

ELM을 이용한 일별 태양광발전량 예측모델 개발

Development of Daily PV Power Forecasting Models using ELM

이 창 성* · 지 평 식†

(Chang-Sung Lee · Pyeong-Shik Ji)

Abstract - Due to the uncertainty of weather, it is difficult to construct an accurate forecasting model for daily PV power generation. It is very important work to know PV power in next day to manage power system. In this paper, correlation analysis between weather and power generation was carried out and daily PV power forecasting models based on Extreme Learning Machine(ELM) was presented. Performance of district ELM model was compared with single ELM model. The proposed method has been tested using actual data set measured in 2014.

Key Words : PV power, Forecasting model, ELM, Neural networks

1. 서 론

근래에 고유가가 지속되는 가운데 이산화탄소 배출 억제 등 지구 온난화 방지를 위하여 각국 정부의 정책적 지원을 바탕으로 세계 태양광 산업 규모는 매년 성장하고 있다[1, 2].

태양광 발전시스템을 구성하는 핵심 부품인 태양전지(PV) 모듈은 반도체 소자인 태양전지 수십 개가 직·병렬로 연결되어 태양의 빛 에너지를 전기 에너지로 변환시키는 발전장치로, 태양광 발전시스템을 구성하는 부품 중에서 가장 고가이면서 시스템 전체의 수명을 좌우한다. 태양전지 모듈의 수명은 제작 방식에 따라 10년~20년 이상으로 사용이 가능하며, 한번 설치해 놓으면 유지 보수비용이 거의 들지 않고 설치장소에 따라 소형에서 대형까지 시스템 규모를 자유롭게 결정할 수 있는 장점이 있다. 태양광 발전 시스템은 무음으로 동작하고, 가동부도 없어 표면상 작동하고 있는지, 정지되어 있는지, 최대 성능을 발휘하고 있는지 또는 일부 고장이 발생하였는지 파악하기 어렵고 계절이나 기후에 의해서 발전량이 크게 변동한다는 것을 인지하고 있기 때문에 이상에 의한 발전량 감소에도 낱씨 탓으로 생각하는 경우가 많다[3, 4].

태양광발전에 영향을 미치는 요소는 발전설비가 설치되는 위치에 따른 위도나 설치 높이와 같은 지리적인 요인, 모듈의 설치형태(고정식, 추적식 등)와 발전설비의 효율 등의 설비요소, 그리고 일사량, 일조시간, 운량, 온도 등의 기상요소의 세 가지로 나눌 수 있다[5-9]. 이들 영향 요소 중 지리적

인 요인과 설비요소는 한번 발전소가 건설되는 시점에서 결정되는 요인이나 기상요소는 발전설비가 운영되는 동안 계속해서 바뀌며 발전량 변동에 직접적인 영향을 준다. 태양광 발전량의 변동은 크게는 국가 전체의 전력공급에까지 영향을 미치게 되므로 발전량의 실시간 모니터링은 물론 하루 뒤 또는 수 시간 뒤의 발전량을 예측하고 다른 발전소의 발전계획에 반영해야만 한다[10].

본 연구에서는 현재 운용 중에 있는 태양광 발전시스템에서 1년간 실측된 발전량 자료와 기상정보를 분석하여 상관성 높은 입력인자를 도출하고, 선정된 입력인자들을 바탕으로 최상학습기계(ELM:Extreme Learning Machine)을 이용한 태양광발전량 예측 모델을 구축하고자 한다.

2. ELM을 이용한 태양광발전량 예측 모델

그림 1에서는 본 연구에서 개발한 ELM을 이용한 최대 전력 수요 예측 기법을 나타냈다. 그림 1에서 보는 바와 같이 ELM 모델은 Huang등에 의하여 제안된 방법으로, 구조는 입력층, 은닉층, 출력층으로 되어 있으며 은닉층의 노드 수는 사용자에 의해 결정된다[11, 12]. 본 연구에서 입력층에 사용된 인자로는 상관성 분석을 통하여 상관관계가 높은 데이터를 이용하였다. ELM은 신경회로망과 동일하게 은닉층과 출력층 사이에는 서로를 연결해 주는 가중치 W 가 존재하며 입력벡터 X 를 출력값 Y 로 대응시켜주는 비선형 함수의 역할을 한다. 은닉층에 사용되는 기저함수로는 일반적으로 sigmoid 함수를 주로 사용한다. 최급경사법(gradient descent method)에 기반한 일반적인 신경 회로망의 학습은 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. 그러나 ELM에서 출력 가중치들은 반복적인 학습 구조 대신에 그림 2에 나타난 바와 같이 모어-페로스의 일반화된 역행렬(Moore-Penrose generalized inverse)에 의해 분석적으로 계산되어 지므로 반복학습이 이루어지지 않는 장점이 있다.

