14에서는 각기 실행 10을 수행할 확률과 평균페널티의 양들의 궤적들을 비교하고 있는데, 그림 12와 유사한 특성을 보여준다. SL_{R-I} 스킴이 가장 빨리 수렴하고, 수렴시의 진동도 제일 적으며, 반면에 SL_{R-P} 스킴은 수렴속도가 제일 느리고, 수렴시 진동 폭도 제일 큼을 알 수 있다.

여러 가지 스킴들을 사용한 위의 수행결과로부터 실행 5 ($P_{Q2}=0.210$ p.u.)를 수행할 확률(b_5)의 궤적이 가장 높은 확률로 수렴하기 때문에 $P_{Q2}=0.210$ p.u.일 때가 주어진 기준을 가장 높게 만족시키는 해임을 알 수 있다. 이 때의 계통상태의 조류계산 결과를 나타내면 표 4와 같다. 경제적 운용 최적치와 안정적 운용 최적치의 간격을 더 세분하거나 가장 만족스러운 해 주변을 다시 세분하여 같은 과정을 반복함으로써 더 세밀하게 결정할 수 있으나, 성능지수의 차이가 조금밖에 발생하지 않는데 비해 계산량이 더욱 많아지는 단점이 있다. 임계값이 약간은 유동적인 것을 감안하면, 실제 적용시에 이 정도의 해로서도 충분한 정도의 만족스러운 해라고 볼 수 있다.

표 4 전력계통의 조류계산 결과

Table 4 Load flow results of the power system

(단위: p.u.)

Bus number	Voltage magnitude	Voltage angle(rad)	P	Q
1	1.0	0.0	0.565	0.138
2	1.0	-0.221	0.210	0.116
3	0.935	-0.318	-0.27	-0.06
4	0.947	-0.223	0.0	0.0
5	0.920	-0.347	-0.19	-0.05
6	0.928	-0.284	-0.28	-0.03

6. 결 론

전력시스템의 경제적운용과 안정적 운용은 서로 상반되는 목적이고, 전력시스템의 부하는 수시로 랜덤하게 변하는 특성을 가지고 있는데, 이러한 점들을 고려하여 전력시스템 운용의 최선의 보상해를 구하기 위해 S 모델 Learning Automata 기법을 적용하였다. 6모선 계통을 사용하였고, 발전기 2의 경제적운용 최적치 P_{Q2}^* 와 안정적운용 최적치 P_{Q2}^* 사이의 간격을 등간격으로 10등분한 실행들 중에서 주어진 기준을 가장 높게 만족하는 보상해를 구하였다. 시도횟수가 400회인 시뮬레이션 결과 S 모델 Learning Automata의 각 스킴 모두 실행5($P_{Q2}=0.210$ p.u.)의 확률이 1 가까이로 잘 수렴해 감을 알 수 있으며, $P_{Q2}=0.210$ p.u.일 때가 주어진 기준을 가장 높게 만족시키는 해임을 알 수 있다. 각 스킴들을 비교해 보면, SL_{R-P} 스킴이 수렴속도가 제일 느리고, 수렴시 진동 폭도 제일 크며, SL_{R-I} 스킴이 가장 빨리 수렴하고, 수렴시의 진동도 제일 작으나 흡인 상태로 수렴하게 되어 최적값으로 수렴하지 않을 가능성이 존재한다. SL_{R-EP} 스킴은 이점들을 보완하며, 수렴속도도 빠르다.

본 논문은 전력시스템에 S 모델 Learning Automata 기법의 적용 가능성을 제시한다. 랜덤하게 변화하는 환경에서 서로 상반되는 목적함수를 동시에 고려하여 결정해야 하는 경우에, 이 S 모델 Learning Automata 기법이 임의로 변화하는 환경에서 스스로 학습해 가며, 주어진 기준을 확률적으로 가장 높게 만족하는 보상해를 제시하여 줌을 보여준다.

감사의 글

본 논문은 한국전력공사 지원(기초전력공학공동연구소 관리)에 의한 연구 결과임 (과제번호 : 98-058).




그림 3 시도횟수에 따른 실행 5를 수행할 확률 (S 모델 SL_{R-P} 스킴)

Fig. 3 Probability of action 5 versus trial number




그림 6 시도횟수에 따른 실행 5를 수행할 확률 (S 모델 $SL_{R-εP}$ 스킴)

Fig. 6 Probability of action 5 versus trial number




그림 4 시도횟수에 따른 실행 10을 수행할 확률 (S 모델 SL_{R-P} 스킴)

Fig. 4 Probability of action 10 versus trial number




그림 7 시도횟수에 따른 실행 10을 수행할 확률 (S 모델 $SL_{R-εP}$ 스킴)

Fig. 7 Probability of action 10 versus trial number




그림 5 시도횟수에 따른 평균 페널티의 양 (S 모델 SL_{R-P} 스킴)

Fig. 5 Average penalty versus trial number




그림 8 시도횟수에 따른 평균 페널티의 양 (S 모델 $SL_{R-εP}$ 스킴)

