

패턴분류와 임베딩 차원을 이용한 단기부하예측

최 재균, 조 인호, 박 종근
서울대학교
jgchoi@mail.lgci.com

김 광호
강원대학교
khokim@cc.kangwon.ac.kr

Abstract

In this paper, a method for the daily maximum load forecasting which uses a chaotic time series in power system and artificial neural network. We find the characteristics of chaos in power load curve and then determine a optimal embedding dimension and delay time. For the load forecast of one day ahead daily maximum power, we use the time series load data obtained in previous year. By using of embedding dimension and delay time, we construct a strange attractor in pseudo phase plane and the artificial neural network model trained with the attractor mentioned above. The one day ahead forecast errors are about 1.4% for absolute percentage average error.

1. 서론

최근들어 우리 사회의 환경이 고도 산업화, 정보화사회로 이행됨에 따라 산업의 규모가 커지고 일반 전력 수용가에서의 냉, 난방 기기 등과 같은 전기 기기의 사용이 급증하고 있다. 이에 따라 주말, 공휴일 등에 대한 전력의 사용 패턴이 과거와는 다르게 나타나고 있고 특히 냉방기기의 보급은 여름에 있어 전력의 사용을 급격하게 증가시키는 요인이 되고 있다.

이러한 사회적인 변화에 따라 전력 수요 예측의 정확성 및 신뢰성을 확보하는 일이 과거에 비해 더욱 어려워 지게 되었다. 이에 반하여 전력 수요 예측이 전력 사업에서 차지하는 중요성은 그 어느 때보다 커지고 있는데 그 이유는 산업구조의 고도화에 따른 양질의 전력 에너지에 대한 수용가의 요구와 전원 개발 입지 확보의 어려움에 따른 문제 등에도 불구하고 전력 회사측의 경제성 추구와 수용가측의 안정성 요구를 동시에 만족시켜 주기 위해서는 향후에 발생하게 될 전력의 수요를 보다 정확하게 예측하여 이에 맞는 전력을 공급하는 것이 최선의 방법이라고 여겨지기 때문이다.

전력수요의 예측은 과거 많은 시도가 이루어졌다. 가장 전형적인 방법은 전력수요를 시계열 함수로 생각하고 예측하고자 하는 시점보다 과거의 데이터를 이용하여 다항의 식으로 계수를 산출하는 회귀분석이나 중회귀 분석법이 있으며 [1], [2], [19][20] 전문가의 지식을 바탕으로 규칙을 생성하여 전문지식이 없는 초보자라도 쉽게 사용할 수 있는 전문가시스템 [8][9]에 의한 방법도 소개되었다. 최근에는 인공지능 기법을 이용하여 수요를 예측하는 방법이 많이 등장하고 있다. 대표적인 방법으로는 신경회로망(Neural Network)을 이용한 방법이 있으며, Fuzzy 이론, Genetic 이론 [23] 등을 이용한 방법도 소개되었다. 또한 앞서 언급한 방법들을 2개 이상 이용한 결합형태(Hybrid) [8]도 소개되고 있다.

본 논문에서는 단기 전력 수요 예측에 대해서 다루었고 단기 예측 중 일일(翌日) 최대 전력 예측을 주로 다루었으며 카오스 이론을 이용한 예측을 시도하였다. 과거의 시계열 데이터를 이용해 Attractor를 구성하는데 필요한 시간 지연(Time Delaying) Embedding 차원을 구하고 이 차원이 신경회로망의 최적 입력임을 실험적으로 증명하였으며 과거 패턴을 데이터 베이스로 구축하여 가장 유사한 패턴을 골라내 그 일일을 출력으로 삼는

패턴인식법을 사용하여 예측을 하고 타당성을 보였다. 그 인식에 필요한 패턴의 형태는 일일과 그전날의 차만을 구하여 그 것을 예측 패턴으로 사용하였다.