* Dept. of Electrical Engineering Korea National University of Transportatio, Korea

† Corresponding Author : Dept. of Electrical Engineering Korea National University of Transportatio, Korea

E-mail : psji@ut.ac.kr

접수일자 : 2015년 8월 7일

수정일자 : 2015년 8월 18일

최종완료 : 2015년 8월 24일

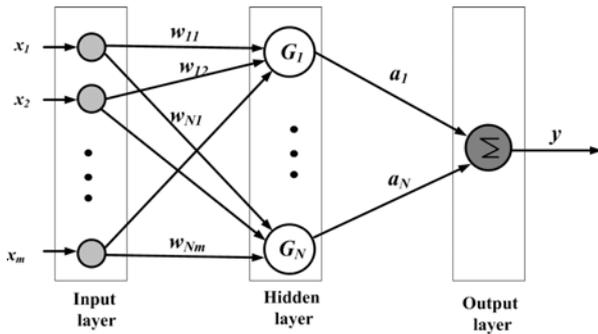


그림 1 ELM을 이용한 태양광 발전량 예측 기법
Fig. 1 PV power forecasting method using ELM

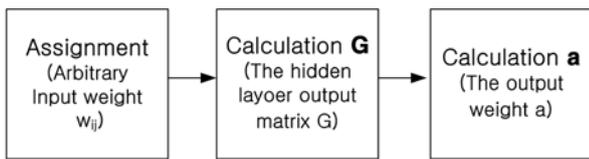


그림 2 ELM의 학습과정
Fig. 2 Learning process of ELM

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

$$\mathbf{g}(\mathbf{w}_j \cdot \mathbf{x}_i) \cdot \mathbf{a} = y_i, \quad i = 1, 2, \dots, m \quad (1)$$

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

식 (1)은 식 (2)와 같이 간결하게 표현될 수 있다.

$$\mathbf{G}\mathbf{a} = \mathbf{y} \quad (2)$$

여기서

$$\mathbf{G}(\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_N, \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m) = \begin{bmatrix} \mathbf{g}(\mathbf{w}_1 \cdot \mathbf{x}_1) & \dots & \mathbf{g}(\mathbf{w}_N \cdot \mathbf{x}_1) \\ \vdots & & \vdots \\ \mathbf{g}(\mathbf{w}_1 \cdot \mathbf{x}_m) & \dots & \mathbf{g}(\mathbf{w}_N \cdot \mathbf{x}_m) \end{bmatrix} \quad \mathbf{y} = \begin{bmatrix} y_1 \\ \vdots \\ y_m \end{bmatrix} \quad (3)$$

\mathbf{G} 는 전방향 신경 회로망에서 은닉층의 출력으로 \mathbf{G} 의 i 번째 열은 입력 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m$ 과 관련된 i 번째 은닉노드들의 출력 벡터이다. 최종적으로, 식 (4)와 같이 최소자승법에 의하여 출력 가중치 $\hat{\mathbf{a}}$ 을 구한다.

$$\hat{\mathbf{a}} = \mathbf{G}^\dagger \mathbf{y} \quad (4)$$

여기서 \mathbf{G}^\dagger 는 은닉층의 출력 \mathbf{G} 의 모어-페로스의 일반화된 역행렬이다. 만일 $\mathbf{G}^T \mathbf{G}$ 가 비정칙인 경우, \mathbf{G} 의 모어-페로스의 일반화된 역행렬은 식 (5)과 같으며, 최종 모델링 결과는 식 (6)과 같다[13].

$$\mathbf{G}^\dagger = (\mathbf{G}^T \mathbf{G})^{-1} \mathbf{G}^T \quad (5)$$

$$\hat{\mathbf{y}} = \mathbf{G} \hat{\mathbf{a}} \quad (6)$$

따라서, ELM의 주된 특징은 다른 신경회로망의 학습방법과 달리 반복학습을 하지 않기 때문에 전형적인 반복 학습 방법들에 비하여 매우 빠른 학습이 가능하다는 점과 ELM은 작은 학습 오차값을 가질 뿐만 아니라 가중치들의 최적의 해를 얻는 경향이 있다는 점이다. 특히, 경사 기반 학습 방법들이 국부최소(local minimum), 오버피팅과 같은 문제점이 있는 반면에 ELM은 한 번의 학습으로 최적의 해에 직접적으로 도달한다.

