

자기회귀모델과 뉴로-퍼지모델로 구성된 하이브리드형태의 일별 최대 전력 수요예측 알고리즘 개발

Development of Daily Peak Power Demand Forecasting Algorithm with Hybrid Type composed of AR and Neuro-Fuzzy Model

박 용 산* · 지 평 식†
(Yong-San Park · Pyeong-Shik Ji)

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 based on hybrid type composed of AR and Neuro-Fuzzy 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, Hybrid model, AR, ANFIS

1. 서 론

최근 들어 경제규모 확대와 상대적으로 저렴한 가격으로 인하여 매년 전력량의 사용은 증대하고 있다. 이러한 전력량 사용 증대에 맞추어 안정적인 전력을 소비자에게 공급하기 위하여 확보해야 할 예비전력도 증가하고 있다. 그러나 전기는 저장이 불가능하기 때문에 예비전력을 과다하게 확보하였을 경우 비용의 낭비를 초래할 수 있으며, 반대로 예비전력이 부족할 경우 부분 단전으로 이어져 생산현장에 치명적인 손실을 초래할 수 있다. 따라서 필요한 만큼 예비전력을 효과적으로 확보하기 위하여 전력수요량을 예측할 수 있는 알고리즘의 개발이 요구된다. 그러나 전력수요는 사회, 경제적 요소 및 기후 등과 연계된 비선형 특성을 가지고 있어 안정적인 수요예측 모델을 개발하는데 어려움이 있다. 특히, 최근에는 이상기후로 인한 폭설 또는 폭염 등에 의하여 전력수요예측의 불확실성을 높이고 있다.

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 웨이블렛과 신경회로망을 결합한 모델[8][9]과 웨이블렛과 뉴로퍼지모델을 결합한 모델[10] 등이 있다. 웨이블렛과 신경회로망을 결합한 모델[9]에서는 지능형 하이브리드 웨이블렛 모델을 이용하여 단기 부하 예측모델을 개발하고, 그 유용성을 평가하였다. 특히, 시계열 데이터를 웨이블렛에 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 자기회귀모델과 뉴로-퍼지모델로 구성된 하이브리드형태의 일별 최대 전력 수요예측 알고리즘 개발한다. 제안된 방법은 자기회귀모델에 의하여 전력 수요량의 특징인 시계열 특성을 반영하고, 뉴로-퍼지 모델에 의해 자기회귀모델의 오차를 보정한다. 개발된 예측모델은 입력으로서 과거의 최대 수요치를 고려하였으며, 기존에 널리 사용되는 자기회귀모델, 뉴로-퍼지 기법들과 비교함으로써 제안방법의 타당성을 입증하고자 한다.

* 정 회 원 : 한국교통대학교 대학원 전기공학과 박사수료

† 교신저자, 시니어회원 : 한국교통대 전기공학과 교수·공학

E-mail : psji@ut.ac.kr

접수일자 : 2014년 7월 28일

수정일자 : 2014년 8월 20일

최종완료 : 2014년 8월 22일

본 논문의 구성은 다음과 같다. 2장에서는 본 논문에서 제안한 하이브리드 모델에 의한 전력수요예측 모델에 대해서 설명한다. 3장에서는 본 실험에 사용된 데이터 구성과 실험 결과에 대하여 설명한다. 4장에서는 결론을 맺는다.

2. 하이브리드 모델에 의한 전력수요예측 모델

그림 1에서는 본 연구에서 제안한 전력수요예측 모델의 구성도를 나타냈다. 그림 1에서 보는 바와 같이 제안된 방법은 자기회귀(AR : Auto-Regressive) 모델에 의해 시계열 데이터에 대한 예측값을 산출한다. 다음 단계로 ANFIS(Adaptive Neuro-Fuzzy Inference System)로 설계한 뉴로-퍼지모델은 AR모델에서 산출된 예측값과 실제값을 오차를 추정하도록 학습한다. 최종 단계에서는 AR모델에 의해 산출된 예측값과 ANFIS에 의해 추정된 오차 보정값을 합산한다. 즉, 제안된 방법은 AR 모델에 의해 전력량에 대해 근사 추정을 한 후 ANFIS에 의해 오차를 보정하는 하이브리드 구조를 갖는 특징이 있다.

