

ART1 신경망을 이용한 다음날의 전력수요 예측

朴源深 · 鄭勝教
제어계측공학과 · 전기공학과

<요 약>

ART1(Adaptive Resonance Theory 1) 신경망을 이용하여 다음날의 시간별 전력수요를 예측하는 산법을 제안하였다. 제안한 산법은 과거 10일간의 실측전력수요로부터 수요모형을 인식한 후, 이 모형을 이용하여 다음날의 시간별 수요를 예측한다. 예측정확도를 높이기 위하여 수요모형을 평일, 일요일, 월요일, 토요일 및 특수일의 5가지로 분류하였으며, 특수일은 다시 신정, 설, 추석 및 기타 공휴일로 구분하였다.

1993년 우리나라의 수요실적 데이터를 사례로 검토해 본 결과, 종래의 지수평활화법에 비하여 우수한 예측결과를 보여 주었다.

One day ahead load forecasting using the ART1 neural network

Park, Won-Sim · Chong, Sung-Kyo
Dept. of Control & Instrumentation Engineering · Dept. of Electrical Engineering

<Abstract>

A load forecasting method using ART1(Adaptive Resonance Theory 1) neural network is proposed. The proposed method analyzes the power demand pattern of past 10 days, then predicts the hourly load of next day. To improve the accuracy of forecasting, five different day groups are defined and investigated according to the power demand, such as Sunday, Saturday, ordinary weekday, the day after holiday, and special day. The special day group includes New Year's day, Thanks giving day, New moon Year's day, and other holidays.

KEPCO's hourly load data recorded between Nov. 15, 1992 and Dec. 31, 1993 are used as case study references. It is shown that the proposed method provides less forecasting error compare to the conventional exponential smoothing method.

1. 서 론

최근 전력시스템에서 나타나는 현상을 살펴보면 발전설비의 대용량화, 심야수요의 감소, 적절한 운전예비력의 확보, 화력기의 기동정지 등을 들 수 있다. 이러한 현상은 안정적이면서 경제적인 전력수급에 여러가지 문제점을 제기하게 되는데, 그 문제점을 해결하기 위한 기본적인 요청은 미래의 전력수요를 정확하게 예측하는 데서 출발한다. 특히 다음날의 수요를 정확하게 예측하는 것은 전력시스템의 단기운용 면에서 무엇보다 중요한 것으로 인식되어지고 있다.

지금까지 널리 쓰이고 있는 전력수요의 예측방법들은 주로 통계적인 수리기법으로 지수평활화법^[1], 중회귀법^[2], Box-Jenkins 법^[3], 적응형 모형법^[4] 등을 들 수 있다. 이러한 예측모형들의 공통적인 특징은 모형의 파라미터가 예측일에 가까운 날의 변화에 민감하게 작용하도록 적응형 알고리즘으로 구성되어 있다. 그러나 예측모형을 구성할 때 과거의 방대한 실측 데이터베이스에 의존하므로써 모형속에 잠재한 과거의 성향이 미래의 예측에 적절히 대응되지 못하는 문제점이 존재한다.

이러한 통계적인 수리기법의 단점을 보완하기 위하여 최근에는 인공지능(Artificial Intelligence; AI) 기법이 도입되는데, 특히 신경회로망을 이용^[7-11]하거나 예측전문가의 지식을 이용^[5-6]하는 전문가 시스템이 활발히 연구되고 있다.

인간의 생체구조와 같은 모형을 가진 신경회로망은 수리계획법과 달리 예측문제가 갖고 있는 비선형성을 쉽게 고려할 수 있는 잇점이 있다. 신경망은 그 학습의 형태에 따라 지도학습과 자율학습으로 분류할 수 있다. 지도학습은 주어진 입력에 대하여 올바른 출력을 지정해 주는 학습법으로, 신경망은 그 출력이 올바른지를

검토하여 자신의 연결강도를 조정한다. 지도학습을 하는 대표적인 신경망으로 역전파(Back Propagation; BP)신경망과 홉필드신경망을 들 수 있다. 지도학습 신경망은 정교한 모형을 가진 반면, 새로운 정보가 학습되면 이전에 학습되었던 내용을 잊어버리거나 변경하는 경우가 발생하므로 실용화라는 면에서 안정성이 미흡하다. 특히 BP신경망의 경우에는 학습 데이터가 모두 학습될 때까지 연결강도의 값이 반복해서 변경되므로, 완전히 학습된 신경망에 새로운 데이터를 더 학습시켜야 할 필요가 생기면 모든 데이터를 다시 학습시켜야 할 문제가 발생한다. 이때 은닉층이 많으면 그만큼 학습시간도 증대하게 된다.

반면 자율학습 신경망은 주어진 입력에 대하여 올바른 출력이 주어지지 않으므로 어떤 출력을 내야 할지가 명확하지 않다. 그러나 자기구조화와 단층구조를 가지므로 학습시간이 절약되며, 연상작용으로 출력을 결정하므로 새로운 입력에 대한 대응성도 있다.