3. 사례 연구

3.1 태양광발전량 분석

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



그림 3 태양광 발전 시스템 전경
Fig. 3 View of the PV system

태양광 발전량 예측모델을 개발하기 위해서는 발전량에 영향을 주는 인자와의 상관성분석이 필연적이다. 즉, 이러한 상관성 분석을 통하여 발전량에 영향을 주는 주요 인자들을 선택하여 발전량 예측을 위한 모델의 입력으로 사용하게 된다. 상관성은 예측하고자하는 시점의 전날의 시간인자와 최고온도, 최저온도, 평균온도, 일조량, 일조시간, 운량 등의 외부 인자로 구분하여 분석하였다. 온도 및 일조량 등의 기상 자료는 기상청과 국가수자원관리 종합정보시스템에서 취득하였다.

표 1에서는 2014년 데이터를 이용하여 시간정보와 기상정

보를 이용한 상관성 분석결과를 나타냈다. 표 1에서 보는 바와 같이 태양광 발전량은 일조시간과 0.81의 상관계수 값으로 0.80의 일사량과 함께 큰 상관관계를 보였다. 또한 운량과의 상관계수는 -0.72로 큰 반비례 관계라는 것을 알 수 있고 평균기온 등의 온도와는 상관관계가 매우 약한 것을 알 수 있다. 한편 예측하려고 하는 날짜보다 하루 전의 발전량과는 0.42의 상관계수 값을 보여 시계열 특성은 보이지 않는 것으로 판단된다. 상관성분석에 사용된 영향인자들과 태양광 발전량 사이의 데이터 분포를 그림 4에 나타냈다.

표 1 상관성 분석

Table 1 Correlation analysis

항 목	상관계수	비고
평균기온	0.0501	
최저기온	-0.0476	
최고기온	0.1566	
일사량	0.8064	
일조시간	0.8150	
운량	-0.7207	
전일	0.4215	

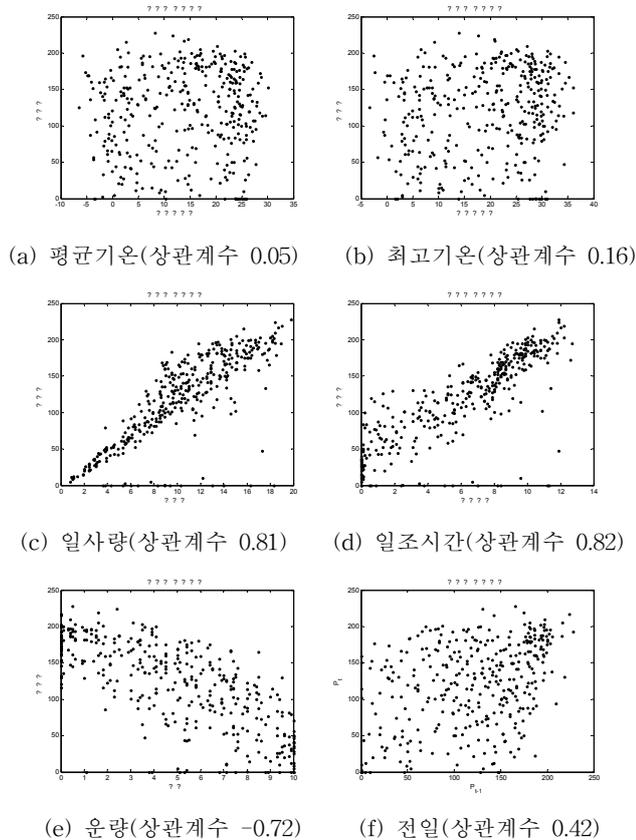


그림 4 발전량과 영향인자의 데이터 분포
Fig. 4 Data distribution between PV power and influence factor

3.2 발전량 예측결과

본 연구에서는 ELM을 이용한 일별 태양광발전량 예측 모델을 개발하였다. 개발된 방법을 평가하기 위하여 2014년도의 발전량 데이터를 이용하여 신경회로망의 학습과 검증에 사용하였다.

