

다변수 시계열 분석에 의한 단기부하예측

이경훈* · 이윤호* · 김진오* · 이효상**
 *한양대학교 전기공학과 · **한국전력거래소

Short-Term Load Forecasting using Multiple Time-Series Model

Kyung-Hun Lee* · Yunho Lee* · Jin-O Kim* · Hyo-Sang Lee**
 *Dept. of EE, Hanyang University · **Korea Power Exchange(KPX)

Abstract - This paper presents a model for short-term load forecasting using multiple time-series. We made one-hour ahead load forecasting without classifying load data according to daily load patterns(e.g. weekday, weekend and holiday). To verify its effectiveness, the results are compared with those of neuro-fuzzy forecasting model(5). The results show that the proposed model has more accurate estimate in forecasting.

1. 서 론

전력 부하의 예측의 정확도 향상은 발전 비용의 감소와 전력 공급의 신뢰도 향상의 결과로 나타나기 때문에 장기 및 단기간의 전력 부하의 예측은 전력 계통의 경제적인 운용의 측면에서 매우 중요하다. 특히 그 결과는 전력 계통의 제어 및 전력조류계산의 입력 자료로 사용되기 때문에 지금까지 다양한 방식에 의한 예측 기법이 제안되었다. 이러한 종래의 방법으로는 크게 시계열 방법 [1]과 인공지능 기법의 신경회로망[3,4] 등이 있다. 시계열 방법, 특히 자기회귀(AR : autoregression)[2], 통합혼합모형(ARIMA : autoregressive integrated moving average) 등은 예측 모형을 설정하는데 있어서 자기 변수만을 고려하므로 예측 모형으로서 단순하다. 또한, 부하 예측 문제에 내재하는 비선형성, 유연한 입력 선택, 모델링의 복잡성 등과 같은 문제를 적절히 해결할 수 있는 방법으로 신경회로망이 알려져 있으나 기본적으로 몇 가지 단점이 있다. 즉, 학습을 통해 유추된 예측 모델의 규칙을 표현할 수 없고, 최적의 성능을 얻기 위한 다층 퍼셉트론(MLP : multilayer perceptron)의 은닉층의 수와 각 은닉층의 노드 수를 결정하는 효과적이며 체계적인 방법이 존재하지 않는다(5).

따라서 본 논문에서는 기존의 전력 부하 예측 방식처럼 부하를 유형별(평일, 월요일, 토요일, 일요일, 특수일)로 분류하는 대신 시간에 대해 연속성을 갖는 부하 특성과 주기성을 고려하여 시전 예측(one-hour ahead forecasting) 방법을 통한 다변수 시계열 분석 모델을 설정하고 단기 부하를 예측하였다. 또한 사례 연구를 통해 실제 부하 데이터를 입력으로 하여 각 시간에 대한 예측 모형을 수립한 후, 이 모형에 의해 부하를 예측하였으며 그 결과를 뉴로-퍼지 모델의 결과와 비교하여 그 우수성을 입증하였다.

2. 본 론

2.1 부하의 특성

기상이나 특수일과 같은 부하의 변동 요인이 없다면 하루의 부하 곡선은 보통 화요일부터 금요일까지 그대로 유지된다. 그림 1은 2000년 12월 4일 월요일부터 12

월 10일 일요일까지 한 주간의 부하 특성 곡선을 나타내는데 토요일, 일요일, 월요일은 평일에 비해 전 시간대에 걸쳐 혹은 시간대별로 낮은 수요치를 보이지만 전주의 동일 요일의 부하 곡선과는 유사한 경향을 보인다. 따라서 부하 예측에 있어서 한 주간의 요일을 보통 화요일부터 금요일까지의 평일, 토요일, 일요일, 월요일, 그리고 특수일로 나누는 것이 일반적이었다.




그림 1. 일반적인 한 주간의 부하특성곡선

그러나 전력 부하를 시간에 대해 연속성을 갖는 시계열 자료로 간주하여 시전 예측 모델을 설정한다면, 부하 데이터를 유형별로 분류하여 예측하는 것보다 더 좋은 결과를 기대할 수 있다. 따라서 본 논문에서는 요일을 유형별로 분류하는 대신 부하 데이터를 예측하고자 하는 시간을 기준으로 36시간 전까지 각 시간의 부하 데이터와 과거 일주일 동안 같은 시간대의 부하 데이터를 예측 모델의 입력으로 하여 시계열 분석을 행하였다.

