

군집화 알고리즘 및 모듈라 네트워크를 이용한 태양광 발전 시스템 모델링

Modeling of Photovoltaic Power Systems using Clustering Algorithm and Modular Networks

이 창 성* 지 평 식†

(Chang-Sung Lee · Pyeong-Shik Ji)

Abstract - The real-world problems usually show nonlinear and multi-variate characteristics, so it is difficult to establish concrete mathematical models for them. Thus, it is common to practice data-driven modeling techniques in these cases. Among them, most widely adopted techniques are regression model and intelligent model such as neural networks. Regression model has drawback showing lower performance when much non-linearity exists between input and output data. Intelligent model has been shown its superiority to the linear model due to ability capable of effectively estimate desired output in cases of both linear and nonlinear problem. This paper proposes modeling method of daily photovoltaic power systems using ELM(Extreme Learning Machine) based modular networks. The proposed method uses sub-model by fuzzy clustering rather than using a single model. Each sub-model is implemented by ELM. To show the effectiveness of the proposed method, we performed various experiments by dataset acquired during 2014 in real-plant.

Key Words : ELM, Modular networks, Photovoltaic power system

1. 서 론

화석 에너지의 고갈에 직면한 세계 각국은 화석 연료를 대체하기 위한 신재생 에너지 개발에 많은 투자를 하고 있다. 또한, 지구 온난화의 주원인으로 꼽히는 온실 가스 배출량 의무감축을 주요 골자로 한 파리 의정서가 발효됨에 따라 온실가스 발생의 주범인 화석 에너지의 사용을 줄이기 위한 대책이 시급하다. 따라서 안정적이고 깨끗한 미래 에너지원의 확보는 경제적 측면은 물론 국가 안보 차원에서도 중요한 과제로 부각되고 있다[1].

태양광발전 시스템을 효과적으로 운영하기 위해서는 성능이 우수한 발전량 예측 모델개발이 중요한 요소이다[2]. 성능이 우수한 태양광발전 시스템 모델은 태양광 설비의 고장진단, 시스템 동특성 분석 및 예측모델에 널리 적용할 수 있다. 즉, 실시간으로 취득된 데이터를 태양광발전량 모델로부터 산출된 추정값과 실제 태양광 설비로부터 취득한 발전량과 비교하여 고장진단 모델에 적용 가능하다. 또한, 예측하고자 하는 날의 외부인자(온도, 일사량, 운량 등)를 알 수 있다면, 태양광발전량 모델로부터 발전량을 예측할 수 있다.

태양광발전량은 일조시간, 일사량, 운량, 온도 등의 다양한 기후조건에 따라 달라진다고 보고되고 있다[3]. 기존 연구에 의하면, 일사량과 발전량이 비례하고 태양광 모듈의 온

도가 낮을수록 태양광발전 효율이 높다고 연구되었다[4].

태양광발전량 시스템은 동특성 분석, 고장진단, 예측, 모델링 분야에 대해 국내외적으로 다양한 알고리즘이 개발 및 적용되고 있다. 시뮬레이션 툴인 MATLAB을 이용하여 태양광발전시스템의 동적 시스템을 분석한 연구[5]와 퍼지 모델을 이용하여 태양광발전시스템의 고장진단을 수행한 연구[6], 뉴로-퍼지모델인 ANFIS를 이용하여 태양광발전 시스템을 모델링한 연구[7], 확률 모델을 이용하여 태양광발전시스템을 모델링 한 연구[8] 등이 있다. 또한, 신경회로망[9], ELM[10], 데이터 마이닝기법[11]을 이용하여 태양광발전량 예측모델을 개발한 연구도 진행되었다.

본 논문에서는 ELM(Extreme Learning Machine) 기반의 모듈라 네트워크를 이용하여 태양광 일일 발전량 추정모델을 제안한다. 전체 데이터에 대해서 학습과 검증에 사용된 데이터간의 유사성이 낮더라도 구간별로는 학습과 검증 데이터의 유사성이 향상되는 경우도 있다. 이런 경우에는 전체 입출력 데이터에 대해서 학습을 하는 대신에 구간별로 몇 개의 서브그룹으로 나누어서 학습을 하는 것이 효과적이다. 이와 같이 하나의 복잡한 문제를 단순한 여러 개의 부분적인 문제로 나누어 해결하는 방식을 모듈라 네트워크라 한다.

