확장칼만필터에 의하여 학습된 다층뉴럴네트워크를 이용한 헬리오스타트 태양추적오차의 모델링

Modeling of Heliostat Sun Tracking Error Using Multilayered Neural Network Trained by the Extended Kalman Filter

이 상 은, 박 영 칠*
(Sang Eun Lee and Young Chil Park)

Abstract: Heliostat, as a concentrator reflecting the incident solar energy to the receiver located at the tower, is the most important system in the tower-type solar thermal power plant, since it determines the efficiency and performance of solar thermal plower plant. Thus, a good sun tracking ability as well as its good optical property are required. In this paper, we propose a method to compensate the heliostat sun tracking error. We first model the sun tracking error, which could be measured using BCS (Beam Characterization System), by multilayered neural network. Then the extended Kalman filter was employed to train the neural network. Finally the model is used to compensate the sun tracking errors. Simulated result shows that the method proposed in this paper improve the heliostat sun tracking performance dramatically. It also shows that the training of neural network by the extended Kalman filter provides faster convergence property, more accurate estimation and higher measurement noise rejection ability compared with the other training methods like gradient descent method.

Keywords: heliostat, sun tracking error, extended Kalman filter, multilayered neural network, error compensation

I. 서론

타워형 태양열 발전시스템(tower-type solar thermal system)의 헬리오스타트(heliostat)는 태양으로부터 지표면으로 입사되는 태양 열에너지를 타워 상단에 위치하는 태양열 흡수기(solar receiver)로 반사시키기 위한 집광장치로서 타워형 태양열 발전시스템의 효율과 성능을 결정하는 가장 중요한 시스템이며, 따라서 높은 태양추적정밀도가 요구되는 시스템이다.

헬리오스타트는 기본적으로 개루프 제어(open loop control)에 의한 태양추적을 수행한다. 따라서 헬리오스타트 태양추적정밀도는, 헬리오스타트 구동축 설치오차, 반사거울 설치오차 등과 같은 기구오차, 반사거울의 곡면오차, 수차(aberration) 그리고 반사된 광의 산란 및 굴절에 따른 오차 등과 같은 광학오차, 마지막으로 태양위치 계산 및 헬리오스타트 방위각과 고도각 계산의 정확성 등과 같은 연산오차에 영향을 받는다. 이들 헬리오스타트 태양추적오차 유발 요인들 중에서 일반적으로 헬리오스타트의 태양추적정밀도에 가장 큰 영향을 미치는 오차는 기구오차이며, 연산오차에 의한 태양추적오차는 무시할 수 있는 정도인 것으로 알려져 있다[1,2].

태양열 발전시스템의 대용량화와 이에 따른 헬리오스타트 규모 및 설치거리의 증대 등은 보다 높은 태양추적정밀도를 필요로 하게 한다. 헬리오스타트의 태양추적정밀도를 향상시키기 위하여, 태양추적정밀도에 영향을 미치는 기구적 오차 요인들에 따른 태양추적오차의 형성에 관한 해석[3-5], 반사거울 설치 방향 조정에 의한 태양추적오차의 보정[6]과 같은 연구가 수행되었으며, 폐루프 제어(closed loop control)에 의한 태양추적[7] 등이 제안되기도 하였다.

그럼에도 불구하고, 현재 상업발전 또는 실증시험을 위한 태양열 발전시스템의 헬리오스타트에는, 계산된 태양추적신호를 해당 헬리오스타트가 이전에 태양추적을 수행하는 동안 측정된 태양추적오차를 근간으로 하여 보정함으로써, 해당 헬리오스타트의 태양추적정밀도를 높이는 방법이 가장 일반적으로 사용되고 있다. 이는 현재 실증운전을 수행하고 있는 헬리오스타트가 여전히 시스템 운전 특성상 개루프 제어에 의한 태양추적을 수행하며, 아울러 오차 발생 요인의 정확한 구분 및 이에 따른 태양추적오차의 보정 등에 대한 한계가 존재하기 때문이다.

본 연구는 개루프 제어를 사용하는 1MW급 실증시험용 태양열 발전시스템[1)]의 헬리오스타트 제어를 위하여, 측정된 태양추적오차를 모델링하고 이를 이용하여 헬리오스타트가 가지고 있는 기구적 광학적 오차로부터 기인하는 태양추적오차를 보정함으로써 헬리오스타트의 태양추적정밀도를 향상시키기 위한 태양추적제어 알고리즘의 개발에 관한 것이다. 이미 언급한 것과 같이, 현재 실증 시험용 이상의 동작 성능을 갖는 헬리오스타트는 측정된 태양추적오차를 사용하여 현재 시간에서의 헬리오스타트 동작제어신호를 보정함으로써 헬리오스타트의 태양추적정밀도를 높이는 방편이 보편적으로 사용되고 있는 것으로 알려지고 있다.

* 책임저자(Corresponding Author)
논문접수: 2010. 4. 13., 수정: 2010. 5. 11., 채택확정: 2010. 5. 20.
이상은, 박영칠: 서울산업대학교 제어계측공학과
(mesia816@nate.com/ycpark@snut.ac.kr)

1) 본 연구는 현재 중국 북경 엔칭에 건설되고 있는 1MW급 태양열 발전소를 위한 기술 개발의 일환으로 수행된 것이며, 따라서 본 연구에서 사용된 일출 및 일몰 시간을 포함하는 모든 시간은 중국 북경 엔칭(동경 115o 56' 19", 북위 40o 22' 54")의 시간이다.

그러나 이와 같은 보정 방법이 현재 사용되고는 있는 것으로 알려지고는 있으나, 실제 어떤 형태의 보정 메커니즘이 사용되고 있는지 등에 관한 연구 결과가 발표된 것이 없으며, 아울러 보정된 추적정밀도가 보정 이전과 비교하여 어느 정도의 성능 향상을 이루어 졌는지 등에 관한 결과가 발표된 것이 없다.

본 연구에서는 우선 비선형성을 갖는 헬리오스타트의 태양추적오차를 확장칼만필터(extended Kalman filter)에 의하여 학습된 다층뉴럴네트워크(MNN: Multilayered Neural Network)를 이용하여 모델링하였다. 모델링된 태양추적오차는 헬리오스타트가 태양추적을 수행하는 동안 발생 가능한 태양추적오차를 예측하여, 계산된 태양추적신호를 보정하는 방편으로 사용되었다. 아울러 본 연구에서는 측정오차가 갖는 잡음에 대한 강인성 및 수렴 속도 그리고 비선형성을 갖는 태양추적오차의 모델에 적합한 뉴럴네트워크의 구조에 대한 분석을 수행하였다.

II. 헬리오스타트 태양추적제어

1. 헬리오스타트 제어시스템의 태양추적 알고리즘

일반적으로 현재 사용되고 있는 헬리오스타트 제어시스템의 태양추적 알고리즘은 그림 1과 같다. 즉 헬리오스타트 제어시스템의 태양추적시스템은 개루프 제어시스템으로서, 현재 시간과 헬리오스타트가 설치된 지점의 위도와 경도를 사용하여 태양의 방위각 A와 고도각 α를 계산한다. 헬리오스타트는 계산된 태양 위치로부터, 태양열 흡수기가 위치하고 있는 목표지점으로 태양광을 반사시키기 위한 헬리오스타트의 방위각 A_H와 고도각 α_H를 계산하며, 태양추적을 위한 서보모터 제어기는 계산된 헬리오스타트의 방위각과 고도각으로 헬리오스타트를 구동시킴으로써 헬리오스타트가 태양추적을 수행하게 된다[2].