2.2 다변수 시계열 분석에 의한 예측 모형 및 부하 예측 절차

시계열 분석의 주요 목적은 시간이 흐름에 따라 변하는 현상을 관찰함으로써 얻어지는 일련의 자료들의 모형을 수립하고 예측하는 것이다. 각 시간별 부하 예측을 위한 모형 수립에 있어서 본 논문에서는 예측 모델의 모형을 결정하는 각 변수의 계수들의 값을 데이터의 예측치와 실제치의 오차가 가장 작도록 하는 합수를 구하는 기법인 최소자승법(OLS : ordinary least squares) 방식을 도입하여 구하였다. 부하 데이터를 요일별로 분류하지 않고 부하의 연속성과 주기성을 고려하여 예측 모델의 모형을 다음 식 (1)과 같이 정의하였다.

$$\widehat{L}_t^d = a_0 + \sum_{i=1}^7 b_i L_t^{d-i} + \sum_{j=1}^{36} c_j L_{t-j} \quad (1)$$

여기서, \widehat{L}_t^d : d일 t시각의 예측 부하(MW)
 L_t^{d-i} : (d-i)일 t시각의 실제 부하(MW)
 L_{t-j} : (t-j)시각의 실제 부하(MW)
 a_0, b_i, c_j : 각 변수에 대한 회귀계수

첫 번째 항은 상수항이고 두 번째 항은 예측하고자 하는 d 일 t 시각을 기준으로 과거 일주일 동안의 같은 시각의 부하량이다. 이 항에서 i 가 2부터 시작하는 이유는 전 날 같은 시각의 부하량은 세 번째 항에 포함되기 때문이다. 그리고 세 번째 항은 t 시각 바로 직전인 ($t-1$)시각부터 ($t-36$)시각까지의 부하량을 뜻한다. 이러한 42개의 입력 변수에 대한 각각의 계수들과 상수항 a_0 의 값을 추정하여 예측 모델의 모형을 설정한 후, 수립된 모형으로 단기 부하를 예측하였다.

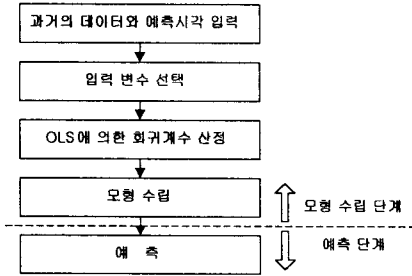


그림 2. 부하예측 순서도

예측하고자 하는 d 일 t 시각에 대한 단기 부하 예측의 순서도를 그림 2에 나타내었다. 첫 번째 단계에서는 과거의 1년치 시간별 부하데이터와 예측할 t 시각을 입력한다. 입력 변수 선택 단계에서는 t 시각을 기준으로 과거 일주일 동안의 같은 시각의 부하량과 t 시각 직전 36개의 부하량을 입력 변수로 선택한다. 계수 산정 단계에서는 최소자승법을 이용하여 42개의 입력 변수에 대한 각각의 회귀계수들(b_i, c_j)과 상수항(a_0)의 값을 추정한다. 그리고 모형 수립의 단계에서는 이러한 계수들의 값을 토대로 예측 모델의 모형을 설정하며 마지막으로 d 일 t 시각에 대한 단기 부하를 예측한다.

2.3 예측 성능 평가

제한한 다변수 시계열 분석의 효용성을 검증하기 위하여 예측 부하의 실제 부하에 대한 평균 오차는 식 (2)와 같이 시간별 및 요일별 평균 오차 절대값의 합을 평균하여 구한 절대 평균 백분율 오차(MAPE : mean absolute percentage error, [%])로 정의하였다(4).

$$MAPE[\%] = \frac{1}{N} \sum_{i=1}^N \frac{|Actual(i) - Forecast(i)|}{Actual(i)} \times 100 \quad (2)$$

여기서, N : 예측 날짜의 개수

3. 사례 연구

3.1 1994년 예측

1993년 1월 1일부터 1994년 1월 17일까지 382개의 실제 우리 나라의 부하 데이터를 초기 입력으로 하여 시전 예측 방법을 통해 각 시간에 대한 예측 모델의 모형을 수립한 후, 뉴로-퍼지 모델과의 비교를 위해 참고 문헌 [5]에서 제시한 모델의 테스트 범위와 동일한 1994년 1월 18일부터 4월 30일까지 단기 부하를 예측하였다.

표 1은 각 시간별 예측 결과를 정리한 것으로 모든 시간의 예측 결과가 뉴로-퍼지 모델의 결과와 비교하여 0.03~1.49[%] 정도의 우수한 예측 결과의 차이를 보였으며 시간에 대한 총평균오차는 약 0.36[%] 정도 낮은 0.64[%]를 얻었다.

