

# 요일 특성을 고려한 일별 최대 전력 수요예측 알고리즘 개발

## Development of Daily Peak Power Demand Forecasting Algorithm Considering of Characteristics of Day of Week

지 평 식\* · 임 재 윤†  
(Pyeong-Shik Ji · Jae-Yoon Lim)

**Abstract** - Due to the increasing of power consumption, it is difficult to construct accurate prediction model for daily peak power demand. It is very important work to know power demand in next day for manager and control power system. In this research, we develop a daily peak power demand prediction method considering of characteristics of day of week. The proposed method is composed of liner model based on AR model and nonlinear model based on ELM to resolve the limitation of a single model. Using data sets between 2006 and 2010 in Korea, the proposed method has been intensively tested. As the prediction results, we confirm that the proposed method makes it possible to effective estimate daily peak power demand than conventional methods.

**Key Words** : Power demand, AR, ELM, Linear model, Nonlinear model

### 1. 서 론

전력 수요 예측은 전력의 안정적인 공급 및 운용을 위해 필수적이다. 이러한 전력의 수요를 예측하기 위하여 시계열 분석방법에 기반을 알고리즘이 사용된다. 전력 수요 예측 모델은 회귀모델과 신경회로망 등으로 대표되는 지능형 예측 모델로 분류된다. 회귀 모델을 이용한 연구동향을 살펴보면, 다중회귀분석법을 이용하여 지역전력의 수요를 예측한 방법[1], 지수평활법 모델[2]과 이중계절 지수평활법[3], 삼중계절 지수평활법[4], ARIMA 모형[5]을 이용한 전력수요 예측 방법이 있다. 또한 다양한 시계열 모형에 따른 일별 최대 수요전력의 예측 성능을 분석한 연구[6]도 진행되었다. 지능형 모델을 이용한 연구동향을 살펴보면, SVR(Support Vector Regression)을 이용하여 월별 전력수요예측을 적용한 방법[7], 뉴로-퍼지 모델을 이용하여 시간, 일간, 주간 단위 전력을 예측한 방법[8] 등이 있다.

최근에는 두 가지 알고리즘을 융합한 하이브리드 형태의 예측모델이 개발되고 있다. 대표적인 하이브리드 모델로는 웨이블릿과 신경회로망을 결합한 모델[9, 10]과 웨이블릿과 뉴로퍼지모델을 결합한 모델[11] 등이 있다. 웨이블릿과 신경회로망을 결합한 모델[10]에서는 지능형 하이브리드 웨이블릿 모델을 이용하여 단기 부하 예측모델을 개발하고, 그 유용성을 평가하였다. 특히, 시계열 데이터를 웨이블릿에 의해 고주파 신호를 제거한 후, 저주파 신호가 강조된 시계열 데이터와 신경회로망을 접목한 모델을 개발한 것이 특징으

로서, 입력인자로는 과거 수요데이터와 온도 특성을 고려하였다.

전력 수요예측을 위해 널리 사용되는 지능형 알고리즘은 학습 데이터와 검증 데이터 간의 상관성이 높은 경우 효과적이지만, 상관성이 떨어지는 경우 학습 데이터를 기준으로 학습이 이루어짐으로 과적합(over-fitting)의 문제점을 지니고 있다. 본 논문에서는 이러한 문제점을 해결하기 위하여 상관성이 높은 요일에 대해서는 학습 알고리즘인 ELM(Extreme Learning Machine)을 이용하여 예측하고, 상관성이 적은 요일에 대해서는 선형 모델인 자기회귀(AR:Auto-Regressive)모델을 이용하여 예측하는 모델을 제안하며, 기존에 널리 사용되는 자기회귀모델, ELM 기법들과 비교함으로써 제안방법의 타당성을 입증하고자 한다.

### 2. 요일 특성을 고려한 일별 최대 전력수요예측 모델

선형 모델에 기반을 둔 시스템 모델링은 데이터의 비선형 특성으로 인하여 시스템 성능에 한계가 있다. 이러한 문제를 해결하기 위하여 다양한 비선형 시스템 모델링 기법이 제안되어 활발히 적용되고 있다. 가장 널리 사용되는 방법은 주어진 입력 및 출력 데이터를 이용하여 학습이 이루어지는 지능형 알고리즘이다. 지능형 알고리즘은 학습에 사용되는 입력 및 출력 데이터와 실제 검증시에 사용되는 데이터 간에 상관성이 높을 경우 탁월한 성능을 보이지만, 학습과 검증 데이터 간에 상관성이 떨어질 경우 과적합에 의해 성능이 저하되는 단점을 지니고 있다.