ELM 학습을 위해서는 효과적인 입력 인자의 선택이 매우 중요하다. 본 논문에서는 3.1절에서 수행한 상관성 분석을 통해 얻어진 상관관계를 바탕으로 일사량, 일조시간, 운량을 입력인자로 선택하였다. 평가지표로는 아래 식의 절대평균 퍼센트 오차인 MAPE (Mean Absolute Percentage Error), MAE(Mean Absolute Error) 및 평균제곱오차인 RMSE(Root Means Square Error)를 고려하였다.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Measured_i - Forecast_i}{Measured_i} \right| \times 100 \quad (7)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Measured_i - Forecast_i| \quad (8)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Measured_i - Forecast_i)^2} \quad (9)$$

3.2.1 전체 자료에 대한 단일 ELM모델의 예측 결과

먼저 전체 출력범위에 대하여 하나의 모델로 예측을 수행하도록 하는 단일 ELM모델을 구축하였다. 모델의 은닉층 개수는 10개로 하였고 시계열 특성을 보이지 않았으므로 2014년 자료를 홀수 번째 자료와 짝수 번째 자료로 나누어 각각 학습과 검증에 이용하였다.

표 2와 그림 5에 단일 ELM모델을 이용한 예측 결과를 나타내었다. 학습 자료에 대한 오차는 약 10.57 [%]이고 검증 자료에 대한 오차는 약 11.92 [%]로 큰 오차를 보이고 있다. 이러한 오차는 그림 4의 상관성 분석에서 보이는 것처럼 동일한 일조시간과 동일한 운량이라고 하더라도 하루 중 어떤 시간대에 구름이 태양광 패널을 가리고 있는가에 따라 그 발전량은 큰 차이가 나기 때문에 발생하는 것으로 단일 ELM모델로 모델링하는 것이 쉽지 않음을 알 수 있다.

표 2 단일 ELM모델의 예측결과

Table 2 Forecasting result of the single ELM model

평가지표	학습	검증
MAPE	10.5706	11.9166
MAE	10.7499	13.3105
RMSE	16.6944	18.0462

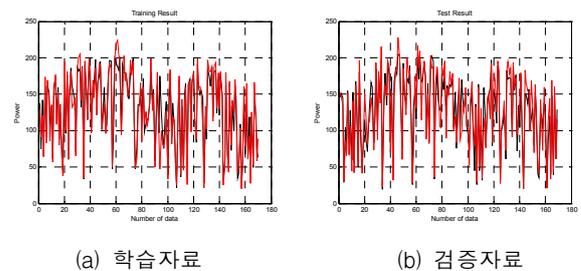


그림 5 단일 ELM모델의 예측 결과
Fig. 5 Forecasting result of the single ELM model

3.2.2 구역별 ELM모델의 예측 결과

단일 ELM모델로 발전량을 예측할 경우 일부 데이터의 특성이 제대로 학습되지 못하는 경우에 예측 오차가 커지게 된다. 이러한 문제를 해결하기 위한 방법의 하나로 본 논문에서는 모델의 출력영역을 나누어 각 구역에 해당하는 구역별 ELM모델을 구축하였다. 데이터 영역을 구역별로 나누어 모델링 하면 그 구조가 복잡해지는 단점이 있지만 데이터들 간의 상호간섭을 줄일 수 있어 비교적 정확한 모델링이 가능하다. 출력영역은 그림 6에서 보이는 것처럼 150 [kW] 이상의 A구역, 100 ~ 150 [kW]인 B구역, 70~100 [kW]의 C 구역과 70 [kW] 이하의 D구역으로 총 4개의 영역으로 나누어 각각 모델링을 수행하였고 그 결과를 표 3에 정리하였다.

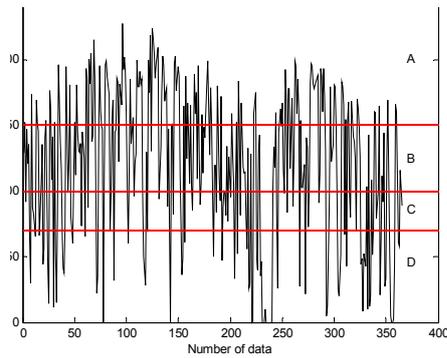


그림 6 출력의 크기에 따른 개별 모델 설정

Fig. 6 The configuration of a Individual model according to amplitude of output

표 3 구역별 ELM 모델의 예측결과

Table 3 Forecasting result of district ELM model

모델	평가지표	학습	검증
A	MAPE	4.0510	4.5260
	MAE	7.2466	8.0623
	RMSE	9.1107	10.0928
B	MAPE	7.9640	8.9520
	MAE	9.8261	10.8067
	RMSE	11.7919	13.2579
C	MAPE	5.7857	6.7966
	MAE	4.8897	5.6656
	RMSE	5.9597	7.3542
D	MAPE	10.8425	10.7321
	MAE	4.3467	4.5127
	RMSE	5.3322	5.2810

