

기온 데이터를 이용한 하계 단기전력수요예측

Short-term Electric Load Forecasting for Summer Season using Temperature Data

구본길* · 김형수** · 이흥석* · 박준호*

(Bon-gil Koo · Hyoung-su Kim · Heung-seok Lee · Juneho Park)

Abstract - Accurate and robust load forecasting model is very important in power system operation. In case of short-term electric load forecasting, its result is offered as an standard to decide a price of electricity and also can be used shaving peak. For this reason, various models have been developed to improve forecasting accuracy. In order to achieve accurate forecasting result for summer season, this paper proposes a forecasting model using corrected effective temperature based on Heat Index and CDH data as inputs. To do so, we establish polynomial that expressing relationship among CDH, load, temperature. After that, we estimate parameters that is multiplied to each of the terms using PSO algorithm. The forecasting results are compared to Holt-Winters and Artificial Neural Network. Proposing method shows more accurate by 1.018%, 0.269%, 0.132% than comparison groups, respectively.

Key Words : Short-term electric load forecasting, PSO, CDH

1. 서론

전력수요예측의 결과는 전력시스템의 운영, 계획에 있어서 다양한 용도로 사용된다. 그 기간에 따라 장기의 경우 송전선의 건설이나 발전설비투자의 목적이 있고, 중·단기의 경우 전력시장에서 가격을 결정하는 중요한 요인으로 피크 저감을 위해 정확한 전력소비패턴을 찾는 등 중요한 역할을 한다. 또한 정확한 단기 전력수요예측은 경제적이면서 안정적으로 전력을 공급할 수 있도록 발전예비력을 정하는데에도 결정적인 역할을 하기 때문에 최근 발생한 정전사태와 같은 심각한 문제를 피하기 위해서라도 정확한 수요예측을 위한 연구는 꼭 필요하다 할 수 있다.

지금까지의 연구를 살펴보면 주로 전력수요예측의 정확도를 높이기 위한 예측기법에 대한 연구가 진행되었다. 크게 지능시스템과 관련된 접근법과 통계적인 접근법, 전문가 시스템으로 나눌 수 있는데, 인공신경망(Artificial Neural Network)은 지능시스템의 대표적인 예측 알고리즘으로 최근에는 training data를 Chaotic 유전알고리즘(genetic algorithm)을 적용하여 학습을 시

키거나[1], 여러개의 ensemble 인공신경망 모델의 결과를 이용하는 연구결과도 발표되었다[2]. 이밖에도 통계적인 방식의 대표적인 알고리즘인 ARIMA(Auto Regressive Integrated Moving Average)와 기법과 결합한 형태나, Neuro-fuzzy, Support Vector Machine-Particle Swarm Optimization 등 두 가지 이상의 알고리즘을 결합한 형태의 연구도 다수 진행되고 있다[3-5]. 그러나 전력수요 예측 알고리즘은 이와 같은 다양한 연구에도 불구하고 수요예측은 최적의 기법을 하나로 특정할 수 없는 실정이다.

하지만 최근의 전력수요의 예측은 예측모델의 형태뿐 아니라 전력수요에 영향을 미치는 다양한 인자들을 입력으로 하여 진행되며 기후변화와 가정용 냉방부하의 증가, 분산전원의 보급으로 인한 소규모 마이크로그리드 망의 증가, 수요관리 시행 등 전력시스템의 큰 변화가 수요예측에 많은 영향을 미치고 있다. 특히 냉방부하의 비중은 해마다 증가하여 이미 전력수요의 20%를 넘어서고 있고 이는 피크부하를 유발하는 중요한 요소로 예측이 빗나갈 경우 발생하는 경제적 손실은 더욱 더 크다고 볼 수 있다. 따라서 하계 냉방부하를 정확하게 예측하는 것은 중요하며 이를 위해 적절한 것을 선정하여 입력데이터로 이용하는 것은 점점 더 중요해 지고 있다. 많은 전력수요와 관련된 데이터 중에서도 하계 기간의 단기 전력수요예측의 경우 기상데이터의 영향을 특히 많이 받는데 기온, 습도, 풍속 등이 주요 입력으로 이용된다. 그 중 기온은 기상데이터 중 가장 중요한 요인으로 우리 나라 하계 기간의 단기 전력수요예측 시 기온데이터를 포함하여 예측하여 피크수요 및 수요의 예측오차를 줄인 연구가 진행되기도 하였다 [6, 7]. 또한, 최대기온, 최저기온, 평균기온 등 관측기온과 그 관측치를 보정하여 사용하는 HI(Heat Index), WCF(Windchill

† Corresponding Author : Dept. of Electrical and Computer Engineering, Pusan National University

E-mail : parkjh@pusan.ac.kr

* Dept. of Electrical and Computer Engineering, Pusan National University

** Dept. of Electrical Engineering, Gyeongnam provincial Namhae

Received : December 30, 2014; Accepted : July 27, 2015

Factor)등과 같은 보정기온을 이용하는 경우도 있다[8]. 최근에는 원시 기상데이터에서 파생된 냉방도시와 난방도시 즉, CDD(Cooling Degree Days)와 HDD(Heating Degree Days) 이라는 지표를 사용하기도 하는데 이는 전력수요 중 기온과 밀접한 관계를 가지는 냉방부하의 변동을 예측하는데 사용하고 과거 한달동안의 냉방도일(Cooling Degree Days)을 이용하여 중기 전력수요예측에 이용한 경우도 있다[9-11].

