

ELM을 이용한 일별 최대 전력 수요 예측 알고리즘 개발

Development of Daily Peak Power Demand Forecasting Algorithm using ELM

지 평 식* · 김 상 규** · 임 재 윤†
(Pyeong-Shik Ji · Sang-Kyu Kim · Jae-Yoon Lim)

Abstract - Due to the increase of power consumption, it is difficult to construct an accurate prediction model for daily peak power demand. It is very important work to know power demand in next day to manage and control power system. In this research, we develop a daily peak power demand prediction method based on Extreme Learning Machine(ELM) with fast learning procedure. 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 : ELM, Neural networks, Peak power, Power demand

1. 서 론

신뢰성 높은 전력 수요예측 기법은 안정적이고 경제적으로 전력계통을 운용하는데 필요한 기본요소이다. 신뢰성 높은 전력 수요 예측을 통하여 전력을 공급할 경우 예비전력의 과다 또는 부족에 따른 손실을 최소화한다. 즉, 실제 소비량보다 예측값이 클 경우 예비전력의 과다로 인하여 전력의 낭비가 발생하며, 이와 반대로 예측값이 실제 소비량보다 작을 경우 예비전력의 부족으로 인하여 단전과 같은 치명적인 경제적 손실을 가져온다. 매년 전력 사용량이 증가하면서 실제 사용량이 전력수요 예측값보다 증가하면서 전력피크를 감소하기 위한 수요관리 예산도 증대되고 있다. 2002년에 525억원에 불과했던 보조금이 2009년 606억원, 2010년 855억원, 2011년 1218억원, 2012년에는 4406억원으로 매년 증가하고 있다. 이러한 보조금의 증대는 전력 요금의 증대로 이어지며, 이로 인하여 국가 경쟁력의 저하를 초래할 것이다. 따라서 전력 수요 예측률을 높이기 위한 다각적인 연구가 진행되어야 할 것이다.

전력 수요 예측을 위해 국내외적으로 다양한 알고리즘이 개발 및 적용되고 있다. 전력 수요예측 알고리즘은 시계열 분석방법에 기반을 둔다. 시계열 분석방법은 시간의 흐름에 따라 수요를 예측하는 기법으로 특정 시점의 시계열 관측값은 그 이전 자료들에 의존하게 된다. 전력 수요 예측 모델은 크게 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. 지능형 모델을 이용한 연구동향을 살펴보면, Support Vector Regression을 이용하여 월별 전력수요 예측을 적용한 방법[6], 뉴로-퍼지 모델을 이용하여 시간, 일간, 주간 단위 전력을 예측한 방법[7] 등이 있다. 최근에는 두 가지 알고리즘을 융합한 하이브리드 형태의 예측모델이 개발되고 있다.

대표적인 하이브리드 모델로는 웨이블릿과 신경회로망을 결합한 모델[8][9]과 웨이블릿과 뉴로퍼지모델을 결합한 모델[10] 등이 있다. 웨이블릿과 신경회로망을 결합한 모델[9]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 특징으로서, 입력인자로는 과거 수요데이터와 온도 특성을 고려하였다. 위에서 살펴본 바와 같이 국내외적으로 전력수요예측을 위하여 다양한 모델이 개발되었다. 모델뿐만 아니라 일일 예측, 특정 요일 예측 등 예측의 범위와 입력인자의 선택 방법 등 다양한 요인 분석도 수행되었다. 그러나 대부분의 연구는 국내 보다는 국외연구에서 이루어졌다. 전력 수요는 동일한 방법론적으로 동일하다 하더라도 나라마다의 특성을 고려한 모델이 개발되어야 한다.

본 연구에서는 학습처리속도가 매우 우수한 ELM(Extreme Learning Machine)을 이용하여 국내 특성에 맞는 일별 최대전력 수요예측 모델을 개발한다. 개발된 예측모델은 입력으로서 과거의 최대 수요치를 고려하였으며, 기존에 널리 사용되는 다층 신경회로망 기법들과 비교함으로써 제안방법의 타당성을 입증하고자 한다.