2.1 AR 모델에 의한 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 고려 한다. 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 짧은구간에서 신호의 실제값으로 수렴하게되고 모델오차의 제곱총합값을 최소화하면서 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.

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

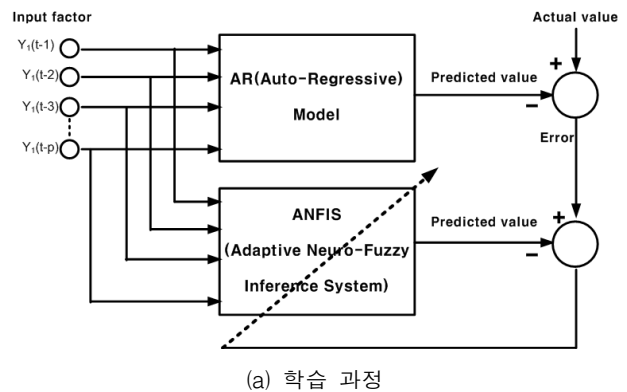
식(2)에서 $e(n)$ 은 식 (3)에서 보는 바와 같이 실제 표본

자료인 $S(n)$ 과 예측된 표본자료 $\hat{S}(n)$ 간의 예측오차를 나타낸다.

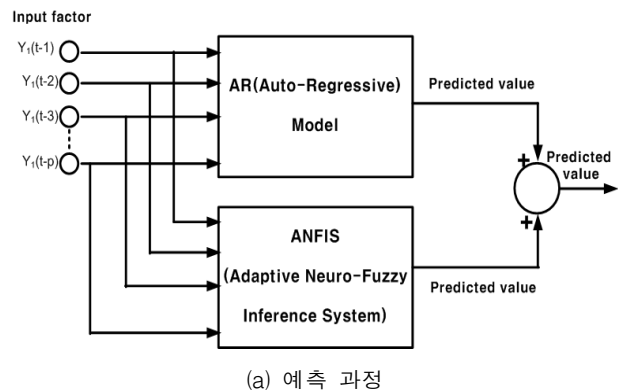
$$e(n) = S(n) - \hat{S}(n) \tag{3}$$

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.

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



(a) 학습 과정



(a) 예측 과정

그림 1 제안된 방법의 학습과정과 예측과정

Fig. 1 A learning and prediction process of the proposed method

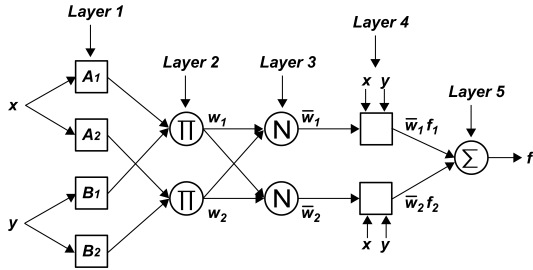
2.2 뉴로-퍼지 모델에 의한 오차 보정 알고리즘

AR 모델에 의해 전력 수요의 근사적 추정값을 예측한 후 ANFIS로 구성된 뉴로-퍼지 모델에 의해 오차를 보정하게 된다. Jang에 의해 제안된 TSK 뉴로-퍼지 모델인 ANFIS에 대해 간략히 살펴보면 다음과 같다[11]. 먼저 아래와 같은 두 개의 TSK 형태의 퍼지 규칙을 갖는 추론시스템에 대해 생각해 보자.


$$R^1: \text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f_1 = p_1x + q_1y + r_1 \tag{5}$$

$$R^2: \text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } f_2 = p_2x + q_2y + r_2$$

여기서 x 와 y 는 입력이고, A_i, B_i 는 언어적 레벨이며 $\{p_i, q_i, r_i\}$ 는 결론부 파라미터이다. 위와 같은 규칙에 대해 뉴로-퍼지 시스템의 구조는 그림 2(a)와 같이 5개의 층으로 이루어진다. 그림 2(b)는 주어진 입력 $[x, y]$ 로부터 출력 f 을 추론해 내기 위한 퍼지 추론과정을 설명하고 있다.