2. 태양추적오차 보정기능을 갖는 태양추적 알고리즘

헬리오스타트의 태양추적이 개루프 제어에 의하여 이루어짐으로 인하여 헬리오스타트의 태양추적정밀도는 헬리오스타트의 기구적, 광학적 그리고 연산오차에 직접적인 영향을 받게 된다. 이는, 바꾸어 말해서, 오차 없는 정확한 태양추적은 헬리오스타트의 기구적 오차, 광학적 오차 그리고 연산 오차가 없을 경우에만 가능하다는 것을 의미한다. 태양열 발전시스템의 발전 단가를 낮추기 위한 시스템의 대형화는 보다 큰 반사면을 갖는 헬리오스타트의 사용을 필요로 하게 되었고, 따라서 헬리오스타트의 설치 및 광학 오차 역시 무시할 수 없는 크기로 존재하게 되면서, 헬리오스타트의 태양추적정밀도 향상을 위한 추가적인 수단이 필요하게 되었다.

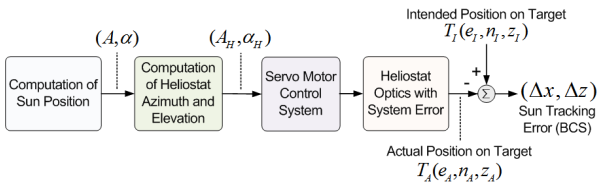

그림 1. 헬리오스타트 제어시스템의 태양추적 알고리즘.

Fig. 1. Sun tracking algorithm of heliostat control system.

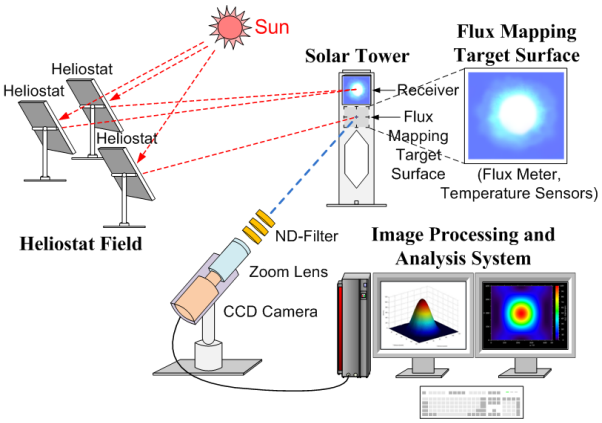

그림 2. 광학 특성 측정 및 분석 시스템.

Fig. 2. Beam characterization system (BCS).

현재 상용 또는 실증시험을 위한 시스템에서 사용되고 있는 헬리오스타트는, 그림 2와 같은 형태의 광학측정장비인 BCS (Beam Characterization System)를 사용하여 측정된 태양추적오차를, 계산된 태양추적신호에 보정함으로써 헬리오스타트가 기구적 광학적 오차를 가지고 있음에도 불구하고 요구되는 정밀도를 갖는 태양추적이 이루어지도록 하고 있다[8]. 물론 BCS는 헬리오스타트의 광학적 성능을 평가하기 위한 것으로서, 헬리오스타트로부터 반사되어 광밀도분석면(flux mapping target surface)에 형성되는 이미지를 영상처리기법을 통하여 분석함으로써 광선에너지(beam power), 광밀도 분포(flux distribution) 그리고 광선 직경(beam diameter)등을 분석하는 장비로서 사용되기도 한다. 그림 2는 일반적으로 사용되고 있는 BCS의 구조를 도식적으로 나타낸 것이다.

그림 3은 태양추적오차 보정 기능을 갖는 헬리오스타트 제어시스템의 태양추적 알고리즘을 나타낸 것이다. 그림에서와 같이, 오차 모델로 만들어진 측정된 헬리오스타트의 태양추적오차는, 해당 태양위치에서 계산된 헬리오스타트의 방위각 및 고도각을 보정하는데 사용된다. 즉 오차보정기능을 가지고 있는 헬리오스타트의 태양추적은, 계산된 헬리오타트의 방위각 A_H 및 고도각 α_H가, 오차모델을 사용하여 계산된 해당위치에서 헬리오스타트의 기구적 광학적 오차에 의하여 유발될 태양추적오차를 보상하기 위한 ΔA_H와 $\Delta\alpha_H$에 의하여 보정되며, 서보모터 제어기는 이와 같이 보정된 위치로 헬리오스타트를 구동시킴으로써 요구되는 정

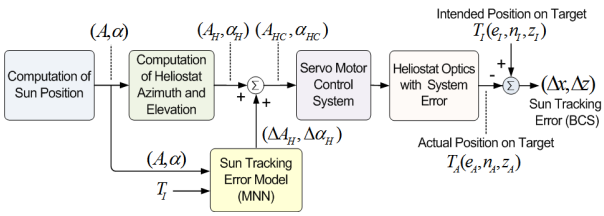

그림 3. 오차보정기능을 갖는 헬리오스타트 제어시스템의 태양추적 알고리즘.

Fig. 3. Sun tracking algorithm of heliostat control system with error compensation.

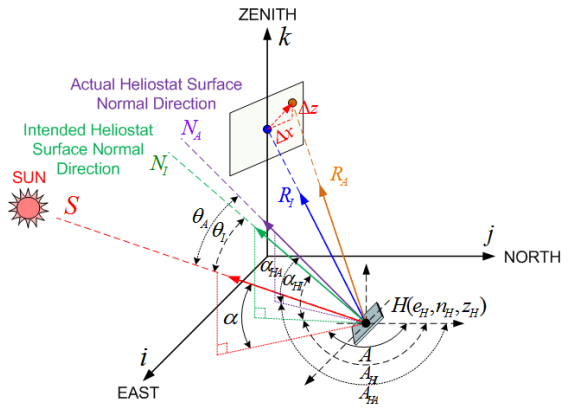

그림 4. 태양추적오차 보정을 위한 태양 및 헬리오스타트의 방위각과 고도각.

Fig. 4. Azimuth and elevation of sun and heliostat for the sun tracking error compensation.

밀도를 갖는 태양추적이 이루어지도록 한다.

그림 4는 헬리오스타트 태양추적오차 모델에 의하여 계산된 예측 태양추적오차 Δx, Δz로부터 보상 방위각 ΔA_H와 보상 고도각 $\Delta\alpha_H$를 계산하기 위하여 요구되는 과정을 기하학적으로 표현한 것이다.

헬리오스타트의 보상 방위각 ΔA_H와 보상 고도각 $\Delta\alpha_H$를 계산하기 위하여, 우선 헬리오스타트 반사면 중심 좌표 $H(e_H, n_H, z_H)$로부터 반사광이 광밀도분석면에 실제로 도달된 지점 $T_A(e_A, n_A, z_A)$를 향하는 단위 벡터 $\boldsymbol{R}_A$, 태양을 향하는 단위 벡터 $\boldsymbol{S}$, 그리고 기구 또는 광학 오차를 갖는 헬리오스타트 반사면의 실제 법선 방향을 표시하는 단위벡터 $\boldsymbol{N}_A$를 각각 다음과 같이 정의한다.

$$\boldsymbol{R}_A = \frac{(e_I+\Delta x-e_H)\boldsymbol{i}+(n_I-n_H)\boldsymbol{j}+(z_I+\Delta z-z_H)\boldsymbol{k}}{\sqrt{(e_I+\Delta x-e_H)^2+(n_I-n_H)^2+(z_I+\Delta z-z_H)^2}} = R_{Ae}\boldsymbol{i}+R_{An}\boldsymbol{j}+R_{Az}\boldsymbol{k} \quad (1)$$

$$\boldsymbol{N_A} = N_{Ae}\boldsymbol{i}+N_{An}\boldsymbol{j}+N_{Az}\boldsymbol{k} = \cos\alpha_{HA}\sin A_{HA}\boldsymbol{i}+\cos\alpha_{HA}\cos A_{HA}\boldsymbol{j}+\sin\alpha_{HA}\boldsymbol{k} \quad (2)$$

$$\boldsymbol{S} = S_e\boldsymbol{i}+S_n\boldsymbol{j}+S_z\boldsymbol{k} = \cos\alpha\sin A\boldsymbol{i}+\cos\alpha\cos A\boldsymbol{j}+\sin\alpha\boldsymbol{k} \quad (3)$$