2. ELM을 이용한 최대부하 예측 알고리즘

그림 1에서는 본 연구에서 개발한 ELM을 이용한 최대 전력 수요 예측 기법을 나타냈다. 그림 1에서 보는 바와 같

* 시니어회원 : 한국교통대 전기공학과 교수 · 공박

** 정 회 원 : 한국교통대 전기공학과 석사과정

† 교신저자, 중신회원 : 대덕대학교 전기과 교수 · 공박

E-mail : jyylim@ddc.ac.kr

접수일자 : 2013년 10월 29일

수정일자 : 2013년 11월 25일

최종완료 : 2013년 11월 27일

이 ELM 모델은 Huang등에 의하여 제안된 방법으로 [11][12], 구조는 입력층, 은닉층, 출력층으로 되어 있으며 은닉층의 노드 수는 사용자에게 의해 결정된다. 본 연구에서 입력층에 사용된 인자로는 상관성 분석을 통하여 상관관계가 높은 과거 시계열 데이터를 이용하였다. ELM은 신경회로망과 동일하게 은닉층과 출력층 사이에는 서로를 연결해 주는 가중치 W 가 존재하며 입력벡터 X 를 출력값 Y 로 대응시켜 주는 비선형 함수의 역할을 한다. 은닉층에 사용되는 기저함수로는 일반적으로 sigmod 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 모어-페로스의 일반화된 역행렬(Moore-Penrose generalized inverse)에 의해 분석적으로 계산되어 지므로 반복학습이 이루어지지 않는다.




그림 1 ELM을 이용한 최대 전력 수요 예측 기법
Fig. 1 Proposed peak power demand forecasting method by ELM

그림 2에서는 본 논문에서 사용된 ELM의 학습과정을 나타냈다. 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.

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

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, $\mathbf{a} = [a_1, a_2, \dots, a_N]^T$ 은 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

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

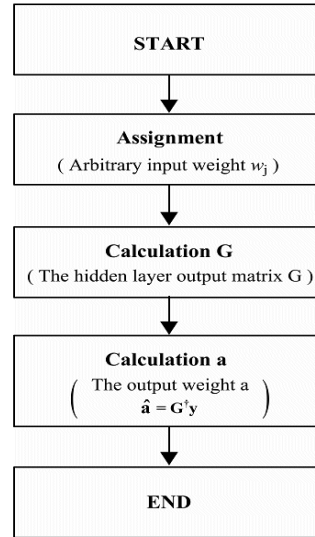


그림 2 ELM의 학습과정
Fig. 2 Learning process of ELM

\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.

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

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

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 데이터의 구성 및 분석

제안된 예측시스템의 성능을 분석하기 위하여 2006년 1월 1일부터 2010년 12월 31일까지 5년간의 자료를 이용하였다. 그림 3에서는 날짜별로 일일 최대부하전력을 나타냈다. 그림 3에서 보는 바와 같이 에너지 소비 증대로 인하여 매년 최대 부하전력은 증가함을 알 수 있다. 즉, 2006년도에는 연간 최대부하전력이 58.994[MW] 이었지만, 2010년에는 71.308[MW]로 2006년에 비하여 20.8[%]의 증가를 보였다. 또한, 2006년, 2007년, 2008년에는 하절기에 최대부하전력을 사용하였지만, 2009년도와 2010년도에는 동절기에 최대부하전력을 사용하였다. 이는 유류비에 비하여 상대적으로 저렴한 전기를 이용하여 난방을 하는 비율이 증대한 것에 기인한 것으로 판단된다.

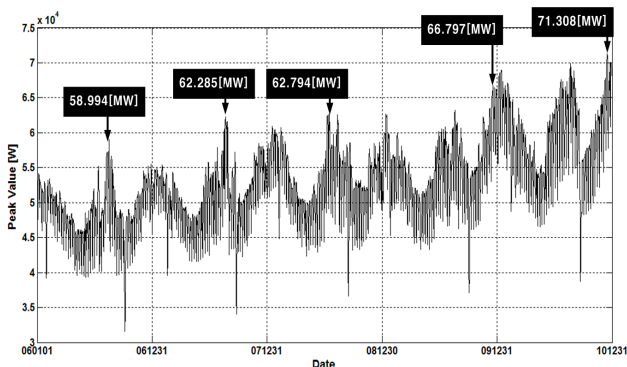


그림 3 최대 수요전력 (2006-2010)
Fig. 3 Peak power demand (2006-2010)