본 논문은 기온의 변화에 따른 전력수요의 변화를 기존의 방식보다 전력수요자의 실제 사용패턴을 더 반영할 수 있도록 CDH(Cooling Degree Hours) 데이터와 HI를 이용하여 하계의 단기 전력수요를 모델링하고 PSO(Particle Swarm Optimization)를 이용한 파라미터 최적화 과정을 거쳐 월요일을 제외한 평일의 단기 전력수요 예측을 실시하였다. 과거데이터와, HI데이터, 기온데이터를 기반으로 한 CDH를 입력으로 하고 PSO(Particle Swarm Optimization)로 파라미터를 추정하는 형태로 그 결과를 각각 지능형 알고리즘과 통계적 방식의 대표적인 알고리즘인 인공신경망과 Holt-Winters 기법의 결과와 수요와 기온간의 민감도만을 고려한 모델과 비교하였다.

2. 본 론

2.1 기상데이터의 이용

우리 나라의 하계 피크 시간대의 냉방 부하는 각각 전체 부하의 23.8%(2012년 기준)로 전체 계통의 전력수급에 큰 영향을 끼칠 수 있는 충분한 양이기 때문에 정확한 예측이 진행되지 않으면 전압불안정, 송전선과부하 심하게는 순환정전을 야기할 수 있다. 전력수요예측시 사용하는 기온데이터의 경우 그대로 적용을 할 수도 있으나, 하계는 습도를 포함하는 기온지표를 사용하는 것이 냉방부하와 같이 전력수요자가 체감하는 기온에 따라 부하량이 변화하는 경우에는 더 효과적인 방법이다. 또한 같은 기온이라 하더라도 냉방부하가 변화하지 않는 경우가 있는데 과거 몇 시간 또는 며칠동안의 기온이 계속해서 냉방부하가 필요할 정도로 높거나 낮아야 냉방부하량이 증가하고, 순간적인 이상고온을 나타내는 경우에는 냉방부하량이 증가하지 않거나 적은양의 부하만 증가하게 된다. 아래 그림 1은 2012년 7월 17일~20일 사이의 시간별 가중평균 기온변화와 전력수요를 나타낸 그래프이다. 그림 1과 같이 최고기온을 기준으로 하여 기온의 경우 7월 18일에 전날대비 3.5°C의 기온상승을 보였지만 전력수요는 2508MW 상승하여 721MW/°C의 민감도를 보였다. 반면에 2012년 6월 3일부터 9월7일 사이의 월요일을 제외한 평일 최고기온 기준 전력수요와 기온사이의 민감도는 그림 2에서 나타난 것과 같이 1388MW/°C로 7월17일과 18일 사이의 민감도가 전체 하계의 평일 피크시간대의 민감도에 비해 낮게 나타나는 것을 볼 수 있다. 이는 하루정도의 짧은 시간 동안의 기온변화가 전력수요에 큰 영향을 미치지 않는다는 것을 보여주는 사례이다. 반면 9·15 순환정전 당시에는 9월 12일에 27.4°C 였던 최고 기온이 13일 29.5°C, 14일 28.3°C를 기록하면서 전력수요가 계속해서 증가하였으며 15일에는 30.4°C를 기록하면서 이 기간동안의 냉방수요가 계속해서 증가하게 되었고 이 기간동안의 평일 최고기온 기준 전

력수요와 기온사이의 민감도는 5864MW/°C로 누적기온의 효과를 보이기도 하였다. 따라서 본 논문에서는 기상데이터 중 기온과 습도를 이용한 HI 적용을 통해 전력수요자가 체감하는 기온과 유사하도록 데이터를 가공하고 CDH를 이용하여 하루 정도의 단기 기간 기온변화와 수주에서 수개월동안 이어지는 장기간 기온변화에 따른 전력수요의 변화를 반영할 수 있도록 모델링하여 전력수요예측을 실시하였다.

한편, 단기 전력수요예측의 경우 하루 전 예측을 실시하기 때문에 기상데이터 또한 예측된 데이터를 사용할 수 밖에 없다. 따라서 기상예보가 정확하지 않을 경우 그 불확실성이 수요예측에 영향을 끼칠 수 있다.그러나 기온에 따른 예측 오차가 가장 크게 발생하는 하계 피크부하 기준 1°C 예보가 낮게 될 경우 예측오차는 약460MW 정도 발생하고 이 기간의 기상청의 최저/최고기온의 평균 예측 오차가 약0.3°C정도 발생하고 있기 때문에 이에 따른 수요예측 오차의 크기는 예측 오차와 기온간의 관계가 선형이라고 가정하였을 때 약138MW로 피크부하의 0.186% 정도로 미비하며 시뮬레이션 결과 기온을 반영한 수요예측에서 감소하는 예측 오차의 크기가 훨씬 큰 것을 확인하였다[12].