(a) ANFIS 구조



(b) 퍼지 추론

그림 2 ANFIS 추론 및 구조

Fig. 2 Peak power demand (2006-2010)

점화력(firing strengths) 혹은 가중치 w_1 과 w_2 는 전제부에서 소속도의 곱으로 얻어지며 출력 f 는 가중 평균법에 의해 구해진다. 좀 더 자세히 설명하면, 출력 f 는 식 (6)과 식 (7)과 같이 표현되어질 수 있다.

$$f = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2} \quad (6)$$

$$f = \frac{u_{A_1}(x)u_{B_1}(y)(p_1x + q_1y + r_1) + u_{A_2}(x)u_{B_2}(y)(p_2x + q_2y + r_2)}{u_{A_1}(x)u_{B_1}(y) + u_{A_2}(x)u_{B_2}(y)} \quad (7)$$

TSK 퍼지 모델의 학습을 수행하기 위해 퍼지 모델을 체계적으로 경사벡터를 계산할 수 있는 적응 네트워크의 구조안으로 배치함으로서 ANFIS를 구축할 수 있다. 위와 같은 ANFIS에 대하여 각 층의 동작특성과 학습 절차는 다음과 같다.

Layer 1: 이 층에서 각 노드는 언어적인 레벨의 소속도를 발행하며 식 (8)과 같이 소속값을 출력으로 가진다.

$$O_i^1 = u_{A_i}(x), O_{i+2}^1 = u_{B_i}(y), \quad i = 1, 2 \quad (8)$$

전제부 소속함수로 식 (9)와 같은 가우시안 소속함수를 선택하였다.

$$u_{A_i}(x) = \exp\left\{-\left(\frac{x - c_i}{a_i}\right)^2\right\} \quad (9)$$

여기서 $\{a_i, c_i\}$ 는 전제부 파라미터이며, a_i 는 소속함수의 폭이고 c_i 는 소속함수의 중심이다.

Layer 2: 이 층에서 각 노드는 Layer 1에서 구한 소속값을 규칙별로 곱한 가중치로 출력된다.

$$O_i^2 = w_i = u_{A_i}(x) \times u_{B_i}(y), \quad i = 1, 2 \quad (10)$$

Layer 3: 이 층에서 노드 i 는 모든 점화력의 합에 대한 i 번째 규칙의 점화력의 비를 계산한다. 즉, 식 (11)과 같이 w_i 에 대해 정규화 된 값을 출력한다.

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (11)$$

Layer 4: 이 층에서 노드 i 는 식 (12)와 같이 정규화 되어진 값과 결론부의 곱으로 출력을 낸다.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i(p_i x + q_i y + r_i), \quad i = 1, 2 \quad (12)$$

여기서 \bar{w}_i 는 Layer 3에서 얻어진 정규화 된 점화력(normalized firing strengths)이다.

Layer 5: 이층에서 가중 평균법에 의해 최종 출력을 구한다.


$$O_i^5 = y_i^* = \sum_{i=1}^2 \bar{w}_i f_i = \frac{\sum w_i f_i}{\sum w_i} \quad (13)$$

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 매



년 최대부하전력은 증가함을 알 수 있다. 즉, 2006년도에는 연간 최대부하전력이 5899[만KW] 이었지만, 2010년에는 7130[만KW]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.

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 9일전까지의 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.

표 2에서는 최고온도, 최저온도, 평균온도 등의 온도와 최대전력과의 상관성을 분석하여 나타냈다. 표 2에서 보는 바와 같이 하절기와 동절기로 구분하여 분석한 결과 최저온도와 상관성이 가장 높은 것으로 나타났다. 그러나 과거 데이터인 시간인자와 비교해 볼 때 상관성은 크지 않은 것으로 분석된다.

