

실시간 단기 부하예측을 위한 동적모형¹

박문희 · 조형기* · 정근모 · 최기련

아주대학교 에너지학과, *아주대학교 교통공학과

Dynamic model for on-line short-term load forecasting

Moon Hee Park, Hyung Ki Cho*, Kun Mo Chung and Ki Ryun Choi

Department of Energy, Graduate School, Ajou University

*Department of Transportation Engineering, Graduate School, Ajou University

요 약

본 연구에서는 단기 전력수요예측에 있어서 필요한 데이터의 수와 계산시간을 경감하면서 보다 정확성을 기할수 있는 알고리즘의 개발을 위하여 이에 적합한 칼만필터링 알고리즘을 고찰하였다. 또한 칼만필터 알고리즘을 토대로 필터의 모형화를 통하여 단기 전력수요를 예측할 수 있는 실시간 동적예측모형을 구축하고 그 적용 가능성을 시험하였다.

Abstract—This paper reviews some of the existing studies on one-to-twenty four hour load forecasting algorithms, and presents dynamic model based on the Kalman filter algorithm which is recommended as an algorithm which might yield improved accuracies as well as have lower computation time and on-line data processing requirements. The absolute error and corresponding standard deviation of the forecast in our test on actual utility load data are shown to be 1.023% and 236.485 MW, respectively. This compares with an average absolute error of 1.432% for forecasts with a currently used forecasting technique applied to the same data.

1. 서 론

전력수요예측은 고품질의 전력을 소비자에게 안정적이면서도 경제적으로 공급하기 위한 전력회사의 계통운영 및 전원개발계획에 있어서 중요한 역할을 한다.

전력수요예측은 예측기간에 따라 1) 장기전원개발계획, 송배전설비계획 및 발전기보수계획 등을 위한 중장기 전력수요예측과 2) 발전기 기동정지, 주간발전계획, 일일발전계획, 경제급전 등의 계통운용을 위한 단기 부하예측으로 구분되어 진다. 이러한 전력 수요예측에 있어서 그 방법론, 정확성 및 계산 소요시간과 같은 사항은 부하예측 함수에 따라 좌우된다고 할 수 있다. 특히, 부하관리 프로그램의 유용성이 높아지고, 이들이 계통 부하에 민감하게 작용함에 따라 단기 부하예측은 더욱 높은 정확성과 신속성을 요구하며 이러한 요구는 전력

회사에 있어서 중요한 과제라 할 수 있다. 따라서 과거 부하예측을 위한 방법론은 예측의 정확성, 유효성 및 신속한 계산능력을 지닌 알고리즘의 개발에 중점을 두어 연구가 수행되어 왔다. 현재까지 수행되어온 단기 예측 기법을 구분하여 보면, 부하에 영향을 주는 날씨변수들이나 그 외의 설명변수(explanatory variables)들의 선형 결합을 통하여 부하를 예측하는 다중선형회귀(multiple linear regression)기법, 부하를 확률변수(random variable)를 입력으로 하는 선형필터(linear filter)의 출력으로 보고 선형필터의 모형화를 통하여 부하를 예측하는 추계적 시계열(stochastic time series) 접근방법, 부하에 영향을 주는 변수들의 관계식과 기타의 모든 정보를 지식화(knowledge-based)시켜 추론기관을 통하여 부하를 예측하는 전문가 시스템(expert system), 마지막으로 최근 활발히 연구되고 있는 신경망(neural network) 이론을 이용한 부하예측기법 등으로 분류하여 볼 수 있다. 그러나 위에서 언급한 많은 예측기법들 중에서 현재까

¹이 논문은 1995년도 아주대학교 특별연구지원비에 의하여 연구되었음.