11. 결론

2-1. 과거 부하의 분석

예측을 하기 위한 기본 단계로서 과거 부하의 패턴을 분석하였다. 본 논문에서 대상은 일최대부하의 예측이며 그림 1에 1994년 및 1995년의 일별 최대부하를 도시하였다. 일최대부하의 경우, 전체적인 모양은 년도별로 큰 차이는 없고 단지 휴일의 이동, 즉 양력과 음력을 동시에 사용하는 우리나라의 경우 가장 큰 변화가 발생하는 설날 및 추석 연휴의 이동으로 인한 변화와 전반적인 에너지량의 증가에 기인하는 변화가 가장 뚜렷하다.




그림 1. 1994년 및 1995년도 일최대 부하 수요곡선

그림 2는 우리나라의 경제구조의 변화에 따른 최대부하의 이동을 나타낸다. 우리나라의 특징은 4계절이 뚜렷하고 특히 여름의 높은 기온 탓으로 1980년 이전에는 겨울에 최대부하가 발생하였고 그 이후부터는 냉방기기의 보급으로 인한 전력 소비의 증가로 최대부하가 여름에 나타나기 시작하였다. 또 이 최대부하의 증가가 최근들어 더욱 심화되어 1995년의 경우, 전력예비율이 3%미만으로 떨어지는 일도 발생하였다.




그림 2. 년중 최대 부하의 발생 시점




그림 3. 부하 패턴과 그 차의 패턴

또 1주일간의 부하 패턴을 살펴보면 특수일이 포함되지 않은 경우, 대체로 비슷한 형태를 나타내므로 본 논문에서는 미래의 패턴도 과거의 패턴과 유사하리라는 가정하에서 패턴인식 기법을 이용하여 예측을 시도하였다.

2-2. 입력 패턴의 결정

일최대 부하의 크기는 1995년도의 경우 10^4 order 약 13,000MW ~ 30,000MW 정도의 규모를 갖고 있고, 변위 즉 특정일과 그 익일간의 차는 이보다는 작은 10^3 order 가진다. 본 논문에서는 입력 패턴을 선정한 후 정규화하여 예측한 다음, 다시 원래의 값으로 복원하는 방법을 사용하였기 때문에 에너지의 레벨이 낮으면 낮을수록 상대적으로 오차는 줄어들 것이다. 따라서 이 패턴을 그대로 사용한 예측결과 보다는 현재날과 다음날의 변위를 입력 및 출력 패턴으로 하였을 경우 그 크기가 10^3 order 로 줄기 때문에 예측 오차는 그 만큼 줄어들게 되므로 일간 변위를 입력 및 출력 패턴으로 정의 하였다. 그림 3은 1995년 11월의 부하 패턴과 그 차의 패턴을 나타낸 그림이다. 그림 3의 경우 처럼 예측을 위한 입력으로 사용되는 패턴은 실선의 실제 부하값이 아니라 점선으로 표시된 변위값으로 하였다.

만일 주어진 일최대 부하의 시계열 데이터가 식 (1)과 같이 주어진다면

$$x(1), x(2), x(3), \dots, x(t) \dots \dots \dots (1)$$

일간 차의 새로운 입력 패턴을 $xn(t)$ 라하면

$$xn(t) = x(t+1) - x(t) \dots \dots \dots (2)$$

라고 쓸 수 있다.

이 패턴을 이용하여 예측을 한다면 예측 결과는 오늘의 패턴에 그 변화분만을 더해 주면 되므로 다음 날의 예측 부하 양을 $xn_p(t)$ 이라 하면 최종 예측량 $x_p(t+1)$ 은 식 3과 같이 표현된다

$$x_p(t+1) = x(t) + xn_p(t) \dots \dots \dots (3)$$

본 논문에서는 과거 5년간의 데이터를 데이터베이스화하여 예측에 사용하는 비교패턴으로 하였다.

