

유전자알고리즘과 퍼지시스템을 이용한 단기부하예측 시스템 개발에 관한 연구

A Study on development of short term electric load prediction system with the genetic algorithm and the fuzzy system

강환일^{*} · 장우석^{*}

Hwan-il Kang, Woo-seok Jang

* 명지대학교 정보공학과

요약

본 논문은 퍼지 시스템과 유전자 알고리즘을 이용하여 단기 전력 부하 예측 방법을 제안한다. 우선 유전자 알고리즘을 이용하여 최적의 퍼지 소속함수를 구한다. 최적의 퍼지 규칙과 시계열 입력 차이를 이용하여 보다 더 나은 예측 시스템을 구한다. 제안된 방법을 이용하여 단기 전력 부하 예측에서 좋은 결과를 얻었다. 또한 제안된 알고리즘에 대한 그래픽 사용자 인터페이스를 구현한다. 마지막으로, 전력부하에 대한 지역 예측 시스템을 구현한다.

키워드 : 유전자 알고리즘, 시계열 예측, 퍼지 시스템

Abstract

This paper proposes a time series prediction method for the short term electrical load with the fuzzy system and the genetic algorithm. At first, we obtain the optimal fuzzy membership function using the genetic algorithm. With the optimal fuzzy rules and its input differences, a better time prediction system may be obtained. We obtain good results for the time prediction of the short term electric load by the proposed algorithm. In addition we implement the graphic user interface for the proposed algorithms. Finally, we implement the regional prediction system for the electric load.

Key Words : genetic algorithm, time prediction, fuzzy system

1. 서 론

시계열(Time series)은 정해진 순간마다 측정된 값 x_1, x_2, \dots, x_n 들의 모임이다. 시계열예측의 응용은 사업 계획 수립, 일기예보, 주가예측과 다양한 신호처리분야 등에서 활발히 응용 발전하고 있다. 일반적으로 시계열은 혼돈된 신호이거나 불규칙적인 특성을 가지고 있어 이를 험수로 모델링하기에는 부족함이 있다. 따라서 근래에는 시계열에서 퍼지규칙과 적당한 소속함수를 선택하여 시계열을 모델링하려는 경향이 있다.[1] 시계열중 특정주기를 가지는 값 사이에는 얼마간의 종속성이 발견되고, 이런 성격에 근거하여 시계열의 발생원을 분석할 수 있다. 즉 시계열의 발생원은 어느 정도의 결정론적인 동력학 시스템(Deterministic Dynamic System)에 의해 지배를 받는다고 볼 수 있기 때문에 우리가 얻는 시계열은 예측이나 모델링을 통해 분석이 가능하다[1]. 신경망과 퍼지 논리를 적용한 모델링과 예측은 과거부터 많은 연구가 수행되었던 문제이다.[2,3,4,5]

Wang과 Mendel[6]은 학습을 통하여 퍼지규칙을 발생시

켰고 Jang과 Sun[7]은 퍼지 IF-Then 규칙을 혼돈신호예측에 이용하였다. Ye와 Gu[8]는 상하이 주가시장예측을 위한 퍼지시스템을 개발하였다. 또한 smart trading을 위한 퍼지 규칙이 Benachenhou[9]에 의해 개발되었다.

이 논문에서는 변형된 입력 방법을 도입함으로써 더 나은 시계열 예측 결과[10]을 얻고 또한 소속함수의 개수를 고정되어 있을 때 소속함수의 변형이 보다 더 좋은 예측결과를 나타냄을 보여주기 위함이다. 성능을 비교하는 척도로는 절대 평균 퍼센트 오차(Mean Absolute Percent Error (MAPE))를 사용하여 사용된 표 데이터는 1997년, 1998년 각 시각별 전력 부하 데이터를 이용하였다. 평일부하예측, 시간, 일일, 주간 예측 실험을 수행하였다. 유전자 알고리즘을 이용하여 소속함수의 최적화를 구하였다. 또한 지역 부하데이터를 이용하여 다른 지역의 부하데이터를 예측하는 실험을 실행하였다. 예를 들면 전라북도와 전라남도의 부하데이터를 이용하여 강원도의 부하데이터를 예측하는 실험을 하였다. 학습을 위한 데이터는 1996년부터 2003년 월 데이터를 사용하였으며 출력은 2004년부터 2005년 8월까지 예측하였다.