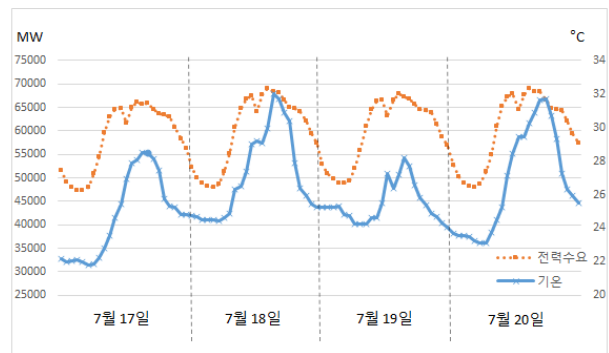


그림 1 전국의 가중평균 기온변화와 그에 따른 전력수요의 패턴 변화

Fig. 1 Electric load pattern variation according to spatial weighted temperature

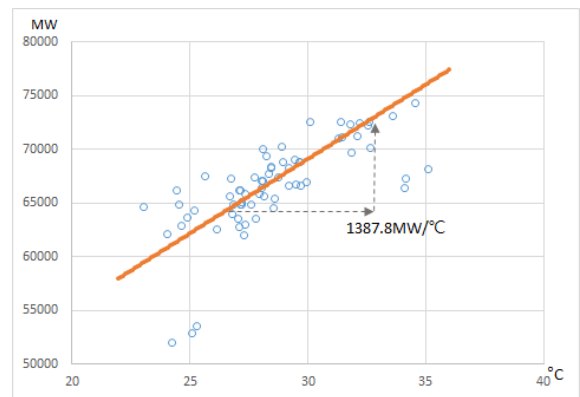


그림 2 하계 평일 최고기온과 전력수요의 민감도

Fig. 2 Sensitivity between temperature and summer peak load

2.1.1 기상데이터의 분석과 HI의 적용 기간 설정 및 대표기온 산정

전력수요자가 실제로 느끼는 기온을 예측모델에 최대한 반영하기 위해서 본 논문에서는 우리나라 기상청의 2012년도 관측데이터를 사용하여 하계 기간(6월~9월)에는 HI를 적용하였다. HI는 사람이 느끼는 더위가 기온과 습도의 복합적인 영향을 받는다는 것을 지수로 표현한 것으로 미국 기상청(NWS)에서 제안한 지수이다. 표 1은 하계기간의 기온과 전력수요, 기온과 HI간의 상관계수를 나타내고 있다. 6월~9월의 평균 상관계수 기준 HI와 전력수요, 기온과 전력수요의 차이는 7월에는 0.044로 비교적 높게 나타났고 6월과 9월에도 0.012, 0.016차이가 나는 것을 확인하였다. 따라서 기온보다는 HI와 전력수요간의 상관관계가 더 높은 것을 확인 할 수 있었고 아래 식(1)과 같이 HI를 계산하여 기온데이터에 반영하였다.

$$HI = c_1 + c_2T_f + c_3R + c_4T_fR + c_5T_f^2 + c_6R^2 + c_7T_f^2R + c_8T_fR^2 + c_9T_f^2R^2 \quad (1)$$

여기서, T_f 는 예측하고자 하는 시간의 기온($^{\circ}F$), R 은 상대습도(%)를 나타내고 $c_1 \sim c_9$ 까지의 각각의 계수들은 아래와 같다.

$$c_1 = -42.379, c_2 = 2.04901523, c_3 = 10.14333127, c_4 = -0.22475541, c_5 = -6.83783 \times 10^{-3}, c_6 = -5.481717 \times 10^{-2}, c_7 = 1.22874 \times 10^{-3}, c_8 = 8.5282 \times 10^{-4}, c_9 = -1.99 \times 10^{-6}$$

표 1 하계기간의 HI와 전력수요, 기온과 전력수요간의 상관계수

Table 1 Average correlation factor for electric load versus temperature, heat index

	평균 상관계수		차이 (A-B)
	HI와 전력수요(A)	기온과 전력수요(B)	
6월	0.643	0.630	0.013
7월	0.296	0.252	0.044
8월	0.578	0.577	0.001
9월	0.513	0.498	0.015

표 2 인구수를 기준으로 한 8대도시 지역별 가중치


Table 2 8 major cities' weight factor by number of population

지역	서울특별시	부산광역시 (경남, 울산)	대구광역시 (경북)	춘천시 (강원)
가중치	0.20	0.16	0.10	0.03
지역	인천광역시	대전광역시 (충북, 충남)	광주광역시 (전남, 전북)	수원시 (경기)
가중치	0.06	0.10	0.10	0.24


기온은 동일한 날짜의 동일한 시간에도 지역별로 큰 편차를 보이기 때문에 우리 나라의 전체 전력수요를 예측하기 위해서 하나의 대표 기온 데이터를 선정하는 것도 예측오차에 큰 영향을 줄 수 있다. 따라서 우리 나라의 전체 기온을 적절히 반영할 수 있도록 지역별 기온데이터를 지역별 부하량과 기온에 민감한 부하인 가정용부하의 비중에 따라 가중치를 적용하여 따라 가중평균 하였다[13].

2.1.2 기온데이터의 CDH

일반적으로 전력수요는 하계(6월, 7월, 8월, 9월)와 동계(11월, 12월, 1월, 2월)기간에 기온과 밀접한 관계를 가지는데 하계에는 기온이 높아질수록 전력수요가 증가하는 양의 상관관계, 기온이 낮아질수록 전력수요가 증가하는 동계에는 음의 상관관계를 가지게 된다. 하지만 실제로 전력수요가 가장 높고, 기온이 가장 높은 하계 냉방 집중 기간에는 오히려 상관관계가 낮게 나타나는 것을 볼 수 있다. 이는 계속된 냉방으로 인해 기온의 변화에 따라 추가적으로 증가하는 폭이 크지 않거나 너무 적고 오히려 더 줄어드는 현상이 원인이라 볼 수 있다. 또한 냉방 부하는 같은 기온에 항상 같은 부하가 나타나는 것이 아니라 그 이전의 전력수요자의 경험에 따라서 달라지며, 이는 기준기온 대비 지속적인 초과분을 누적한 식(2)의 CDH를 통해 수치화가 가능하다. 그림 3에서 기온과 전력수요간의 상관관계보다 CDH와 전력수요간의 상



