

Chaos를 이용한 단기부하예측

최 재균, 박 종근
서울대학교

김 광호
강원대학교

A Daily Maximum Load Forecasting System Using Chaotic Time Series

Jae-Gyun Choi, Jong-Kcun Park
Seoul National University

Kwang-Ho Kim
Kangwon National University

Abstracts - 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, 정보사회로 이행됨에 따라 산업의 규모가 커지고 일반 전력 수용가에서의 냉, 난방 기기등과 같은 전기 기기의 사용이 급증하고 있다. 이에 따라 주말, 공휴일 등에 대한 전력의 사용 패턴이 과거와는 다르게 나타나며 특히 냉방기의 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 회사의 경제성 추구하고 수용가측의 안정성 요구를 동시에 만족시켜 주기 위해서는 향후에 발생하게 될 전력의 수요를 보다 정확하게 예측하여 이에 맞는 전력을 공급하는 것이 최선의 방법이라고 여겨지기 때문이다.

본 논문에서는 단기 전력 수요 예측에 대해서 다루었고 단기 예측 중 익일(翌日) 최대 전력 예측을 주로 다루었고 카오스 이론을 이용한 예측을 시도하였다. 과거의 시계열 데이터를 이용해 Attractor를 구성하였고 이 Attractor의 궤적을 인공신경회로망으로 학습하여 예측을 시도하였다.

II. 본론

2-1. Chaos

최근 약 20년 사이에 비선형 동역학(Nonlinear Dynamics)분야에 새로운 개념의 이론이 등장하여 여러분야에서 활발한 검토 및 연구의 대상이 되고 있다. 이

카오스 현상이 발생하는 곳은 매우 다양하며 특히 자연계의 움직임 속에서 착안되었다. 이 자연 현상들 속에서 원인을 알지도 결과를 예측할 수 없는 것들, 예를 들어 대기의 운동은 천체들처럼 물리학 법칙을 준수하나 기상 예보에서는 아직도 확률의 용어를 쓰고 있는 실정이다. 그 중에서도 활발한 연구를 보이고 있는 분야가 예측(Prediction)분야 이고 주기(株價) 예측, 환율 예측 등 경제 분야에서 많은 연구가 진행되고 있다. 이러한 분야들과 유사하게 시계열 데이터를 다룬다는 입장에서 전력 수요 예측과 상당한 유사성이 있다. 이러한 시계열 데이터를 이용한 Chaos 예측 방법에 대해서 살펴 보면 먼저 카오스 성질은 다음과 같은 특징을 들 수 있다.

- 결정론적(的)이다.
- 복잡한 형태를 띠고 있다.
- 장기 예측이 불가능하다.
- 자기 유사성을 가지고 있다.

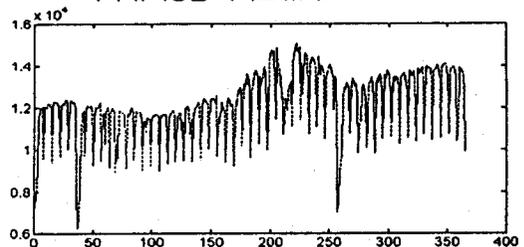


그림 1. 일별 최대부하 곡선(단위 MW) 1989년

그림 1에서 본 바와 같이 전력 수요 곡선(일별 최대 부하 곡선)은 1주일의 주기로 유사성을 어느 정도 가지고 있으나 특수일, 예를 들어 설날이나 하절기의 냉방 수요, 추석 등의 변수에 따라 복잡한 형태의 변이가 발생하여 예측이 어려운 형태를 띠고 있다.(불확실성, 복잡성)

일반적으로 어떤 대상이 카오스성을 가지고 있는지의 유무를 판별하기 위한 방법들은 여러 가지가 있다. 본 연구에서는 이중 Fourier Spectrum과 Attractor를 이용하여 카오스 성을 검증하였고 카오스성을 찾은 뒤에는 Well-Shaped Attractor를 구성하고 그것을 바탕으로 예측을 행하였다.