Fig. 8 Average penalty versus trial number




그림 9 시도횟수에 따른 실행 5를 수행할 확률 (S 모델 SL_{R-I} 스킴)

Fig. 9 Probability of action 5 versus trial number




그림 12 시도횟수에 따른 실행 5를 수행할 확률 비교 (S 모델)

Fig. 12 Comparison of probabilities of action 5 in each scheme




그림 10 시도횟수에 따른 실행 10을 수행할 확률 (S 모델 SL_{R-I} 스킴)

Fig. 10 Probability of action 10 versus trial number




그림 13 시도횟수에 따른 실행 10을 수행할 확률 비교 (S 모델)

Fig. 13 Comparison of probabilities of action 10 in each scheme




그림 11 시도횟수에 따른 평균 페널티의 양 (S 모델 SL_{R-I} 스킴)

Fig. 11 Average penalty versus trial number




그림 14 시도횟수에 따른 평균 페널티의 양 비교 (S 모델)

Fig. 14 Comparison of average penalties in each scheme

참 고 문 헌

[1] H.Merrill, F.Schwepe, "Multiple Objective Tradeoff Analysis in Power System Planning," *The Ninth Power Systems Computation Conference*, 1987.

[2] T.H.Jung, F.L.Alvarado, C.L. DeMarco, "Optimal Reactive Power Dispatch Based on a Multiobjective Optimization Technique," *Proc.IFAC Symposium on Power Systems and Power Plant Control*, Seoul, , pp. 106-111, Aug. 1989.

[3] M.L.Tsetlin, "On the Behaviour of Finite Automata in Random Media," *IAutomatika i Telemekhanika*, Vol. 22, pp. 1345-1354, 1961.

[4] T.M.Cover, M.E.Hellman, "The Two-Armed Bandit Problem with Time Invariant Finite Memory," *IEEE Trans. on Information Theory*, Vol.16, No.2, pp. 185-195, 1970.

[5] H.Aso, M. Kimura, "The Structures of Automata to Adapt to an Unknown Environment," *IEEE Trans. Syst., Man and Cybern.*, SMC-6, pp. 494-504, 1976.

[6] M.A.L.Thathachar, P.S.Sastry, "A New Approach to the Design of Reinforcement Schemes for Learning Automata," *IEEE Trans. Syst., Man and Cybern.*, SMC-15, pp. 168-175, 1985.

[7] K.S.Narendra, M.A.L.Thathachar, "*Learning Automata*", Prentice Hall, New Jersey, 1989.

[8] M.A.L.Thathachar, V.V.Phansalkar, "Convergence of Teams and Hierarchies of Learning Automata in Connectionist Systems," *IEEE Trans. Syst., Man and Cybern.*, Vol. 25, No. 11, pp. 1459-1469, 1995.

[9] K.Najim and A.S.Poznyak, "Multimodal Searching Technique Based on Learning Automata with Continuous Input and Changing Number of Actions," *IEEE Trans. Syst., Man and Cybern.*, Vol. 26, No. 4, pp.666-673, 1996.

[10] 이 병하, "전력시스템의 다목적 최적 운용을 위한 Learning Automata 적용에 관한 연구", *대한전기학회*, Vol.46, No.1, pp. 23-30, Jan. 1997.

[11] B.H.Lee, J.K.Park, " Multiple objective optimal operation of power system using learning algorithm", *1998 International Conference on Energy Management and Power Delivery*, Singapore, Vol.1, pp.247-252, 1998.

[12] B.H.Lee, K.Y. LEE, "Dynamic and static voltage stability enhancement of power systems", *IEEE Transactions on Power Systems*, Vol.8, No.1, pp.231-238, 1993.

[13] T.R.Crossley and B. Porter, " Eigenvalue and eigenvector sensitivities in linear systems theory", *Int.J.Control*, vol. 10, pp.163-170, 1969

[14] P.M.Anderson, A.A.Fouad, *Power System Control and Stability*, Ames, IA, The Iowa State University Press, 1977.

저 자 소 개



이 병 하 (李 丙 河)

1954년 7월 12일생. 1978년 서울대 공대 전기공학과 졸업. 1980년 동 대학원 전기공학과 졸업(석사). 1991년 미국 Pennsylvania 주립대 전기공학과 졸업(공학박). 1979 ~ 1994년 한국전력공사 기술연구원 선임연구원.

현재 시립 인천대 공대 전기공학과 부교수
Tel : 032-770-8437, Fax : 032-765-8118
E-mail : bhlee@lion.inchon.ac.kr



박 종 근 (朴 鍾 根)

1952년 10월 21일생. 1973년 서울대 공대 전기공학과 졸업. 1979년 일본 동경대 대학원 전기공학과 졸업(석사). 1982년 일본 동 대학원 전기공학과 졸업(공학박). 현재 서울대 공대 전기공학부 교수, 당 학회 국제이사, 기초전력공학공동연구소장.

현재 시립 인천대 공대 전기공학과 부교수
Tel : 02-880-7241, Fax : 02-883-0827
E-mail : jkpark@plaza.sun.ac.kr