

상관성 분석과 ELM을 이용한 태양광 고장진단 알고리즘 개발

Development of Fault Diagnosis Algorithm using Correlation Analysis and ELM

임재윤* · 지평식†
(Jae-Yoon Lim · Pyeong-Shik Ji)

Abstract - It is difficult to establish accurate modeling of PV power system because of various uncertainty. However, it is important work to modeling of PV for fault diagnosis. This paper proposes modeling and fault diagnosis method using correlation analysis and ELM(Extreme Learning Machine). Rather than using total data, we select optimal time interval with higher correlation between PV power and solar irradiation. Also, we use average value during 60 minute to avoid rapid variation of PV power. To show the effectiveness of the proposed method, we performed various experiments by dataset.

Key Words : ELM, Modular networks, Photovoltaic power system

1. 서론

환경보호와 저렴한 에너지 확보의 장점으로 인하여 태양광 발전시스템은 각국 정부의 지원을 받아 국내외적으로 널리 보급되어 활용되고 있다[1, 2]. 태양광 발전시스템을 구성하는 핵심 부품인 태양전지 모듈은 반도체 소자인 태양전지 수 십 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 날씨 탓으로 생각하는 경우가 많다[3, 4].

태양광발전 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 시스템

을 모델링한 연구[7], 확률 모델을 이용하여 태양광발전시스템을 모델링한 연구[8] 등이 있다. 또한, 신경회로망[9], ELM(Extreme Learning Machine)[10], 데이터 마이닝기법[11]을 이용하여 태양광발전량 예측모델을 개발한 연구도 진행되었다.

본 논문에서는 상관성 분석과 ELM을 이용하여 태양광 고장진단 알고리즘을 제안한다. 제안된 방법은 24시간 취득된 데이터를 이용하기 보다는 태양광 발전과 상관성이 높은 시간대에 있는 데이터만을 고려하여 태양광 발전량 모델링을 수행한다. 또한 1분단위의 데이터를 이용할 경우 순간적인 운량 변화 등으로 인한 발전량 변화로 인하여 모델링 오차가 커지는 단점이 있다. 이를 해결하기 위하여 60분 단위의 평균값을 이용하여 태양광 발전량을 모델링한다. 최종적으로 개발된 모델링에서 예측한 평균 발전량과 실제 발전량의 비교를 통하여 고장진단을 수행한다.

2. 상관성 분석을 통한 시간대별 특성 분석

그림 1에 태양광 발전 시스템의 구성도를 나타냈다. 그림에서와 같이 센서박스는 수평일사량, 경사일사량, 대기온도, 모듈온도를 취득하고, 인버터는 태양광 패널의 발전량을 취득한다. 센서박스와 인버터에서 취득한 데이터 정보들은 TCP/IP 네트워크 통신을 이용하여 PC로 데이터를 전송한다. PC에서는 1분단위로 관련된 데이터를 저장하고 처리한다.

2016년 1월에서 5월까지 1분단위로 취득한 데이터를 이용하여 경사 일사량과 태양광 발전량의 시간대별 상관성 분석한 결과를 그림 2에 나타냈다. 그림 2에서 보는 바와 같이 6시에서 10시까지는 상관성이 낮은 것으로 나타났다. 가장 높은 상관성을 나타낸 시간대는 14시부터 16시까지로 나타났다. 따라서 본 논문에서는 14시부터 16시까지 취득한 데이터를 대상으로 태양광 발전량 모델링 및 고장진단을 수행하였다.

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

E-mail : psji@ut.ac.kr

* Dept. of Computer Electronics, Daeduk College, Daejeon, Korea

접수일자 : 2016년 8월 11일

최종완료 : 2016년 8월 18일




그림 1 시스템 구성도
Fig. 1 System configuration




그림 2 경사일사량과 태양광 발전량과의 상관성
Fig. 2 Correlation coefficient between slope irradiation and PV power

그림 3에 2016년 1월에서 5월까지 1분단위로 취득한 데이터 중에서 상관성이 높게 나타난 14시부터 16시 사이의 경사 일사량과 태양광 발전량의 산포도를 나타냈다. 그림 3에서 보는 바와 같이 동일한 경사 일사량에 대해서 태양광 발전량의 편차가 크게 발생하는 것을 알 수 있으며, 이러한 특성으로 인하여 태양광 발전량 모델링의 오차가 크게 발생한다. 그림 4에는 14시부터 16시 사이에 취득한 데이터를 60분 단위로 경사 일사량과 태양광 발전량의 평균값을 계산한 후, 계산된 60분 단위 평균값을 이용하여 경사 일사량과 태양광 발전량의 산포도를 나타냈다. 그림에서와 같이 동일한 경사 일사량에 대해서 태양광 발전량의 선형성이 1분 단위의 경우에 비하여 매우 높아졌음을 알 수 있다.