(a)



(b)

그림 3 CDH(a)와 기온(b)에 따른 전력수요 패턴

Fig. 3 Electric load pattern according to CDH (a) and temperature (b)

관관계가 훨씬 더 높은 양의 상관관계를 가지고 있고 이에 따라 기온만 고려하는 것 보다 CDH를 고려하는 것이 전력수요예측 오차를 줄이는데 도움이 될 수 있다. 여기서 CDH의 n은 2주, 1주, 2일, 1일, 12시간, 6시간, 3시간의 7가지 상황을 우선 시물레이션 해 보았고, 그 이후 예측 오차가 가장 낮은 12시간을 기점으로 하여 3시간 부터 3시간 단위로 48시간까지 증가 세부적으로 시물레이션을 하였으며 그 결과 12시간의 데이터가 가장 낮은 예측 오차를 보였다.

$$T_{d,h} = \sum_{i=1}^n [T_h(i) - T_{standard}] \quad (2)$$

T_h : i시간의 HI
 $T_{standard}$: CDH의 기준기온

2.2. 전력수요예측모델

2.2.1 제안한 예측모델

전력수요는 동일한 시간대의 전달수요나 바로 전 시간의 전력수요와 크게 다르지 않으며 하계와 동계기간에는 기온에 따른 변화량을 반영하여 예측을 실시한다. 따라서 일반적인 전력수요는 이전 시간의 수요에 기온에 따른 민감도를 더한 형태로 모델링할 수 있으며 여기서 CDH에 따른 전력수요의 증감분은 아래와 같이 로그 함수로 모델링한다. 전력수요와의 관계에서 볼 때 CDH가 계속해서 증가한다고 해서 전력수요가 이에 따라 계속해서 증가하지 않고 주기성을 가지고 증가 감소하지도 않기 때문에 지수함수와 삼각함수등의 형태는 적합하지 않다. 따라서, CDH는 로그함수의 형태가 그 영향을 가장 잘 나타낼 수 있으며 본 논문에서는 기존의 전력수요와 기온과의 선형결합으로 나타낼 수 있었던 모형에 로그 형태의 CDH항을 추가할 것을 식(3)과 같이 제안한다.

$$\hat{L}(t) = L(t-24) + a \ln(T_{d,h}(t)) + b(T_h(t)) + c \quad (3)$$

또한, 적합도함수 F는 아래 식(4)와 같이 예측수요와 관측수요의 차이로 나타낼 수 있다.

$$F = \sum_{i=1}^n |\hat{L}(i) - L(i)| \quad (4)$$

여기서, $\hat{L}(t)$: t시간의 예측 전력수요
 $T_{d,h}(t)$: CDH
 $T_h(t)$: t시간의 HI
 $L_R(t-24)$: t-24시간의 관측 전력수요
 a, b, c : 가중치
 n : 예측모델에 반영되는 과거데이터의 수

2.2.2 PSO를 이용한 예측모델의 변수 추정

본 논문에서는 위 식 (3)의 변수 a,b,c를 추정하기 위해서 PSO를 사용하였다. 변수를 추정하는 알고리즘에는 대표적으로

least square, maximum likelyhood[14]등이 있지만 연속이고 미분가능해야하고 초기 조건에 따라 국부최적해를 찾을 가능성이 높다. 또한 유전알고리즘[15, 16]과 같은 경험적 알고리즘을 사용하기도 하는데 이 경우에 데이터를 스트링 형태로 변·복조 해야하는 번거로움이 있다. 따라서 본 논문에서는 다른 유사한 경험적 알고리즘과는 다르게 연속 또는 이산최적화문제 뿐만 아니라 비선형 혼합정수계획법(mixed-integer nonlinear optimization)에도 적용이 가능하며, 구조가 간단하고 구현하기가 편리하고 해의 탐색공간 전체를 복수의 탐색점을 이용하기 때문에 국부최적해에 수렴 할 가능성이 낮은 장점이 있는 PSO 알고리즘을 사용하였다.

PSO는 1990년대에 발표된 자연 현상을 기반으로 한 경험적(heuristic) 최적화 기법 중 하나로 조류나 어류의 무리지어 다니는 패턴을 이용한 알고리즘이다. Eberhart 와 Kennedy가 개발한 이 알고리즘은 'individual learning'과 'cultural transmission', 두 가지를 통해 하나의 해인 개체 각각의 최적값과 전체 개체의 최적해를 동시에 고려하여 전체 무리(swarm)의 진행방향 및 속도를 결정짓는다. 이는 개체가 자신의 경험과 주변의 경험에 따른 선택 모두에 영향을 받는 형태로 기본 개념은 개체로 묘사된 각각의 해가 목적함수의 최적값을 찾기 위해서 해공간을 계속해서 이동하는 것이다. 랜덤하게 초기위치와 초기속력을 가진 상태에서 각각의 해들은 현재속도, 현재위치, 자신의 과거 최적해와 현재의 위치간의 거리, 모든 개체의 과거 최적해와 현재위치간의 거리의 정보를 이용하여 자신의 다음 iteration의 위치를 수정한다. 해를 찾아 해공간을 이동하는 형태로 모델링 된 알고리즘이므로 자신의 위치를 수정하는 개념은 속도로 정의하는데 본 논문에서 사용한 모델의 속도는 아래 식(5)와 같이 나타낼 수 있다 [17].

$$v_i^{k+1} = w v_i^k + c_1 rand_1 \times (p_{best_i} - s_i^k) + c_2 rand_2 \times (g_{best} - s_i^k) \quad (5)$$