제안된 방법은 훈련 데이터 전체를 이용하는 대신에 퍼지 클러스터링 기법(FCM : Fuzzy C-Means)을 이용하여 훈련 데이터를 여러 개의 서브 그룹으로 분할한다. 각각의 분할된 모델에 대해서 ELM을 이용하여 독립적인 학습모델을 구축한다. 퍼지 클러스터링 기법에 의해 산출된 각각 그룹의 중심값은 검증 데이터를 분할하기 위하여 사용되고, 각각의 서브 모델에 대한 ELM 학습 파라미터는 검증 데이터에 대한 태양광발전 추정을 위해 사용되어야 하므로 학습단계에서 저장해 놓는다. 발전량 추정단계에서는 주어진 입력 데이

† Corresponding Author : Dept. of Electrical Engineering
Korea National University of Transportation, Korea
E-mail : psji@ut.ac.kr

* Semyeong ENG Ltd. Korea
접수일자 : 2016년 4월 18일
최종완료 : 2016년 5월 17일

터를 학습 단계에서 미리 계산된 서브 그룹의 중심값과 비교하여 중심값에 가장 근접한 서브 모델을 선택한 후, 선택된 서브모델에 입력 데이터를 입력함으로써 태양광의 발전량을 추정하게 된다. 제안된 방법은 전체 데이터를 이용하는 대신에 여러 개의 서브그룹으로 분할 한 후, 해당되는 서브 모델로부터 태양광발전량을 추정하는 특징이 있다.

2. 제안된 태양광 발전 시스템 모델링 기법

2.1 제안된 알고리즘 구성도

본 논문에서는 그림 1에서 보는 바와 같이 ELM 기반의 모듈러 네트워크를 이용하여 태양광발전 시스템 모델을 제안한다. 그림 1에서 보는 바와 같이 외부 인자를 이용하여 태양광발전 모델을 구축하고, 모델 구축시에 사용되지 않은 데이터를 이용하여 태양광발전량을 추정한다. 모델의 입력 인자로는 일조시간, 일사량, 운량, 온도를 이용하였다.

모델 구축시 그림 1(a)에 나타난 바와 같이 훈련 데이터 전체를 이용하는 대신에 퍼지 클러스터링 기법(FCM)을 이용하여 학습데이터를 여러 개의 서브 그룹으로 분할한다. 각각의 분할된 모델에 대해서 ELM을 이용하여 독립적인 학습모델을 구축한다. 퍼지 클러스터링 기법에 의해 산출된 각각 그룹의 중심값은 검증 데이터를 분할하기 위하여 사용되고, 각각의 서브 모델에 대한 ELM 학습 파라미터는 검증 데이터에 대한 태양광발전 추정을 위해 사용되어야 하므로 학습단계에서 저장해 놓는다. 그림 1(b)에 나타난 추정단계에서는 주어진 입력 데이터를 학습 단계에서 미리 계산된 서브 그룹의 중심값과 비교하여 중심값에 가장 근접한 서브 모델을 선택한 후, 선택된 서브모델에 입력 데이터를 입력함으로써 태양광의 발전량을 추정하게 된다. 제안된 방법은 전체 데이터를 이용하는 대신에 여러 개의 서브그룹으로 분할한 후, 해당되는 서브모델로부터 태양광발전량을 추정하는 특징이 있다.

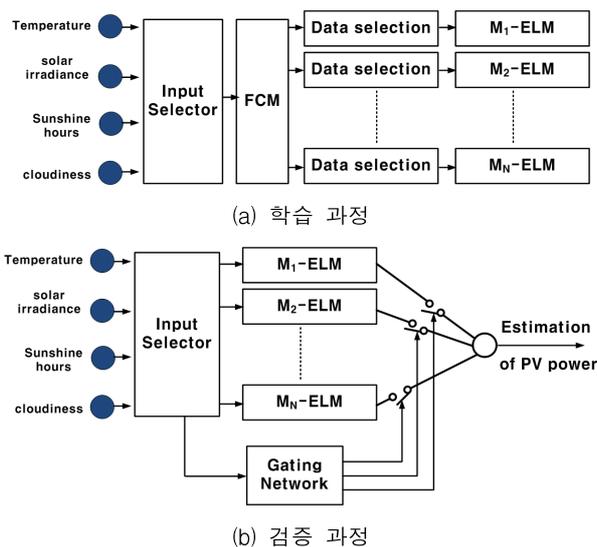


그림 1 제안된 방법의 학습과정과 검증 과정
Fig. 1 Training and testing process of the proposed method