지도 활발히 연구가 수행되고 있고 전력회사에서 가장 많이 적용되고 있는 예측기법은 추계적 시계열 접근방법이라 할 수 있다. 이 접근방법은 선형필터의 모형화 방법에 따라 MA(moving average)모형, AR(auto-regressive)모형, ARMA(auto-regressive moving-average)모형, 그리고 ARIMA(auto-regressive integrated moving average) 등으로 분류가 된다. 과거 위의 기법을 이용한 몇편의 논문들은 부하를 예측하기 위하여 설명변수들(explanatory variables)과 시간별 부하자료들간의 상호 연관관계를 세우는데 있어서 통계적기법들을 이용하였고, 실적부하와 설명변수들의 자료를 모형화하여 주는 Box and Jenkins모형이 가장 활발히 논의되어 왔다. 이때 통계적기법들은 모형의 모수(parameter)들을 추정하는데 사용하였다. 따라서 실제로 전력회사에서 가장 널리 적용하고 있는 부하예측모형은 ARMA, ARIMA 모형을 토대로 하고 있다. 예를 들어 Keyhani와 Miri는 실시간으로 날씨변수와 부하와의 상호 연관관계를 모형화하여 부하예측을 위한 수리적알고리즘을 제시하고, 해당지역의 부하와 기온간에 관계식을 모형화하여 예측한 결과 시간별 예측치에 대한 오차(RMS)를 일침두부하를 기준으로 2.0-4.4%였다고 보고하였다¹⁾. Vemuri, et al.은 기존의 Box and Jenkins보다 단순화되고 효과적인 결과를 제시해줄 수 있는 ARMA 모형을 제시하였다²⁾. 그들은 일부하를 예측하면서 예측오차인 RMS의 범위가 3.66%-5.28%이며 이때 일부하가 189-349 MW였다고 한다. Abu-Hussien, et al.은 시간별부하와 날씨변수를 토대로한 적응모형(adaptive model)을 제시하였다³⁾. 그들은 제시한 알고리즘을 보다 정확하게 검증하기 위하여 날씨변수와 밀접한 연관이 있는 각 모선(bus)에 대한 시간별 부하를 이용하였다. 이때 표준편차 1.4%를 갖는 시간별 평균부하에 대한 최대오차가 4%라고 주장하였다. Irisarri, et al.은 예측모형의 모수들에 대한 불편추정치를 구하기 위하여 최소자승법을 이용한 실시간 알고리즘을 적용하였다⁴⁾. 이때 예측오차가 2.21-4.77%이라고 제시하였다.

위의 논문들에서 개발된 부하예측용 모형들은 수많은 복잡한 수학적 관계식들을 필요로 하며 계산시간도 방대함을 보여주고 있다. 또한 이들 모형들은 부하의 확률적 요소들을 모형화함에 있어서 항시 수리적 불안정성을 내포하고 있다. 이러한 불안정성으로 야기되는 오차(error)에 대해서는 이미 많은 논쟁의 대상이 되어 왔다.

본 논문의 연구목적은 필요한 데이터의 수와 계산시간을 경감하면서 보다 정확성을 기할 수 있는 알고리즘의 개발에 있다. 따라서 본 논문에서는 이에 적합한 칼만필터링 알고리즘을 고찰하고, 필터의 모형화를 통하여 단기 전력수요를 예측할 수 있는 실시간 동적예측모

형을 구축하고 그 적용 가능성을 시험하였다.

2. 칼만필터(Kalman Filter) 알고리즘

칼만필터(Kalman Filter) 알고리즘은 확률변수(random variable)를 시간영역을 기준으로 상태공간(state space)으로의 모형화를 통하여 추정하는 최적 재환필터링(optimal recursive filtering)방법이다⁵⁾.

칼만은 1960년 발표한 논문에서 시계열 그 자체를 실시간에서 파악된 신호 $X(t)$ 로 정의하고 이는 어떤 백색잡음(White Noise)에 의해 구동된 선형동적시스템(linear dynamic system)의 출력으로 하여 신호의 상관성(공분산함수 혹은, 스택트럼 밀도함수)은 동적구조에 유래하는 것으로 간주하고, 그 동적구조하에서 최적필터(optimal filter)를 구했다. 이와 같이 선형필터를 구성하는 칼만필터링은 선형시스템의 실현이론(system realization theory)으로서 정립되어 확률통계이론과는 무관하게 최종적으로 선형시스템이론의 틀 안에서 해석되어 졌다.