본 논문에서는 요일 특성을 분석하여 선형성이 강한 요일에 대해서는 선형모델을 이용하여 일별 최대전력을 예측하고, 비선형성이 강한 요일에 대해서는 비선형 모델을 이용하여 일별 최대전력을 예측하는 모델을 개발한다. 그림 1에서는 본 논문에서 제안한 전력수요예측 모델의 구성도를 나타냈다. 그림 1에서 보는 바와 같이 선형 모델은 자기회귀(AR

† 교신저자 : 대덕대학교 전자공학과 교수 · 공박  
E-mail : jyylim@ddc.ac.kr

\* 한국교통대 전기공학과 교수 · 공박  
접수일자 : 2014년 11월 12일  
수정일자 : 2014년 11월 25일  
최종완료 : 2014년 11월 26일

: Auto-Regressive) 모델로 구현하였으며, 비선형 모델은 처리 속도가 우수한 ELM 모델로 구성하였다. 게이트 네트워크에 의해 최종 모델의 일별 최대 전력 수요값을 예측하도록 하였다.

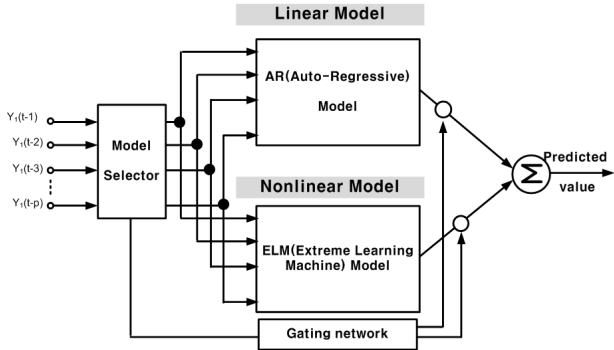


그림 1 제안된 알고리즘  
Fig. 1 The proposed algorithm

2.1 AR 모델에 의한 일별 전력 수요 예측 과정

본 논문에서는 시계열 자료의 현재 상태가 과거와 미래의 상태와 밀접한 연관성이 있다고 예상하고, 회귀분석에서 시계열의 관측값이 선행된 관측값에 의존하여 자기상관을 보일 때, 즉 관측값이 선행 관측값들의 회귀관계를 갖는 현상인 자기회귀성을 고려한다. 이에 대표적인 자기회귀모델인 AR모델을 이용하여 시계열 데이터를 분석한다.

안정성을 가진 시계열을 AR 모델로 나타낼 경우, AR 모델에서 신호의 샘플 값  $Y_k$ 는 다음과 같이 나타낼 수 있다.

$$Y_k = \sum_{i=1}^p a_i Y_{k-i} + W_k \tag{1}$$

식(1)에서  $Y_k$ 는 이산시간 지표  $k$ 에서 기록된 신호,  $a_i$ 는 AR 매개변수,  $W_k$ 는 백색잡음,  $p$ 는 모델의 차수를 나타낸다. 따라서 AR 모델의 시계열  $Y_k$ 의 현재값이 시계열  $Y_{k-1}$ ,  $Y_{k-2}$ ,  $Y_{k-3}$ , ...,  $Y_{k-p}$ 의 과거값에 의존하게 된다.

시계열 모델의 매개변수 추정은 확률적 근사법(stochastic approximation), 최소제곱법(least square method), 자기상관법(autocorrelation method), 공분산법(covariance method) 등의 알고리즘을 이용할 수 있다. 그러나 자기상관법과 공분산법은 매개변수 추정에서 발생하는 역행렬로 인하여 계산이 어려움이 따른다. 따라서 본 연구에서는 짧은 구간에서 신호의 실제값으로 수렴하게 되고 모델오차의 제곱총합값을 최소화 하면서 연속적 접근으로 추정하는 최소제곱알고리즘을 이용하여 시계열 데이터에 적합한 매개변수를 추정한다. 일반적으로 실제 표본자료  $s(n)$ 은 식 (2)에서 보는 바와 같이 과거의 표본자료와 오차의 항으로 표현할 수 있다.