1분 평균, 10분 평균, 20분 평균 및 30분 평균값을 이용하여 태양광 발전량과 외부 인자와의 상관성 분석결과를 표 1에 나타냈다. 1분 평균인 경우 수평일사량과 태양광 발전량과의 상관성은 0.952, 경사일사량은 0.979, 대기온도는 0.19, 모듈온도는 0.531의 상관관계를 나타냈다. 60분 평균인 경우 수평일사량과 태양광 발전량과의 상관성은 0.971, 경사일사량은 0.998, 대기온도는 0.218, 모듈온도는 0.561의 상관관계를 보여 1분 단위 평균에 비하여 상관성이 높아졌음을 알 수 있다. 그림 5에는 60분 단위의 평균값을 이용하여 대기온도와 태양광 발전량, 모듈온도와 태양광 발전량과의 산포도

를 나타냈다. 그림에 나타난 바와 같이 외부 온도와 모듈 온도는 태양광 발전량과의 상관관계가 크지 않음을 알 수 있다. 본 논문에서는 14시부터 16시 사이에 1분 단위로 취득한 데이터를 60분 단위로 평균하고, 평균한 값들을 이용하여 태양광 모델을 개발하고, 개발된 모델링 기법을 이용하여 고장 진단을 수행하고자 한다.




그림 3 경사일사량과 태양광 발전량의 산포도(1분 단위)
Fig. 3 Data distribution between PV power and slope irradiation (per 1minute)





그림 4 경사일사량과 태양광 발전량의 산포도(60분 평균)
Fig. 4 Data distribution between PV power and slope irradiation (per average in 60 minute)


표 1 상관성 분석 결과 (14시에서 16시 사이)

Table 1 Result of correlation analysis (from 14 to 16 hours)

단위	수평 일사량	경사 일사량	대기온도 (°C)	모듈온도 (°C)
1분 평균	0.952	0.979	0.190	0.531
10분 평균	0.963	0.996	0.204	0.526
20분 평균	0.962	0.997	0.206	0.528
60분 평균	0.971	0.998	0.218	0.561



(a) 외부온도와 발전량



(b) 모듈 온도와 발전량

그림 5 온도와 태양광 발전량과의 산포도(60분 평균)

Fig. 5 Data distribution between PV power and temperature (per average in 60 minute)

3. ELM을 이용한 특정 구간의 태양광 출력 모델링

3.1 제안된 모델링 알고리즘

그림 6에는 본 논문에서 개발한 ELM을 이용한 태양광 출력 모델링 구성도를 나타냈다. 그림에서와 같이 ELM 모델은 Huang등에 의하여 제안된 방법으로[12, 13], 구조는 입력층, 은닉층, 출력층으로 구성 되어 있으며 은닉층의 노드 수는 사용자에 의해 결정된다.

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 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T \in R^n$ 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.

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

여기서, $\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jm}]^T, j = 1, 2, \dots, N$ 은 j 번째 은닉노드

와 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

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

\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 역행렬[13]은 식 (5)과 같으며, 최종 모델링 결과는 식 (6)과 같다.

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

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

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.




그림 6 ELM을 이용한 태양광 발전량 모델링

Fig. 6 Modeling of PV power using ELM

3.2 모델링 결과

본 논문에서는 14시부터 16시 사이에서 취득된 데이터 중에서 60분 평균한 데이터만을 이용하여 태양광 발전량을 예

측하는 방법을 제시하였다. 제안된 모델링 성능을 평가하기 위한 성능지표로는 아래 식에 나타난 평균제곱근오차 RMSE (Root means square error), 절대 평균 퍼센트오차 MAPE (Mean absolute percentage Error) 및 절대 평균 오차 MAE (Mean absolute prediction Error)를 고려하였다. 입력데이터로는 표 2에서 보는 바와 같이 세 가지의 DB 셋으로 구성하여 실험을 실시하였다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Actual_i - Forecast_i)^2} \quad (7)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Actual_i - Forecast_i}{Actual_i} \right| \times 100 \quad (8)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Actual_i - Forecast_i| \quad (9)$$

표 2 입력 인자 선택을 위한 데이터 구축

Table 2 Experimental result of face and gait

Dataset	모델 입력 인자
DB-1	일사량, 일조시간
DB-2	일사량, 일조시간, 모듈온도
DB-3	일사량, 일조시간, 모듈온도, 외부온도

표 3 모델링 결과(1분 평균)

Table 3 Modeling result (per 1minute)