칼만필터링에의한 예측방법은 시변(time varied)에 따라 입력되는 관측치와 이전시간을 기준으로 예측된 예측치를 비교하여 오차(MSE)의 최소화조건을 만족하게끔 필터를 동적적응(dynamic adaptive)시키는 방법이다. 따라서 칼만필터 모형은 추계적(stochastic)모형으로서 조건부 추정오차를 최소화하는 동적예측모형이며, 모델링은 초기조건에 대한 정보, 시스템의 동적상태에 대한 모형화가 요구된다. 필터링은 신호의 초기추정치, 오차공분산(error covariance)과 새로운 측정치를 이용하여 이전 상태의 추정치를 새로운 추정치로 교체한다. 이러한 재환과정(recursive process)은 시스템이 관측 가능한 상태에서 초기추정치를 더 이상의 향상이 불가능한 정상상태(steady state)에 도달할 때까지 새로운 측정데이터를 이용하여 개선된다. 따라서 칼만필터링은 시스템의 현재 상태(state)에 관한 추정값들을 예측하거나 과거의 수치값들을 수정하는데 쓰이고 있다. 이와 관련한 과거의 발표된 몇편의 논문을 살펴보면, Harrison과 Stevens은 베이지안(Bayesian) 예측관점에서 칼만필터링을 유도하였으며⁶⁾, Morrison과 Pike는 시변모수(time varied parameter)를 갖는 단기에측모형에 칼만필터링을 적용하였다⁷⁾. Ledolter는 회귀모형과 ARIMA모형에서의 모수들을 추정하기 위하여 칼만필터링을 적용하였고⁸⁾, Salas와 Haville는 혼합모형을 위한 재환추정(recursive estimation) 방정식을 유도하기 위하여 칼만모형을 이용하였다⁹⁾. 한편 Duncan과 Horn은 백색잡음(White noise)이 정규분포(평균 0, 분산 σ^2)를 따르지 않을 경우에도 칼만 추정은 선형 최소제곱추정기(minimum mean square

linear estimator)가 된다고 증명하였다¹¹⁾. Sastri는 기존의 시계열 모형을 상태공간모형(state space model)으로 변환시켜 실시간 예측모형을 구축하였다¹²⁾.

칼만필터링의 응용분야를 살펴보면 적응제어를 갖는 자동제어계의 최적설계응용(자동제어 및 신호처리 등), 추적시스템(유도탄, 미사일, 레이더, 인공위성, 선박 등), 통계적공정관리, 통계적예측, 신경망이론에서의 학습기법, 기타 여러 분야에서 제어(control) 및 예측기법으로서 응용되고 있다.

3. 동적 예측모형 구축

칼만필터링(Kalman Filtering)기법을 이용한 동적 예측모형을 구축하기 위해서는 우선적으로 측정방정식(measurement equation)과 상태방정식(state equation)이 수립되어야 한다.

- 측정 방정식(measurement equation)

$$y(t) = C(t) \cdot X(t) + V(t) \quad (1)$$

- $y(t)$: t시점에서의 관측 부하
- $X(t)$: t시점에서의 예측 부하
- $C(t)$: t시점에서의 시간천이행렬(time transition matrix)
- $V(t)$: t시점에서의 관측 오차

- 상태 방정식(state equation)

$$X(t) = A(t) \cdot X(t-1) + W(t) \quad (2)$$

- $X(t)$: t시점에서 예측 부하
- $X(t-1)$: t-1 시점에서 예측 부하
- $A(t)$: t시점에서의 시간천이행렬(time transition matrix)
- $W(t)$: t시점에서의 시스템 오차

여기서 두개의 백색잡음(white noise) $W(t)$, $V(t)$ 에 대한 공분산행렬(covariance matrix)은 다음과 같이 주어진다.

$$E[V(t), V^T(i)] = \begin{cases} R(t), & i = t \\ 0, & i \neq t \end{cases} \quad (3)$$

$$E[W(t), W^T(i)] = \begin{cases} Q(t), & i = t \\ 0, & i \neq t \end{cases} \quad (4)$$

또한 상태잡음(state noise)와 관측잡음(measurement noise)는 상호 비상관(uncorrelated)이라 가정되며 다음과 같다.

$$E(W(t), V(t)^T) = 0 \quad \text{for all } t \text{ and } i \quad (5)$$




Fig. 1. Block diagram of Kalman filter.