2. 퍼지 추론 방법

퍼지 추론 시스템은 식(1)을 만족하는 퍼지규칙 R 을 찾아내는 작업이다.

접수일자 : 2006년 10월 8일

완료일자 : 2006년 11월 30일

감사의 글 : 본 연구는 산업자원부의 지원에 의하여 기초전력연구원 (과제관리번호: R-2004-B-201) 주관으로 수행된 과제임.

$$\widehat{x_{n+k}} = R(x_1, x_2, \dots, x_n) \quad (1)$$

위의 식은 단기간의 예측에 이용된다. 보다 더 개선된 방법으로 식 (1) 대신에 변형된 입력 $(x_1 - x_2), (x_2 - x_3), \dots, (x_{n-1} - x_n)$ 을 사용하면 보다 더 좋은 결과[10]를 얻을 수 있다. 즉 식(2)을 이용하여 예측할 수 있다.

$$\widehat{x_n} - \widehat{x_{n+k}} = R((x_1 - x_2), \dots, (x_{n-1} - x_n)) \quad (2)$$

이 논문에서는 식 (2)를 이용하고 퍼지규칙은 우선 변형된 입력과 변형된 출력력을 이용하여 퍼지 소속함수 중 어느 곳에 속하는가를 결정한다. 예를 들면 $(x_1 - x_2)$ 의 경우, 주어진 퍼지 소속함수 중에 어느 함수에 가장 많이 속하는 퍼지 소속함수를 기억하고 그 소속함수 값도 기억한다. 이때 동일한 전전부에 대하여 상이한 후전부가 발생하면 모순된 규칙이 발생하게 된다. 이 경우 Max-Min의 방법을 이용하면 해결 할 수 있다.[10] Max-Min의 방법은 모순된 규칙의 입력과 출력의 모든 소속함수의 최소값이 큰 것이 있는 것을 후전부로 택하는 방식이다. 이 퍼지규칙을 이용하여 예측치를 구하기 위해 Middle of Area(MOA), 중앙평균법(Centroid), Middle of Maxima(MOM)등의 비퍼지화기법을 사용하고 출력을 얻기 위해서는 Mandani의 Max-Min방법과 Larson product 방법을 사용할 수 있다.[12,14]

본 논문에서는 두 개의 입력을 이용하여 하나의 출력을 구하는 방식을 선택하고 Mandani의 Max-Min방법과 중앙평균법을 이용한다.

3. 유전자 알고리즘 기법의 도입

퍼지함수의 모양을 동일한 모양의 삼각형으로 구성할 수 있으나 입력과 출력의 상황에 따라 퍼지함수를 각각 다른 삼각형의 모습으로 변형시키기 위해 유전자알고리즘을 도입한다. 교배와 돌연변이가 주연산자인 유전자알고리즘을 이용하여 최적의 퍼지 함수모양을 정하여 예측결과를 구하였다.

3.1 유전자 알고리즘

유전자알고리즘은 생물학적 진화와 적자생존의 원리를 이용한 반복적인 탐색최적화기법으로 경사하강법(Steepest descent)의 단점인 지역극소점에 빠질 가능성을 제거하는데 있다. 유전자알고리즘의 특징은 주어진 변수에 해당되는 이진수를 만들고 적합도함수를 구하여 적합도함수의 값에 따라 다음세대에 선택되어 지는데, 2개의 기본연산자로서 교배와 돌연변이가 있으며 선택이라는 방법을 통해 반복 수행된다.[11] 선택의 방법은 비례선택, 룰올렛 훨(Roulette Wheel), 토너먼트(Tournament), 우월주의를 갖는 토너먼트(Tournament with Eliticism)등이 있다. 유전자알고리즘에 관한 수학적 기초는 다음과 같다. 유전자 알고리즘은 길이가 ℓ 인 이진(binary)표현을 사용하며 한 세대의 수(Population size)가 N으로 고정된 형태의 유전자 알고리즘이다. 이 논문에서는 선택(selection)방법으로 룰올렛 훨과 우월주의(eliticism)를 사용하고 한 점에서의 교배(crossover)와 돌연변이(mutation)를 사용한다. 각 세대의 개체는 개체공간(individual space) $S = \{0, 1\}^\ell$ 에 표현되며, 세대공간(Population space)을 S^N 그리고 부모 공간을 S^2 으로 나타낸다. 편의를 위해서 세대 $X \in S$ 를 아래와 같은