$$S(n) = \sum_{i=1}^p a_i S(n-1) + e(n) \tag{2}$$

식(2)에서  $e(n)$ 은 식 (3)에서 보는 바와 같이 실제 표본 자료인  $S(n)$ 과 예측된 표본자료  $\hat{S}(n)$ 간의 예측오차를 나타낸다.

$$e(n) = S(n) - \hat{S}(n) \tag{3}$$

따라서 예측된 표본 자료  $\hat{S}(n)$ 은 식 (4)로 정의되며 계수  $a_i (i=1,2,\dots,p)$ 는 각 계수에 관한 오차표본들의 총합 제곱오차를 최소화하여 구할 수 있다.

$$\hat{S}(n) = \sum_{i=1}^p a_i S(n-1) \tag{4}$$

2.2 ELM에 의한 일별 전력 수요 예측 과정

ELM 모델은 그림 2에서 보는 바와 같이 단일 은닉층을 가지는 전방향 네트워크이다[12]. 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.




그림 2 ELM의 구조  
Fig. 2 The structure of ELM

ELM의 학습과정을 설명하기 위해  $m$ 개의 데이터  $\{(x_i, y_i), i=1, 2, \dots, m\}$ 와 한개의 출력노드를 가지고  $N$ 개의 은닉노드들을 가지는 전방향 신경 회로망의 학습을 고려해 보자. 여기서, 입력  $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$  이고,  $y_i \in R$ 이며,  $N$ 개의 은닉노드들의 활성화 함수  $g(x)$ 에 의한 전방향 신경 회로망의 출력은 식 (5)와 같이 나타낼 수 있다.

$$g(\mathbf{w}_j \cdot \mathbf{x}_i) \cdot \mathbf{a} = y_i, \quad i = 1, 2, \dots, m \tag{5}$$

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 (5)는 식 (6)과 같이 간결하게 표현될 수 있다.

$$\mathbf{G}\mathbf{a} = \mathbf{y} \tag{6}$$

$\mathbf{G}$ 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 (7)과 같이 최소자승법에 의하여 출력 가중치  $\hat{\mathbf{a}}$ 을 구한다.

$$\hat{\mathbf{a}} = \mathbf{G}^{\dagger} \mathbf{y} \quad (7)$$

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 (8)과 같으며, 최종 모델링 결과는 식 (9)와 같다.

$$\mathbf{G}^{\dagger} = (\mathbf{G}^T \mathbf{G})^{-1} \mathbf{G}^T \quad (8)$$

$$\hat{\mathbf{y}} = \mathbf{G} \hat{\mathbf{a}} \quad (9)$$

### 3. 사례연구

#### 3.1 데이터의 구성 및 분석

1970년대 산업화와 함께 급격한 성장세를 보이던 전력수요는 그림 3에서 보이는 것처럼 2000년대에 들어선 이후에도 꾸준히 성장하고 있다. 2001년 연간 최대 전력수요는 43,125[MW], 최소 전력수요는 18,292[MW]에서 2010년에는 연간 최대 전력수요 71,308[MW], 최소 전력수요 32,173[MW]로 연간 최대 전력수요는 약 165[%], 최소 전력수요는 약 176[%] 증가하였다. 제안된 예측시스템의 성능을 분석하기 위하여 2006년 1월 1일부터 2010년 12월 31일까지 5년간의 자료를 이용하였다.




그림 3 년도별 전력 수요  
Fig. 3 Power demand per year

최대 부하전력 예측모델을 개발하기 위해서는 최대 부하에 영향을 주는 인자와의 상관성분석이 필수적이다. 즉, 이러한 상관성 분석을 통하여 전력수요에 영향을 주는 주요 인자들을 선택하여 전력 수요 모델링이 수행된다. 상관성은 크게 과거 1일전에서 9일전까지의 시간인자를 고려하였다. 표 1에서는 2006년에서 2010년 데이터를 이용하여 과거 시간정보를 이용한 상관성 분석결과를 나타냈다. 표 1에서 보

표 1 최대 수요전력간의 상관성 분석  
Table 1 Correlation analysis between peak power demand

인자	1일전	2일전	3일전	4일전	5일전
상관계수	0.79	0.59	0.55	0.53	0.52
인자	6일전	7일전	8일전	9일전	
상관계수	0.67	0.84	0.66	0.50	

는 바와 같이 7일전의 최대 전력 수요값이 가장 큰 상관계수를 나타냈으며, 그 다음으로 1일전 데이터가 상관성이 큰 것으로 나타났다.