칼만추정은 t시점에서 t-1시점에서의 정보를 토대로 추정되어지며 이를 사전추정치(priori estimate)라 하며 $X(t|(t-1))$ 로 표현된다. 실제부하(actual load)와 사전추정치와의 오차는 다음과 같다.

$$e(t|(t-1)) = X(t) - X(t|(t-1)) \quad (6)$$

여기서 오차벡터 $e(t|(t-1))$ 는 다음과 같이 표현되는 사전오차공분산행렬(priori error covariance)을 갖는다.

$$E[e(t|(t-1)), e(t|(t-1))^T] = P(t|(t-1)) \quad (7)$$

$$P(t|(t-1)) = A(t)P(t-1|(t-1))A^T(t) + Q(t-1) \quad (8)$$

만약 모형의 초기값 $X(0/0)$ 와 오차공분산 $P(0/0)$ 이 주어진다면 $\hat{y}(t|(t-1))$ 를 계산할 수 있다. 또한 $Q(t)$ 와 $R(t)$ 에 대한 사전정보가 없다면 다음의 식을 통하여 갱신(update) 할 수 있다.

$$\hat{Q}(t) = \frac{1}{t} \left[(t-1)\hat{Q}(t-1) + K(t)y(t)y^T(t)K^T(t) + P(t|t) - A(t)P(t-1|(t-1))A^T(t) \right] \quad (9)$$

$$\hat{R}(t) = \frac{1}{t} \left[(t-1)\hat{R}(t-1) + y(t)y^T(t) + C(t)P(t|(t-1))C^T \right] \quad (10)$$

최종적인 예측치인 사후추정치(posterior estimate)는 $X(t|t)$ 로 표현되며 사전추정치(priori estimate)와 관측잡음(measurement noise)의 선형결합으로 구해진다.

$$X(t|t) = X(t|(t-1)) + K(t) [y(t) - C(t)X(t|(t-1))] \quad (11)$$

이때 실제부하(actual load)와 사후추정치와의 오차는 다음과 같다.

$$e(t|t) = X(t) - X(t|t) \quad (12)$$

여기서 오차벡터 $e(t|t)$ 는 다음과 같이 표현되는 사후오차공분산행렬(posterior error covariance)을 갖는다.

$$E[e(t|t), e(t|t)^T] = P(t|t) \quad (13)$$




Fig. 2. Estimation procedure.

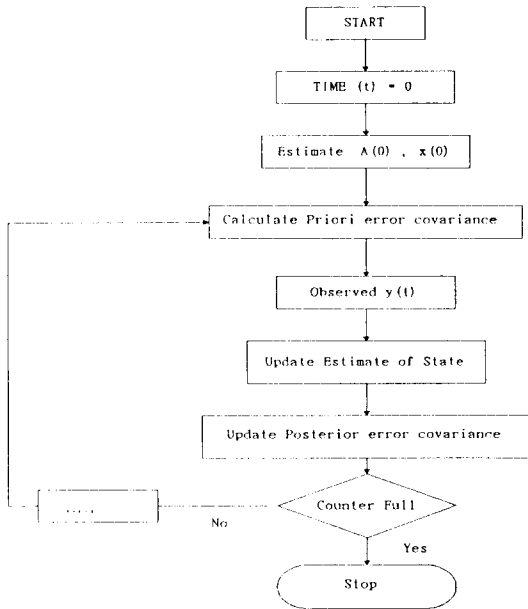


Fig. 3. Flow diagram of Dynamic model.

칼만 게인(Kalman gain) $K(t)$ 는 조건부 MSE(minimum mean squares error)를 최소화 하도록 동태적으로 적응하여 최적의 $X(t)$ 를 추정해 주는 조정자 역할을 하여 주며 그 산출식은 다음과 같다.

$$K(t) = P(t|(t-1))C(t)^T ((C(t)P(t|(t-1))C(t)^T + R(t))^{-1}) \quad (15)$$

칼만필터 추정절차는 Fig. 2와 같이 재환(recursive) 방법을 취하며, 이를 토대로 구축된 동적예측모형의 흐름도(flow diagram)는 Fig. 3과 같다.

4. 사례 연구

제한된 동적모형에 대한 사례연구는 1993년 9월 1일부터 11월 30일까지 한국전력공사의 부하자료를 이용하여 24시간 이전 즉 하루전 예측을 수행하였다. 모형에 사용된 부하자료는 정상성(stationality) 조건과 계산

Table 1. % Relative error and forecasting load for 1993.12.1 using the Dynamic model.