또한 헬리오스타트 반사면 법선벡터를 기준으로 헬리오스타트를 떠난 반사광이 실제로 도달된 지점 T_A를 향하는 태양광의 입사각과 반사각을 나타내는 θ_A는 다음과 같이 정의된다.

$$\cos(2\theta_A) = \boldsymbol{S}\cdot\boldsymbol{R}_A = R_{Ae}S_e+R_{An}S_n+R_{Az}S_z \quad (4)$$

헬리오스타트 실제의 법선방향을 표시하는 단위벡터 $\boldsymbol{N}_A$는 그림 5에서와 같이 단위벡터 $\boldsymbol{R}_A$ 및 $\boldsymbol{S}$로부터 식 (5)에서와 같이 표시될 수 있다.

$$\boldsymbol{N_A} = \frac{\boldsymbol{R_A}+\boldsymbol{S}}{2\cos(\theta_A)} = \frac{(R_{Ae}+S_e)\boldsymbol{i}+(R_{An}+S_n)\boldsymbol{j}+(R_{Az}+S_z)\boldsymbol{k}}{2\cos(\theta_A)} \quad (5)$$

태양추적오차를 갖는 헬리오스타트 실제 방위각과 실제

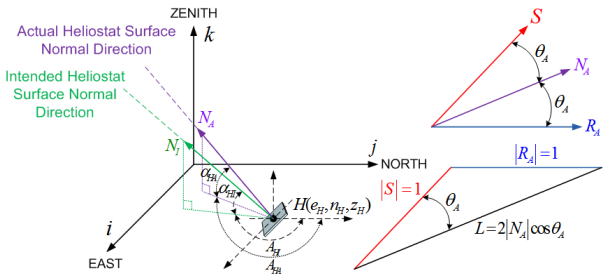

그림 5. 오차를 갖는 헬리오스타트의 법선방향 단위벡터.

Fig. 5. Unit vector of heliostat surface normal direction with sun tracking error.

고도각은 식 (2)와 식 (5)로부터 다음과 같이 표시되며, 따라서 식 (9)와 식 (10) 같이 계산된다.

$$\sin\alpha_{HA} = \frac{R_{Az}+\sin\alpha}{2\cos\theta_A} \quad (6)$$

$$\sin A_{HA} = \frac{R_{Ae}+\cos\alpha\sin A}{2\cos\theta_A\cos\alpha_{HA}} \quad (7)$$

$$\cos A_{HA} = \frac{R_{An}+\cos\alpha\sin A}{2\cos\theta_A\cos\alpha_{HA}} \quad (8)$$

$$\alpha_{HA} = \sin^{-1}\left(\frac{R_{Az}+\sin\alpha}{2\cos\theta_A}\right) \quad (9)$$

$$A_{HA} = atan2(\sin A_{HA},\ \cos A_{HA}) \quad (10)$$

오차를 갖는, 따라서 당초 목표 지점 T_I 대신 실제 지점 T_A로 태양에너지를 반사시키고 있는 헬리오스타트의 보상 방위각 ΔA_H와 보상 고도각 $\Delta\alpha_H$은 식 (11)과 같이 계산된다. 식 (12)와 식 (13)은 태양추적오차 모델을 사용하여 예측된 태양추적오차가 보정된 헬리오스타트의 방위각 A_{HC}와 고도각 α_{HC}을 나타내며, 서보모터 제어기는 계산된 헬리오스타트의 방위각 A_H와 고도각 α_H가 아닌, 식 (12)와 식 (13)으로 주어지는 위치로 헬리오스타트를 구동시키게 된다.

$$\Delta A_H = A_{HI}-A_{HA} \text{ and } \Delta\alpha_H = \alpha_{HI}-\alpha_{HA} \quad (11)$$

$$A_{HC} = A_{HI}+\Delta A_H = 2A_{HI}-A_{HA} \quad (12)$$

$$\alpha_{HC} = \alpha_{HI}+\Delta\alpha_H = 2\alpha_{HI}-\alpha_{HA} \quad (13)$$

III. 확장칼만필터에 의한 다층뉴럴네트워크의 학습

헬리오스타트 태양추적오차 모델은, 측정된 태양추적오차의 모델이며, 따라서 BCS에 의하여 측정된 그림 4의 태양추적오차 Δx, Δz와 해당 추적오차를 생성시킨 헬리오스타의 운전 조건, 즉 태양의 방위각, 고도각 그리고 목표 지점의 위치 T_I와의 상관관계를 나타내는 것이다.

본 연구에서는 확장칼만필터에 의하여 학습된 다층뉴럴네트워크를 이용하여 비선형성을 갖는 헬리오스타트의 태양추적오차를 모델링하였다.

1. 다층뉴럴네트워크(MNN)

다층뉴럴네트워크는 비선형시스템의 모델링을 위한 적합한 구조로서 동적시스템의 모델링과 제어분야에서 많이 사

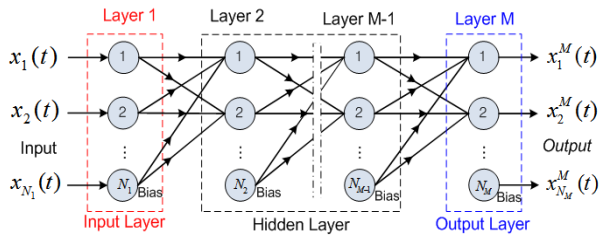

그림 6. 다층뉴럴네트워크의 구조.

Fig. 6. Structure of multilayered neural network.

용된다[9]. 그림 6은 다층뉴럴네트워크의 구조를 나타낸 것이다. 그림에서와 같이, 다층뉴럴네트워크는 여러 개의 층으로 이루어져 있으며, 각각의 층은 많은 수의 노드(node)를 포함하고 있다. 노드들은 연결가중치(connection weight)로 연결되어 있고, 각각의 노드는 입력을 받아서 이들은 더하는 합산기(summation)와 합산기의 출력을 변환하는 활성화함수(activation function)로 이루어져 있다.

다층뉴럴네트워크에서 일반적으로 사용되는 활성화함수는 시그모이드 함수이며, 식 (14)의 양극성(bipolar)을 갖는 시그모이드 함수를 나타낸 것이다.

$$f(x)=\frac{1-e^{-2x}}{1+e^{-2x}} \tag{14}$$

아울러 각 패턴에 대한 제곱오차를 나타내는 목적함수(objective function)는 식 (15)와 같이, 그리고 전체 패턴 N에 대한 평균제곱오차는 식 (16)과 같이 정의될 수 있으며, 이들 목적함수들은 다층뉴럴네트워크의 학습 성과를 나타내는 지표로 사용할 수 있다.

$$E(n)=\sqrt{\frac{\sum_{i=1}^{i=N_d}(\|d_i-x_i\|^2)}{N_d}} \tag{15}$$

$$E=\frac{1}{N}\sum_{n=1}^{N}E(n) \tag{16}$$

식 (15)의 d_i는 출력층 i번째 뉴런의 목표 출력값을, x_i는 출력층 i번째 뉴런의 실제 출력값이며, N_d는 각 학습 패턴의 목표 출력값의 수이다.

2. 확장칼만필터(EKF)를 이용한 학습 알고리즘

선형화된 비선형 시스템에 칼만필터를 적용함으로써 비선형 동적시스템 상태변수를 근사된 최소변위(approximated minimum variance)로 추정하는 확장칼만필터[10]는 다층뉴럴네트워크의 연결가중치를 학습하는 학습 알고리즘으로 사용될 수 있으며, 확장칼만필터는 일반적으로 뉴럴네트워크의 학습을 위하여 사용되는 최급강하법(GD: Gradient Decent method) 보다 빠른 수렴속도를 보장하는 것으로 알려지고 있다[11].