최대 부하전력 예측모델을 개발하기 위해서는 최대 부하에 영향을 주는 인자와의 상관성분석이 필연적이다. 즉, 이러한 상관성 분석을 통하여 전력수요에 영향을 주는 주요 인자들을 선택하여 전력 수요 모델링이 수행된다. 상관성은 크게 과거 1일전에서 10일전까지의 시간인자와 최고온도, 최저온도, 평균온도 등의 외부 인자로 구분하여 실험하였다. 표 1에서는 2006년에서 2010년 데이터를 이용하여 과거 시간정보를 이용한 상관성 분석결과를 나타냈다. 표 1에서 보는 바와 같이 7일전의 최대 전력 수요값이 가장 큰 상관계수를 나타냈으며, 그 다음으로 1일전 데이터가 상관성이 큰 것으로 나타났다. 그림 4에서는 최대 수요전력간의 상관성 분석을 나타냈다. 그림 4에서 보는 바와 같이 상관관계가 가장 높은 7일전 데이터와 상관성이 높음을 확인할 수 있다.

표 2에서는 최고온도, 최저온도, 평균온도 등의 온도와 최대전력과의 상관성을 분석하여 나타냈다. 표 2에서 보는 바와 같이 하절기와 동절기로 구분하여 분석한 결과 최저 온도와 상관성이 가장 높은 것으로 나타났다. 그러나 과거 데이터인 시간인자와 비교해 볼 때 상관성은 크지 않은 것으로 분석된다. 그림 5에서는 최저 온도와 최대 부하전력과의 데이터 분포도를 나타냈다. 여기서 하절기는 15도 이상의 온도에 해당하는 데이터를 이용하였고, 동절기는 1도 이하의 온도에 해당하는 데이터를 이용하였다. 그림 5에서 보는 바와 같이 최대 수요전력간의 상관성 분석을 나타낸 그림 4와 비교해 볼 때 온도와의 상관성은 크지 않음을 알 수 있다.


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	



(a) 1일전(상관계수 0.79) (b) 2일전(상관계수 0.59)



(a) 3일전(상관계수 0.55) (b) 7일전(상관계수 0.84)


그림 4 최대 수요전력간의 데이터 분포

Fig. 4 Data distribution between peak power demand

표 2 최대 수요전력과 온도와의 상관성 분석

Table 2 Correlation analysis between peak power demand and temperature

인자	최고온도	최저온도	평균온도
하절기	0.39	0.51	0.50
동절기	-0.35	-0.37	-0.31



(a) 하절기(상관계수 0.51) (b) 동절기(상관계수 -0.37)

그림 5 최대 수요전력과 온도와의 데이터 분포

Fig. 5 Data distribution between peak power demand and temperature

3.2 예측결과

본 연구에서는 ELM을 이용한 최대 전력 수요 예측 기법을 개발하였다. 개발된 방법을 평가하기 위하여 2006년도에 2009년도에 발생한 최대수요전력 데이터를 학습용으로 사용하였고, 나머지 2010년도 데이터를 이용하여 검증을 하였다. 입력인자와 출력인자는 식 (7)과 식 (8)과 같이 각각 구성하였다.

$$X = \begin{bmatrix} y(\tau) & y(2\tau) & y(m\tau) \\ y(2\tau) & y(3\tau) & y((m+1)\tau) \\ \vdots & \vdots & \vdots \\ y((N-m)\tau) & y((N-m+1)\tau) & y((N-1)\tau) \end{bmatrix} \quad (7)$$

$$Y = \begin{bmatrix} y((m+1)\tau) \\ y((m+2)\tau) \\ \vdots \\ y(N\tau) \end{bmatrix} \quad (8)$$

ELM 학습을 위해서는 효과적인 입력 인자의 선택이 매우 중요하다. 본 논문에서는 3.1절에서 수행한 상관성 분석을 통해 얻어진 상관관계를 이용하여 입력인자를 선택하고자 한다. 표 3에서는 입력 선택을 위한 5가지 모델을 구축하였다. 모델 1은 상관관계가 매우 높은 1일전과 4일전 데이터를 이용하여 구축하였고, 모델 2는 상관성이 높은 5가지 입력인자를 이용하여 구축하였다. 모델 3은 시계열 데이터 특성을 고려하여 1일전과 6일전 사이에 있는 과거 시계열 데이터를 이용하여 구축하였다, 모델 4는 1일전과 7일전 사이에 있는 과거 시계열 데이터를 이용하였고, 모델 5는 1일전과 8일전 사이에 있는 모든 과거 시계열 데이터를 이용하였다. 온도와 최대 수요전력과의 상관성이 낮은 이유로, 본 논문에서는 온도 정보를 입력인자로 사용하지 않았다. 성능지표로는 아래 식의 평균제곱오차인 RMSE(Root Means Square Error), 절대평균퍼센트오차인 MAPE (Mean Absolute Percentage Error) 및 MAE(Mean Absolute Prediction Error)를 고려하였다.