2.2 FCM을 이용한 서브 모델 분할

클러스터링의 목적은 주어진 데이터로부터 유사한 클러스터들을 나누는 것이다. 여기서 유사하다는 것은 같은 그룹 내 모든 데이터들이 서로 근접하고 다른 그룹의 데이터들과 멀리 떨어져 있다는 것을 의미한다. 클러스터링 알고리즘은 패턴 부류들을 만들거나 관련된 정보를 유지하도록 하면서 데이터 집합의 크기를 줄이기 위해 사용될 수 있다. 일반적으로, 데이터 집합 내에 서로 다른 클러스터들이 함께 존재하게 된다. 그러나 이러한 클러스터들의 분리는 퍼지 집합에 의해 클러스터의 표현이 어떤 상황에서는 더 적절할 수 있다.

Bezdek에 의해 제안된 FCM(Fuzzy C-Means) 클러스터링은 식 (1)과 같은 목적함수를 최소화하도록 하는 반복적인 알고리즘으로서 주어진 데이터로부터 유사한 클러스터를 나누며 생성된 클러스터는 시스템의 특성적인 동작을 기술하는 규칙으로서 사용되어진다[12].

FCM 알고리즘을 단계별로 간략히 설명하면 다음과 같다.

[단계 1] 취득하고자 하는 대표점의 수 c , 클러스터의 개수 $c(2 \leq c \leq n)$ 를 정하고, 초기 분할행렬 $U^{(0)}$ 를 초기화한다. 분할행렬에 할당될 소속정도의 값 u_{ik} 는 식(1)을 만족한다.

$$u_{ik} = u_{A_i}(x_k) \in [0, 1] \quad (1)$$

여기서, $i = 1, 2, \dots, c$ 로 클러스터의 개수를 의미한다.

[단계 2] 데이터 \mathbf{x} 와 초기 분할행렬값 $U^{(0)}$ 를 이용하여 대표 특징의 중심 $v_{ij}^{(r)}$ 을 계산하면 식(2)와 같다.

$$v_{ij}^{(r)} = \frac{\sum_{k=1}^n u_{ik}^m \cdot x_{kj}}{\sum_{k=1}^n u_{ik}^m} \quad (2)$$

여기서, m 은 퍼지화 정도를 나타내는 퍼지 수로써 일반적으로 2를 이용한다.

[단계 3] [단계 2]에서 계산된 대표 특징들의 중심값과 데이터 \mathbf{x} 와의 거리값 d 에 의하여 분할행렬 $U^{(r)}$ 를 식(3)과 같이 갱신한다.

$$u_{ik}^{(r+1)} = \left[\sum_{j=1}^c \left(\frac{d_{ik}^{(r)}}{d_{jk}^{(r)}} \right)^{2/(m-1)} \right]^{-1} \quad (3)$$

여기서, d_{jk} 는 p 차원을 갖는 j 번째 데이터 x_j 와 k 번째 대표 중심값 v_k 와의 유클리디안 거리값은 식(4)와 같다.

$$d_{jk} = d(x_j, c_k) = \left[\sum_{i=1}^p (x_{ji} - v_{ki})^2 \right]^{-1} \quad (4)$$

[단계 4] 식 (5)와 같이 목적함수를 계산한 후, 만약 식

(6)을 만족하면 알고리즘을 종료하고 그렇지 않으면 [단계 2]로 가서 반복 수행한다. 여기서 ϵ 은 목적함수의 개선정도를 나타내는 임계값이다.