벡터와 행렬로 나타낸다.

$$X = (X_1, X_2, \dots, X_N)^T = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1l} \\ x_{21} & x_{22} & \dots & x_{2l} \\ \dots & \dots & \dots & \dots \\ x_{N1} & x_{N2} & \dots & x_{Nl} \end{pmatrix}$$

여기서 $X_i \in S$ 는 벡터 X 의 i 번째 개체이며 반면에 x_{ij} 는 X_i 의 j 번째 요소이다. 이러한 유전자 알고리즘의 동작과정은 다음과 같은 5단계로 분류할 수 있다.

- 1 단계) $k=0$ 로 설정하고 초기세대 $X(k)$ 을 발생시킨다.
- 2 단계) 현 세대로부터 N개의 개체의 쌍을 선택한다.
- 3 단계) 선택된 N개의 개체의 쌍을 교배시켜 새로운 N개의 개체를 생성한다.
- 4 단계) 새로운 N개의 개체에 대해 각 비트 돌연변이를 수행한다.
- 5 단계) 정지조건을 만족하면 동작을 끝내고 그렇지 않으면 $k=k+1$, 그리고 단계 2)로 간다.

4. 소속 함수의 정의

기존의 방법은 소속함수를 입력변수의 최소값과 최대값 사이를 임의의 개수로 등분하여 일률적으로 정의하였다. 그러나 시계열은 어떤 특정한 값 근처에 많이 분포할 가능성이 있으므로 그 특성에 따라 소속함수를 정의하는 것이 보다 합리적인 방법이다. 본 논문에서는 유전자알고리즘을 이용하여 소속함수를 정의한다. 소속함수 정의 알고리즘은 다음과 같다.

단계1 : 랜덤 수를 50개를 생성시킨다. 이 50개를 염색체로 이용한다. 그중에서 가장 작은 4개를 선정하고 그것이 있는 자리는 1로 다른 자리는 0으로 하여 50개의 비트를 가진 이진수를 만든다.

단계1 : 6개의 소속함수 다음과 같이 정의한다.

$$\mu_1 = \frac{(x - p_{\min} + \epsilon)}{\epsilon} \quad p_{\min} - \epsilon < x < p_{\min} = b(0)$$

$$\frac{(b(1) - x)}{b(1) - p_{\min}} \quad p_{\min} < x < b(1)$$

$$\mu_i = \frac{(x - b(i-2))}{b(i-1) - b(i-2)} \quad b(i-2) < x < b(i-1)$$

$$\frac{(b(i) - x)}{b(i) - b(i-1)} \quad b(i-1) < x < b(i)$$

$$(i = 2, \dots, 5)$$

$$\mu_6 = \frac{(x - b(4))}{p_{\max} - b(4)} \quad b(4) < x < p_{\max} = b(5)$$

$$\frac{(p_{\max} - x) + \epsilon}{\epsilon} \quad p_{\max} < x < p_{\max} + \epsilon$$

여기서

$$b(i) = p_{\min} + \frac{j(i)(p_{\max} - p_{\min})}{51}, \quad i = 1, 2, 3, 4$$

이고 $j(i)$ 는 50개의 비트를 가진 이진수에서 자릿수를 왼쪽에서 오른쪽으로 세어 i 번째 1이 나오는 자릿수가 j 라는 것을 뜻한다. 예를 들면 이진수 000000000100000000010000000001000000000000에서 $j(2) = 20$ 이 된다.

단계3 : 단계2의 소속함수를 이용하여 학습데이터를 이용하여 퍼지규칙을 찾아내고 이 최적의 소속함수를 구하기 위해 테스트 데이터를 이용하여 MAPE(mean absolute percentage error)의 역수를 적합도 함수로 정하였다. 유전자 알고리즘을 이용하여 최적의 소속함수의 모양을 찾는다.

유전자알고리즘을 구현하기 위한 각 변수들의 정의와 값은 다음과 같다. 세대수는 40세대이며 문자열의 최대길이는 50개 교배 율은 0.3, 돌연변이율은 0.01, 교배의 위치는 한번만 허락하며, 선택은 룰올렛 훨과 우월주의를 반반씩 이용하였다. 그리고 교배는 50개의 랜덤수를 가지는 두 염색체를 이용하여 행하며 돌연변이는 돌연변이가 일어난 곳은 실수인 난수를 선택한다. 기준의 유전자 알고리즘은 이진수를 이용하나 본 논문에서는 실수를 이용한다. 그리고 MAX-MIN 법과 중앙평균법을 이용하였다.