본 연구에서는 이런 점에 착안하여 자율학습신경망인 ART1 신경망을 도입하였다. ART1 신경망은 패턴인식능력이 뛰어나므로 수요패턴을 자기연상하도록 학습하여 다음날의 예측에 활용하였다. 즉 ART1 신경망의 입력과 출력사이의 연결가중치에 입력된 과거 수요실적들을 하나의 패턴으로 인식하여 일반화된 수요모형으로 구성한 후 다음날의 수요패턴을 추정하였다. 또 예측의 중요한 인자인 온도-수요 감응계수를 구하여 예측결과를 보정하도록 하였다.

제안한 예측방법의 효용성을 검증해 보기 위하여 우리나라 실계통의 수요를 대상으로 시뮬레이션을 한 결과 종래의 지수평활화법에 비하여 예측정확도가 개선되고 안정된 예측결과를 얻을 수 있었다.

2. ART1 신경망의 개요

Carpenter 와 Grossberg에 의해 고안된 ART1 신경망^{[12][14]}은 인간의 두뇌를 모방한 생물학적인 구조를 가지고 있다. 인간의 두뇌는 외부에서 입력되는 수많은 정보를 적절히 저장하여 필요시 이를 이용하게 되는데, 이때 새로운 사실이 입력되어도 기존의 내용을 변경되지 않는다. 즉, 기존에 기억된 내용을 없애거나 방해하지 않는 안정성(stability)을 가지면서도 새로 입력되는 정보를 기억 할 수 있는 유연성(plasticity)을 갖고 있다.

ART1 신경망도 이전에 학습된 패턴을 어느 정도 유지하면서도 새로운 패턴의 학습에 따른 유연성을 잃지 않도록 설계되어 있다. 이는 이전에 저장된 패턴과 새로 입력된 패턴간의 차이가 주어진 임계값 범위 이상일 때만 그 연결강도의 값이 변하게 된다. ART1 신경망은 온전한

입력패턴에 대해서는 잘 적용되지만 잠음 등이 섞인 패턴에 대해서는 애매한 결과를 초래하기도 하는데, 예측이나 패턴인식 문제에 도입하기 위해서는 입력에 섞인 잠음을 배제할 수 있는 적절한 대책도 강구되어야 한다.

본 연구에서는 이런 점을 감안하여 신경망에 입력되는 과거 전력수요를 [MW] 값 대신에 정규화된 [pu]값으로 환산하도록 하였다. 또 입력된 정규화 패턴은 ART1 신경망 특유의 강점인 패턴의 인식과 분류에 이용하지 않고 그 연결강도 값을 자기연상기억값으로 기억하여 일반화된 일간 수요모형을 구성하였으며, 이 모형으로 부터 다음날의 전력수요를 예측하도록 접근하였다.

ART1 신경망은 1개의 입력층과 1개의 출력층을 가진 단층구조를 가지는데, 그림 1은 그 개념을 나타낸 것이다.

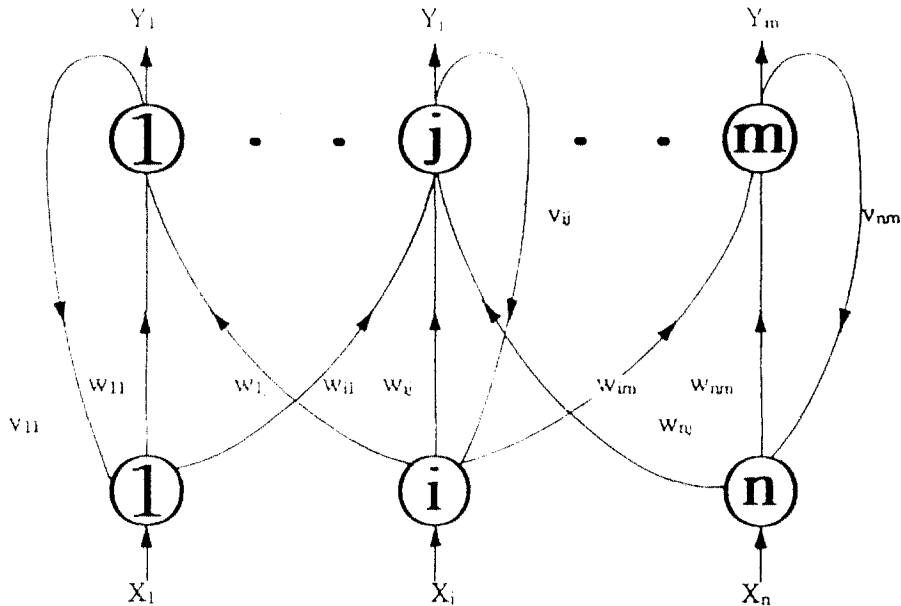


그림 1. ART1 신경망
Fig. 1. ART1 neural network

3. 수요패턴의 분류

예측정확도를 높이기 위해서는 일간수요를 특성이 비슷한 것 끼리 분류하여 예측에 활용하는 것이 유용하다. 본 연구에서는 ART1 신경망을 이용하여 수요패턴을 분류하였으며, 그 절차를 나열하면 다음과 같다.