2-2. 부하 곡선의 분석 및 카오스

앞서 그림 1에서도 본 바와 같이 일별 최대 부하 곡선은 1주일을 단위로 어떤 유사성을 가지고 있음을 알 수 있다. 일별 부하 곡선에 대해서 Fourier Spectrum을 구해 보면 그림 2와 같은 형태를 나타낸다. 카오스성이 있는 경우, 그 Spectrum은 전영역에 걸쳐 고른 분포를 나타내는 것이 특징이며 카오스성이 없는 경우는 어떤 일정한 영역에만

분포를 보이는 경향을 나타낸다. 따라서 일일 최대 전력 부하는 카오스 특성이 존재함을 알 수 있다.

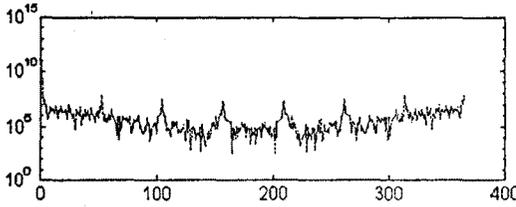


그림 2. 부하 곡선의 Fourier Spectrum 분석

2-3. 벌안 끌개(Strange Attractor)의 구성

만일 어떤 시스템에 대한 미분(혹은 차분) 방정식을 알고 있다면 즉, 그 시스템의 동역학(Dynamics)이 주어지면 시스템의 미래값을 예측하는 것은 쉬운 일이다. 그러나 전력 부하 예측에서는 우리가 알 수 있는 정보는 부하의 변동, 즉 시계열 데이터(Time series data)뿐이므로 이 정보만 가지고 state space phase plane을 구성하여야 한다. 일단 Phase Plane이 구해진 후라면 현재 시간의 값을 알면 궤적을 따라 움직이면서 t+시간의 상태를 알 수 있다. 마찬가지로 전력 수요의 시계열 데이터로 이 Phase plane을 유도해 낸다면 예측을 할 수가 있다. 그러나 운동 방정식을 모르는 상태에서 정확한 궤적을 그리는 것은 불가능하고 따라서 Pseudo Phase Plane을 구성하여야 된다. 이 경우에 있어서 시계열 데이터로 최소 embedding dimension과 delay time을 구하여야 하는데 각각은 다음과 같은 방법으로 구하였다.

1) 최소 embedding dimension

embedding dimension이라 함은 대상 시스템의 변수의 차수를 뜻하는 것으로 주어진 데이터가 몇차원 혹은 몇 개의 독립된 변수로 기술 될 수 있는가 하는 것을 의미한다. 최소 embedding dimension을 구하는데 널리 쓰이는 방법으로 k-th nearest neighbor를 구한 후 False Nearest Neighbor법을 이용하였고 그 방법을 이용한 결과는 다음과 같다. 주어진 시계열 데이터를 $x(n)$ 이라 하면 이 데이터로 차원의 벡터로 구성할 수 있다.

$$y(n) = \{x(n), x(n+T), \dots, x(n+(d-1)T)\}$$

여기서 d : Embedding Dimension
T : Delay Time

구하여진 각 Vector들 중, 만일 k-th nearest neighbor를 $y^k(n)$ 이라 한다면

$y(n)$ 과 이 neighbor와 의 유클리디언 거리는 다음과 같이 표현 할 수 있다.

$$R_d^2(n,r) = \sum_{k=0}^{d-1} [x(n+kT) - x^{(r)}(n+kT)]^2$$

여기서 d(embedding dimension)을 점차 1씩 증가하여 갈 때, 더이상 이웃 점들이 거리가 멀어지지 않을 때를 최소 embedding dimension이라 설정한다. 그림 3은 이 방법으로 하였을 때의 False neighbor의 개수를 percentage로 표시한 것이다. 즉 False Neighbor가 더 이상 감소하지 않을 때를 결정하는 것이다.

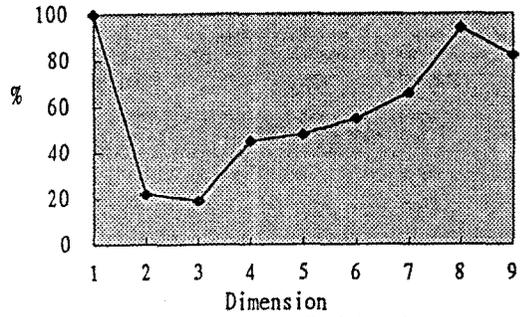


그림 3. False NN법에 의한 결과

2) Delay Time의 설정

Delay Time을 결정하는 문제도 이 Attractor를 구성하는데 있어 상당히 중요한 요소로 작용을 한다. 이 Delay Time을 정하는 문제에는 아직 Optimal한 방법이 소개되어 있지 않기 때문에 대부분 각 delay Time을 변화시켜 가면서 Well shaped Attractor를 구성하고 있다.