5. 실험

본 논문에서는 평일 데이터에 의한 각 월별 실험 결과 및 지역 부하 예측을 실험하였다. 평일이라는 개념은 화요일, 수요일, 목요일, 금요일을 뜻한다. 그리고 성능 지수로서 MAPE 값을 구하였다. 또한 특수일, 토요일, 일요일, 월요일의 부하 예측 시스템도 개발하였다. 특수일이라는 개념은 공휴일을 뜻한다.

5.1 성능 평가 함수

본 논문에서 예측 알고리즘의 성능을 평가하기 위해 절대 평균 퍼센트 오차 MAPE(mean absolute percentage error)을 사용하였다. 즉

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{T_i - E_i}{T_i} \right| \times 100 (\%)$$

로 표현된다. 여기서 T_i 는 실제 값을 뜻하고 E_i 는 예측 값을 뜻하며 N 은 예측시스템의 데이터의 개수를 뜻한다.

5.2 평일 데이터에 의한 연별 예측 실험

본 논문에서는 1997년의 평일의 매시간 데이터를 이용하여 한 시간 후를 예측하는 실험을 하였다.

다시 말해 이 경우 리드 시간(lead time)이 한 시간이라고 한다. 리드 시간이 1시간인 경우 출력이 $i + 24$ 번째 시각의 데이터이면 입력중 하나는 i 번째 시각의 입력을 사용하는 것이다. 두 번째 입력은 $i + 23$ 번째 입력을 이용한다. 그림 1에서는 평일의 전기부하를 나타낸다. 여름철에 전기 부하를 많이 소비하고 겨울철에 2번째로 많이 소비하는 것을 볼 수 있다. 그림 2에서는 6개의 퍼지 함수와 퍼지 규칙 데이터베이스를 이용하여 예측 값과 실제 값을 비교하였다. 그 결과 MAPE(mean absolute percentage error)는 2.43%로 나타난다. 그림 3의 위 그림은 적합도 함수의 최대치와 평균치의 변화를 나타낸다. 그림 3의 아래그림은 최적의 소속함수의 모양을 나타내었다.

5.3 평일 데이터에 의한 월별 예측 실험

본 논문에서는 1997년의 평일의 매시간 데이터를 이용하여 한 시간, 하루, 일주일 후를 예측하는 실험을 하였다. 다시 말하면 리드 시간[15]이 한 시간, 24시간, 168시간으로 나누었다. 일반적으로 성능이 매우 우수하게 나타났다. 유전자 알고리즘을 이용하는데 세대수를 200회 각 세대의 수를 6개로 하고 교배율은 0.3, 돌연변이 확률은 0.01로 하여 실험하였다. 그 결과를 표 1, 2, 3에 보였다. 5.2절에 나타난 결과와 차이점은 5.2절에서는 일년을 예측한 결과이고 5.3절에서는 한 달을 예측한 실험을 서술하였다.

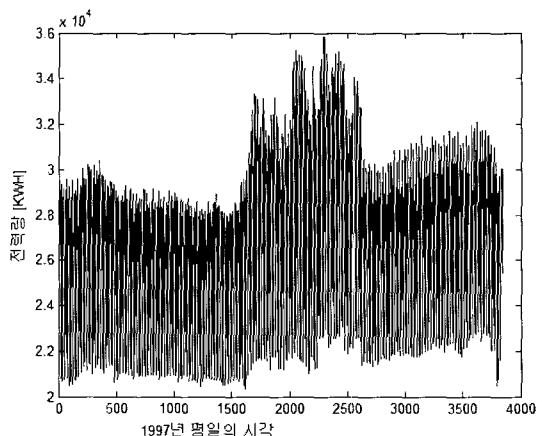


그림 1. 각 시각별 평일의 전기 부하

Fig. 1. Electric load for the normal days per each

표 2에서는 리드시간(lead time)이 24시간인 경우의 결과를 나타낸다. 여기서 리드시간이 24시간인 경우는 다음과 같다. 최대 리드 시간이 24시간으로 선택하는 것이다. 즉 최소 1시간에서 24시간의 리드시간을 설정할 경우 대표적으로 리드시간을 24시간이라고 정의한다.