표 3의 결과에서 A영역에 대한 구역별 ELM모델 A에 대한 학습 오차는 약 4.05 [%], 검증 오차는 약 4.53 [%]로 잘 모델링되었음을 알 수 있다. 이러한 결과는 A 영역에 해당하는 발전량은 다른 영역에 비해 상대적으로 양호한 기상상태에 해당하기 때문에 발전량 예측을 위한 ELM 모델의 학습이 수월하게 이루어진 것으로 해석된다. D영역에 대한 구

역별 ELM모델 D의 경우 학습 오차는 약 10.84 [%], 검증 오차는 약 10.73 [%]로 예측 오차가 크게 나타났다. D영역의 경우는 기상상태가 좋지 않아 발전량이 작게 나온 영역으로 추정할 수 있고 이에 따라 ELM 모델의 학습이 어려운 영역으로 판단된다. 구역별 ELM모델 D의 RMSE 값이 각각 5.3322, 5.2810으로 구역별 ELM모델 A의 RMSE 값보다 작게 나온 것은 D영역에 해당하는 자료의 개수가 A영역보다

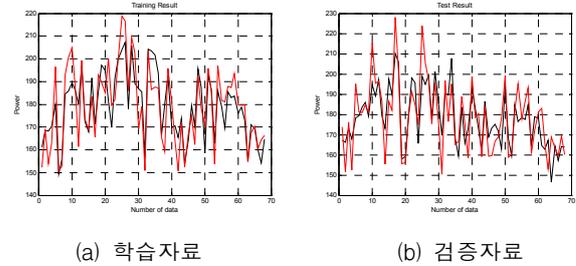


그림 7 구역별 ELM모델 A의 예측 결과

Fig. 7 Forecasting result of district ELM model A

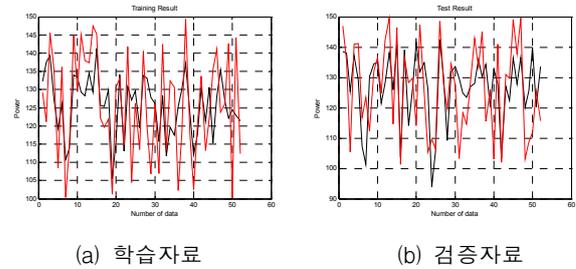


그림 8 구역별 ELM모델 B의 예측 결과

Fig. 8 Forecasting result of district ELM model B

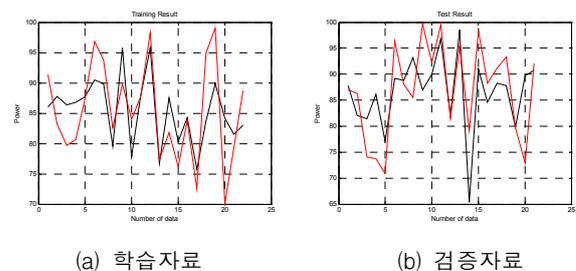


그림 9 구역별 ELM모델 C의 예측 결과

Fig. 9 Forecasting result of district ELM model C

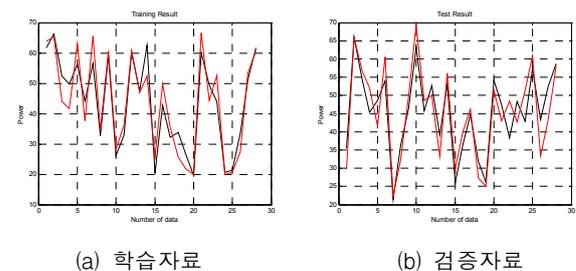


그림 10 구역별 ELM모델 D의 예측 결과

Fig. 10 Forecasting result of district ELM model D

매우 적기 때문이다. B영역과 C영역에 대한 발전량 예측 결과는 A영역에 대한 결과와 D영역에 대한 결과의 중간 정도의 결과로 나타났다. 이들 각 모델의 학습 및 검증자료에 대한 예측 결과를 그림 7~그림 10에 그래프로 나타냈다.