- 1) 유사도 테스트를 위한 임계값을 선택($0 < \rho < 1$)하고, 입력층에서 출력층으로의 연결강도(W)를 초기화하며, 출력층에서 입력층으로의 역전파 연결강도(V)를 초기화한다.

$$W = \left[\frac{1}{1+n} \right], \quad V = [1]$$

n : 입력벡터의 수

(3.1)

- 2) 이진 입력벡터(X)를 입력한다.

$$X_i = 0 \text{ or } 1$$

for $i = 1, 2, \dots, n$

- 3) 워너 노드를 선택한다.

$$y_m^o = \sum_{i=1}^n W_{im} X_i$$

for $m = 1, 2, \dots, M$

(3.2)

또한 기존 Cluster에서 가장 비슷한 패턴을 찾는다.

$$y_j^o = \max(y_m^o)$$

for $m = 1, 2, \dots, M$

(3.3)

- 4) 워너 뉴런 j에 대한 유사도를 검증한다.

$$\frac{1}{\|X\|} \sum_{i=1}^n V_{ij} x_i > \rho$$

단, ρ 는 유사도 시험 임계값

$$\|X\| \cong \sum_{i=1}^n |X_i| \quad (3.4)$$

만약 검증을 통과하면 5)로, 실패하면 6)으로 진행한다.

- 5) 절차 4)를 통과한 패턴 j에 대한 연결강도를 수정한다.

$$W_{ij}[t+1] = \frac{V_{ij}[t] X_i}{0.5 + \sum_{i=1}^n V_{ij}[t] X_i}$$

$$V_{ij}[t+1] = X_i V_{ij}[t] \quad (3.5)$$

절차 2)로 진행하여 다른 입력벡터에 대한 유사도를 검증한다.

- 6) 패턴 j를 억제시키기 위해 $Y_j=0$ 으로 reset하고, 패턴 j를 패턴분류 경쟁에서 배제한다.

- 7) 만약 또 다른 입력벡터(패턴 j제외)가 존재하면 절차 4)에서 부터 다시 실행하고, 아니면 새로운 패턴을 구성한다.

이상의 절차를 흐름도로 나타내면 그림 2와 같다.