2-3. Embedding Dimension의 결정

우리가 측정할 수 있는 전력부하 데이터는 1차원이다. 그러나 전력 부하의 변동에 영향을 줄 수 있는 요인들을 살펴보면 요일, 기온, 습도, 운량, 휴일 그리고 정책적인 면(예를들면 DSM 등) 등 여러 가지가 있기 때문에 전력시스템에서 일어난 이 1차원적 신호는 여러개의 시스템 변수로 구성된 다차원의 신호의 합으로 가정할 수 있다. 어떤 주어진 n-차원의 신호(Time Series)를 m-차원의 신호로 재구성(Reconstruction)할 때, 이 새로이 생성되는 m차원을 embedding 차원이라 부르며 Takens[14]는 시스템의 원래 차원을 d라 하였을 때, m과 d의 관계는 다음과 같이 식(1)의 조건을 만족시켜야 한다고 하였다.

$$m \geq 2d + 1 \dots \dots \dots (4)$$

본 논문에서는 embedding 차원과 신경회로망의 입력과의 관계를 분석하여 이 embedding 차원 d가 신경회로망의 최적입력이 됨을 보인다.

$$y(t) = \{x(t-\tau), x(t-2\tau), \dots, x(t-(d-1)\tau)\} \dots \dots \dots (5)$$

식(5)에서 τ 를 지연시간(delay time)이라 부르고 주어진 시계열 함수의 resampling 시간을 뜻한다. 이 embedding 차원을 구하는 방법은 여러 가지가 있으나[3],[4] 계산상의 용이함과 빠른 속도 등의 장점으로 본 논문에서는 Grassberger가 제안한 Correlation Dimension을 사용하였다. 이 차원을 계산하기 위해서는 Correlation Sum을 먼저 정의해야 하고 식(6) 같이 정의된다.

$$C(R) = \frac{1}{N(N-1)} \sum_{j=1}^N \sum_{i=1}^N \Theta(R - |y(i) - y(j)|) \quad i \neq j \dots \dots \dots (6)$$

또 여기서 $\Theta(t)$ = Heaviside function

식 (6)의 의미를 살펴보면 반경 R을 변화시켜 감에 따라 공간 내 임의의 두점사이의 Euclidian 거리가 R보다 적은 것들의 개수를 구하여 전체 개수에 대한 비율을 나타낸 것이 식4의 C(R)이다. 이 반경 R을 아주 작은 값에서부터 서서히 변화시켜갈 때, 이 C(R)의 변화를 주시하면 아주 작은 R에서는 모든 점이 포함될 가능성이 적지만 R이 커짐에 따라 이 초구에 포함되는 재구성 점들의 개수는 점점 커지게 된다. 이 변화량을 주시하면서 그 변화량이 갑자기 증가하지 않고 일정하게 증가하는 부분을 우리는

Scaling Region이라 부르고 그때의 기울기를 Correlation Dimension이라 정의한다. 그림 4는 반경 R을 변화시킴에 따른 C(R)의 변화를 log좌표에서 나타낸 것이며 각 그림위의 숫자는 embedding 차원을 나타내고 있다. 그러나 여기서 제기되는 문제점은 일반적으로 실험적 데이터에서 이 Scaling Region을 결정하기란 어려운 일이다. 그림 4에서도 각 차원간의 곡선을 분석해 보면 2차원일 때, 가장 곡선이 완만하다가 차원이 증가됨에 따라 차원이 증가함에 따라 7을 넘어서 부터는 곡선의 변이가 큰 차이를 보이지 않고 있다. 그림 5는 그림 4의 각 차원에 대한 순간 기울기를 계산한 것이다. 역시 차원이 7을 넘어서 부터는 거의 비슷한 분포 형태를 나타내고 있다. 그림 6은 각 차원의 곡선중 기울기가 가장 일정하거나 0에 가까운 Scaling Region을 결정하여 Embedding 차원에 대한 Correlation 차원의 변화를 표시한다.




그림 4. logC(R)-logR plot




그림 5. 반경의 증가에 따른 기울기의 변화

Scaling Region을 결정하는 방법은 그림4의 각 곡선에 대하여 가장 변화량이 적은 R의 구간에 대하여 구하였으며 그 결과는 그림6과 같다. 그림 6.의 결과에서 처음으로 Correlation Dimension이 포화되는 영역인 8이 최적 Embedding Dimension이 됨을 알 수 있다.