Time	Load	Forecasted Load	% Relative Error
1.00	15328.00	15431.56	0.68
2.00	14962.00	14831.92	0.87
3.00	14561.00	14542.26	0.13
4.00	14595.00	14487.39	0.74
5.00	14632.00	14545.70	0.59
6.00	15069.00	14953.31	0.77
7.00	16092.00	15817.67	1.70
8.00	17004.00	16884.02	0.71
9.00	18696.00	18494.54	1.08
10.00	20071.00	19936.77	0.67
11.00	20250.00	20151.16	0.49
12.00	20090.00	20135.14	0.22
13.00	18468.00	18571.86	0.56
14.00	19461.00	19394.86	0.34
15.00	19906.00	19787.75	0.59
16.00	19946.00	19776.59	0.85
17.00	20257.00	19958.67	1.47
18.00	21103.00	20683.28	1.99
19.00	20994.00	20977.66	0.08
20.00	20355.00	20196.09	0.78
21.00	19575.00	19468.31	0.55
22.00	18674.00	18691.06	0.09
23.00	18031.00	17987.50	0.24
24.00	17179.00	17080.80	0.57
Mean	18137.46	18032.74	0.70

의 효율성을 위하여 자연대수를 취하여 사용하였다. 모형의 모수 조정을 위하여 9월 1일의 24시간 부하자료가 이용되었으며, 본 논문에서 제한된 모형의 비교모형인 ARMA(autoregressive moving average) 모형의 모수(parameter)추정을 위하여 1990, 1991, 1992년 각년도의 9월에서 11월 사이의 부하자료가 이용되었다. 따라서 실제 예측기간은 9월 2일에서 12월 1일까지이다.

ARMA 모형은 SAS PC Version 6.03을 이용하여 예측을 수행하였으며, 이때 ARMA 모형의 차수는 모의(simulation)을 통하여 오차(MSE)를 최소화하는 수준에

서 정하였다.

본 논문에서 제안된 동적모형의 초기값은 $X(0|0)=\text{예측}$

시점 24시간 이전 부하의 평균값, $P(0|0)=\begin{bmatrix} 2 & 0 \\ 0 & 3 \end{bmatrix}$, $A=\begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix}$,

$R(0)=1$, $Q(0)=1$ 로 정하였다.

모형의 성능비교를 위한 기준 척도는 다음의 3가지 척도를 이용하여 비교평가 하였다.

- Percent relative error

$$E = \frac{1}{N} \sum_1^N \left| y(t) - \hat{y}(t) \right| \cdot 100 / y(t)$$

- Standard deviation

$$\sigma = \sqrt{\frac{1}{N} \sum_1^N (|y(t) - \hat{y}(t)|)^2}$$

- Root Mean square error

$$MSE = \sqrt{\frac{1}{N} \sum_1^N \left[\frac{y(t) - \hat{y}(t)}{y(t)} \right]^2} \cdot 100$$

예측 결과를 살펴보면 예측기간 동안의 상대오차 백분율과 표준편차가 각각 1.023%, 236.485 MW로 ARMA모형의 1.432%, 321.36 MW보다는 우수한 예측률을 보였다. 그러나 부하변동이 1000 MW 이상일 경우에 있어서는 변동에 대한 적응력이 상대적으로 떨어져 오차율이 높게 나타났다. Table 1은 예측률이 전체적으로 높게 나타났던 1993년 12월 1일의 예측 결과를 보여주고 있으며 시간대 부하변동이 큰 시간대에 있어서는 평균오차율 0.7%보다 오차율이 상대적으로 크게 나타났다. 그러나 증가 패턴이 유지되면 게인(gain)이 적용되어 오차율이 감소함을 보였다. 본 동적모형을 이용하여 부하변동이 심한 여름철(6월-8월) 부하예측을 수행한 결과 상대오차 1.005%, RMSE 1.479% 표준편차 227.052 MW로 평균적으로 가을철(9월-11월) 예측보다 우수한 예측을 보였으나 부하변동 시간대에 있어서 최고 상대오차율이 9.743%로 높게 나타났다. 따라서 부하변동이 증가에서 감소 또는 감소에서 증가로 변하는 부하변동 시간대의 예측을 위해서는 패턴인식 즉 부하변동의 학습화 등을 통하여 게인(gain)의 적응력을 향상시켜 예측력을 높일 수 있는 후속연구가 필요하다.