상태변수 추정을 위한 확장칼만필터를 다층뉴럴네트워크의 학습알고리즘으로 사용하기 위하여, 우선 다층뉴럴네트워크를 비선형 상태방정식으로 표시하는 것이 필요하다. 이를 위하여 다층뉴럴네트워크의 연결가중치를 상태벡터로 표현하면 식 (17)과 같이 나타낼 수 있다. 식 (18)의 $a_{i,j}^n$는 다층뉴럴네트워크의 n번째 층의 j번째 노드로부터 n+1번째 층의 i번째 노드로 연결되는 연결가중치이고, 아울러 N_n과 N_{n+1}은 n번째 및 n+1번째 층의 노드 수이다.

$$a=[(a_1^n)^T,(a_2^n)^T,\cdots,(a_{N_{n+1}-1}^n)^T]^T \quad (N_n(N_{n+1}-1)\times 1) \tag{17}$$

$$a_i^n=[(a_{i,1}^n,a_{i,2}^n,\cdots,a_{i,N_n}^n]^T \quad (N_n\times 1) \tag{18}$$

또한 다층뉴럴네트워크의 n번째 층 노드들의 출력과 출력층에서의 목표 출력을 벡터(vector)로 나타내면 각각 식 (19)와 식 (22)와 같이 표시된다. 식 (20)의 $x_i^n(k)$는 n번째 층 i번째 노드의 출력을 나타내는 것으로, 함수 $f(x)$는 다층뉴럴네트워크의 활성화함수를, 그리고 θ_i^{n-1}은 n-1번째 층의 마지막 노드인 N_{n-1}번째 노드로부터 n번째 층 i번째 노드로 연결된 바이어스이다. 또한 식 (21)은 입력층의 출력을 나타내며 따라서 입력층에서는 아무런 연산이 일어나지 않고 있음을 보여주고 있다. 식 (22)의 N_M은 출력층, 즉 입력층과 출력층을 포함하여 M개의 층을 갖는 다층뉴럴네트워크의 출력층에서의 노드수를 나타낸다.

$$x^n(k)=[x_1^n(k),x_2^n(k),\cdots,x_{N_n}^n(k)]^T \quad (N_n\times 1) \tag{19}$$

$$x_i^n(k)=f\left(\sum_{j=1}^{N_{n-1}-1}a_{i,j}^{n-1}x_j^{n-1}(k)+\theta_i^{n-1}\right)=f\left(\sum_{j=1}^{N_{n-1}}a_{i,j}^{n-1}x_j^{n-1}(k)\right) \tag{20}$$

$$x_i^1(k)=x_i(k), \quad 1\le i\le N_1-1 \tag{21}$$

$$d(k)=[d_1(k),d_2(k),\cdots,d_{N_M}(k)]^T \quad (N_M\times 1) \tag{22}$$

식 (23)과 식 (24)는 이와 같이 정의된 상태벡터, 입력 및 출력 벡터를 사용하여 다층뉴럴네트워크를 상태방정식(state space equation)으로 표현한 것이다. 식 (24)의 함수 $h_k(a(k))$는 다층뉴럴네트워크의 구조와 결합된 패턴 k에 대한 출력을 결정하는 비선형시변함수(nonlinear time variant function)이며, $v(k)$는 백색잡음(white noise)이라고 가정된 공분산행렬(covariance matrix) $R(k)$를 갖는 모델링 오차이다.

$$a(k+1)=a(k) \tag{23}$$

$$d(k)=h_k(a(k))+v(k)=x^M(k)+v(k) \tag{24}$$

식 (23)과 식 (24)로 표시된 비선형 시스템의 상태변수, 즉 다층뉴럴네트워크의 연결가중치를 추정하기 위한 확장칼만필터 알고리즘은 따라서 다음과 같다[10].

$$K(k)=P(k-1)H(k)^T[H(k)P(k-1)H(k)^T+R(k)]^{-1} \tag{25}$$

$$\hat{a}(k)=\hat{a}(k-1)+K(k)[d(k)-\hat{x}^M(k)] \tag{26}$$

$$P(k)=[I-K(k)H(k)]P(k-1) \tag{27}$$

식 (27)의 $P(k)$는 상태변수 추정오차의 공분산행렬을 나타낸 것으로 다음의 식 (28)과 같이 정의되며, $\hat{x}^M(k)$은 $x^M(k)$의 추정값을 나타내고, 또한 $H(k)$는 비선형 출력방정식인 식 (24)를 선형화하기 위한 과정에서 생성된 행렬로서, 본 연구에서 사용된 식 (14)와 같은 양극성 시그모이드 활성화 함수의 미분된 함수인 식 (29)를 사용하여, 식 (30)과 같이 정의된다[11].

$$P(k) = E\{[a(k)-\hat{a}(k)][a(k)-\hat{a}(k)]^T\} \tag{28}$$

$$f'(x) = (1+f(x))(1-f(x)) \tag{29}$$

$$H(k) = \left(\frac{\partial x^M(k)}{\partial a}\right)_{a=\hat{a}(k-1)} \tag{30}$$
$$= [H_1^1(k),\ldots,H_{N_2-1}^1, H_1^2(k),\ldots,H_{N_3-1}^2(k),\ldots,H_1^{M-1},\ldots,H_{N_M-1}^{M-1}]$$

$$H_i^n(k) = \left(\frac{\partial x^M(k)}{\partial a_i^n}\right)_{a=\hat{a}(k-1)} = \hat{\Delta}_i^n(k)\hat{x}^n(k)^T \tag{31}$$

$$\hat{\Delta}_i^n(k) = (1+\hat{x}_i^{n+1})(1-\hat{x}_i^{n+1})\sum_{l=1}^{N_{n+2}-1}\hat{a}_{l,i}^{n+1}(k-1)\hat{\Delta}_l^{n+1}(k)$$
$$1 \le n \le M-2 \tag{32}$$

$$\hat{\Delta}_i^{M-1}(k) = (1+\hat{x}_i^M)(1-\hat{x}_i^M)[0,\ldots,0,1,0,\ldots0]^T \tag{33}$$

식 (25)로부터 식 (33)에 의하여 정의되는 확장칼만필터는 식 (23)과 식 (24)에 의하여 정의되는 비선형시스템인 다층뉴럴네트워크의 연결가중치를 시스템의 실제 연결가중치의 근사값, 즉 식 (16)에 의하여 정의되는 목적함수를 최소화하는 값으로 수렴하게 된다.

그러나 식 (25)로부터 식 (33)에 정의되어 있는 확장칼만필터 알고리즘을 적용하려면, 모든 연결가중치가 동시에 갱신되어야 하며, 따라서 연산이 대단히 복잡해 질 수 있다.

연결가중치를 동시에 갱신시킴으로 인한 연산의 복잡성을 감소시키기 위하여, 추정 연결가중치 $\hat{a}_i^n(k)$를 개별적으로 식 (34)에서와 같이 n의 내림차순, i의 오름차순으로 계산하면, 확장칼만필터를 적용하는 학습알고리즘은 식 (35), 식 (36) 및 식 (37)과 같이 표시될 수 있다.

$$[\hat{a}^{M-1}(k),\cdots,\hat{a}^{n+1}(k),\hat{a}_1^n(k),\cdots,\hat{a}_{i-1}^n(k),$$
$$\hat{a}_{i+1}^n(k-1),\cdots,\hat{a}_{N_{n+1}-1}^n(k-1),\hat{a}^{n-1}(k-1),\cdots,\hat{a}^1(k-1)] \tag{34}$$

$$K_i^n(k) = P_i^n(k-1)H_i^n(k)^T\left[H_i^n(k)P_i^n(k-1)H_i^n(k)^T + R(k)\right]^{-1} \tag{35}$$

$$\hat{a}_i^n(k) = \hat{a}_i^n(k-1) + K_i^n(k)\left[d(k)-\hat{x}^M(k)\right] \tag{36}$$

$$P_i^n(k) = [I-K_i^n(k)H_i^n(k)]P_i^n(k-1) \tag{37}$$

또한 확장칼만필터의 연산 간편화 및 이에 따른 수렴속도의 향상을 위하여 식 (35)의 공분산행렬 $R(k)$를 대각행렬(diagonal matrix) λI라고 가정하면, 확장칼만필터 이득값(Kalman gain)을 계산하는 식 (35)는 역행렬 공식을 이용하여 식 (38)과 같이 표현된다.