#### 3.2 예측결과

개발된 방법을 평가하기 위하여 2006년도에 2009년도에 발생한 최대수요전력 데이터를 학습용으로 사용하였고, 나머지 2010년도 데이터를 이용하여 검증을 하였다. 입력인자와 출력인자는 식 (10) 및 식 (11)과 같이 각각 구성하였다.

$$X = \begin{bmatrix} y(\tau) & y(2\tau) & y(m\tau) \\ y(2\tau) & y(3\tau) & y((m+1)\tau) \\ \vdots & \vdots & \vdots \\ y((N-m)\tau) & y((N-m+1)\tau) & y((N-1)\tau) \end{bmatrix} \quad (10)$$

$$Y = \begin{bmatrix} y((m+1)\tau) \\ y((m+2)\tau) \\ \vdots \\ y(N\tau) \end{bmatrix} \quad (11)$$

AR 모델의 매개 파라미터와 ELM 학습을 위해서는 효과적인 입력 인자의 선택이 매우 중요하다. 본 논문에서는 상관성 분석을 통해 얻어진 상관관계를 이용하여 상관성이 높은 5가지 입력인자(1일전, 2일전, 6일전, 7일전, 8일전)를 이용하여 구축하였다.

성능지표로는 식 (12)에서 식 (14)까지 나타낸 평균제곱오차인 RMSE(Root means square error), 절대 평균 퍼센트 오차인 MAPE (Mean absolute percentage Error) 및 MAE(Mean absolute prediction Error)를 고려하였다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Actual_i - Forecast_i)^2} \quad (12)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Actual_i - Forecast_i}{Actual_i} \right| \times 100 \quad (13)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Actual_i - Forecast_i| \quad (14)$$

표 2에서는 AR 모델에 의한 일별 최대전력 수요예측 결과를 나타냈다. 표 2에서 보는 바와 같이 학습데이터에 대해서는 RMSE가 2029, 검증 데이터에 대해서는 2367로 나타났다. 표 3에서는 ELM 모델에 의한 일별 최대전력 수요예측 결과를 나타냈다. 표 3에서 보는 바와 같이 학습데이터에 대해서는 RMSE가 1864, 검증 데이터에 대해서는 2231로 나타났다. 표 2와 표 3로부터 ELM 모델이 AR 모델보다 효과적인

표 2 예측 결과 (AR 모델)  
Table 2 Prediction results (AR model)

성능지표	학습 데이터	검증 데이터
RMSE	2029	2367
MAPE	2.7	2.9
MAE	1384	1690

표 3 예측 결과 (ELM 모델)

Table 3 Prediction results (ELM model)

성능지표	학습 데이터	검증 데이터
RMSE	1864	2231
MAPE	2.5	2.7
MAE	1239	1584

임을 알 수 있다.

표 4에서는 학습 데이터에 대한 AR 모델과 ELM 모델에 의한 요일별 최대전력 오차를 분석하여 나타냈다. 표 4에서 보는 바와 같이 모든 요일에 대해서 ELM 모델이 AR 모델에 비하여 우수함을 확인할 수 있다. 표 5에서는 검증데이터에 대한 AR 모델과 ELM 모델에 의한 요일별 일별 최대전력 오차를 분석하여 나타냈다. 표 5에서 보는 바와 같이 ELM 모델은 월, 화, 수, 토요일과 관련된 데이터가 AR 모델에 비하여 우수하게 나타났다. 목요일은 RMSE 관점에서는 AR 모델이 우수하게 나타났으나, MAPE와 MAE 관점에서는 ELM 모델이 우수하게 나타났다. 본 논문에서는 MAPE와 MAE 측면에서 우수한 결과를 보인 ELM 모델을 이용하여 목요일의 최대 전력을 예측하였다.