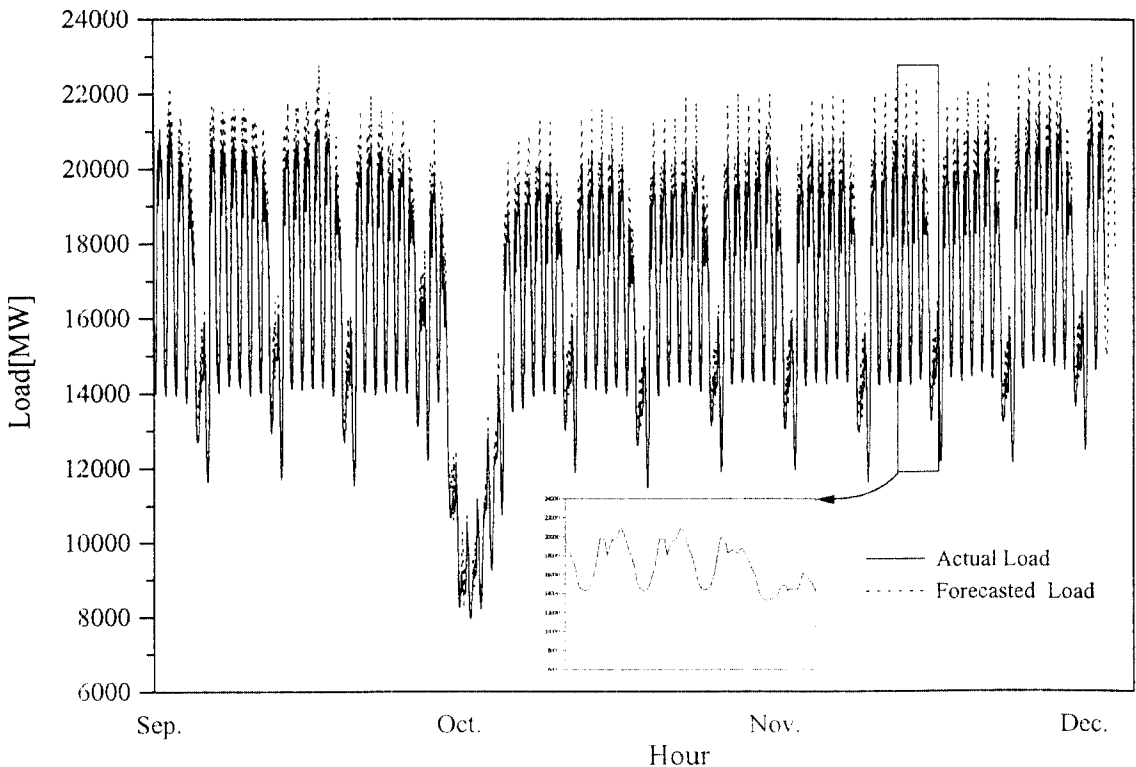


Fig. 4. Comparison of actual load and forecasted load for fall using the Dynamic model.




Fig. 5. Comparison of actual load and forecasted load for summer using the Dynamic model.

Table 2. Results of forecasting error.

구 분	Dynamic model	ARMA
Percent Relative Error	1.023%	1.432%
Root Mean Square Error	0.156%	0.190%
Standard Deviation	236,485 MW	321.360 MW

5. 결 론

칼만필터추정은 여러 분야에 응용될 수 있는 예측기법이다. 이 기법은 최소자승(least Squares)접근방법과 유사한 점이 많이 있지만 예측시 가장 문제가 되는 정확성과 계산상의 효율성 등에서 강력한 우위를 갖는다. 만약 정상상태(stationary)에서 칼만필터의 계수가 제한된다면 그때 칼만필터추정과 ARMA모형의 결과는 비슷하게 나타난다. 그러나 칼만필터의 강점은 모형의 계수가 동태적(nonstationary)일때 그 위력을 발휘 한다. 본 연구에서 구축한 선형동적모형(linear dynamic model)을 이용하여 예측한 결과는 ARMA모형을 이용하였을 경우보다도 우수한 결과를 얻을 수 있음을 확인하였다. 또한 예측에 소요된 계산시간이 펜티엄90 퍼스날컴퓨터