$$J(U, c_1, c_2, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 \quad (5)$$

$$\|J(U^r, v^r) - J(U^{(r-1)}, v^{(r-1)})\| \leq \epsilon \quad (6)$$

2.3 ELM을 이용한 모듈러 모델 구축

ELM은 그림 2에서 보는 바와 같이 단일 은닉층을 가지는 전방향 네트워크로 Huang[13] 등에 의하여 제안되었다. 최급경사법(gradient descent method)에 기반한 신경 회로망의 학습은 일반적으로 좋은 성능을 얻기 위해 많은 반복 학습을 필요로 하며, 적절하지 못한 학습에 의하여 낮은 적응성을 보이거나 종종 국부 최소해(local minimum)에 수렴하는 단점을 가지고 있다. ELM에서 출력 가중치들은 반복적인 학습 구조 대신에 Moore-Penrose 일반화된 역행렬(Moore-Penrose generalized inverse)에 의해 분석적으로 계산되어진다. ELM은 반복학습을 하지 않기 때문에 전형적인 반복 학습 방법들에 비하여 매우 빠른 학습이 가능하다. 주요 특징으로 ELM은 작은 학습 오차값을 가질 뿐만 아니라 가중치들의 가장 작은 해를 얻는 경향이 있다. 따라서 ELM은 신경 회로망의 우수한 성능을 얻을 수 있다. 또한, 경사기반 학습방법들이 국부최소(local minimum), 과잉적합(over-fitting)과 같은 문제점이 있는 반면에 ELM은 한 번의 학습으로 최적의 해에 직접적으로 도달하는 경향이 있다.

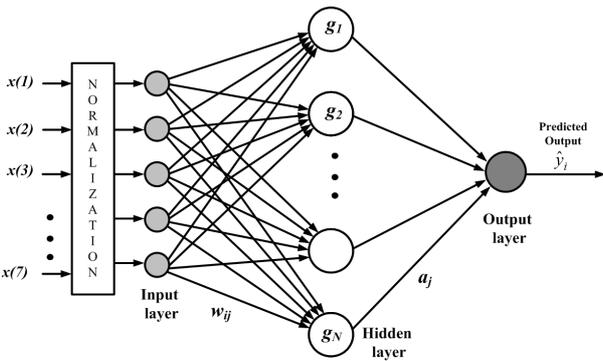


그림 2 ELM 구조

Fig. 2 Structure of ELM

그림 2에 나타낸 ELM에 의한 학습과정을 살펴보면 다음과 같다.

m 개의 데이터 $\{(x_i, y_i), i=1, 2, \dots, m\}$ 와 한개의 출력노드를 가지고 N 개의 은닉노드들을 가지는 전방향 신경 회로망의 학습을 고려해보자. 여기서, 입력 $x_i = [x_{i1}, x_{i2}, \dots, x_{ie}]^T \in R^n$ 이고, $y_i \in R$ 이며, N 개의 은닉노드들의 활성화 함수 $g(x)$ 에 의한 전방향 신경 회로망의 출력은 다음과 같이 나타낼 수 있다.

$$g(w_j \cdot x_i) \cdot a = y_i, \quad i = 1, 2, \dots, m \quad (7)$$

여기서, $w_j = [w_{j1}, w_{j2}, \dots, w_{jn}]^T, j = 1, 2, \dots, N$ 은 j 번째 은닉노드와 입력노드들을 연결하는 가중치 벡터로 임의의 값으로 초기화 되며, $a = [a_1, a_2, \dots, a_N]^T$ 는 은닉노드들과 출력노드를 연결하는 가중치 벡터이다. $w_j \cdot x_i$ 는 w_j 와 x_i 의 내적을 의미한다.