표 1. 시간별 예측 결과 비교[%](1994.1.18~4.30)

시간	제안된 방법			뉴로-퍼지 모델[5]		
	평균오차	표준편차	최대오차	평균오차	표준편차	최대오차
1	0.57	0.47	3.00	1.14	1.02	5.21
2	0.43	0.30	1.51	0.76	0.59	3.08
3	0.42	0.32	1.80	0.64	0.58	3.20
4	0.38	0.29	1.50	0.60	0.61	3.52
5	0.42	0.35	1.84	0.66	0.63	3.30
6	0.72	0.56	2.44	0.75	0.71	4.69
7	0.82	0.69	3.86	1.12	0.92	5.83
8	0.85	0.69	4.02	1.39	1.19	7.05
9	1.46	1.23	9.45	1.87	1.39	8.84
10	0.71	0.68	3.88	0.98	1.37	11.87
11	0.58	0.62	4.38	0.84	1.31	11.28
12	0.49	0.35	1.86	0.73	1.03	9.33
13	0.55	0.66	4.11	0.88	0.81	6.61
14	0.62	0.54	2.23	0.80	0.89	7.61
15	0.54	0.47	2.58	0.64	0.93	8.58
16	0.44	0.41	2.33	0.75	0.93	8.04
17	0.50	0.36	2.41	0.76	0.96	8.58
18	1.02	0.87	6.07	1.58	1.25	5.79
19	0.76	0.66	4.45	1.07	0.88	4.83
20	0.76	0.62	3.06	2.25	1.34	7.67
21	0.66	0.52	2.42	0.71	0.72	4.43
22	0.44	0.35	1.88	0.92	0.92	5.35
23	0.59	0.38	1.91	0.92	0.98	5.93
24	0.54	0.41	1.88	1.11	1.00	4.94
평균	0.64	0.53	3.12	1.00	0.96	6.49





그림 3. 시간별 예측 결과

표 2. 요일별 예측 결과 비교[%](1994.1.18~4.30)

제안된 방법	(날수)	월 화 수 목 금 토 일 특수일							
		(14)	(13)	(15)	(14)	(15)	(15)	(14)	(3)
제안된 방법	평균오차	0.60	0.62	0.63	0.51	0.59	0.66	0.67	1.45
	표준편차	0.51	0.55	0.54	0.45	0.51	0.62	0.64	1.59
	최대오차	1.58	1.39	1.46	1.25	1.29	1.48	1.12	4.63
뉴로-퍼지 모델[5]	평균오차	1.19	0.83	0.81	0.86	0.83	0.92	1.55	-
	표준편차	1.12	0.75	0.74	0.75	0.75	0.78	1.86	-
	최대오차	5.83	3.60	3.64	4.24	5.21	4.99	11.87	-

실제 부하에 대해 분석한 결과 04시에 오차가 가장 작고, 09시에 가장 크게 나타났다. 이 결과를 그림 3에 나타내었다.

표 2는 예측 결과를 요일별로 분석한 것으로 뉴로-퍼

지 모델과 비교하여 전 요일에 걸쳐 매우 우수한 결과를 얻었다. 특히 참고문헌 [5]의 뉴로-퍼지 모델로는 예측하지 못한 설날, 삼일절, 식목일 등 특수일의 경우 특별한 추가적인 방법을 사용하지 않고 단순히 본 논문에서 제시한 모델만으로도 1.45(%)의 우수한 예측 결과를 얻을 수 있었다.




그림 4. 요일별 최대/최소 평균오차 비교

그림 4는 실제 부하에 대해 요일별 최대오차 및 최소 오차를 보인 특수일과 목요일을 비교하여 각 시간에 대한 총평균오차와 함께 나타낸 것이다. 이 그림에서 저녁 시간대인 18시~19시와 아침 출근 시간대인 07~10시의 예측 오차가 다른 시간대에 비해 높게 나타났는데 이는 이 시간대가 부하 데이터의 유동성이 커서 데이터의 불규칙성이 심하기 때문이다.

3.2 2000년 예측

사례 연구 3.1과 같이 1999년 데이터를 이용하여 예측 모델의 모형을 수립한 후, 2000년 1월 1일부터 4월 30일까지의 부하를 예측하였다.

그 결과를 시간과 요일별로 정리하여 표 3과 표 4에 나타내었다. 표 3에서 각 시간에 대해 1994년과 비슷한 결과를 얻을 수 있었고, 이는 예측 모델의 안정성을 입증한다고 사료된다. 총평균오차는 0.68(%)를 얻었고, 12시에 최소오차 0.40(%)를 23시에 최대오차 1.78(%)를 얻을 수 있었다. 표 4에서 특수일의 경우 1994년의 사례연구(1.45(%) 보다 더 좋은 1.31(%)의 예측 결과를 얻었다.