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

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Actual_i - Forecast_i}{Actual_i} \right| \times 100 \quad (10)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Actual_i - Forecast_i| \quad (11)$$

표 4에서는 입력인자 선택에 따른 ELM 검증 데이터의 예측성능을 나타냈다. 실험은 2006년도와 2009년도 사이의 데이터를 이용하여 ELM 학습을 하였다. 실험방법은 선택된 모델에 따라 은닉층의 개수를 5에서 100까지 5씩 증가하면서 성능을 평가하였다. 또한, ELM은 입력층과 은닉층 사이의 웨이트 초기값에 의해 성능 차이가 발생하므로 동일한 은닉층의 수에 대해 총 10번의 반복실험을 실시하였고, 성능은 10번의 실험에서 얻어진 값을 평균하여 나타냈다. 성능을 나타낸 표 4로부터 가장 우수한 예측을 보인 모델은 입력인

자를 5개(1일전, 2일전, 6일전, 7일전, 8일전 데이터), 은닉층의 노드의 개수를 20개 사용한 2번 모델로 나타났다. 모델 2가 성능이 좋은 이유는 상관성 분석을 통해 나타난 바와 같이 5개의 입력인자가 상관성이 가장 높게 나타난 것에 기인한 것이라 분석된다.

표 5에서는 MLP와 ELM 성능 비교를 나타냈다. 표 5에서 보는 바와 같이 제안된 ELM 방법이 MLP에 비하여 RMSE, MAPE 및 MAE 모두 우수하게 나타났다. 표 5에 나타난 MLP 성능은 모든 실험에서 검증 데이터가 가장 우수하게 나타났을 때를 기준으로 하였으며, 이때 MLP의 은닉층의 개수는 5개이며, MLP 학습은 Matlab Toolbox중에서 lmbp 알고리즘을 이용하였다. 본 실험은 은닉층의 개수를 5에서 100까지 5씩 증가하면서 실험하였고, 동일한 은닉층에 대해서 10번 반복 실험하여 총 200회의 실험을 하였다. 200회의 학습을 하는데 있어서, ELM은 7초 소요되었으나 MLP는 2217초 걸려 ELM에 비하여 학습시간이 오래 소요되었다.

그림 6에서는 ELM에 의한 예측 결과를 나타냈으며, 그림 7에서는 ELM과 MLP에 의해 발생한 오차를 분석하여 나타냈다. 이러한 그림들로부터 제안된 ELM 기반의 예측모델은 성능뿐만 아니라 학습시간 관점에서서 효과적임을 알 수 있다.

표 3 입력인자 선택을 위한 모델 구축

Table 3 Model construction for selecting input factors

모델	모델 입력 인자
model(1)	$y(t-1), y(t-7)$
model(2)	$y(t-1), y(t-2), y(t-6), y(t-7), y(t-8)$
model(3)	$y(t-1), y(t-2), y(t-3), y(t-4), y(t-5), y(t-6)$
model(4)	$y(t-1), y(t-2), y(t-3), y(t-4), y(t-5), y(t-6), y(t-7)$
model(5)	$y(t-1), y(t-2), y(t-3), y(t-4), y(t-5), y(t-6), y(t-7), y(t-8)$

표 4 ELM의 입력 인자 선택에 따른 성능

Table 4 Performance according to selection of input factors of ELM

모델	RMSE	MAPE	MAE
model (1)	3318	4.12	2401
model (2)	2384	2.89	1699
model (3)	3106	3.71	2195
model (4)	3023	3.51	2060
model (5)	2504	3.03	1797