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	

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

3.2 예측결과

본 연구에서는 자기회귀모델과 뉴로-퍼지모델로 구성된 하이브리드형태의 일별 최대 전력 수요예측 알고리즘 개발하였다. 개발된 방법을 평가하기 위하여 2006년도에 2009년도에 발생한 최대수요전력 데이터를 학습용으로 사용하였고, 나머지 2010년도 데이터를 이용하여 검증을 하였다. 입력인자와 출력인자는 식 (14)와 식 (15)와 같이 각각 구성하였다.

$$X = \begin{bmatrix} y(\tau) & y(2\tau) & y(m\tau) \\ y(2\tau) & y(3\tau) & y((m+1)\tau) \\ \vdots & \vdots & \vdots \\ y((N-m)\tau) & y((N-m+1)\tau) & y((N-1)\tau) \end{bmatrix} \quad (14)$$

$$Y = \begin{bmatrix} y((m+1)\tau) \\ y((m+2)\tau) \\ \vdots \\ y(N\tau) \end{bmatrix} \quad (15)$$

AR 모델의 매개 파라미터와 ANFIS 학습을 위해서는 효과적인 입력 인자의 선택이 매우 중요하다. 본 논문에서는 3.1절에서 수행한 상관성 분석을 통해 얻어진 상관관계를 이용하여 상관성이 높은 5가지 입력인자(1일전, 2일전, 6일전, 7일전, 8일전)를 이용하여 구축하였다. 온도와 최대 수요전력과의 상관성이 낮은 이유로, 본 논문에서는 온도 정보를 입력인자로 사용하지 않았다.

성능지표로는 아래 식의 평균제곱오차인 RMSE(Root means square error), 절대 평균 퍼센트오차인 MAPE(Mean absolute percentage Error) 및 MAE(Mean absolute prediction Error)를 고려하였다.

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

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Actual_i - Forecast_i}{Actual_i} \right| \times 100 \quad (17)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Actual_i - Forecast_i| \quad (18)$$

표 3에서는 AR모델, ANFIS모델과 제안된 하이브리드 방법의 성능을 비교하여 나타냈다. ANFIS 모델에서 각각의 입력에 대한 전제부 소속함수는 8개로 설정하였다. 표 3에서 보는 바와 같이 제안된 AR모델과 ANFIS 모델에 비하여 RMSE, MAPE 및 MAE 모두 우수하게 나타났다. 표 3에서 학습 데이터에 대하여 ANFIS 모델이 AR모델에 비하여 성능이 우수하게 나타났으나, 검증 데이터에 대해서는 ANFIS 모델이 AR모델보다 성능이 저하된 것으로 나타났다. 이는 신경회로망 또는 뉴로-퍼지 모델과 같은 지능형 알고리즘의 단점인 오버피팅에 기인한 결과라 볼 수 있다. 그러나 제안된 방법은 데이터의 주 특성은 AR 모델에 의해 예측하고, 오차 성분에 대해서만 ANFIS에 의하여 학습함으로써 오버피팅의 문제점을 해결할 수 있음을 알 수 있다.


표 3 예측 결과

Table 3 Prediction results


구분	성능지표	AR	ANFIS	Proposed method
training	RMSE	2030	1771	1750
	MAPE	2.7	2.4	2.3
	MAE	1384	1205	1183
testing	RMSE	2367	2761	2295
	MAPE	2.9	3.5	2.8
	MAE	1690	2064	1632

그림 4에서는 AR 모델에 의한 예측 결과, ANFIS에 의한 오차 보정 결과, 그리고 제안된 하이브리드 모델에 의한 일일 최대 전력 예측결과를 검증 데이터에 대하여 나타냈다. 그림 5에서는 첫 번째 입력에 대한 소속함수의 ANFIS 학습 전과 학습 후의 모양을 나타냈다. 그림 5에서 보는 바와 같이 학습 후에 미세한 소속도의 변화가 발생함을 알 수 있다.