에서 실시간으로 자료 2210개를 처리하는데 약 72 sec로 뛰어난 신속성을 보임에 따라 실시간적용의 유용성을 확인 하였다. 본 연구의 향후과제로 본 연구에서 배제한 외생변수(날씨변수)를 고려한 동적모형(dynamic model)을 구축하고, 부하변동이 급작스럽게 변동되는 시간대에 있어서 적응(adaptive) 능력을 향상시키기 위하여 부하변동의 패턴인식이 가능한 신경망(neural network) 이론과의 접목에 두고 있다.

참고문헌

1. A. Keyhani and S.M. Miri: "On-Line Weather-Sensitive and Industrial Group Bus Load Forecasting for Microprocessor Based Applicatins," IEEE Transactions on Power Apparatus and Systems, **PAS-102**, 3868-3876 (1983)
2. S. Vemuri, et al.: "On-Line Algorithms for Forecasting Hourly Loads of an Electric Utility," *ibid.*, **PAS-100**, 3775-3784 (1981).
3. M.S. Abou-Hussien, et al.: "An Accurate Model for Short-Term Load Forecasting," *ibid.* **PAS-100**, 4158-4165 (1981).
4. G.D. Irisarri, et al.: "On-line Load Forecasting for

- Energy Control Centre Application," *ibid.*, **PAS-101**, Jan. 71-78 (1982).
5. Kalman, R.E.: "A New Approach to Linear Filtering and Prediction Problems," *Journal of Basic Engineering*, Mar., 35-45 (1960).
 6. Kalman, R.E. and Bucy, R.S.: "New Results in Linear Filtering and Prediction Theory," *Journal of Basic Engineering*, Mar., 95-108 (1961).
 7. Harrison, P.J. and C.F. Stevens: "Bayesian Forecasting," *Journal of the Royal Statistisal Society*, B. 38, 205-228 (1986).
 8. Morrison, G.W. and D.H. Pike, "Kalman Filtering Applied to Statistical Forecasting," *Management Science*, **23**, 768-774 (1977).
 9. Ledolter, J.: "A Recursive Approach to Parameter Estimation in Regression and Time series Models," *Communication in Statistics*, **A-10**, 227-1246 (1979).
 10. Sallas, W.M. and D.A. Harville: "Best Linear Recursive Estimation for Fixed Linear Model," *Journal of the American Statistical Association*, **76**, 860-869 (1981).
 11. Duncan, D.B. and S.D. Horn: "Linear Dynamic Recursive Estimation from the Viewpoint of Regression Analysis," *Journal of the American Statistical Association*, **67**, 815-821 (1972).
 12. Sastri, T.: "A State Space Modeling Approach for Time Series Forecasting," *Management Science*, **31**(11), 1451-1470 (Nov., 1985).
 13. English, J.R., Krishnamurthi, M. and Sastri, T.: "Quality Monitoring of Continuous Flow Process," *Computers and Industrial Engineering*, **20**(2), 251-260 (1991).
 14. Harrison, P.J.: "Exponential Smoothing and Short-Term Sales Forecasting," *Management Science*, **13**, 821-842 (1967).
 15. Sant, D/T.: "Generalized Least Squares Applied to Time-Varying Parameter Models," *Annals of Economic and Social Measurement*, **6**, 301-311 (1977).
 16. Sarris, A.H.: "A Bayesian Approach to Estimation of Time-Varying Regression Coefficients," *Annals of Economic and Social Measurement*, **2**, 501-523 (1973).
 17. Mohinder S. Grewal and Angus P. Andrews, *Kalman Filtering-theory and Practice*, Prentice Hall, (1993).
 18. G.E.P.Box and G.M. Jenkins: *Time series Analysis-Forecasting and Control* Holden-Day, (1976).
 19. Goodwin and Sin, *Adaptive filtering, prediction and Control*, Prentice-Hall, (1984).
 20. G. Minkler and J. Minkler: *Theory and Application of Kalman Filtering*, Magellan, Book Company, (1992).