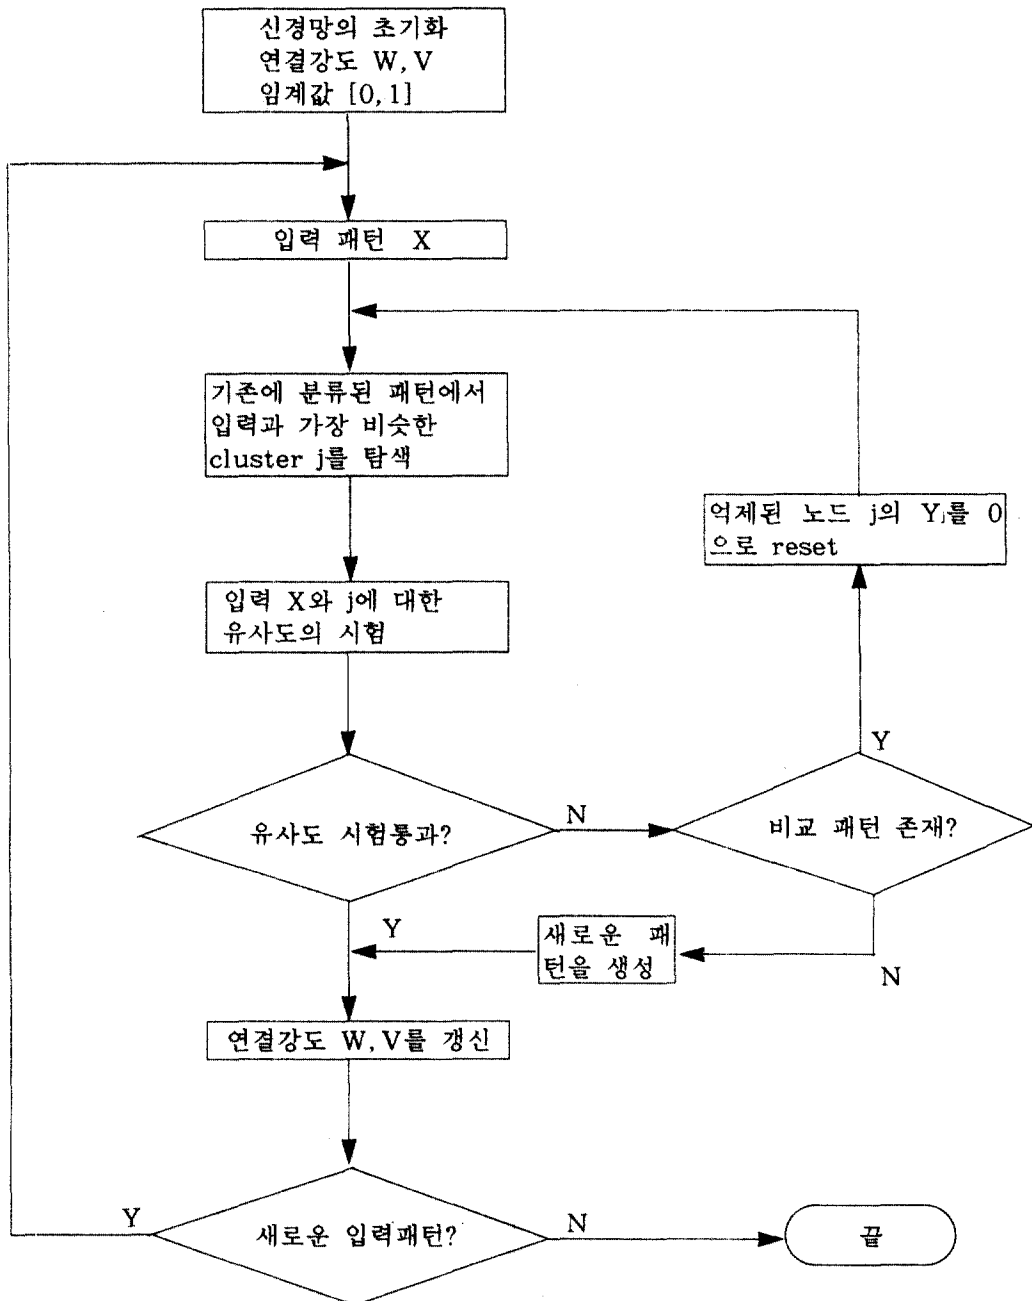


그림 2. 패턴분류의 흐름
Fig. 2. Flow for pattern clustering

4. 일간수요의 특성

ART1신경망을 이용하여 분류한 수요패턴의 특성을 살펴보면 그 형태는 예측일에 따라 크게 평일과 특수일로 나눌 수 있다. 특수일에는 토요일, 일요일, 경축일 등이 포함되며 평일은 특수일을 제외한 날로 월요일, 화 - 금요일로 나누어 진다.

그림 3은 1993년도 월요일과 평일의 대표적인 수요패턴을 비교하여 나타낸 것이다.

보이고 있다.

그림 4는 토요일, 일요일 및 평일의 수요패턴을 나타낸 그림이다. 토요일의 수요는 오후시간대에 비교적 낮고, 일요일 수요는 오전시간대가 매우 낮으며 전체적으로도 낮은 수요수준을 나타낸다. 또 토요일 오후 시간대의 수요가 평일수요에 비해 상대적으로 낮음도 알 수 있다.




그림 2. 패턴분류의 흐름
Fig. 2. Flow for pattern clustering

그림 3은 월요일과 평일의 수요패턴을 비교한 것으로 월요일의 오전 시간대 수요는 일요일의 영향을 받아 상대적으로 낮으며, 이러한 영향은 주중 공휴일이나 경축일 다음날 오전 시간대 수요형태에서도 나타난다. 즉 공휴일 전날이 평일인 경우 일반적인 평일의 수요패턴을 보이고, 그 다음날은 월요일과 비슷한 수요패턴을

본 연구에서는 이러한 일간수요의 특성을 반영하여 예측을 위한 일반적인 수요모형을 표 1과 같이 분류하였다.