식 (7)은 다음과 같이 간결하게 표현될 수 있다.

$$Ga = y \quad (8)$$

여기서

$$G(w_1, \dots, w_N, x_1, \dots, x_m) = \begin{bmatrix} g(w_1 \cdot x_1) & \dots & g(w_N \cdot x_1) \\ \vdots & & \vdots \\ g(w_1 \cdot x_m) & \dots & g(w_N \cdot x_m) \end{bmatrix} \quad (9)$$

$$y = \begin{bmatrix} y_1 \\ \vdots \\ y_m \end{bmatrix}_{m \times 1} \quad (10)$$

G 는 전방향 신경 회로망에서 은닉층의 출력으로 G 의 i 번째 열은 입력 x_1, x_2, \dots, x_m 과 관련된 i 번째 은닉노드들의 출력 벡터이다. 최종적으로, 다음과 같이 최소자승법에 의하여 출력 가중치 \hat{a} 을 구한다.

$$\hat{a} = G^\dagger y \quad (11)$$

여기서 G^\dagger 는 은닉층의 출력 G 의 Moore-Penrose 일반화된 역행렬이다. 만일 $G^T G$ 가 비정칙인 경우, G 의 Moore-Penrose 일반화된 역행렬은 다음과 같이 얻어진다.

$$G^\dagger = (G^T G)^{-1} G^T \quad (12)$$

최종 예측은 다음과 같이 얻어진다.

$$\hat{y} = G \hat{a} \quad (13)$$

3. 실험 및 결과

3.1 데이터 취득 및 평가 지표

제안된 예측모델의 성능을 분석하기 위하여 그림 3에 나타난 청주의 S 태양광 발전시스템의 2014년 자료를 이용하였다. 대상 태양광발전 시스템은 70 [kW]의 계통연계형으로 250 [W] 모듈 280장과 36 [kW]급 인버터 2대로 구성되어있고 2012년에 설치, 운용중이다.

평가지표로는 아래 식의 절대평균 퍼센트 오차인 MAPE (Mean Absolute Percentage Error), MAE(Mean Absolute Error) 및 평균제곱오차인 RMSE(Root Means Square Error)를 고려하였다.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Measured_i - Forecast_i}{Measured_i} \right| \times 100 \quad (14)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Measured_i - Forecast_i| \quad (15)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Measured_i - Forecast_i)^2} \quad (16)$$



그림 3 데이터 취득에 사용된 태양광 발전 시스템
Fig. 3 PV system for data acquisition

3.2 실험 결과

본 논문에서는 전체 데이터에 대해서 학습을 하는 대신에 구간별로 몇 개의 서브그룹으로 나누어서 학습을 한 후, 검증데이터에 대해서도 해당되는 서브그룹의 학습파라미터를 이용하여 태양광발전량을 추정하는 모듈러 네트워크를 제안하였다. 모듈러 네트워크의 모델은 다른 모델에 비하여 우수한 성능을 나타낸 ELM을 기반으로 하였다. 모듈러 네트워크를 기반으로 하여 태양광발전량을 추정하기 위해서는 서브 그룹의 수, 즉 모듈의 수를 설정하여야 한다.

본 논문에서는 모듈을 수를 최소 2개에서 최대 5개까지 1씩 증가하여 실험을 하였다. 표 1에서는 클러스터의 수에 따른 MAPE, MAE, RMSE를 나타냈다. 표 1에서 알 수 있는 바와 같이 모델이 한 개인 ELM 모델을 이용할 경우 학습데이터에 대해서 MAPE는 7.26 [%], MAE는 9.12, RMSE는 11.44로 나타났으며, 검증데이터에 대해서 MAPE는 7.45[%], MAE는 9.18, RMSE는 11.48로 나타났다.

분할모델이 2개인 ELM 모델을 이용할 경우 학습데이터에 대해서 MAPE는 7.51[%], MAE는 9.17, RMSE는 11.41로 나타났으며, 검증데이터에 대해서 MAPE는 6.97[%], MAE는 8.68, RMSE는 11.57로 나타났다. 분할모델이 3개인 ELM 모델을 이용할 경우 학습데이터에 대해서 MAPE는 6.73[%], MAE는 8.50, RMSE는 10.79로 나타났으며, 검증데이터에 대해서 MAPE는 6.95[%], MAE는 8.55, RMSE는 11.18로 나타났다. 분할모델이 4개인 ELM 모델을 이용할 경우 학습데이터에 대해서 MAPE는 6.15[%], MAE는 8.02, RMSE는 9.83으로 나타났으며, 검증데이터에 대해서 MAPE는 6.41[%], MAE는 7.92, RMSE는 10.01로 나타났다. 마지막으로, 분할모델이 5개인 ELM 모델을 이용할 경우 학습데이터에 대해서 MAPE는 6.44, MAE는 8.14, RMSE는 9.94로 나타났으며, 검증데이터에 대해서 MAPE는 6.76[%], MAE는 8.17, RMSE는 10.77로 나타났다. 따라서 분할모델이 4개 일 때 태양광 추정모델의 성능이 가장 우수함을 알 수 있다.