표 3. 시간별 예측 결과[%](2000.1.1~4.30)

시간	평균오차	표준편차	최대오차	시간	평균오차	표준편차	최대오차
1	0.87	0.55	2.66	13	0.60	0.47	2.31
2	0.69	0.47	2.04	14	0.72	0.78	6.11
3	0.48	0.38	2.02	15	0.47	0.37	1.76
4	0.48	0.39	2.07	16	0.42	0.39	2.43
5	0.41	0.32	1.43	17	0.51	0.53	3.38
6	0.43	0.33	1.72	18	1.51	0.74	3.38
7	0.77	0.61	3.15	19	0.74	0.60	3.69
8	0.86	0.71	5.85	20	0.73	0.58	3.39
9	0.89	0.94	6.79	21	0.44	0.32	1.41
10	0.64	0.64	4.69	22	0.53	0.36	1.49
11	0.47	0.36	2.00	23	1.78	0.83	4.08
12	0.40	0.30	1.44	24	0.55	0.45	2.40
	평균	0.68	0.52	2.99			

표 4. 요일별 예측 결과[%](2000.1.1~4.30)

(날수)	월 (17)	화 (17)	수 (15)	목 (17)	금 (17)	토 (16)	일 (18)	특수일 (4)
평균오차	0.70	0.61	0.62	0.66	0.63	0.64	0.76	1.31
표준편차	0.63	0.54	0.54	0.59	0.57	0.56	0.68	1.43
최대오차	1.72	1.70	1.56	1.69	1.49	2.03	2.51	3.04




그림 5. 예측 결과 비교(1994년, 2000년)

그림 5는 1994년과 2000년의 예측 결과를 시간별로 비교한 것이다. 2000년 23시의 오차가 1994년의 사례연구(0.59(%)보다 크게 나타난 것은 1999년에 비해 2000년도의 경우 심야전력 수요창출이나 그 밖의 전력 사용 패턴의 변화에 기인한다고 사료된다. 따라서 23시를 비롯한 예측 오차가 큰 시간대는 보정과 같은 다른 방법으로 예측 모델을 수립함으로써 오차를 줄일 수 있을 것으로 사료된다.

4. 결 론

본 논문에서는 부하 데이터를 유형별로 분류하지 않고 요일 및 특수일에 관계없이 모든 날에 대해 1시간 앞의 시간별 전력 부하를 예측하였다. 부하 데이터의 주기의 규칙성과 연속성을 이용하여 입력 변수를 정의하였으며, 다변수 시계열 분석에 의해 최적의 예측 모델을 설정하여 단기 부하를 예측하였다. 그 결과 기존의 뉴로-퍼지 모델과 비교하여 모든 시간에 대해 훨씬 더 우수한 결과를 얻을 수 있었으며, 특히 뉴로-퍼지 모델에서는 예측하지 않은 특수일의 경우 추가된 모델의 변화 없이 본 논문에서 제시한 모델만으로도 우수한 예측 결과를 얻을 수 있었다.

향후 각 시간별로 부하 데이터의 보정이나 혹은 입력 변수의 가감과 같은 별도의 방법을 예측 모델에 적용하여 예측 모형을 수립한다면 더 좋은 예측 결과를 얻을 수 있을 것으로 사료된다.

(참 고 문 헌)

- [1] M. T. Hagan and S. M. Behr, "The Time Series Approach to Short-Term Load Forecasting", IEEE Trans. on Power Systems, Vol.2, No.3, pp.785~791, 1987
- [2] A. D. Papalexopoulos and T. C. Hesterberg, "A Regression-Based Approach to Short-Term System Load Forecasting", IEEE Trans. on Power Systems, Vol.5, No.4, pp.1535~1547, 1990
- [3] C. N. Lu and H. T. Wu "Neural Network Based Short Term Load Forecasting", IEEE Trans. on Power Systems, Vol.8, No.1, pp.336~342, 1993
- [4] M. Daneshdoost, M. Lotfalian and G. Bumroonggit, "Neural Network with Fuzzy Set-Based Classification for Short-Term Load Forecasting", IEEE Trans. on Power Systems, Vol.13, No.4, pp.1386~1391, 1998
- [5] 박영진, 심현정, 왕보현, "뉴로-퍼지 모델을 이용한 단기 전력 수요 예측시스템", 전기학회 논문지, 49권 3호, pp.107~117, 2000