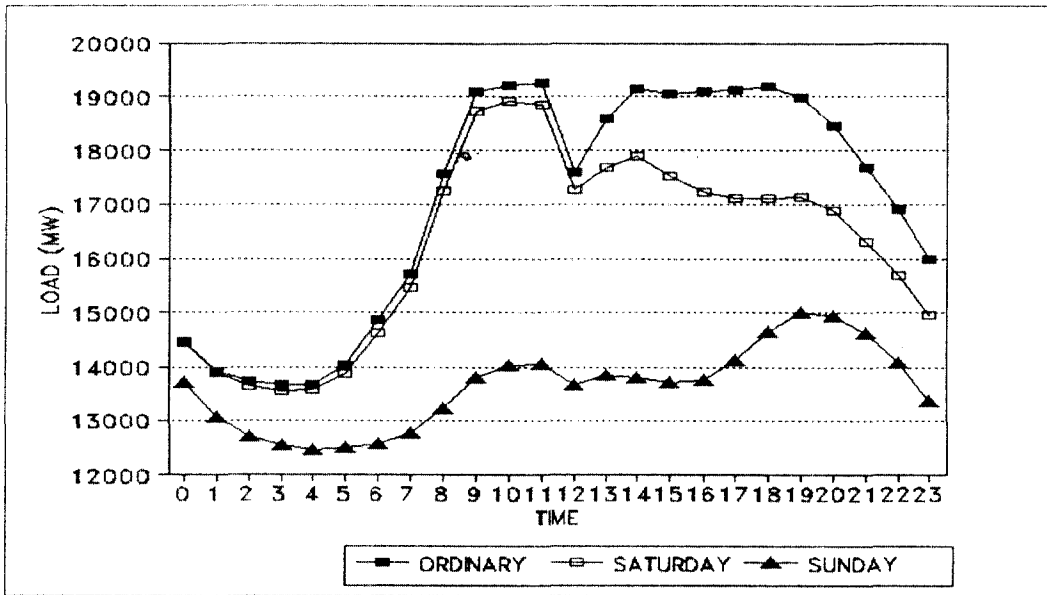


그림 4. 토요일, 일요일 및 평일수요패턴의 비교

Fig. 4. Comparison of saturday, sunday and ordinary day pattern

표 1. 수요 패턴의 분류

Table 1. classification of load pattern

코드번호	항 목
1	월요일, 공휴일 다음날
2	평일 (화 - 금요일)
6	토요일
7	일요일

년간 수요형태의 특성을 살펴보면, 겨울철 침두수요는 난방이 필요한 저녁시간 (19 - 20시)에 발생하며, 여름철 침두수요는 냉방이 필요한 오후시간(14 - 15시)에 발생한다. 그리고 여름철 휴가기간 (8월 첫 1주일)은 특별한 침두수요가 없이 오전과 오후의 수요가 거의 유사하게 나타난다.

그림 5는 1994년 월별 침두수요의 발생 시간과 침두수요값을 나타낸 것으로, 여름철 수요가 급격히 증가한 것은 이상고온 현상에 기인한 것이다.




그림 5. 1994년의 월별 첨두수요
Fig. 5. Monthly peak load in 1994

5. 예측 산법

전력수요는 온도, 습도, 풍속, 일조량 등 여러 가지 기상조건에 따라 변화된다. 이러한 기상요인들은 모두 고려하는 데는 그 영향력을 구별해서 규명하기가 어렵기 때문에, 일반적으로 자료수집이 용이한 온도만을 택하고 있다. 본 연구에서도 실용화의 관점에서 온도만을 고려하였으며, 최대온도-첨두수요의 상관계수를 최소자승법으로 구하여 다음과 같은 모형으로 표현하였다.

$$Y[t] = KF[t] \quad (5.1)$$

단, K : 기상-수요계수

$F[t]$: t 시각의 온도 변화량

그림 6과 그림 7은 여름철(93년 7월)과 겨울철(93년 1월)의 온도-수요의 산포도를 선형회귀 분석한 대표적인 모형이다. 산포도 분석시 수요특성이 다른 일요일이나 특수일 등은 제외시켰다.




그림 6. 여름철의 온도-수요 모형 (1993)
Fig. 6. Temperature-load model in summer (1993)




그림 7. 겨울철의 온도-수요 모형 (1993)
 Fig. 7. Temperature-load model in winter (1993)

다음날의 시간별 전력수요를 예측하기 위한 기본 데이터로는 예측일에 가까운 3~10일분의 과거 실적수요를 사용한다. 과거수요는 텍스트 형태의 화일로 구성되어 있다. 원시 과거실적은 [MW]값이므로 이것을 [pu]로 정규화하여 이진값으로 변환한 후 신경망에 입력하며, 입력된 각 수요패턴들은 신경망의 연결강도를 변화시키면서 자기연상작용으로 하나의 수요모형을 구성하게 된다. 즉, 유사한 수요패턴들의 집합을 단일패턴으로 인식, 분류하도록 하는 ART1신경망의 특성을 이용하여 예측모형을 구성하게 된다.

예측의 절차를 순서대로 열거하면 다음과 같다.

표 2. 온도-수요 모형의 계수

Table 2. Coefficients of temperature-load models

구 분		1992		1993		모 형 식	제 약
		2월	8월	1월	7월		
여 름 철	Ks	60.943		62.795		$Y[t] = Ks(Tm - 25)$	$25 \leq Tm \leq 40$
	$Y[t]^{MAX}$	463.18		314			
겨 울 철	Kw	9.946		13.969		$Y[t] = Kw(5 - Tm)$	$-13 \leq Tm \leq 5$
	$Y[t]^{MAX}$	97.47		196			

이때 온도감응 수요모형을 지역별로 매 시각마다 구하는 것은 실용성이 떨어지므로 경인지역에서 침두가 발생하는 시각의 온도만을 이용하였다. 이렇게 구한 수요모형은 온도의 영향이 적은 시간대에서 예측오차를 크게 할 소지가 있으므로 오차의 표준편차를 구하여 기상수요모형의 적용이 효과적인 시간대(오전 10시 - 오후 11시)에만 적용되도록 하였다.