Dataset	학습/검증	오차		
		MAPE [%]	MAE	RMSE
DB-1	학습데이터	7.37±0.04	0.04±0.000	0.05±0.000
	검증데이터	6.86±0.53	0.04±0.005	0.06±0.011
DB-2	학습데이터	7.46±0.11	0.03±0.000	0.05±0.000
	검증데이터	6.49±0.56	0.04±0.006	0.05±0.007
DB-3	학습데이터	7.46±0.07	0.03±0.000	0.04±0.000
	검증데이터	5.93±0.17	0.03±0.001	0.04±0.002

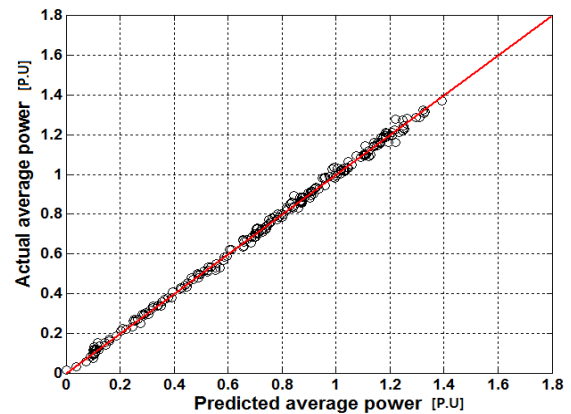
표 4 모델링 결과(60분 평균)

Table 4 Modeling result (per average in 60 minute)


Dataset	학습/검증	오차		
		MAPE [%]	MAE	RMSE
DB-1	학습데이터	2.94±0.05	0.02±0.000	0.03±0.000
	검증데이터	4.58±0.37	0.04±0.004	0.05±0.007
DB-2	학습데이터	2.83±0.15	0.01 ±0.000	0.02±0.001
	검증데이터	3.65±0.77	0.02±0.006	0.03±0.006
DB-3	학습데이터	2.65±0.17	0.01±0.001	0.02±0.001
	검증데이터	3.01±0.64	0.01±0.004	0.02±0.004

표 3과 표 4에는 1분 단위로 모델링 한 결과와 60분 단위로 평균한 값을 이용하여 모델링 한 결과를 나타냈다. 학습 데이터는 2016년 1월에서 4월까지 취득한 데이터를 이용하였으며, 검증 데이터는 2106년 5월에 취득한 데이터를 사용하였다. 실험은 가중치를 랜덤하게 변경하면서 100번 실험하였다. 표 3 및 표 4에서 보는 바와 같이 1분 단위인 경우보

다 60분 단위의 평균값을 적용한 결과가 모델링 결과가 우수함을 알 수 있다. 또한 일사량, 일조시간, 모듈온도, 외부온도 모두 이용한 DB-3인 경우가 모델링결과가 우수함을 알 수 있다. 그림 7에는 60분 단위의 평균값으로 구성된 DB-3 데이터 셋을 적용하였을 때 학습데이터와 검증데이터에 대한 산포도를 나타냈다. 그림 7에서 보는 바와 같이 학습데이터와 검증데이터 모두 실제 출력값과 본 논문에서 개발된 모델에 의해 출력된 평균 발전량이 매우 유사한 값을 나타냄을 알 수 있다.



(a) 학습데이터



(b) 검증데이터

그림 7 실제 평균 출력과 태양광 모델에 의해 산출된 평균 출력에 대한 산포도

Fig. 7 Data distribution between actual average power and average power calculated by PV model

4. 태양광 고장진단 결과

그림 8에는 3장에서 개발된 태양광 모델링 알고리즘을 바탕으로 고장진단 알고리즘 구성도를 나타냈다. 그림에서 보는 바와 같이 미리 구축된 태양광 모델링으로부터 출력된 예측값과 태양광 시스템으로부터 취득된 데이터의 오차를 비교하여 고장진단이 수행된다. 오차는 MAPE를 기준으로 5%이상 차이가 발생한 경우 고장으로 판단한다.