금요일과 일요일은 AR모델이 ELM 모델에 비하여 우수하게 나타났다. 이는 금요일과 일요일과 관련된 데이터는 학습 데이터와 검증 데이터 간의 상관성이 상대적으로 낮은 것에 기인한 것으로 분석된다. 즉, ELM과 같은 학습 알고리즘의 단점인 학습 데이터에 대한 과적합에 의한 결과라 볼 수 있다. 학습 데이터와 검증 데이터간의 상관성이 떨어지는 경우 학습 알고리즘 보다는 선형 모델인 AR 모델이 효과적일 수 있다. 따라서 본 논문에서는 학습데이터와 검증 데이터간의 상관성이 높은 요일(월, 화, 수, 목, 토)은 비선형 모델인 ELM에 의해 일별 최대 전력 수요값을 예측하고, 두 데이터간의 상관성이 적은 요일(금, 일)은 AR 모델에 의해 일별 최대 전력 수요값을 예측하도록 구성하였다.

표 6에서는 제안 방법에 의한 예측 결과를 나타냈다. 표 6에서 보는 바와 같이 학습데이터에 대해서 RMSE는 1896, MAPE는 2.5, MAE는 1275로 나타났다. 검증 데이터에 대해서는 RMSE는 2106, MAPE는 2.5, MAE는 1474로 성능이 향상됨을 알 수 있다.

표 4 학습 데이터에 대한 요일별 오차 분석

Table 4 Analysis of error per day for training data

(a) AR 모델

	월	화	수	목	금	토	일
RMSE	2550	1737	2123	2182	1678	1480	2246
MAPE	3.43	2.48	2.70	2.74	2.42	2.31	3.01
MAE	1774	1291	1435	1404	1229	1084	1467

(b) ELM 모델

	월	화	수	목	금	토	일
RMSE	2441	1533	1820	1935	1546	1392	2162
MAPE	3.27	2.15	2.33	2.44	2.20	2.06	2.74
MAE	1661	1114	1229	1251	1119	971	1334

표 5 검증 데이터에 대한 요일별 오차 분석

Table 5 Analysis of error per day for testing data

(a) AR 모델

	월	화	수	목	금	토	일
RMSE	3394	2727	3204	1921	1492	1510	1328
MAPE	4.61	2.90	4.17	2.52	1.83	2.05	2.01
MAE	2815	1684	2457	1522	1130	1130	1044

(b) ELM 모델


	월	화	수	목	금	토	일
RMSE	2848	2407	2705	2001	2223	1352	1744
MAPE	3.59	2.54	3.40	2.36	2.58	1.95	2.51
MAE	2155	1488	2025	1400	1608	1075	1313

표 6 제안 방법에 의한 예측 결과


Table 6 Prediction results by the proposed method

성능지표	학습 데이터	검증 데이터
RMSE	1896	2106
MAPE	2.5	2.5
MAE	1275	1474

그림 4에서는 학습 데이터와 검증 데이터에 대해서 RMSE를 기준으로 비교하여 나타냈다. 그림 4에서 보는 바와 같이 학습 데이터에 대해서는 ELM(RMSE:1864), 제안방법(RMSE:1896), AR(RMSE:2029) 순으로 성능이 우수하게 나타났다. 그러나 ELM과 제안방법간의 성능 차이는 크게 나타나지 않았다. 검증 데이터에 대해서는 제안방법(RMSE:2106), ELM(RMSE:2231), AR(RMSE:2367) 순으로



(a) 학습 데이터



(b) 검증 데이터

그림 4 적용 방법에 따른 결과

Fig. 4 Prediction result for each applied method

성능이 우수하게 나타났으며, ELM 방법에 비하여 성능 향상도 크게 나타났음을 확인할 수 있다. 그림 5에서는 검증 데이터에 대해서 제안된 방법에 의한 일별 최대 전력 수요 예측결과를 나타냈다. 그림 5에서 보는 바와 같이 효과적으로 예측함을 확인할 수 있다.

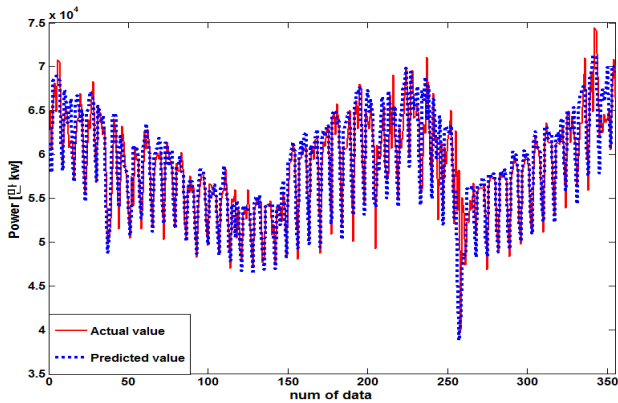


그림 5 검증 데이터에 대한 최대 수요 예측 결과  
 Fig. 5 Prediction result of peak power demand for test data