- 1) 예측일의 특성과 같은 실적수요패턴을 읽어온다.
- 2) 시간별 전력수요 [MW]를 단위값 [pu]으로 변환한다.

$$P_n[i][t] = \frac{P[i][t]}{P[i]_{max}} [pu]$$

$$i = 1, 2, \dots, 10$$

$$t = 1, 2, \dots, 24 \quad (5.2)$$

단, $P[i]_{max}$: 일간 최대부하[MW]

$P[i][t]$: i 일 t 시각의 부하[MW]

- 3) $P_n[i][t]$ 를 24배수하고 정수로 변환하여 [24x24]차원의 이진값으로 표현한다.
- 4) 이진화된 데이터를 ART1 신경망에 입력하여 연결강도를 구한다. 이때 입력되는 과거의 실적이 단일패턴으로 분류되도록 임계값을 조정한다.
- 5) [24x24] 형태의 연결강도를 [1x24] 형태의 단위값으로 변환하여 일반화된 시간별 전력수요의 모형을 구성한다.

$$P_n[i] = \frac{\sum_{t=1}^{24} \sum_{i=1}^{24} W(t)[i]}{W_{\max}} \text{ [pu]} \quad (5.3)$$

$t = 1, 2, \dots, 24$ (시간)
 $i = 1, 2, \dots, 24$ (열벡터)

$\sum W(t)[i]$: t 시각의 열벡터 합

W_{\max} : 열 벡터 연결강도 합중 최대값

- 6) 예측일에 가까운 실측수요로부터 척도값을 전력수요모형에 적용하여 수요를 예측한다.

s

$$\hat{P}_1[t] = P_n[t] * P_{\max}^o \quad (5.4)$$

단, $\hat{P}_1[t]$: 예측수요 [MW]

P_{\max}^o : 실측수요중 최대 [MW]

- 7) 온도 감응모형을 이용하여 예측된 수요곡선을 보정한다.

$$\hat{P}[t] = \hat{P}_1[t] + KF[t] \quad (5.5)$$

단, K : 부하-온도계수

$F[t]$: 온도감응 수요량 [MW]

$\hat{P}[t]$: 최종 예측수요 [MW]

6. 사례연구

제안한 예측산법의 효용성을 검증해 보기 위하여 1992. 11. 15 부터 93. 12. 31 까지 우리나라의 수요실적을 이용하여 예측 시뮬레이션을 행하였다. ART1신경망의 입력은 이 기간중 예측일에 가까운 과거 10일분의 패턴으로 분류된 시간별 수요를 자동적으로 검색, 추출하여 사용되었다. 수요의 패턴은 월요일, 평일(화요일-금요일), 토요일, 일요일과 특수일로 구분되며, 특수일의 경우 과거의 데이터 수집이 어려워 사례검토에서 제외하였다. 수요를 분류할 때, 공휴일 다음날은 월요일과 같은 수요패턴을 갖는 경향이 있으므로 월요일 패턴으로 취급하였다. 예측사례는 4계절을 대표하는 1월, 4월, 7월 및 10월을 표본으로 하여 각 계절의 수요모형 별로 예측을 수행하였다.

ART1 신경망을 이용한 수요모형을 일반화하기 위해서는 2진값의 수요값을 처리하여 자기연상기억이 되도록 유사도 시험(vigilance test)을 거쳐야 하는데, 시뮬레이션 결과 그 임계값으로는 0.1이 적합함이 밝혀졌다.

예측결과를 평가하기 위한 오차는 다음식과 같이 평균절대 백분율오차(Mean Absolute Percentage Error:MAPE)로 산정하였다.

$$MAPE[t] = \left| \frac{P[t] - \hat{P}[t]}{P[t]} \right| * 100 [\%]$$

$$MAPE = \frac{1}{24} \sum_{t=1}^{24} MAPE[t] \quad (6.1)$$

단, $P[t]$: 실측수요 [MW]

$\hat{P}[t]$: 예측수요 [MW]

표 3은 계절별 예측오차(MAPE)의 추이로 요일별 오차의 평균값을 비교한 것이다.

표 3. 계절별 예측오차의 추이
Table 3. Forecasting error for season base

항목	겨울(1월)		봄(4월)		여름(7월)		가을(10월)	
	날자	MAPE (%)	날자	MAPE (%)	날자	MAPE (%)	날자	MAPE (%)
월요일	930104	2.60	930406	1.84	930705	4.37	931005	2.98
	930111	3.05	930412	1.17	930712	2.19	931011	2.5
	930118	1.19	930419	2.22	930719	3.32	931018	1.25
			930426	1.81	930726	1.29	931025	1.13
평일	930112	1.95	930420	2.85	930720	2.08	931019	3.22
	930113	1.76	930421	1.05	930721	3.99	931020	3.49
	930114	1.48	930422	1.25	930722	4.57	931021	3.83
	930115	0.85	930423	1.68	930723	3.48	931022	1.89
토요일	930109	1.82	930403	1.27	930703	2.50	931009	1.92
	930116	2.23	930410	1.42	930710	1.77	931016	2.99
	930130	1.18	930417	2.28	930724	2.42	931023	2.34
			930424	1.19	930731	1.66	931030	2.15
일요일	930110	1.95	930404	1.71	930704	1.27	931010	3.19
	930117	2.51	930411	2.32	930711	5.51	931017	2.16
	930131	1.88	930418	2.26	930718	1.71	931024	3.39
			930425	3.49	930725	3.53	931031	1.62

표 4는 시간별 예측오차중 침두수요 발생시점에서의 예측오차값을 표시하였다. 표 3~4를 비교해 볼 때 침두시각에서의

예측오차가 평균오차에 비해 그다지 크지 않음을 알 수 있다.