$$K_i^n(k) = \frac{1}{\lambda+\alpha_i^n(k)\beta_i^n(k)}\psi_i^n(k)\hat{\Delta}_i^n(k)^T \tag{38}$$

$$\hat{a}_i^n(k) = \hat{a}_i^n(k-1) + \frac{\hat{\Delta}_i^n(k)^T(d(k)-\hat{x}^M(k))}{\lambda+\alpha_i^n(k)\beta_i^n(k)}\psi_i^n(k) \tag{39}$$

$$\hat{P}_i^n(k) = \hat{P}_i^n(k-1) - \frac{\beta_i^n(k)}{\lambda+\alpha_i^n(k)\beta_i^n(k)}\psi_i^n(k)\psi_i^n(k)^T \tag{40}$$

$$\alpha_i^n(k) = \hat{x}^n(k)^T P_i^n(k-1)\hat{x}^n(k) \tag{41}$$

$$\beta_i^n(k) = \hat{\Delta}_i^n(k)^T\hat{\Delta}_i^n(k) \tag{42}$$

$$\psi_i^n(k) = P_i^n(k-1)\hat{x}^n(k) \qquad (N_n \times 1) \tag{43}$$

대각행렬로 가정된 공분산행렬 $R(k)$은 식 (44)와 같은 일반적인 업데이트 방정식을 사용하여 추정될 수 있으며, 따라서 λ는 식 (45)와 같이 추정 될 수 있다.

$$\hat{R}(k) = \hat{R}(k-1)$$
$$+\mu(k)[(d(k)-\hat{x}^M(k))(d(k)-\hat{x}^M(k))^T - \hat{R}(k-1)] \tag{44}$$

$$\hat{\lambda}(k) = \hat{\lambda}(k-1)$$
$$+\mu(k)\left[\frac{(d(k)-\hat{x}^M(k))(d(k)-\hat{x}^M(k))^T}{N_M} - \hat{\lambda}(k-1)\right]$$
$$\text{if} \quad t > T_{\max}, \quad then \quad \mu(t) = \frac{1}{T_{\max}} \tag{45}$$

확장칼만필터에 의한 연결가중치의 추정은, 또한 연결가중치가 식 (34)에서와 같이 n의 내림차순, i의 오름차순으로 순차적으로 계산되며, 따라서 $\hat{a}_i^n(k)$의 추정에서, 식 (34)에서와 같은 연결가중치를 사용하여 계산된 출력층의 출력값 $\hat{y}_i^n(k)$를 $(k-1)$에서의 연결가중치를 사용하여 계산된 $\hat{x}^M(k)$ 대신 사용함으로써 계산의 정확성을 높일 수 있다. 식 (34)에서와 같은 연결가중치를 사용하여 계산된 출력층의 출력값을 $\hat{y}_i^n(k)$라고 하면, 연결가중치를 갱신하는 식 (39)는 식 (47)과 같이 다시 정의된다.

$$\hat{y}_i^n(k) = [\hat{y}_{i,1}^n(k), \hat{y}_{i,2}^n(k), \cdots, \hat{y}_{i,N_M}^n(k)]^T \tag{46}$$

$$\hat{a}_i^n(k) = \hat{a}_i^n(k-1) + \frac{\hat{\Delta}_i^n(k)^T(d(k)-\hat{y}_i^n(k))}{\hat{\lambda}(k)+\alpha_i^n(k)\beta_i^n(k)}\psi_i^n(k) \tag{47}$$

IV. 태양추적오차 보정 모의실험

태양추적오차의 다층뉴럴네트워크에 의한 모델링과 이를 이용한 태양추적오차의 보정 성능 평가를 위하여 모의실험을 수행하였다. 모의실험에 사용된 헬리오스타트와 관련된 데이터들은 현재 건설 중인 태양열발전시스템의 실제 데이터들이며, 헬리오스타트의 태양추적오차는 모의실험을 통하여 얻어진 헬리오스타트의 기구오차로부터 기인하는 태양추적오차[4,5]들이다.

그림 7은 현재 중국 북경 엔칭에 건설중에 있는 $10m \times 10m$ 크기의 반사거울 100개로 구성된 1MW급 태양열발전시스템의 헬리오스타트 필드를 나타낸 것이다.

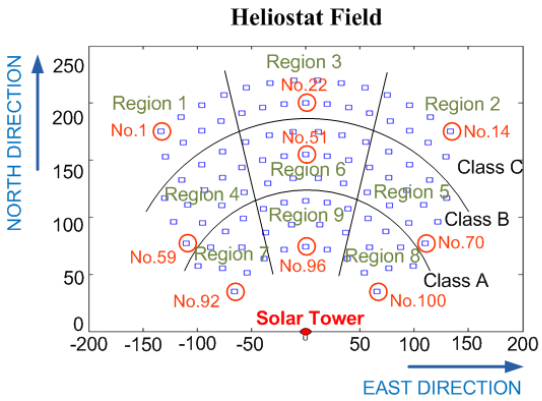

그림 7. 1MW 급 태양열발전시스템의 헬리오스타트 필드.
Fig. 7. Heliostat field of 1MW solar thermal power plant.

1. 다층뉴럴네트워크의 구조

헬리오스타트의 태양추적오차 모델링을 위한 다층뉴럴네트워크는, 실험적으로 결정된, 최적의 모델링 성능을 나타내는 그림 8과 같은 구조를 가지고 있다. 즉 다층뉴럴네트워크는 그림에서와 같이 시간지연 입력(time lagged input)과 은닉층 2개를 포함한 4개의 층으로 구성되어 있으며, 각 층 노드의 개수는 실험적으로 얻어진 적으면서도 우수한 모델링 성능을 보이는 9·6·6·3의 구조를 선택하였다.

다층뉴럴네트워크에 입력으로 사용되는 시간지연 입력값은, 최초 학습데이터 패턴 입력의 경우에는 시간 지연값과 최초 학습데이터 입력값을 동일한 것으로 사용하고, 이후부터는 이전 패턴의 입력값을 사용하였다.

표 2는 최급강하법(GD) 또는 확장칼만필터(EKF)에 의한 다층뉴럴네트워크의 학습에서 사용된 각종 초기값들로서, 측정 잡음(measurement noise)은 모의실험을 통하여 얻어진 헬리오스타트 기구오차로부터 기인하는 태양추적오차[4,5]에 실제 측정시 발생 가능한 측정 잡음 효과를 모사하기 위하여 더해준 태양추적오차 값이다.

2. 학습데이터의 정규화

다층뉴럴네트워크의 학습에 사용된 데이터들은 총 6가지로, 태양의 방위각 A와 고도각 α, 목표 표적 중심의 좌표 e_I와 z_I 그리고 측정된 태양추적오차 Δx, Δz이다.

목표 표적은 그림 9와 같이 $5m \times 5m$ 크기이며, 목표 표적의 중심좌표 $(0, 0, 93)$(m)을 기준으로 xz평면상에서 $\pm 2.5m$의 범위를 갖는다.