본 논문에서는 각 궤적간의 교차빈도수(Crossing Rate)를 구하여 Minimum이 될 때의 값을 구하여 최적 Delay Time으로 하였다. 교차 빈도수는 다음과 같이 정의된다.

Attractor를 구성하는 점이 n개이면 총 Line의 수는 n-1개가 된다. 따라서 각 궤적으로 이루어지는 선분의 방정식을 f_k 라 하자. k를 1부터 n-1까지 증가 시키면 다른 f_{rk} 인 선분과의 교차수를 계산하여 전체 n-1로 나눈다.

교차빈도수 C = (각 선분들이 다른 선분과의 교차횟수의 합)/(n-1)

완전한 형태의 Attractor라면 이 교차율은 0%에 가깝게 된다.

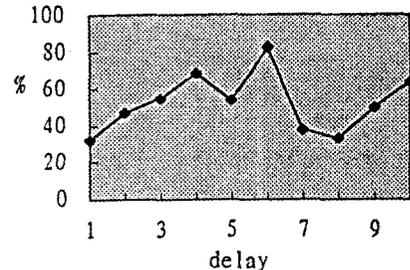


그림 4. Crossing Rate %

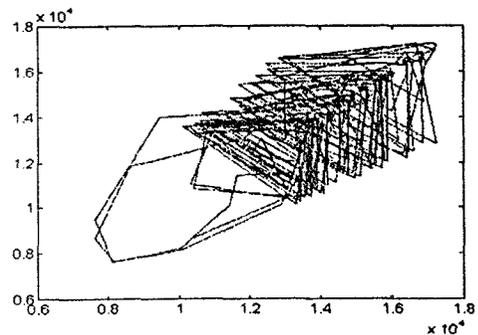


그림 5. Attractor의 구성

그림 4에서 보면 delay 1, 7, 8일때 궤적간의 교차율이

작음을 알 수 있다. 다시말하면 하루 전과 1주일, 8일전의 데이터가 현재 시점의 값과 가장 밀접한 관계를 가지고 있음을 알 수 있다. 아래의 그림은 delay time이 1인 경우의 Attractor를 나타내고 있다.

2-4. 예측(Forecasting)

카오스 예측 방법에는 예측함수를 근사화 하는 방법에 따라 Global 기법과 Local 기법으로 나뉜다. Global 기법은 예측 함수를 전체 Attractor의 궤적을 근사화 하는 방법으로 비교적 구현이 쉬운 반면에 비교적 큰 Embedding Dimension과 Delay Time을 설정하여 계산량이 많은 단점을 지니고 Local 기법은 일정한 Step단위로 국지적인 근사함수를 만들어 나가므로 계산량이 많은 단점은 있지만 비교적 근사율이 높다는 장점을 지니고 있다. 본 논문에서는 1년 전의 수요 곡선으로 Attractor를 구성하고 그 Attractor를 Neural Network으로 학습을 하여 일단 Global predictor를 구성하고 예측 년도의 실제값을 이용하여 1주일 단위로 새로운 데이터를 학습하여 정밀도를 높였다. 예측의 수순은 다음과 같다.

step 1) 1년전의 부하 곡선을 데이터로 Embedding Dimension과 Delay Time을 결정한다.

step 2) 2차원 평면상에 Attractor를 구성하고 각 좌표와 방향을 기억한다.

step 3) n-개의 좌표를 입력으로 n시점일 때를 출력으로 하여 NN을 학습시킨다.

step 4) 학습된 결과를 바탕으로 당해 년도의 일별 부하량을 예측시키고 1주일 단위로 재학습을 시킨다. (NN의 보정)

본 논문에서 사용된 NN은 Adaptive Back propagation Algorithm을 사용하고 2개의 은닉층을 갖고 각 9개의 뉴런을 갖고 있다.