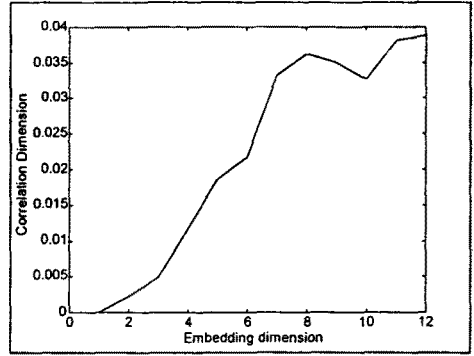


그림 6. Correlation - Embedding Dimension plot

2-4. 예측 후보의 선정

본 논문에서는 특징 추출을 통한 Nearest Neighbor Matching법을 사용하였으며 특징추출은 Euclidian 거리를 이용하였다. 현재의 부하값을 $x(t)$, 예측 하고자 하는 날을 $x(t+1)$ 이라 하면 과거의 데이터들 중에서 $x(t-d)$ 부터 $x(t)$ 까지의 부하패턴상과 가장 유사한 패턴이 확률적으로 그 익일 또한 가장 유사하다는 가정하에서 출발한다. 즉, 앞절에서 입력 패턴의 개수가 8일 때(Dimension 8)를 선정하였으므로 우리가 예측하고자하는 날을 $t+1$ 일이라고 하고 그 전 8일 분의 데이터의 벡터를 다음과 같이 정의하면 식 5에의해 새로운 벡터군 $A(t)$ 는

$$A(t) = \{xn(t), xn(t-1), xn(t-2), \dots, xn(t-(d-1))\} \dots (7)$$

여기서 $d=8, r=1$

이 된다. 이 패턴을 과거의 패턴과 비교하기 위해서는 정규화 과정이 필요하고 그 범위는 0과 1사이로 하였다. 그 이유는 다음 절에서 설명될 신경회로망의 입력으로 사용되기 위해서는 입력 및 출력 패턴의 값이 0과 1 사이에 있어야되고 또 올해의 패턴 절대 크기가 과거년도의 패턴 크기와는 다르므로 정규화를 하지 않을 경우 비교의미가 없어진다. 따라서 다음 식 10을 이용하여 정규화를 한다. 식 9의 d개의 원소에 대한 최대, 최소값을 각각 Max, Min이라 하면 새로이 변환된 부하값($xn_{con}(t)$)들은 다음과 같이 변환되어진다.

$$xn_{con}(t) = \frac{(xn(t) - Min)}{(Max - Min)} \dots (8)$$

따라서 식 9의 $A(t)$ 의 각 원소들을 변환시키면 식 11과 같이 변환다.

$$0 \leq A(t) \leq 1 \dots (9)$$

이 벡터와 유사한 후보 벡터를 과거년도 데이터 베이스로부터 Euclidian 거리를 이용하여 가장 가까운 것부터 그 크기순으로 배열하여 $B(r)$ 배열에 저장한다. 즉 과거년도 데이터베이스의 d차원 단위로 정규화된 값을 $xo(t)$ 라 하면

$$B(r) = \text{sort}(\min \sum_{k=0}^{d-1} |xn_{con}(t-k) - xo(i-k)|) \dots (10)$$

여기서 $i=d, d+1, \dots, \text{end of database}$

식 (10)에서 $B(r)$ 배열의 의미는 계산된 값들을 거리가 작은 순으로 재배열한 것을 의미한다. 또한가지 전체

조건으로 필요한 것은 예측하고자 하는 날의 요일과 같은 요일끼리, 그리고 특수일일 경우는 같은 특수일끼리 비교하여야 한다. 후보의 선정이 끝난 후 1위부터 5위까지의 후보군만 다음에 언급된 신경회로망의 입력으로 사용된다.