그림 4에서는 각 분할모델의 중심값을 나타냈다. Modular-1의 대표값은 다른 Modular 대표값에 비하여 최고 온도, 일사량, 일조시간이 가장 높은 반면 운량이 가장 적다. Modular-2의 대표값은 다른 Modular 대표값에 비하여 최고

온도는 가장 낮고, 일사량은 중간정도, 일조시간은 두 번째로 높고, 운량이 가장 적다. Modular-3의 대표값은 다른 Modular 대표값에 비하여 최고온도, 일사량, 일조시간은 가장 낮고 운량은 가장 많다. Modular-4의 대표값은 다른 Modular 대표값에 비하여 최고온도는 가장 높고, 일사량은 중간정도, 일조시간은 상대적으로 작고, 운량은 가장 적다. 그림 4의 각 모듈의 입력패턴의 중심값을 이용하여 태양광 출력패턴과 연계시켜 설명하면, Modular-1은 온도, 일사량, 일조시간이 가장 많고, 운량이 가장 적음으로 태양광 출력이 가장 많은 부분에 해당하는 입력패턴의 대표값이라 할 수 있다. 그리고 Modular-3은 온도, 일사량, 일조시간이 가장 적고, 운량이 가장 많음으로 태양광 출력이 가장 낮은 부분에 해당하는 입력패턴의 대표값이라 할 수 있다. Modular-2와 Modular-3에 해당하는 입력패턴은 출력패턴이 높은 부분과 낮은 부분의 중간정도에 위치에 있는 입력데이터의 대표값이라 할 수 있다.

표 1 분할 모듈의 수에 따른 제안된 방법의 모델링 결과
Table 1 Modeling results according to number of sub model

서브모듈의 수		Training data			Testing data		
		MAPE	MAE	RMSE	MAPE	MAE	RMSE
1	ELM	7.26	9.12	11.44	7.45	9.18	11.48
2	Modular 1	10.63	10.38	12.79	9.64	9.80	12.72
	Modular 2	5.03	8.21	10.18	4.70	7.73	10.48
	M2-ELM	7.51	9.17	11.41	6.97	8.68	11.57
3	Modular 1	7.59	9.29	11.38	7.22	8.96	11.15
	Modular 2	4.32	7.20	9.23	4.46	7.37	10.24
	Modular 3	9.23	9.48	12.10	10.30	9.90	12.42
	M3-ELM	6.73	8.50	10.79	6.95	8.55	11.18
4	Modular 1	4.54	7.86	9.46	4.10	7.13	9.04
	Modular 2	5.86	8.69	10.62	5.10	7.46	9.96
	Modular 3	8.14	6.44	7.54	11.55	9.22	10.81
	Modular 4	8.07	8.73	11.03	7.41	8.56	10.60
	M4-ELM	6.15	8.02	9.83	6.41	7.92	10.01
5	Modular 1	8.77	9.12	11.34	8.93	9.51	11.92
	Modular 2	6.66	9.46	11.28	5.69	7.96	10.62
	Modular 3	4.98	8.19	9.58	5.08	7.74	10.51
	Modular 4	3.44	6.38	7.94	3.62	6.70	9.63
	Modular 5	9.18	6.40	7.72	12.71	9.45	11.28
	M5-ELM	6.44	8.14	9.94	6.76	8.17	10.77