2-6 예측 값의 보정

학습된 데이터가 예측년도에 대해 1년전의 값이기 때문에 매년 Attractor를 구성해 보면 20%정도 기본적인 shift가 생김을 알 수 있다. 따라서 NN의 입력시 Normalize를 할 때 그에 해당하는 양을 고려하여 정규화를 하고 출력시 이를 보정하여 주면 된다.

III. 사례 연구

본 논문에서는 제안된 수법으로 1989년부터 1991년까지 3개 년을 학습하여 1990년부터 1993년까지의 최대 부하 전력을 예측하였고 그림 6 및 그림 7에 그 결과를 도사하였다.

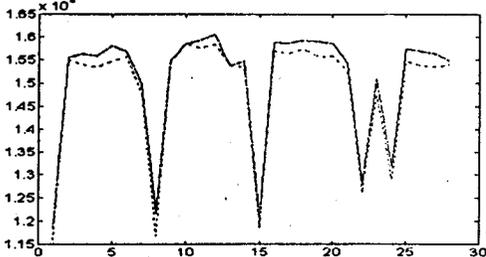


그림 6. 1990년 1월의 예측 결과
실선 : 실제값 점선 : 예측값

년도	1990	1991	1992
오차율(%)	1.389	1.495	1.533

IV. 결론 및 향후 계획

카오스성을 이용한 익일 최대 부하 예측은 기존의 인공 신경 회로망을 이용한 방법이나 시계열 해석법에 비하여 좋은 결과를 나타내고 있다. 일반적으로 신경 회로망의 경우 경험적인 법칙으로 입력 데이터를 선정하거나 개수를 정하여야 하는 단점을 보이는 반면에 Attractor를 구성하면서 얻어지는 Embedding Dimension이나 Delay Time 등의 결과가 바로 NN의 입력으로 사용되어지기 때문에 데이터의 선정 시 필요한 노하우를 제공하고 있다. 또 예측 함수의 근사는 Attractor를 구성하는 각각의 Vector의 좌표로 학습되어지기 때문에 학습데이터로 구성된 Attractor와 예측 년도의 Attractor와는 단지 그 절대치에서 만 차이가 나고 기본 모양은 비슷하기 때문에 비교적 작은 오차율을 보이고 있다.

향후 최소 Embedding Dimension의 설정시 Lyapunov 지수나 Correlation dimension등을 이용하여 보다 고차원의 Attractor를 구성하여 안정된 예측을 할 수 있는 방법의 강구가 필요하며 장기 부하 예측 방법의 도움을 받아 자동으로 다음 년도의 전력 증가율을 산정하여 보장하게 하는 연구의 추진이 필요하다. 본 연구에서 사용한 Adaptive Back Propagation NN은 수렴성이 양호하기는 하나 학습에 요하는 시간이 많이 걸리고 편차가 발생하였을 때 미다 보정해 주어야 하는 번거로움이 있으므로 RBF(Radial Basis Function) NN을 이용한 학습 방법도 고려할 예정이다.

V. 참고 문헌

1. M. Sano and Y. Sawada, "Measurement of the Lyapunov Spectrum from a Chaotic Time Series", Physical Review Letters, Vol. 55, No. 10, 1985
2. J. Doyné Farmer and John J. Sidorowich, "Predicting Chaotic Time Series", Physical Review Letters, Vol. 59, No. 8, 1987
3. G. Gross, F. D. Galiana, "Short-Term Load Forecasting", Proceedings of IEEE, vol 75, no.12, 1987
4. 合原 一幸외 1인, "카오스とその電力分野 への應用", 일본 전기학회 논문지 B, Vol. 114, No 2, 平成 6年
5. 伊庭 健二, "카오스의電力技術への應用", CHM
6. J. Gao and Z. Zheng, "Direct Dynamical Test for Deterministic Chaos", Euro Physical Letters, Vol. 25, No. 7, 1994
7. Hsiao-Dong Chiang외 4인, "Chaos in a Simple Power System", IEEE Trans. on Power System, Vol. 8, No. 4, Nov. , 1993
8. 森啓之외 1인, "電力需要의 카오스성을考慮したRBF 네트워크による短期負荷豫測", 일본전기학회논문지, PE-94-49, 平成6年
9. 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", 4th Symp. on Expert System Applications to Power Systems, Jan. 1993
10. 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