표 5. 침두시의 예측오차
Table 5. Forecasting error for peak time

항 구	겨울(1월)		봄(4월)		여름(7월)		가을(10월)	
	DATE	MAPE (%)	DATE	MAPE (%)	DATE	MAPE (%)	DATE	MAPE (%)
인 요 일	930104	3.81	930406	1.24	930705	5.79	931005	1.42
	930111	5.37	930412	4.22	930712	1.92	931011	2.93
	930118	0.27	930419	2.22	930719	4.11	931018	0.46
			930426	4.52	930726	0.72	931025	1.56
인 평 일	930112	1.25	930420	0.78	930720	0.51	931019	0.51
	930113	0.78	930421	0.93	930721	3.23	931020	0.16
	930114	1.22	930422	0.75	930722	1.45	931021	1.32
	930115	0.04	930423	1.60	930723	0.59	931022	0.64
인 요 보 일	930109	4.96	930403	1.34	930703	3.40	931009	3.33
	930116	0.23	930410	4.96	930710	8.46	931016	2.64
	930130	0.37	930417	5.86	930724	0.83	931023	2.84
			930424	1.80	930731	0.23	931030	2.49
인 평 보 일	930110	1.41	930404	1.50	930704	0.00	931010	6.83
	930117	2.76	930411	2.37	930711	0.62	931017	3.81
	930131	1.73	930418	0.74	930718	1.50	931024	0.18
			930425	4.49	930725	1.09	931031	0.13

그림 8~11은 계절별 대표적인 일요일 로 나타낸 것이다.
의 예측결과를 실측치와 비교하여 그래프




그림 8. 겨울철 일요일 수요의 예측
Fig. 8. Load forecast on sunday in winter

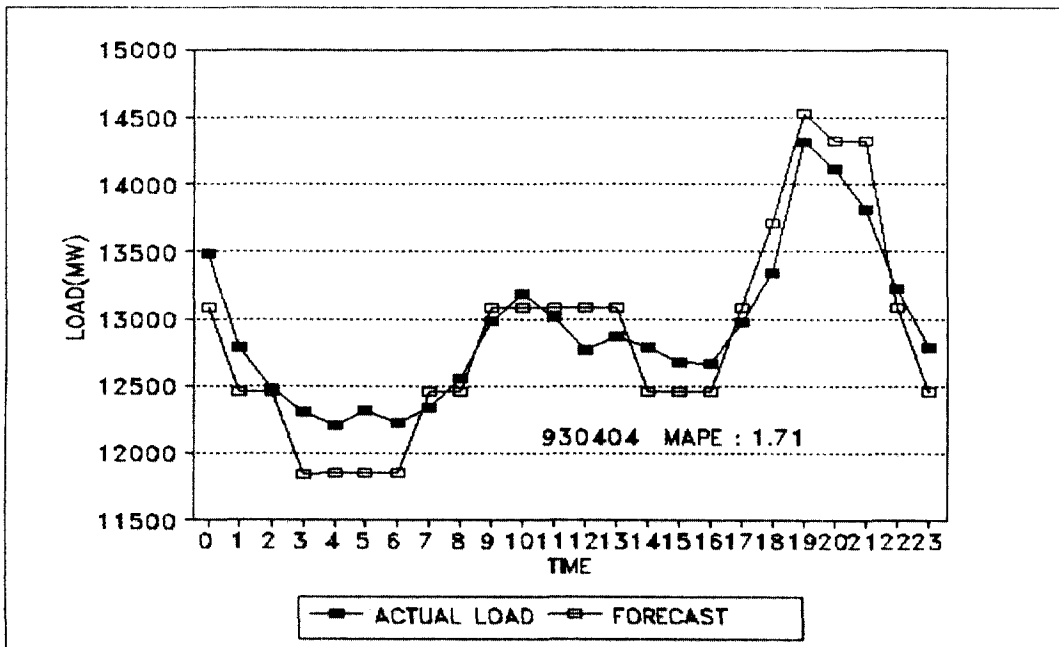


그림 9. 봄철 일요일 수요의 예측
Fig. 9. Load forecast on sunday in spring




그림 10. 여름철 일요일 수요의 예측
 Fig. 10. Forecasting results on Sunday in summer




그림 11. 가을철 일요일 수요의 예측
 Fig. 11. Forecasting results on Sunday in Autumn

표 5는 계절을 대표하는 1, 4, 7, 10월에 대한 ART1신경망과 현재 사용되고 있는 지수평활화법과의 예측오차를 비교한 표이다. 여기서 오차값은 예측에 참여한 날의 절대백분율오차를 각 계절별로 평균한 것이다. 표에서 알 수 있듯이 제안한 ART1신경망은 종래의 지수평활화법에 비하여 전반적으로 예측정확도가 개선됨을 알 수 있다.