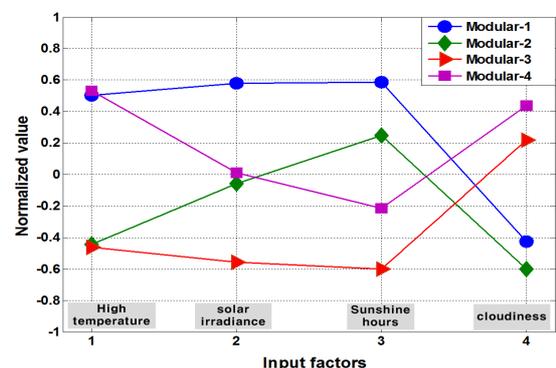
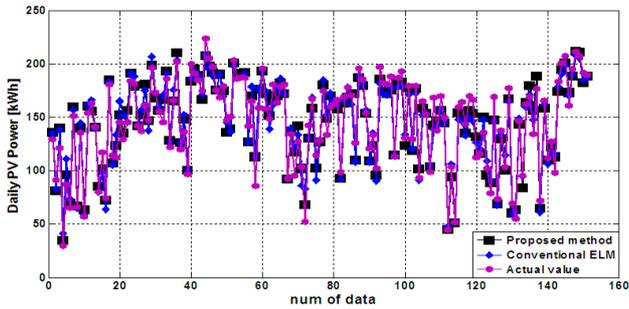
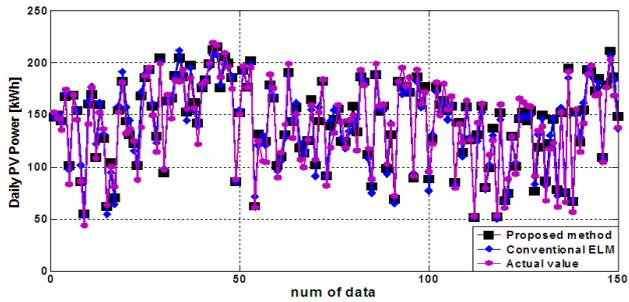