고장 진단을 위한 실험방법으로 10개의 태양광 패널 중에서 1개를 제거, 2개를 제거, 3개를 제거하여 성능을 평가하

표 5 고장진단 결과

Table 5 Result of fault diagnosis

번호	구간 1(14:00-14:59)		구간 2 (15:00-16:59)		MAPE (%)	판정	조건
	실제값	예측값	실제값	예측값			
1	0.61	0.67	0.52	0.57	9.34	Fault	패널1개
2	1.13	1.12	0.88	0.87	0.79	Normal	정상
3	0.83	1.02	0.68	0.82	18.44	Fault	패널2개
4	1.04	1.05	0.47	0.46	1.15	Normal	정상
5	0.31	0.32	0.40	0.40	1.58	Normal	정상
6	0.98	1.08	0.82	0.91	9.69	Fault	패널1개
7	0.35	0.43	0.11	0.12	16.99	Fault	패널2개
8	0.90	0.91	0.46	0.46	0.97	Normal	정상
9	0.66	0.94	0.55	0.77	28.70	Fault	패널3개
10	1.06	1.06	0.80	0.79	0.61	Normal	정상
11	0.76	0.75	0.57	0.56	0.39	Normal	정상
12	0.64	0.70	0.52	0.58	9.53	Fault	패널1개
13	0.72	0.70	0.82	0.81	1.51	Normal	정상
14	0.52	0.65	0.22	0.27	19.45	Fault	패널2개
15	0.72	0.70	0.79	0.78	1.67	Normal	정상
16	0.16	0.22	0.25	0.34	27.72	Fault	패널3개
17	1.09	1.08	0.77	0.76	0.48	Normal	정상

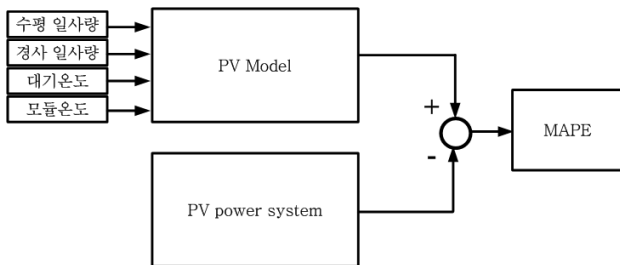


그림 8 고장진단 구성도

Fig. 8 Configuration of fault diagnosis

였다. 고장진단 결과를 표 5에 정리하였다. 표 5에서와 같이 정상적인 상태에서는 모델링에서 예측한 값과 태양광 발전 시스템에서 출력한 값 사이의 MAPE가 1.58[%] 이내로 큰 차이를 보이지 않았다. 패널 1개를 제거한 경우(1번, 6번, 12번) MAPE는 9%로 실제 출력 감소율 10%와 큰 차이가 없음을 알 수 있다. 패널 2개를 제거한 경우(7번, 14번) MAPE는 17[%]~19[%]로 실제 출력 감소율 20%와 큰 차이가 없음을 알 수 있다. 패널 3개를 제거한 경우(9번, 16번) MAPE는 27[%]~29[%]로 실제 출력 감소율 30%와 큰 차이가 없음을 알 수 있다. 따라서 제안된 모델링 방법에 의해 효과적으로 태양광 발전량을 예측할 뿐만 아니라 고장진단도 효과적으로 수행됨을 알 수 있다.

5. 결 론

본 논문에서는 상관성 분석과 ELM을 이용하여 태양광 고장진단 알고리즘을 개발하였다. 제안된 방법은 24시간 취득된 데이터를 이용하기 보다는 태양광 발전과 상관성이 높

은 14시간에서 16시에 취득한 60분 단위의 평균값을 이용하여 태양광 발전량 모델링을 수행하고 고장진단을 수행하였다. 실험결과 정상적인 상태에서는 MAPE가 1.58[%] 이내로 큰 차이를 보이지 않았고, 패널 1개를 제거한 경우 MAPE는 9%로 실제 출력 감소율 10%와 큰 차이가 없음을 알 수 있다. 패널 2개를 제거한 경우 MAPE는 17[%]~19[%]로 실제 출력 감소율 20%와 큰 차이가 없음을 알 수 있다. 패널 3개를 제거한 경우 MAPE는 27[%]~29[%]로 실제 출력 감소율 30%와 큰 차이가 없음을 알 수 있다. 따라서 제안된 모델링 방법에 의해 효과적으로 태양광 발전량을 예측할 뿐만 아니라 고장진단도 효과적으로 수행됨을 알 수 있다.

감사의 글

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

References

[1] M. Y. Kim, D. G. Lim, J. H. Lee, "Solar Industry Market trends and Forecasts", KIEE Magazine, Vol. 62, No. 11, pp. 29~32, 2013.
 [2] J. H. Kim, "Photovoltaic Technology and Industry Status", Optical Science and Technology, 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] 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



임 재 윤 (林 裁 尹)

1984년 충북대 공대 전기공학과 졸업, 1986년 동 대학원 전기공학과 졸업(공학석사), 1995년 홍익대 대학원 전기공학과 졸업(공학박사), 1999~2000 Texas A&M Univ. 방문교수, 현재 대덕대학교 교수
E-mail : jyylim@ddc.ac.kr



지 평 식 (池 平 植)

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