여기서, v_i^{k+1} : 개체i의 k번째 반복시의 속도
 w : 관성 가중치
 c_j : 가속 상수(acceleration constant)
 $rand_1, rand_2$: [0, 1]범위의 균등 분포된 난수
 s_i^k : 개체 i의 k번째 세대의 현재 위치
 p_{best_i} : 개체 i의 이동경로 중 최적해
 g_{best} : 모든 개체의 이동경로 중 최적해

또한, 속도는 일반적으로 최대값의 한계치를 가지는데 아래와 같이 속도수정을 반복할수록 w 는 작아지도록 식(6)와 같이 설정하고 있다.

$$w = w_{max} - \frac{w_{max} - w_{min}}{iter_{max}} \times iter \quad (6)$$

여기서, w_{max} : 초기 가중치 계수
 w_{min} : 최종 가중치 계수
 $iter_{max}$: 세대수의 최댓값
 $iter$: 현재 세대수

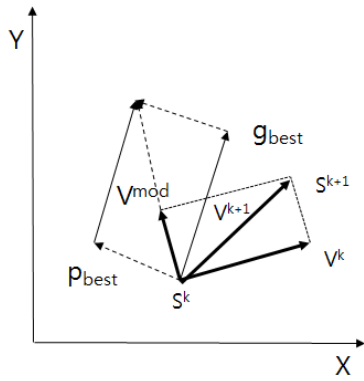


그림 4 PSO알고리즘에서의 해공간 탐색 개념
 Fig. 4 Solution searching concept for PSO algorithm

현재의 위치에서 다음 iteration시점의 위치까지 이동은 아래의 식(7)과 같이 나타나며 그림 4에 나타난 벡터의 합으로 이동을 하게 된다. 그 순서는 아래와 같다.

$$s_i^{k+1} = s_i^k + v_i^{k+1} \quad (7)$$

- Step 1 초기 개체의 상태를 설정한다. 해가 가질 수 있는 특정한 범위 내에서 초기 위치(해) s_i^0 , 초기 속도 v_i^0 는 랜덤하게 설정하며 현재의 상태가 개체i의 p_{best_i} 가 되고, 초기 상태 중 적합도가 높은 해가 전체 개체의 g_{best} 가 된다.
- Step 2 목적함수의 적합도를 평가하여 개체별로 p_{best_i} 보다 현재의 해의 적합도가 높다면 현재의 해를 p_{best_i} 로 교체하고 그렇지 않다면 p_{best_i} 를 유지한다. 전체의 p_{best_i} 중 가장 적합도가 높은 해가 g_{best_i} 보다 적합도가 높다면 가장 적합도가 높은 p_{best_i} 와 g_{best} 를 교체하고 그렇지 않다면 유지한다.
- Step 3 각각의 개체들은 위의 식 (5),(6),(7)을 이용하여 위치를 업데이트한다.
- Step 4 종료조건을 체크하여 종료조건에 해당하면 종료하고 그렇지 않으면 step2부터 반복한다.

위 식(3)의 가중치 a, b, c를 추정하기 위해 그 파라미터는 아래 표 3과 같이 설정하여 시뮬레이션을 진행하였다. 일반적으로 가속상수 c_1, c_2 는 동일하게 2로 설정하고 해 공간 전체의 개체수와 세대수의 최댓값은 계속해서 증가시켜 반복실행한 결과로 예측오차가 어느 정도 수렴하는 값으로 정하였다[18, 19].

그림 5는 PSO알고리즘의 파라미터 추정을 위한 계산 순서를 나타낸 것이다. 각각의 개체별 적합도를 계산하여 개체별로 이전 세대의 해 중에서 적합도가 가장 높은 것을 p_{best_i} 에 저장하고 개

표 3 PSO 파라미터 설정 값

Table 3 Selection of PSO parameter

파라미터	설명	값
dimension	추정하고자 하는 파라미터의 개수	3
swarm size	해공간의 전체 개체 수	1,000,000
c_1	가속상수	2
c_2	가속상수	2
$rand_1, rand_2$	랜덤계수	0~1
er_{max}	세대수의 최댓값	10,000
w_{max}, w_{min}	관성가중치	0.8, 0.4

체별 p_{best_i} 중에서 가장 높은 것은 g_{best} 에 저장한다. 또한 식(5)을 이용하여 계속해서 유력한 해의 방향으로 전체개체의 속도벡터가 변화되며 정해진 반복횟수에 도달하면 알고리즘은 종료되고 마지막의 g_{best} 가 최적해가 되도록 설정하였다.