그림 4 각 분할모델의 중심값
Fig. 4 Centers for each sub-model



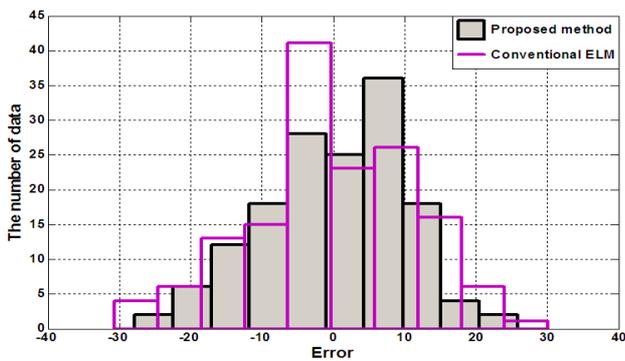
(a) 학습데이터



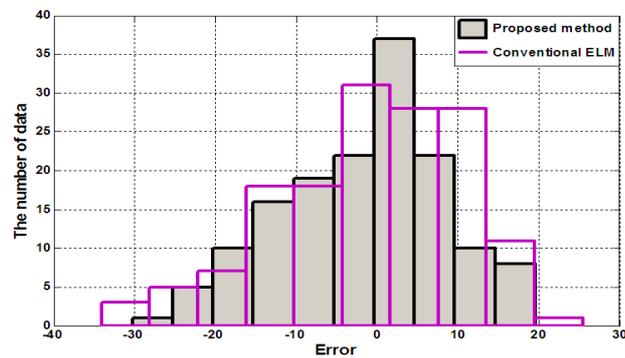
(b) 검증 데이터

그림 5 제안된 모델과 기존 ELM 모델의 모델링 결과

Fig. 5 Modeling result for proposed method and conventional ELM



(a) 학습데이터



(b) 검증 데이터

그림 6 제안된 모델과 일반적인 ELM 모델의 오차 분석

Fig. 6 Error analysis for proposed method and conventional ELM

4. 결 론

태양광발전 시스템을 효과적으로 운영하기 위해서는 성능이 우수한 발전량 예측 모델개발이 중요한 요소이다. 본 논문에서는 고려대상인 데이터 전체를 이용하는 대신에 퍼지 클러스터링 기법을 이용하여 여러 개의 서브그룹으로 분할하는 ELM 기반의 모듈라 네트워크를 이용한 태양광 발전 시스템 모델링 기법을 제안하였다. 제안된 방법을 적용하여 태양광 발전시스템을 모델링 한 결과 학습데이터에 대해서 MAPE는 6.15[%], MAE는 8.02, RMSE는 9.83을 나타냈으며, 검증데이터에 대해서는 MAPE는 6.41[%], MAE는 7.92, RMSE는 10.01의 성능을 보였다. 이러한 성능은 기존의 ELM 방법에 비하여 학습 및 검증 데이터 모두 효과적인 것으로 나타났다. 향후 태양광 발전시스템의 모델 성능 향상을 위하여 본 논문에서 고려하지 않은 다양한 입력인자 등을 적용하는 방법과 효과적으로 분할모형을 구성하는 방법에 대해서도 지속적으로 연구하고자 한다.

감사의 글

본 연구는 중소기업청에서 지원하는 2015년도 산학연협력 기술개발사업(No.C0330870)의 연구수행으로 인한 결과물임을 밝힙니다.

References

- [1] Jong-Jae Choi, Chan-Gyu Hwang, Chae-Joo Moon, "Development of Evaluation Model for the Korean New & Renewable Energy Policies : Focusing on RPS & FIT," The Korea Institute of Electronic Communication Sciences, Vol. 8, No. 9, pp. 1333-1342, 2013.
- [2] K. D. King, "The Development of the Short-Term Predict Model for Solar Power Generation," Journal of the Korean Solar Energy Society, Vol. 33, No. 6, pp. 62-69, 2013.
- [3] A. Molki, "Dust affects solar cell efficiency," Physics Education, Vol. 45, pp. 456-458, 2010.
- [4] Pratish Rawat, Pardeep Kumar, "Performance evaluation of solar photovoltaic/thermal systems," International Journal of Science and Research, Vol. 4, Issue 8, pp. 1466-1471, 2015.
- [5] C. S. Chin, A. Babu, W. McBride, "Design, modeling and testing of a standalone single axis active solar tracker using MATLAB/Simulink," Renewable Energy, vol. 36, no. 11, pp. 3075-3090, 2011.
- [6] Modeling and fault diagnosis of a photovoltaic systems," Electrical Power Research, Vol. 78, No. 1, pp. 97-105, 2008.
- [7] A. Mellit, S. Kalogirou, "ANFIS-based modelling for photovoltaic power supply system: A case study," Renewable Energy, vol. 36, no. 1, pp. 250-258, 2011.

- [8] Hyun Cheol Cho, Young Jin Jung, "Probabilistic Modeling of Photovoltaic Power Systems with Big Learning Data Sets," Korean Institute of Intelligent Systems, Vol. 23, No. 5, pp. 412-417, 2013.
- [9] Jae-Ju Song, Yoon-Su Jeong, Sang-Ho Lee, "Analysis of prediction model for solar power generation," Journal of Digital Convergence, Vol. 12, No. 3, pp. 243-248, 2014.
- [10] Kim Kwang-Deuk, "The Development of the Short-Term Predict Model for Solar Power Generation," The Korean Solar Energy Society, Vol. 33, No. 6, pp. 62-69, 2013.
- [11] Chang-Sung Lee, Pyeong-Shik Ji, "Development of Daily PV Power Forecasting Models using ELM," The Korean Institute of Electrical Engineers, Vol. 64P, No. 3, pp. 164-168, 2015.
- [12] J. C. Bezdek, Pattern recognition with fuzzy objective function algorithms, Plenum Press, New York, 1981.
- [13] G. B. Huang, Q. Y. Zhu, and C. K. Siew, "Extreme learning machine: a new learning scheme of feedforward neural networks," in Proc. 2004 IEEE Int. Conf. Neural Networks, Vol. 2, pp. 985-990, 2004.

저 자 소 개



이 창 성 (李 唱 成)

2011년 한국교통대학교 전기공학과 석사과정 졸업(석사), 2016년 동대학원 박사과정 졸업(박사), 발송배전기술사, 현재 ㈜세명이앤씨 전무이사

E-mail : csd66@empas.com



지 평 식 (池 平 植)

1994년 충북대학교 대학원 전기공학과 석사과정 졸업(석사), 1998년 동대학원 박사과정 졸업(박사), 현재 한국교통대학교 전기공학과 교수

E-mail : psji@ut.ac.kr