#### 4. 결 론

전력 수요예측을 위해 널리 사용되는 지능형 알고리즘을 학습 데이터와 검증 데이터 간의 상관성이 높은 경우 효과적이지만, 상관성이 떨어지는 경우 학습 데이터를 기준으로 학습이 이루어짐으로 과적합의 문제점을 지니고 있다. 본 논문에서는 이러한 문제점을 해결하기 위하여 상관성이 높은 요일에 대해서는 학습 알고리즘인 ELM을 이용하여 예측하고, 상관성이 적은 요일에 대해서는 선형 모델인 AR모델을 이용하여 예측하도록 하였다.

실험결과 학습 데이터에 대해서는 ELM(RMSE:1864), 제안방법(RMSE:1896), AR(2029) 순으로 성능이 우수하게 나타났지만, 검증 데이터에 대해서는 제안방법(RMSE:2106), ELM(RMSE:2231), AR(2367) 순으로 성능이 우수하게 나타났다. 향후 뉴로-퍼지모델, 신경회로망 등 다양한 조합모델을 고려한 예측 알고리즘을 개발하고자 한다.

#### References

[1] B. W. Nam, et al, "The Spatial Electric Load Forecasting Algorithm using the Multiple Regression Analysis Method," Journal of the Korean Institute of Illuminating and Electrical Installation Engineers, Vol. 22, No. 2, pp. 63-70, 2008.  
 [2] R. Ramanathan, et al, "Short-term forecasts of electricity loads and peaks," International Journal of Forecasting, Vol. 13, pp. 161-174, 1997.  
 [3] J. W. Taylor, "Short-term electricity demand forecasting using double seasonal exponential smoothing," Journal of the Operational Research Society, Vol. 54, pp. 799-805, 2003.  
 [4] J. W. Taylor, "Triple seasonal methods for short-term

electricity demand forecasting," European Journal of Operational Research, Vol. 204, pp. 139-152, 2010.  
 [5] R. Weron, "Modeling and Forecasting Electricity Loads and Prices: A Statistical Approach," Wiley, Chichester.  
 [6] J. S. Lee, H. G. Sohn, S. Kim, "Daily Peak Load Forecasting for Electricity Demand by Time series Models," The Korean Journal of Applied Statistics, Vol. 26, No. 2, pp. 249-360, 2013.  
 [7] HyoungRoo Lee, Hyunjung Shin, "Electricity Demand Forecasting based on Support Vector Regression," IE Interfaces, Vol. 24, No. 4, pp. 351-361, 2011.  
 [8] Yong-Jin Park, Bo-Hyeun Wang, "Neuro-Fuzzy Model based Electrical Load Forecasting System: Hourly, Daily, and Weekly Forecasting," International Journal of Fuzzy Logic and Intelligent Systems, Vol. 14, No. 5, pp. 533-538, 2004.  
 [9] A. S. Pandey, D. Singh, S. K. Sinha, "Intelligent Hybrid Wavelet Models for Short-Term Load Forecasting," IEEE Trans. on Power systems, Vol. 25, No. 3, pp. 1266-1273, 2010.  
 [10] C. Guan, P. B. Luh, L. D. Michel, Y. Wang, P. B. Friedland, "Very Short-Term Load Forecasting: Wavelet Neural Networks With Data Pre-Filtering," IEEE Trans. on Power systems, Vol. 28, No. 1, pp. 30-41, 2013.  
 [11] M. Hanmandlu, B. K. Chauhan, "Load Forecasting Using Hybrid Models," IEEE Trans. on Power systems, Vol. 26, No. 1, pp. 20-29, 2011.  
 [12] G. B. Huang, Q. Y. Zhu, and C. K. Siew, "Extreme learning machine: theory and applications," Neurocomputing, Vol. 70, No. 1, pp. 489-501, 2006.

### 저 자 소 개



#### 지 평 식 (池平植)

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



#### 임 재 윤 (林載尹)

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 : jylin@ddu.ac.kr