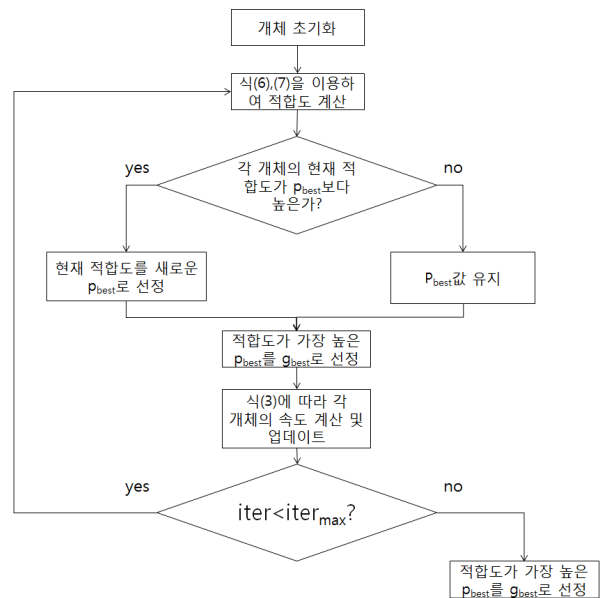


그림 5 PSO알고리즘의 순서도
 Fig. 5 Flow chart of PSO algorithm

2.3 예측 결과 비교를 위한 일반적인 두가지 예측모델

2.3.1 Holt-winters multiplication 알고리즘

Holt-Winters 모형은 지수평활(Exponential Smoothing) 기법의 하나로 전력수요데이터만을 이용하여 예측하는 대표적인 univariate 알고리즘이다. 지수평활 방식은 현재에도 한국전력거래소에서 실계통 부하예측에 사용할 만큼 예측력이 탁월하고 그 중에서도

Holt-winters 승법(multiplicative)모형은 추세와 단일 계절성을 모의할 수 있다. 따라서 본 논문은 Holt-Winters 승법모형과 제안한 모델의 예측 결과를 비교하였고 그 식은 아래와 같이 수준(level), 추세(trend), 계절(seasonality) 성분의 평활 방정식으로 구성된다.

$$\hat{L}(t+m) = [L(t)+b(t)m] \times S(t-s+m) \tag{8}$$

$$L(t) = \alpha \frac{X(t)}{S(t-s)} + (1-\alpha)L(t-1) + b(t-1) \tag{9}$$

$$b(t) = \beta L(t) - L(t-1) + (1-\beta)b(t-1) \tag{10}$$

$$S(t) = \gamma \frac{F(t)}{L(t)} + (1-\gamma)S(t-s) \tag{11}$$

여기서, $L_f(t+m)$: 시점 t에서 예측한 시점 t+m의 예측값
 $L(t)$: 시점 t에서 시계열의 평균수준
 $S(t)$: 시점 t에서 시계열의 계절성분
 $X(t)$: 시점 t에서 관찰된 시계열의 값
 s : 계절 성분의 길이

또한, 초기값은 아래와 같이 설정하였다[20].

$$L(0) = \bar{Y}(1)$$

$$b(0) = 0$$

$$S(t-s) = \frac{X(t)}{\bar{X}(1)}, t=1,2,\dots,s$$

2.3.2 인공신경망 알고리즘

인공신경망 알고리즘은 최근 단기 전력수요예측 관련 논문 중 가장 많이 그 사례를 찾아볼 수 있는 대표적인 알고리즘이다. 그




그림 6 (a) 뉴런의 구조 (b) 1-층 순방향 인공신경망
 Fig. 6 (a) Structure of artificial neuron (b) 1-layer feed-forward artificial neural network

림 6은 뉴런(neuron)의 모습을 보여주고 있는데, 각각의 뉴런은 연결된 다른 신경을 통해 정보를 입력($1, x_1, x_2, \dots, x_{24}$)으로 받고 그 입력에 가중치(w_1, w_2, \dots, w_{24})를 곱한값을 선형결합하여 활성화함수(activation function)의 인수(argument)로 사용한다. 활성화함수의 출력이 결국 뉴런의 출력이 되며 여러개의 뉴런이 연결되어 입력데이터를 공유하는 형태로 이루어져 있고 이를 MLP(Multi-Layer Perceptron) 형태라고 한다. 그리고 입력과 출력 뉴런사이를 연결하는 층은 은닉층(hidden layer)라고 한다.

본 논문에서는 가장 간편적으로 사용하는 MLP형태의 인공신경망을 채택하였으며 입력은 24~72개의 수요데이터와 일간 최저, 최고 기온 데이터를 사용하여 최저의 예측오차를 나타내는 입력을 선택하였고, 출력은 24개로 하였다. 은닉층은 1개, 활성화함수는 hyperbolic tangent를 사용하였다[21].

3. 사례 연구

본 논문에서 제안한 전력수요예측모델의 정확도를 확인하기 위해서 기온 민감도가 높은 하계기간에 해당하는 2012년 6월 3일~2012년 9월 7일의 우리 나라 전체 전력수요데이터와 기상청에서 제공하는 기온, 상대습도 데이터를 이용하여 평일 전력수요예측을 실시하였다. 그 중 6월6일, 8월15일의 특수일과 7월30일~8월15일은 특수경부하기간으로 간주하여 제외하였다. CDH의 기준기온은 다양한 요인에 따라 $18^{\circ}\text{C} \sim 24^{\circ}\text{C}$ 가 사용되고 있으나 우리나라의 기온자료와 비교해 보면 18°C 가 24°C 보다 더 뚜렷한 증가추세를 확인 할 수 있기 때문에 CDH의 기준기온을 18°C 로 설정하였다[22]. 예측모델은 각 시간별로 구성하며 전일까지의 전력수요데이터와 PSO를 사용하여 식(6)의 계수를 추정한다. 이때 사용하는 과거 데이터는 예측일 기준 최근 7일~28일 이전까지의 데이터를 사용하고 시간에 따라 가장 낮은 MAPE를 가지는 데이터 개수를 적용하였다. 그리고 예측하고자 하는 날과 시간에 따라 다른 모델을 구성하는 dynamic 형태로 구성하였다. 즉, 예측일이 바뀌게 되면 그에 따라 예측모델을 구성하는데 사용하는 데이터의 범위가 변하게 되어 모델이 예측일에 따라 바뀌게 된다.