4. 결 론

태양광 발전량의 실시간 모니터링과 신뢰성 있는 발전량 예측은 전력계통의 운용에 경제성과 신뢰성을 향상시킬 수 있다. 본 연구에서는 ELM을 기반으로 일별 태양광발전량 예측 모델을 구축하였다. 먼저 ELM의 입력인자를 선택하기 위하여 기상정보와 발전량 사이의 상관성 분석을 한 결과 온도보다는 일사량, 일조시간, 운량이 더 큰 영향력을 갖는 것으로 나타났다. 또한 전체에 대한 단일 ELM모델과 구역별 ELM모델로 발전량을 추정할 결과 구역을 나누어 모델링하는 것이 예측 오차를 줄일 수 있음을 보였다.

앞으로 입력영역에서 구역을 합리적으로 나누기 위한 입력영역의 클러스터링 관련 연구와 일별 발전량과 시간대별 발전량을 모두 예측할 수 있는 예측모델에 대한 연구가 필요하다.

References

[1] M. Y. Kim, D. G. Lim, J. H. Lee, "A Status and Prospects of e PV Industry", The proceedings of KIEE, Vol. 62, No. 11, pp. 29~32, 2013.

[2] J. H. Kim, "A PV Technology and industrial condition", Optical Science and Technology, ETRI, Vol. 6, No. 1, pp. 3~8, 2012.

[3] 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.

[4] C. C. Hyun, J. J. Young, "Probabilistic Modeling of Photovoltaic Power Systems with Big Learning Data Sets,"Journal of Korean Institute of Intelligent Systems, Vol. 23, No. 5, pp. 412~417, 2013.

[5] W. C. Cha, J. H. Park, U. R. Cho, and J. C. Kim, "A study on Solar Power Generation Efficiency Empirical Analysis according to Temperature and Wind speed", The Transactions of the Korean Institute of Electrical Engineers, Vol. 64P, No. 1, pp. 1~6, 2015.

[6] J. W. Ko, N. R. Yun, Y. K. Min, T. H. Jung, C. S. Won, H. K. Ahn, "Prediction of Output Power for PV Module with Tilted Angle and Structural Design", The Transactions of the Korean Institute of Electrical Engineers Vol. 62, No. 3, pp. 371~375, 2013.

[7] D. K. Jo, Y. H. Kang, "A Detail Survey of Horizontal Global Radiation and Cloud Cover for the Installation of Solar Photovoltaic System in Korea", Journal of the Korean Solar Energy Society, Vol. 30, No. 3, pp. 2~9, 2010.

[8] D. K. Jo, C. Y. Yun, K. D. Kim, Y. H. Kang, "A Detail Survey of Horizontal Global Radiation and Hours of Bright Sunshine for the Installation of Solar Photovoltaic System in Korea", Journal of the Korean Solar Energy Society, Vol. 31, No. 3, pp. 48~56, 2011.

[9] D. K. Jo, C. Y. Yun, K. D. Kim, Y. H. Kang, "A Study on the Estimating Solar Radiation Using Hours of Bright Sunshine for the Installation of Photovoltaic System in Korea", Journal of the Korean Solar Energy Society, Vol. 31, No. 4, pp. 72~79, 2011.

[10] J. M. Won, G. Y. Doe, N. R. Heo, "Predict Solar Radiation According to Weather Report", Journal of Navigation and Port Research, Vol. 35, No. 5, pp. 387~392, 2011.

[11] 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.

[12] G. B. Huang, Q. Y. Zhu, and C. K. Siew, "Extreme learning machine: theory and applications," Neurocomputing, Vol. 70, No. 1-3, pp. 489-501, 2006.

[13] D. Serre, Matrices : Theory and Application, New York, Springer-Verlag, 2002.

저 자 소 개



이 창 성 (李 唱 成)

2011년 한국교통대학교 전기공학과 석사과정 졸업(공학석사), 2015년 동대학원 박사과정 수료, 발송배전기술사, 현재 (주)세명이앤씨 전무이사
E-mail : csd66@empas.com



지 평 식 (池 平 植)

1994년 충북대학교 대학원 전기공학과 석사과정 졸업(공학석사), 1998년 동대학원 박사과정 졸업(공학박사), 현재 한국교통대학교 전기공학과 교수, 대한전기학회 충북지회장
E-mail : psji@ut.ac.kr