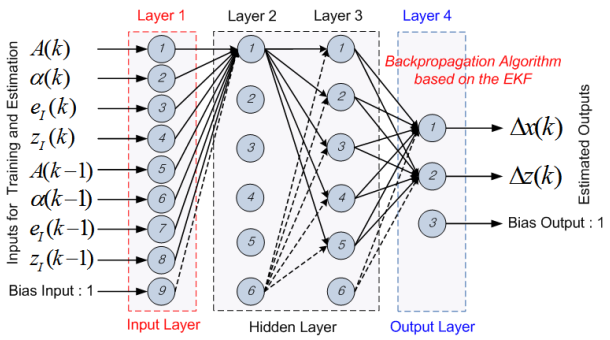

그림 8. 모의실험에서 사용된 다층뉴럴네트워크의 구조.

Fig. 8. Structure of multilayered neural network used in simulation.

표 1. 다층뉴럴네트워크의 학습을 위한 초기값.

Table 1. Initial values used in training the neural network.

Variable	GD	EKF	Type
Target RMS error	0.02~0.05	0.02~0.05	Fix
Learning rate (η)	0.3	·	Fix
Time-lag horizon	1	1	Fix
Network structure	8·5·5·2	9·6·6·3	Fix
Limit $T_{\max}$	·	$30 \times N_{pair}$	Fix
Initial connection weight	± 0.5	± 0.5	Random
Initial bias	$-1.0 \sim 0.0$	·	Random
Initial error covariance (P_0)	·	± 0.3	Random
Measurement noise	± 0.05	± 0.05	Random

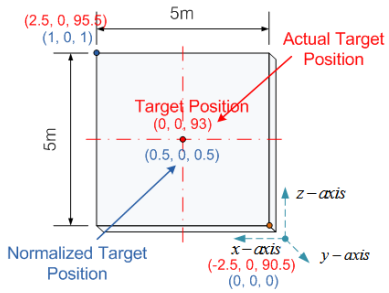

그림 9. 목표 표적 좌표계.

Fig. 9. Target surface coordinates.

표 2. 태양추적오차 모델링을 위한 학습데이터 정규화.

Table 2. Normalization of training data for sun tracking error modeling.

Variable	Range	Unit	Normalized Range	I/O
Sun azimuth A	$0 \sim 360$	deg	± 1.0	in
Sun elevation α	$0 \sim 90$	deg	± 1.0	in
Target x pos. e_I	$-2.5 \sim +2.5$	m	$0.0 \sim 1.0$	in
Target z pos. z_I	$90.5 \sim 95.5$	m	$0.0 \sim 1.0$	in
x-axis Δx	$-2.5 \sim +2.5$	m	± 1.0	out
z-axis Δz	$-2.5 \sim +2.5$	m	± 1.0	out

표 2는 학습에서 사용된 데이터들의 실제 범위와 다층뉴럴네트워크에서 사용된 활성화 함수의 출력값에 따라 정규화된 학습 데이터들의 범위를 나타낸 것이다.

3. 학습 알고리즘의 성능 분석

3.1 학습 알고리즘에 따른 오차 모델링 성능

확장칼만필터에 의한 다층뉴럴네트워크의 학습 속도, 즉 수렴 속도 및 측정 데이터에 포함되어 있는 측정 잡음에 따른 모델의 정확성을 평가하기 위하여, 헬리오스타트 No. 100(65.566, 35.163, 6)(m)의 2009년 3월 20일(춘분) 태양추적오차 데이터를 사용하였다. 그림 10은 헬리오스타트 No. 100의 2009년 3월 20일 기구오차에 따른 일출부터 일몰까지의 태양추적오차를 나타낸 것이다[4].

그림 10을 살펴보면, 헬리오스타트 No. 100의 태양추적오차는 오전 9시 25분경에 발생된 구동축의 백래시(backlash) 현상과 오후 5시 20분경 고도각이 30°가 되는 지점에서 무게편심에 따른 반사면의 움찔거리는 불연속 회전 현상에 의한 2개의 불연속점을 가지고 있다.

그림 11은, 그림 10에서 나타낸 헬리오스타트 No. 100의

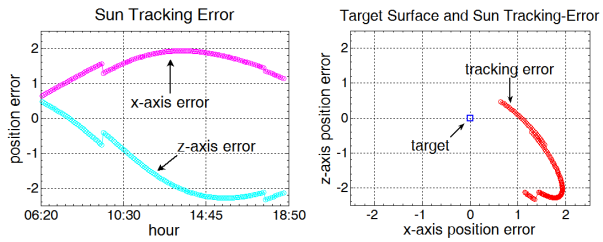

그림 10. 헬리오스타트 No. 100의 태양추적오차(2009년 3월 20일).

Fig. 10. Sun tracking error of heliostat No. 100(March 20, 2009).

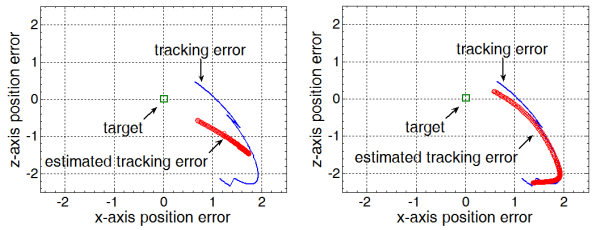

(a) Gradient descent (b) Extended Kalman filter

그림 11. 헬리오스타트 No. 100의 태양추적오차 모델의 성능.

Fig. 11. Performance of sun tracking error model for heliostat No. 100.

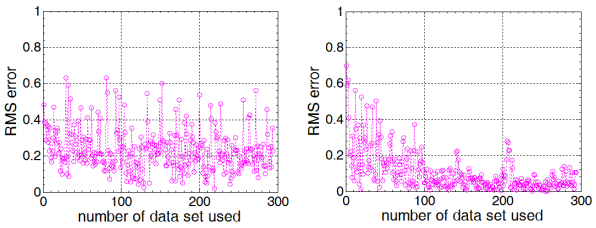

(a) Gradient descent (b) Extended Kalman filter

그림 12. 헬리오스타트 No. 100의 학습에서 사용된 학습 데이터 수의 변화에 따른 RMS 오차의 변화.

Fig. 12. Change of RMS error according to the number of data set used in training for heliostat No. 100.

2009년 3월 20일 일출부터 일몰까지 매 5분 간격으로 생성된 147개의 태양추적오차 데이터 패턴을 사용하여, 총 2회 반복 학습한 이후, 예측된 태양추적오차이다. 그림에서와 같이 학습데이터 패턴 전체를 2회 학습한 결과, 학습된 태양추적오차 모델의 정확성을 나타내는 식 (16)으로 표시되는 RMS 오차가 최급강하법의 경우 0.188m로, 그리고 확장칼만필터의 경우에는 0.035m까지 감소하였다.

또한 그림 12는 147개의 학습 데이터 패턴을 총 2회 반복 학습하는 동안에, 학습 데이터 패턴의 순차적 입력에 따른 학습된 태양추적오차 모델의 정확성을 식 (16)을 사용하여 계산한 RMS 오차로 나타낸 것이다. 그림에서와 같이 확장칼만필터에 의한 학습은, 학습을 위한 데이터 패턴이 모두 학습되기 전에 이미 RMS 오차가 0.1m이하로 감소하는 우수한 수렴 속도를 가지는 것을 확인할 수 있다.