예측결과를 평가하기 위해서 실제 전력수요와 예측 전력수요의 오차는 아래 식(12)을 이용하여 n개의 예측결과와 관측치의 차의 평균인 Mean Absolute Percentage Error이며 아래와 같이 나타낸다.

$$MAPE(\%) = \frac{1}{n} \sum_{t=1}^n \left[\frac{|\hat{L}(t) - L_R(t)|}{L_R(t)} \right] \times 100 \tag{12}$$

여기서, $\hat{L}(t)$ 와 $L_R(t)$ 는 각각 t시간의 예측치와 관측치이다.

제안한 논문의 모델(case4)을 검증하기 위해서 Holt-Winters multiplicative(case1)의 평활상수 α, β, γ 는 각각 0.1~1.0까지 0.1씩 증가시켜 MAPE기준 가장 낮은 예측오차를 선택하여 비교하였다. 또한, 인공신경망은 역전파 알고리즘으로 훈련(training)하였고 오차가 0.005이하인 경우 종료하는 조건으로 시뮬레이션하였고 그 결과를 표 4에 나타내었다. Holt-winters의 경우 입력데이터로 과거 전력수요데이터만 이용하였고, 인공신경망(case2)은

과거 전력수요데이터와 기온데이터를 모두 고려하였으나 CDH 데이터는 사용하지 않았다. 두 모델 다 예측일 기준 과거 1년데이터(특수일제외)를 사용하여 모델링하였다. 마지막으로 CDH의 효과를 입증하기 위해서 식(3)에서 CDH항을 제외한 형태로 2개의 파라미터를 PSO로 추정한 모델(case3)의 결과를 비교하였다.

표 4 각 시뮬레이션 사례별 예측알고리즘과 입력데이터

Table 4 Forecasting methods and inputs data of cases

	예측알고리즘	입력데이터
Case 1	Holt-Winters multiplicative	수요데이터
Case 2	인공신경망	수요데이터, 기온데이터
Case 3	제한한 모델(CDH항 제외)	수요데이터, 기온데이터
Case 4	제한한 모델	수요데이터, 기온데이터, CDH




그림 7 2012년 하계기간 전력수요예측 결과의 시간별 MAPE

Fig. 7 Load forecasting result in MAPE by 1hour for 2012's summer season

표 5 2012년 하계기간(6월~9월) 전력수요예측 결과(%)

Table 5 Result of electric load forecasting for 2012's summer season in MAPE

	case1	case2	case3	case4
평균	2.016	1.267	1.130	0.998
표준편차	1.326	0.258	0.271	0.204

예측 결과 과거 데이터의 전체적인 트렌드 관련 파라미터를 계산하여 예측을 거듭하는 case1은 전체적으로 예측값이 크게 나타났고, 상대적으로 전력수요의 변동이 적은 이른 아침이나 심야 시간대가 11시~18시까지의 활동시간대보다 높은 예측오차를 보였다. case2, case3와 제한한 모델인 case4의 경우 오후 피크시간 부근의 예측오차가 높은 형태로 전력수요의 변동패턴과 유사하게 나타났다. 시간별 평균 예측오차의 표준편차는 case1의 경우 1.326%으로 case2와 case3, case4의 0.258%, 0.271%, 0.204%에 비해 상대적으로 높게 나타났다. case4의 경우 예측기간동안의 평균 예측오차율에서 각각 2.016%, 1.267%, 1.130%로 나타난 case1, case2, case3에 비해서 각각 1.018%, 0.269%, 0.132% 개

선된 예측결과를 나타내는 것을 볼 수 있었다. 따라서 하계기간의 단기전력수요예측에서 HI와 CDH를 포함하여 예측모델을 구성할 경우 예측오차가 개선됨을 알 수 있다.

4. 결 론

전력수요의 과거데이터와, 기온데이터, 기온데이터를 기반으로 한 CDH 데이터를 입력으로 하고 PSO로 파라미터를 추정하는 전력수요예측모델을 제안하였다. 제안한 모델은 기온의 변화에 따른 전력수요의 변화를 기존의 방식보다 전력수요자의 실제 사용 패턴을 더 반영할 수 있도록 HI와 CDH 데이터를 이용한 것으로 PSO를 이용한 파라미터 최적화 과정을 거쳐 하계기간의 단기 전력수요의 예측오차를 줄이기 위해 제안되었으며 Holt-Winters 방법과 인공신경망, 제한한 형태에서 CDH데이터를 제외한 모델의 결과를 제안한 논문의 결과와 비교 하였다. 그 결과 제안한 방법은 수요예측오차가 각각 1.018%, 0.269%, 0.132% 개선된 결과를 볼 수 있었다. 향후 다른 예측모델의 입력데이터의 변화나 파라미터 최적화에 적용하여 예측모델의 최적화 및 예측 정확도의 향상에 적용이 가능하고 Heating Degree Hour를 적용한 동계난방부하예측도 가능할 것으로 기대된다.