2.4 신경회로망에 의한 학습

본 연구에서 사용된 신경회로망은 일반적으로 가장 널리 사용되는 모멘텀을 갖는 Adaptive Backpropagation Model이다. 기존의 신경회로망을 이용한 예측 모델들은 입력의 개수와 선정 문제에 있어서 경험적인 방법을 많이 사용하였다. 본 논문에서는 앞서 설명한 카오스의 별난끝개를 재구성하는데 사용한 Embedding Dimension을 사용하여 이 차원과 입력 개수와의 관계를 규명하였다. 앞에서 언급한 $B(r)$ 의 백터중 상위 5개만을 선택하여 신경회로망의 입력으로 선정하여 학습시킨다. 이렇게 유사한 패턴만을 학습시킬 때는 그렇지 않은 경우보다 수렴속도가 빠르며 학습 오차도 줄어든다. 학습 후 나온 결과를 $O(t+1)$ 이라 하고 실제값을 $O_{predict}(t+1)$ 이라 하면 $O(t+1)$ 은 정규화된(0과 1사이의 값)이므로 식 (10)을 변형시켜 적용하면

$$O_{predict}(t+1) = O(t+1) \times (Max(t+1) - Min(t+1)) + Min(t+1) \dots \dots \dots (14)$$

가 된다. 다시 식 (8)에의해 최종 목적값 $P_{predict}(t+1)$ 은 다음 식 (15)와 같이 된다.

$$P_{predict}(t+1) = x(t) + O_{predict}(t+1) \dots \dots \dots (15)$$

2-5. 실험 결과

그림 7은 학습오차와 예측오차를 각각 점선과 실선으로 나타낸 것이다. 이 결과를 보면 Embedding 차원과 학습오차 및 예측 정도는 서로 밀접한 관계가 있음을 알 수 있다. 즉 학습오차도 7이상의 차원에서는 거의 일정한 수준을 유지하였고 예측의 경우 7-8정도의 차원에서 최소를 보이고 그 보다 큰 경우 오히려 오차가 증가하고 있음을 알 수 있다.




그림 7. 학습 및 예측 오차

III. 결론

본 논문에서는 신경 회로망에 의한 익일 최대부하 예측에 관하여 다루었다. 본 논문의 특징은 다음과 같다.

1. 신경회로망의 최적입력을 결정할 수 있다.

기존의 신경회로망을 이용한 단기예측에서는 입력의 개수 및 종류를 선택하는 방식에 대한 언급이 없었고 단지 간단한 Autocorrelation Function 등에 의해 종류를 선택하는 몇몇가지 방법들이 제안 되었다. 본 논문에서는

카오스의 별난 끝개를 구성할 때 사용하는 Embedding Dimension을 Grassberger의 Correlation Integral을 이용하여 차원을 결정하여 Adaptive Backpropagation Network 상에서 일최대부하 데이터에 대해 적용하여 최적임을 보였다.

2. 입력패턴으로 일부하량의 차분을 사용하여 오차를 줄일 수 있었다.

3. 과거 DB에 대한 k-th Nearest Neighbor Matching법을 사용하였고 이때 비교대상이 되는 후보중에서 특수일 및 같은 요일끼리 비교하게하여 별도의 특수일 처리부분 혹은 모듈없이 특수일의 처리가 가능하였다.

기존의 방법들은 별도의 특수일 처리모듈을 설계하거나 특수일을 제외하고 예측을 시도한 반면에 본 논문에서는 하나의 예측 모듈에 전처리를하여 예측을 하였다.