BCS에 의하여 측정되는 태양추적오차는 측정 잡음을 포함하고 있다. 그림 13은 측정 잡음에 따른 모델의 정확성을 확인하기 위하여, 우선 그림 10에서의 태양추적오차에 최대값 0.05m의 정규분포를 갖는 가우시간 랜덤 노이즈(Gaussian random noise)를 더하고, 이와 같은 측정 잡음이 포함된 학습 데이터로 학습된 다층뉴럴네트워크를 이용하여 예측된 태양추적오차를 나타낸 것이다. 아울러 표 3은 측정된 태양추적오차에 랜덤 노이즈 측정 오차가 포함되어 있을 경우와 노이즈가 없는 경우에 대하여, 확장칼만필터 및 최급강하법에 의하여 학습된 다층뉴럴네트워크의 학습 정확성을 식 (16)에서 정의된 RMS 오차로 나타낸 것이다. 표에서와 같이, 확장칼만필터에 의한 학습은 노이즈가 포함되어 있는 경우 RMS 오차가 감소하는 경향을 보였다. 그

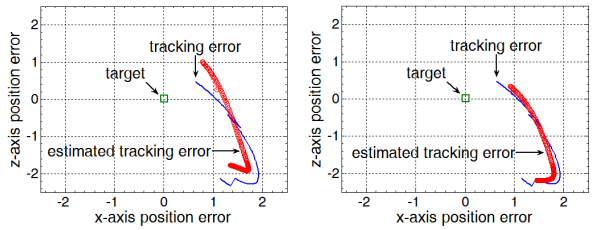

(a) Gradient descent (b) Extended Kalman filter

그림 13. 랜덤 노이즈가 더해진 태양추적오차에 의해 학습된 태양추적오차 모델의 성능.

Fig. 13. Performance of sun tracking error model when the random noise is included in the training data(heliostat No.100).

표 3. 랜덤노이즈가 더해진 태양추적오차에 의해 학습된 태양추적오차 모델의 RMS 오차(m).

Table 3. RMS error(m) of sun tracking error model when the random noise is included in the training data.

Method	Heliostat No. 100		Heliostat No. 14	
	Noiseless	Included	Noiseless	Included
GD	0.0295	0.0529	0.0209	0.0228
EKF	0.0480	0.0343	0.0262	0.0215

러나 최급강하법에 의한 학습은 오히려 RMS 오차가 증가하는 경향이 있는 것으로 확인되었다.

학습 방법에 따른 오차모델의 정확성은, 학습에서 사용된 수렴조건에 따라 달라지게 된다. 바꾸어 말해서, 동일한 데이터 패턴을 사용하여 학습을 수행하더라도, 학습의 수렴조건을 결정하는 식 (16)과 같은 목적함수 값의 크기를 달리하면, 학습된 모델의 정확성은 달라지게 된다. 표 3의 태양추적오차모델의 RMS 오차는, 학습 방법에 따른 측정잡음의 필터링효과를 보여주기 위한 것으로서, 최급강하법의 경우와 확장칼만필터의 경우가 각기 다른 수렴 조건을 사용하여 학습된 결과이다. 즉, 표 3의 결과는 확장칼만필터의 측정잡음 필터링 효과를 최급강하법과 대비하여 나타낸 것으로, 측정 잡음이 없는 경우 최급강하법이 확장칼만필터에 의한 학습보다 작은 RMS 오차를 가지고 있으나, 그것이 곧바로 최급강하법에 의한 학습이 확장칼만필터에 의한 학습보다 정확한 오차모델링을 이룬다는 것을 의미하지는 않는다.

3.2 학습데이터의 수량에 따른 오차 모델링 성능

태양추적오차의 모델링에서 사용되는 학습 데이터의 수량이 모델의 정확도에 미치는 영향을 확인하기 위하여, 일출부터 일몰까지의 5분(143개 학습 데이터), 10분(72개 학습 데이터), 30분(25개 학습 데이터) 그리고 1시간(13개 학습 데이터) 간격으로 측정된 데이터 패턴을 사용하여 학습한 경우에 대한 오차 모델의 정확성을 비교하였다.

표 4는 2009년 3월 20일 측정된 태양추적오차를 사용하여 모델링된 헬리오스타트 No. 22(0, 200.213, 6)(m)의 오차 모델의 정확성을 식 (16)으로 표시된 RMS 오차(m)로 나타낸 것이다.

표 4. 학습데이터 수량에 따른 모델의 RMS 오차(m).

Table 4. RMS error(m) of sun tracking error model depending on the number of training data.

Method	Number of Data Pattern used in Training			
	143	72	25	13
GD	0.0268	0.0315	0.0409	0.0387
EKF	0.0263	0.0297	0.0230	0.0253

태양추적오차 모델의 정확성은 학습에 사용되는 데이터의 수에 비례하여 향상될 것으로 생각되는 것이 일반적이다. 그러나 표 4를 살펴보면, 학습데이터 패턴의 수가 143개에서 13개로 감소되어도 모델의 정확성이 크게 영향을 받지 않는다는 것을 볼 수 있다.

표 4의 결과는 태양추적오차의 모델링에 있어 대단히 중요하다. 즉 태양추적오차의 모델은 많은 양의 학습데이터가 아닌 1시간 간격으로 측정된 데이터를 사용하여도 충분한 정확성을 제공할 수 있다. 따라서 BCS를 이용한 태양추적오차의 측정은 충분한 시간 간격을 가지고 이루어 져도 되며, 이는 다시 하루 일중 보다 많은 헬리오스타트에 대한 태양추적오차의 측정이 가능하고, 따라서 개별 헬리오스타트의 태양추적오차 모델의 갱신 주기를 보다 짧게 가져감으로써 헬리오스타트 필드의 집광 성능을 크게 향상시킬 수 있다는 것을 의미하고 있다.

3.3 학습 데이터의 누적에 따른 오차모델링 성능

측정된 학습 데이터의 누적 사용 또는 독립적 사용에 따른 태양추적오차 모델의 정확성을 비교하기 위하여, 매월 1회 측정된 태양추적오차에 의하여 학습된 태양추적오차 모델을 다음 달 측정이 이루어지는 시점까지 사용하여 태양추적오차를 보정하는 경우와 매월 측정된 태양추적오차를 누적적으로 사용하여 얻어진 태양추적오차 모델을 사용하여 태양추적오차를 보정하는 경우에 대한 헬리오스타트의 태양추적 정확성을 해당 헬리오스타트 태양추적오차의 RMS 값을 사용하여 비교하였다.

표 5는 헬리오스타트 No. 1(-133.196, 175.364, 6)(m)에 대하여, 2009년 1월부터 12월까지 매달 15일 측정된 태양추적오차 데이터를 독립적 이용하여 모델링 된 모델을 사용한 경우와 누적적으로 사용하여 모델링된 모델을 사용한 경우의 월별 태양추적오차의 RMS 값을 비교한 것이다. 표 5를 살펴보면, 독립적으로 모델링할 경우 최급강하법의 경우 연중 발생되는 태양추적오차의 RMS 값이 약 0.121m, 확장칼만필터의 경우 약 0.1m로 감소하였으며, 매달 독립적인 데이터를 기반으로 모델링을 한 경우의 태양추적오차가 누적적으로 사용하는 경우보다 더 작아지는 것을 확인할 수 있다. 태양추적오차를 누적적으로 사용하는 경우가 독립적으로 사용하는 경우보다 낮은 태양추적 정확성을 보이는 이유는, 백래시 등에 의한 불연속점 및 비선형성을 갖는 추적오차가 누적되면서, 따라서 오차 모델의 정확성이 떨어지기 때문이다.

표 5. 개별적 또는 누적된 데이터 사용에 따른 모델 성능 비교.

Table 5. Comparison of performance of models obtained using independent and accumulated data.

Method		Month						
		1	2	3	4	5	6	
Acc	GD	0.134	0.108	0.063	0.214	0.179	0.134	·
	EKF	0.086	0.162	0.146	0.193	0.157	0.190	·
Ind	GD	0.134	0.111	0.181	0.154	0.173	0.111	·
	EKF	0.086	0.108	0.095	0.144	0.105	0.099	·
Method		Month						Mean
		7	8	9	10	11	12	
Acc	GD	0.244	0.238	0.167	0.132	0.141	0.160	0.168
	EKF	0.170	0.155	0.516	0.246	0.161	0.209	0.199
Ind	GD	0.118	0.098	0.096	0.076	0.088	0.106	0.121
	EKF	0.105	0.098	0.083	0.087	0.091	0.097	0.100

4. 태양추적오차 보정 모의실험 결과

태양추적오차 모델을 이용한, 그림 3과 같은 태양추적오차 보정 알고리즘의 성능을 평가하기 위하여, 헬리오스타트의 기구오차로부터 기인하는 태양추적오차를 확장칼만필터에 의하여 학습된 다층뉴럴네트워크로 모델링하고, 이를 이용하여 태양추적오차를 보정하는 경우의 헬리오스타트 태양추적 성능을 모의실험을 통하여 확인하였다.