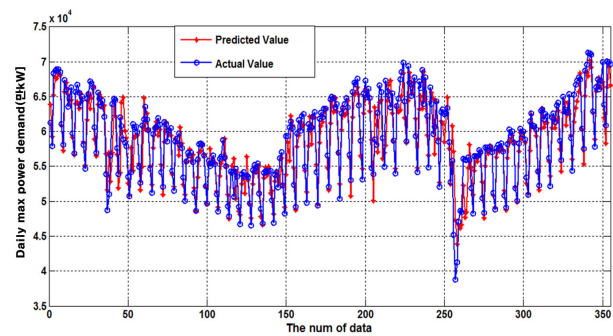
그림 4의 (a)와 (c)만을 보면, AR 모델과 제안방법의 성능 차이를 구분하는 것이 쉽지 않다. 이를 위해 그림 6에서 예측 오차를 기준으로 두 방법을 비교하여 나타냈다. 그림 6에서 보는 바와 같이 제안된 방법은 AR방법에 비하여 오차가 큰 부분의 비율이 작아짐을 알 수 있다. 즉, 그림 6은 AR 모델에서 오차가 크게 발생하는 부분을 뉴로-퍼지모델에 의해 효과적으로 보정했음을 보여준다.



(a) AR 모델에 의한 예측 결과



(b) ANFIS에 의한 오차 보정 결과



(c) 제안된 하이브리드 방법에 의한 예측 결과

그림 4 최대 수요 예측 결과

Fig. 4 Prediction result of peak power demand for test data





그림 5 입력 인자 1에 대한 소속도

Fig. 5 Membership function for the first input factor




그림 6 AR 모델과 제안된 방법의 오차 분석

Fig. 6 Error analysis calculated by AR and the proposed method

4. 결 론

신뢰성 높은 전력 수요예측 기법은 안정적인 경제적으로 전력계통을 운용하는데 필요한 기본요소이다. 본 연구에서는 자기회귀모델과 뉴로-퍼지모델로 구성된 하이브리드 형태의 일일 최대 전력 수요예측 알고리즘 개발하였으며, AR 모델, ANFIS 단독 모델과 비교하여 개발 방법의 타당성을 검증하였다. 실험결과 AR모델과 ANFIS 모델에 비하여 RMSE, MAPE 및 MAE 모두 우수하게 나타났다. 특히, 제안된 방법은 데이터의 주 특성은 AR 모델에 의해 예측하고, 오차 성분에 대해서만 ANFIS에 의하여 학습함으로써 오버피팅의 문제점을 해결하였다. 향후 특징일을 고려한 모델과 개발방법을 접목하여 예측 성능을 향상시키고자 한다.

References

[1] Bong-Woo Nam, Kyung-Bin Song, Kyu-Ho Kim, Jun-Min Cha, "The spartial electric load forecasting algorithm using the multiple regression analysis method", Journal of the Korea Institute of Illuminating and Electrical Installation Engineers, 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, Chichester. 2006
- [6] HyoungRo Lee, Hyunjung Shin "Electrical demand forecasting based on support vector regression," IE Interfaces, Vol. 24, No. 4, pp. 351-361, 2011
- [7] Yong-Jin Park, Bo-Hyeun Wang, "Neuro-fuzzy based electrical load forecasting system : hourly, daily, and weekly forecasting," Journal of Korean Institute of Intelligent Systems, 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] J. S. R. Jang, "ANFIS: Adaptive-network-based fuzzy inference system," IEEE Trans. on Systems, Man and Cybernetics, Vol. 23, No. 3, pp. 665-685, 1993

저 자 소 개



박용산 (朴鏞山)

1961년 5월 27일생. 2001년 8월 한국교통대학교 전기공학과 졸업(석사), 2013년 2월 동대학원 전기공학과 박사과정(수료), 현재 한국산업인력공단 기술자격출제실 연구원

E-mail : pysan2@hanmail.net



지평식 (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