[References]

- [1] IEEE Committee Report, Load Forecasting Bibliography Phase I, *IEEE Trans. on Power Apparatus and Systems*, vol. PAS-99, 1980, pp. 53-58
- [2] Andreas S. Weigend, Neil A. Gershenfeld, *Time Series Prediction: Forecasting Future and Understanding the Past*, Addison-Wesley Publishing Company, 1992
- [3] M. Sano and Y. Sawada, "Measurement of the Lyapunov Spectrum from a Chaotic Time Series", *Physical Review Letters*, vol. 55, no. 10, 1985
- [4] J. Doyne Farmer and John J. Sidorowich, "Predicting Chaotic Time Series", *Physical Review Letters*, vol. 59, no. 8, 1987
- [5] G. Gross, F. D. Galiana, "Short-Term Load Forecasting", *Proceedings of IEEE*, vol 75, no.12, 1987
- [6] J. Gao and Z. Zheng, "Direct Dynamical Test for Deterministic Chaos", *Euro Physical Letters*, vol. 25, no. 7, 1994
- [7] Hsiao-Dong Chiang et al, "Chaos in a Simple Power System", *IEEE Trans. on Power System*, vol. 8, no. 4, Nov. , 1993
- [8] K. H. Kim, D. Y. Park and J. K. Park, "A Hybrid Model of Artificial Neural Network and Fuzzy Expert System for Short-term Load Forecast", *Proc. of 4th Symp. on Expert System Applications to Power Systems*, Jan. 1993, Melbourne, Australia, pp. 164-169
- [9] K. H. Kim, J. K. park, "Implementation of Hybrid Short-term Load Forecasting System Using Artificial Neural Networks and Fuzzy Expert Systems", *'95 IEEE PES Winter Meeting*, Jan., 1995, NewYork, USA
- [10] Edward Ott, Tim Sauer and James A. Yorke, *Copying With Chaos*, Wiley Interscience, 1994
- [11] Arther R. Bergen, *Power System Analysis*, Prentice-Hall, 1986
- [12] Tomonobu Senjyu et al, "Short-Term Load Forecasting Using Deterministic Prediction Method", 1996, International Conference on Electrical Engineering, Beijing, China
- [13] Robert C. Hilboron, *Chaos and Nonlinear Dynamics*, Oxford University Press, 1994
- [14] F. Takens, "Detecting Strange Attractors in Turbulence", in *Dynamical Systems and Turbulence*, Springer-Verlag, Berlin, pp. 366-381, 1981

- [15] S. Kiartzis, A. Kehagias, A. Bakirtzis and V. Petridis, "Short term load forecasting using a Bayesian combination method". *Electrical Power & Energy Systems*, Vol. 19, No3, pp 171-177, 1997
- [16] S. A. Soliman, S. Persaud, K. El-Nagar and M. E. El-Hawary, "Application of least absolute value parameter estimation based on linear programming to short-term load forecasting", *Electrical Power & Energy Systems*, Vol. 19, No3, pp 209-216, 1997
- [17] S. Rahman and O. Hazim, "A Generalized-Based Short-Term Load Forecasting Technique", *IEEE Trans. on PAS*, Vol. 8, No.2, May, 1992
- [18] C. S. Shin, T. S. Kim, Y.H. Choi and S.H. Park, "Radial Basis Function Network Design for Chaotic Time Series Prediction", *Trans. of KIEE*, Vol. 45, No. 4, April, 1996
- [19] Takeshi Haida and Shoichi Muto, "Regression Based Peak Load Forecasting using a Transformation Technique", *IEEE Trans. on Power Systems*, Vol. 9, No. 4, November, 1994
- [20] H.T. Yang, C. M. Huang and C.L. Huang, "Identification of ARMAX for Short Term Load Forecasting: An Evolutionary Programming Approach", *IEEE Trans. on Power Systems*, Vol. 11, No. 1, February, 1996
- [21] Anssi Seppala, "The Estimation and Simulation of Electricity Customer Hourly Load Distribution", 12-th Power System Computation Conference, Dresden, August, 1996, pp 238-244
- [22] T. Senjyu, S. Higa and Katsumi Uezato, "Short-Term Load Forecasting using Deterministic Prediction Method", *ICEE 96*, pp 86-90, 1996
- [23] N. P. Padhy and S.R. Paranjothi, "Short Term Load Forecasting using Genetic Algorithm", *ICEE 96*, pp 77-80, 1996