References

- [1] Feng Liu, Zhifang Wang, "Electric Load Forecasting Using Parallel RBF Neural Network", Global Conference on Signal and Information Processing (GlobalSIP), 2013 IEEE, pp.531-534
- [2] Shu Fan, Luonan Chen, Wei-Jen Lee, "Short-Term Load Forecasting Using Comprehensive Combination Based on Multimeteorological Information", vol.45, no.4, pp.1525-1528, July/Aug. 2009
- [3] J.H.Park, Y.M.Park, K.Y.Lee, "Composite Modeling for Adaptive Short-term Load Forecasting", IEEE Transactions on Power Systems, vol.6, no.2, May 1991
- [4] El Desouky, A.A. Elkateb, M.M., "Hybrid adaptive techniques for electric-load forecast using ANN and ARIMA", IEE Proceedings Generation, Transmission and Distribution, vol.147, no.4, pp.213~217, July 2000
- [5] Senjyu, T. Mandal, P. Uezato, K. Funabashi, T., "Next day load curve forecasting using hybrid correction method", IEEE Transactions on Power Systems, vol.20, no.1, pp.102 ~ 109, 2005
- [6] Bon-Hui Ku, Kyoung-Ha Yoon, Jun-Min Cha, Kyung-Bin Song,, Ung-Ki Baek, "A Study on the Summer Load Forecasting by using the Characteristics of Temperature Change", Kiee Conference, 2010.11, pp.153-155,
- [7] Jong-In Park, Kwang-In Kim, "A Study on the Temperature Adjusting Method of Maximum Demand of Electricity", Kiee Summer Conference, 2011.7, pp.616-617

[8] Wen-Chen Chu, Yi-Ping Chen, Zheng-Wei Xu, Wei-Jen Lee, "Multiregion Short-Term Load Forecasting in Consideration of HI and Load/Weather Diversity", IEEE TRANSACTIONS ON INDUSTRY APPLICATIONS, vol.47, no.1, Jan./Feb. 2011

[9] PJM, "PJM Manual 19 : Load Forecasting and Analysis", June 2014

[10] M.Christenson, H.Manz, D.Gyalistras, "Climate warming impact on degree-days and building energy demand in Switzerland", vol.47, pp.671~686, 2006

[11] E. González-Romera, M. A. Jaramillo-Mora'n, D. Carmona-Fernández, "Forecasting of the electricity energy demand trend and monthly fluctuation with neural networks," Computers & Industrial Engineering, vol. 52, pp336~343, 2007

[12] Sanglim Lee, "The estimation of weather risk in electric market", Korea Energy Economic Institute, 2013

[13] Jong-Hun Lim-Si-Yeon Kim-Jeong-Do Park-Kyung-Bin Song "Representative Temperature Assessment for Improvement of Short-Term Load Forecasting Accuracy", Journal of the Korean Institute of Illuminating and Electrical Installation Engineers, 2013, vol.27, no.6 pp.39~43, 2013

[14] J. V. Beck and K. J. Arnold, Parameter Estimation in Engineering and Science. New York: Wiley, 1977

[15] B. Ye, N. N. Yan, C. X. Guo, and Y. J. Cao, "Identification of fuzzy model for short-term load forecasting using evolutionary programming and orthogonal least squares", Power Engineering Society General Meeting, 2006. IEEE

[16] Ahmed N. Abd-Alla, S. J. Cheng, J. Y. Wen, Jing Zhang, "Model Parameter Identification of Excitation System based on a Genetic Algorithm Techniques", 2006 International Conference on Power System Technology pp.1~5

[17] J. Kennedy and R. C. Eberhart, "Particle Swarm Optimization", Proceedings of IEEE international Conference on Neural Networks, vol. 4, pp.1942~1948, 1995

[18] Schwwab, M., Biscaia, E. C., Monteiro, J.L. and Pinto, J.C., "Nonlinear Parameter Estimation through Particle Swarm Optimization", Chem. Eng. Sci., vol.63, no.6, pp.1542~1552, 2008

[19] Se-Hwan, Jun-Ho, Jong-Bae Park, Juneho Park, The Security Constrained Economic Dispatch with Line Flow Constraints using Hybrid PSO Algorithm", The Transactions of the Korean Institute of Electrical Engineering, vol.57, no.8, pp.1334~1341, Aug 2008

[20] Granger, C.W.J., P.Newbold, "Forecasting Economic Time Series", New York, Academic press.

[21] Henrique Steinherz Hippert, Carlos Eduardo Pedreira,

and Reinaldo Castro Souza, Neural Networks for Short-Term Load Forecasting: A Review and Evaluation, IEEE Transactions on Power Systems, vol.16, No.1, pp.44~55, Feb 2001

[22] Hyunjin Lim, SooKwan Jung, Doohwan Won "An Analysis of the Impact of Global Warming on Residential Energy Consumption: Focused on the Case of Electricity Consumption", Korea Energy Economic Institute, 2013, vol.12, no.2, pp.33~58, September 2013

저 자 소 개



구본길 (Bon-gil Koo)

1984년 07월 19일생 2008년 부산대학교 전기공학과 졸업 2010년 동대학원 전기공학과 졸업 공학석사, 2010~현재 동대학원 박사수로 현재 한전 전력연구원 재직
E-mail : koobg@kepco.co.kr



김형수 (Hyoung-su Kim)

1972년 1월 26일생 2002년 부산대학교 전기공학과 졸업 공학박사. 2006년 한국지역난방공사근무 현재 경남 남해도립대학전기과 조교수
E-mail : kimhsu@namhae.ac.kr



이흥석 (Heung-seok Lee)

1989년 08월 23일생 2012년 울산대학교 전자전기컴퓨터 공학과 졸업 2014년 부산대학교 전기공학과 대학원 졸업 공학석사, 2014년~현재 동대학원 박사과정
E-mail : zznada@naver.com



박준호 (Juneho Park)

1955년 9월 17일생 1978년 서울대 전기공학과 졸업 1980년 동대학원 전기공학과 졸업 1987년 동대학원 전기공학과 졸업 박사. 1984년~현재 부산대학교 전기 컴퓨터 공학과 교수
E-mail : parkjh@pusan.ac.kr