하여 반영하므로써 예측 정확도를 높일 수 있을 것이다. 기상의 영향을 효과적으로 반영하기 위해서 과거의 비슷한 기상을 가진 수요패턴을 분류하여 예측하는 방안도 연구중에 있다.

표 5. 지수평활화법과의 예측오차 비교

Table 5. Comparison of forecasting error with exponential smoothing method

단위 : [%]

산법 \ 계절	겨울(1월)	봄(4월)	여름(7월)	겨울(10월)
ART1	1.88	1.86	2.85	2.50
Exponential Smoothing	2.22	1.92	3.27	3.11

7. 결 론

본 연구에서는 연상기억능력이 뛰어난 ART1 신경망을 이용하여 과거의 24시간별 전력수요패턴을 일반화된 수요모형으로 구성하여 다음날의 전력수요를 예측하였다.

제안한 산법을 1992년 11월부터 1993년 12월까지의 우리나라 24시간별 전력수요 데이터를 이용하여 사례검토를 한 결과, 종래의 지수평활화법과 비교하여 개선된 예측결과를 얻을 수 있었다. 특히, 첨두수요에서의 예측오차가 2[%] 내외로 양호한 예측결과를 나타내었다.

연구에서 수요예측의 중요한 인자인 기상요인은 실용성을 건지에서 온도감응계수를 이용하여 예측결과를 보정하도록 하였으나, 지역별, 시간별 계수를 정확히 구

ART1 신경망에서 수요패턴은 이진값으로 기억되고 처리되므로 컴퓨터의 기억용량이 많이 필요하고, 패턴의 변환과정에서 패턴이 손상되기도 하였다. 제안한 산법에서 이런 점이 개선되고 사용자의 편리성을 위한 그래픽 인터페이스가 추가된다면 상용화도 가능할 것으로 기대된다.

참고문헌

- [1] W. R. Christiaanse, "Short-Term Load Forecasting Using General Exponential Smoothing", IEEE Trans. PAS, Vol. 90, 1971, pp. 900-911
- [2] G. D. Irissari, S. E. Widergren, P. D. Yehsakul, "On Line Load

- Forecasting for Energy Control Center Application", IEEE Trans. PAS, Vol. 101, 1982, pp. 71-78.
- [3] G. E. P. Box, G. M. Jenkins, "Time Series Analysis : forecasting and control", 2nd ed., Holden-day, 1976
- [4] Park. J., Lee. K., (1990), "Composite Modeling for Adaptive Short-Term Forecasting of Electric Load", Presented at the IEEE Power Systems Engineering Summer Meeting.
- [5] S. Rahman, "Formulation and Analysis of a Rule-based Short-Term Load Forecasting Algorithm", Proc. IEEE, Vol. 78, May 1990, pp. 805-816.
- [6] S. Rahman, O. Hazim, "A Generalized Knowledge Based Short-Term Load Forecasting Technique," IEEE Trans. PWRS, Vol.8, 1993, pp. 508-514.
- [7] C. N. Lu, H. T. Wu, S. Vemuri, "Neural Network Based Short Term Load Forecasting," IEEE Trans. PWRS, Vol. 8, Feb. 1993, pp. 336-342.
- [8] T. M. Peng, N. F. Hubble, G. G. Karady, "An Adaptive Neural Network Approach to One-Week Ahead Load Forecasting", IEEE Trans, PERS, Vol. 8, Aug. 1993, pp. 1195-1203.
- [9] D. C. Park, M. A. El-sharkawi, R. J. Markes II, L. E. Atlas and M. J. Damborg, "Electric Load Forecasting Using An Artificial Neural Network". IEEE Trans, PWRS, Vol. 6, May 1991, pp. 442-448.
- [10] K. Y. Lee, Y. T. Cha, J. H. Park, "Short-Term Load Forecasting Using An Artificial Neural Network", IEEE Trans, PWRS, Vol. 7, Feb. 1992, pp. 124-131.
- [11] T. M. Peng, N. F. Hubele, G. G. Krady, "Advancement in the application of Neural Networks for Short-Term Load Forecasting", IEEE Trans. Vol. 3, Feb. 1992, pp. 250-257.
- [12] B. Kosko, "Neural Networks and Fuzzy Systems", Prentice-Hall, 1992.
- [13] J.A.Freeman, D.M.skapura, "Neural Networks Algorithms, Application and Programming Techniques", Addison-Wesley, Oct. 1991, pp.291-339.
- [14] S. I. Gallant, "Neural Network Learning and Expert System", MIT press, 1994