그림 14와 표 6은 오차보정이 이루어지고 있는 헬리오스타트 No. 51(0, 155.066, 6)(m)의 연중 태양추적 성능을 나타낸 것이다. 그림에서 표시된 태양추적오차의 보정은, 우선 2009년 매월 15일, 즉 3월에는 3월 15일, 6월에는 6월 15일 등과 같이 매월 15일에서 측정된 태양추적오차를 사용하여 태양추적오차 모델을 형성하고, 3월 20일(춘분), 6월 21일(하지), 9월 23일(추분) 그리고 12월 22일(동지) 각각에서 해당 월의 태양추적오차 모델을 이용하여 헬리오스타트의 기구오차로부터 기인하는 태양추적오차를 보정하였다.

그림 14와 표 6은, 헬리오스타트의 태양추적 오차가 태

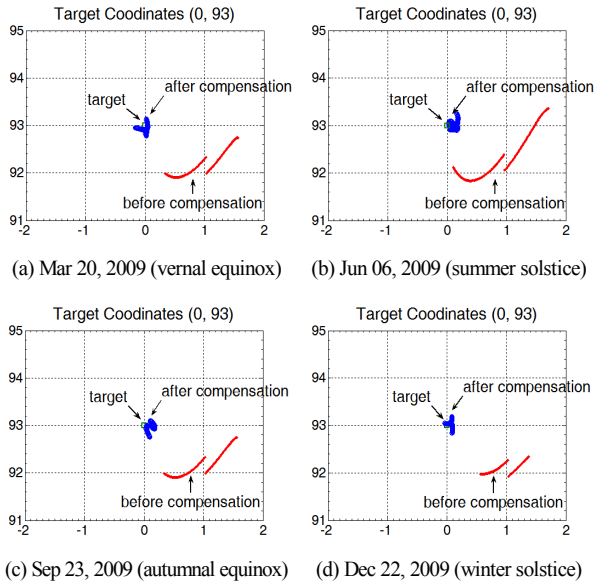

(a) Mar 20, 2009 (vernal equinox) (b) Jun 06, 2009 (summer solstice)

(c) Sep 23, 2009 (autumnal equinox) (d) Dec 22, 2009 (winter solstice)

그림14. 헬리오스타트 No. 51의 보정 전·후 계절별 태양추적 오차.

Fig. 14. Sun tracking error of heliostat No. 51 before and after the error compensation.

표 6. 헬리오스타트 No. 51의 태양추적오차(m).

Table 6. Sun tracking error(m) of heliostat No. 51 before and after the error compensation.

Date	RMS Sun Tracking Error (m)		
	No Comp.	Compensated	
		GD	EKF
Mar 30, 2009	1.351	0.127	0.093
Jun 21, 2009	1.333	0.184	0.141
Sep 23, 2009	1.352	0.119	0.136
Dec 22, 2009	1.368	0.112	0.107

양추적오차 모델을 사용하여 보정될 수 있음을 보여주고 있다.

V. 결론

본 연구는 개루프 제어에 의하여 태양추적을 수행하는 헬리오스타트의 태양추적오차를 보정하기 위하여, 측정된 태양추적오차로부터 모델링된 태양추적오차 모델을 사용하여, 헬리오스타트가 태양추적을 수행하는 동안 발생 가능한 태양추적오차를 예측하여 보정함으로써, 헬리오스타트의 태양추적 정밀도를 향상시키기 위한 것이다.

본 연구에서는, 우선 불연속성과 비선형성을 갖는 헬리오스타트 태양추적오차를 확장칼만필터에 의하여 학습이 이루어지는 다층뉴럴네크워크로 모델링하였다. 그리고 제안된 태양추적오차 보정에 대한 성능을 검증하기 위한 모의실험을 수행하였다. 모의실험을 통하여, 본 연구에서 제안된 태양추적오차 모델에 의한 태양추적오차의 보정은 헬리오스타트의 태양추적정밀도를 향상시키는 것으로 확인되었다. 아울러 태양추적오차의 모델링을 위한 다층뉴럴네트워크 및 확장칼만필터에 의한 학습이, 불연속 및 비선형성을 갖는 헬리오스타트 태양추적오차를 적절하게 모델링하고 있는 것으로 나타났다. 특히 확장칼만필터에 의한 다층뉴럴네트워크의 학습은, 최급강하법과 같은 다른 학습 방법과 비교하여 우수한 수렴 속도와 측정 잡음 필터링 효과를 보여주었으며, 따라서 수백개 또는 수천개의 헬리오스타트와 다량의 측정 잡음이 포함되어 있을 것으로 예상되는 실제 태양열발전시스템에서 실용화 될 수 있는 학습법인 것으로 보인다.

본 연구에서 제안된 태양추적오차 보정 방법은 현재 건설 중인 1MW급 태양열발전시스템에 적용되며, 이를 위한 태양추적오차의 측정을 위한 BCS의 구축이 현재 진행되고 있다.

참고문헌

[1] PIER: California Energy Commission, Renewable Energy : Solar Two Central Receiver, Oct. 1999.

[2] Y. C. Park, "Heliostat control system," *Journal of the Korean Solar Energy Society*, vol. 29, no. 1, 2009.

[3] K. W. Stone and S. A. Hones, "Analysis of solar two heliostat tracking error sources," SAND99-0239C, 1999.

[4] Y. C. Park, "Analysis of sun tracking error caused by the heliostat driving axis geometrical error utilizing the solar ray tracing technique," *Journal of the Korean Solar Energy Society*, vol. 29, no. 2, pp. 39-46, 2009.

[5] Y. C. Park, "Analysis of sun tracking error due to the mirror installation and drive mechanism induced errors," *Journal of the Korean Solar Energy Society*, vol. 29, no. 3, pp. 1-1, 2009.

[6] Y. C. Park, "Compensation of sun tracking error caused by the heliostat geometrical error through the canting of heliostat mirror facets," *Journal of the Korean Solar Energy Society*, vol. 29, no. 6, pp. 22-31, 2009.

[7] A. Kribus, I. Vishnevetsky, A. Yogev, and T. Rubinov, "Closed loop control of heliostat," *Energy 29*, pp. 905-913, 2004.

[8] John W. Strachan, "Revisiting the BCS, a Measurement System for Characterizing the Optics of Solar Collectors," Solar Thermal Test Division, Sandia National Laboratories, 1993.

[9] S. Haykin, *Neural Networks: A Comprehensive Foundation*, 2nd Ed., Prentice Hall, 1999.

[10] R. G. Brown and P. Hwang, *Introduction to Random Signals and Applied Kalman Filtering*, John Wiley & Sons, 1997

[11] Y. Iiguni, H. Sakai, and H. Tokumaru, "A real-time learning algorithm for a multilayered neural network based on the extended Kalman filter," *IEEE Trans. Signal Processing*, vol. 40, no. 4, pp. 959-966, 1992.

이 상 은

2007년 서울산업대 제어계측공학과(공학사). 2009년 서울산업대 제어계측공학과(공학석사). 현재 서울산업대학교 전기정보기술연구소 특별연구원. 관심분야는 동적 시스템 모델링 및 제어응용, 신경회로망, 지능제어 및 예측제어. 메카트로닉스.

박 영 칠

1981년 인하대학교(공학사). 1983년 인하대학교(공학석사), 1990년 The Univ. of New Mexico(공학박사), 현재 서울산업대학교 제어계측공학과 교수. 관심분야는 태양추적시스템, 헬리오스타트 필드제어시스템 및 태양열 발전시스템의 통합운전제어시스템.