표 5 예측 결과

Table 5 Prediction results

구분	성능지표	MLP	ELM
training	RMSE	2069	1961
	MAPE	2.81	2.62
	MAE	1422	1327
testing	RMSE	3056	2384
	MAPE	3.81	2.89
	MAE	2307	1699




그림 6 ELM에 의한 예측 결과

Fig. 6 Prediction result by ELM




그림 7 ELM과 MLP에 의해 발생된 오차 분석

Fig. 7 Error analysis calculated by ELM and MLP

4. 결 론

신뢰성 높은 전력 수요예측 기법은 안정적이고 경제적으로 전력계통을 운용하는데 필요한 기본요소이다. 본 연구에서는 ELM 기반의 일일 최대부하 예측 알고리즘을 개발하였다. 우선 ELM의 입력인자를 선택하기 위하여 상관성 분석을 한 결과 온도의 영향보다는 과거 데이터로 구성된 시계열 데이터가 주도적인 영향을 주는 것으로 나타났다. 이런 결과를 바탕으로 다양한 시계열 데이터로 구성된 모델을 구성하고, 각각의 모델에 대해서 실험한 결과 1일전, 2일전, 6일전, 7일전, 8일전의 최대 전력 데이터로 구성된 모델이 가장 효과적인 것으로 나타났다.

이러한 모델을 MLP와 ELM에 동일하게 적용하여 실험한 결과 ELM은 RMSE가 2384, MPAE가 2.89, MAE가 1699로 나타났으며, MLP는 RMSE가 3056, MPAE가 3.81, MAE가 2307로 나타나 제안된 ELM에 의한 예측 방법의 성능이 더 우수하였다. 또한, 예측된 데이터의 오차를 분석한 결과 MLP에 의한 오차보다 ELM에 의한 오차가 전반적으로 적음을 확인하였다. 또한 오차 성능뿐만 아니라 학습 소요시간 과정에서도 제안된 방법이 매우 빠름을 알 수 있다. 따라서 제안된 방법이 효과적으로 일일 최대 소요 전력을 추정함을 알 수 있다. 향후 2010년 이후의 최근 데이터에 적용하여 제안 방법의 성능 분석과 온도 등의 외부 인자에 대한 영향 및 일일 최대 부하가 아닌 시간대별 예측모델을 개발하고자 한다.

감사의 글

이 논문은 2013년도 한국교통대학교 교내학술연구비의 지원을 받아 수행한 연구임.

참 고 문 헌

- [1] 남봉우, 송경빈, 김규호, 차준민, “다중회귀분석법을 이용한 지역전력수요예측 알고리즘”, 조명·전기설비학회 논문지, Vol. 22, No. 2, pp. 63-70, 2008,
- [2] R. Ramanathan, R. Engle, C. W. J. Granger, F. VahidAraghi, C. Brace, “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, 2006.
- [6] 이형로, 신현정, “Support Vector Regression에 기반한 전력 수요 예측,” IE Interfaces, Vol. 24, No. 4, pp. 351-361, 2011.
- [7] 박영진, 왕보현, “뉴로-퍼지 모델 기반 전력 수요예측 시스템 : 시간, 일간, 주간 단위 예측,” 퍼지및지능시스템학회 논문지, Vol. 14, No. 5, pp. 533-538, 2004.
- [8] 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.
- [9] 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.

pp.30-41, 2013.

- [10] M. Hanmandlu, B. K. Chauhan, "Load Forecasting Using Hybrid Models," IEEE Trans. on Power systems, Vol. 26, No. 1, pp. 20-29, 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



지 평 식 (池平植)

1964년 3월 5일생. 1989년 2월 국립 한밭대학교 전기공학과 졸업, 1994년 충북대학교 대학원 전기공학과 졸업(공학석사), 1998년 동대학원 전기공학과 졸업(공학박사), 현재 국립 한국교통대학교 전기공학과 교수

E-mail : psji@ut.ac.kr



김 상 규 (金相圭)

1972년 11월 29일생. 2000년 2월 국립 한국교통대학교 전기공학과 졸업, 2013년 한국교통대학교 대학원 석사과정 재학중. 건축전기설비기술사. 2012년 06월 ~ 현재 (주)청솔엔지니어링 이사



임 재 윤 (林裁尹)

1961년 8월 4일생. 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 대덕대학 전기과 교수

E-mail : jylim@ddu.ac.kr