여기서 리드 시간이 24시간인 경우 두 입력중의 하나의 입력과 출력의 차이가 24 시간 차이가 나도록 설정하였다. 즉 출력이 $i + 24$ 번째 시각의 데이터이면 입력중 하나는 i 번째 시각의 입력을 사용하는 것이다. 두 번째 입력은 $\text{ceil}(i/24)*24$ 번째 입력을 이용한다. 여기서 $\text{ceil}(x)$ 은 정수이며 x 보다 작지 않으나 $x + 1$ 보다 크지 않다.

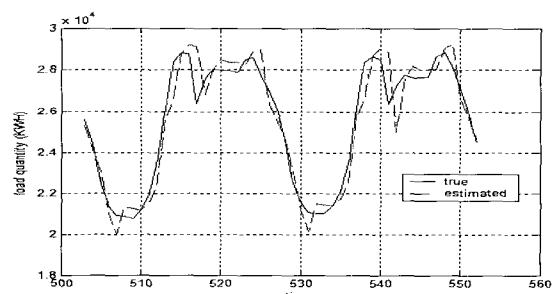


그림 2. 실제치와 예측치

Fig. 2. The predicted value vs the true value

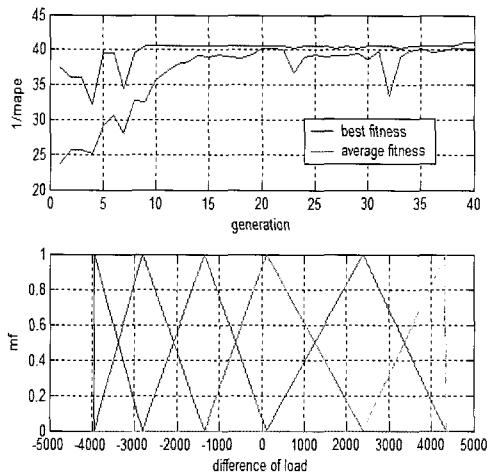


그림 3. 위: 가장 성능이 좋은 적합도 함수와 평균 적합도 함수
아래: 최적 소속함수

Fig. 3. Above: The best fitness and average fitness.
Bottom: The optimal membership function

표 1. 리드타임이 1시간인 경우 각 월별 MAPE
Table 1. The MAPE per each month for the hourly prediction

월	MAPE (1997)	MAPE (1998)	학습월일기간
1	1.15	1.19	1월(24*3+1 ~ 24*8)
2	1.26	1.34	1월(24*3+1 ~ 24*8)
3	1.05	1.33	1월(24*3+1 ~ 24*8)
4	1.21	1.19	1월(24*3+1 ~ 24*8)
5	1.20	1.42	1월(24*3+1 ~ 24*8)
6	1.55	1.38	1월(24*3+1 ~ 24*8)
7	1.44	1.66	98년2월(24*3+1 ~ 24*8)
8	1.38	1.43	97년8월(24*3+1 ~ 24*8) 98년5월(24*3+1 ~ 24*8)
9	1.40	1.21	98년2월(24*3+1 ~ 24*8)
10	1.43	1.02	1월(24*3+1 ~ 24*8)
11	1.08	1.07	1월(24*3+1 ~ 24*8)
12	1.16	1.06	1월(24*3+1 ~ 24*8)

표 2. 리드타임이 24시간인 경우 각 월별 MAPE
Table 2. The MAPE per each month for the daily prediction

월	MAPE (1997)	MAPE (1998)	학습월일기간
1	1.09	1.17	1월(24*3+1 ~ 24*8)
2	1.06	1.13	1월(24*3+1 ~ 24*8)
3	1.13	1.14	1월(24*3+1 ~ 24*8)
4	1.10	1.06	1월(24*3+1 ~ 24*8)
5	1.09	1.30	1월(24*3+1 ~ 24*8)
6	1.59	1.31	1월(24*3+1 ~ 24*8)
7	1.41	1.44	1월(24*3+1 ~ 24*8)
8	1.37	1.29	1월(24*3+1 ~ 24*8)
9	1.18	1.16	1월(24*3+1 ~ 24*8)
10	1.08	1.10	1월(24*3+1 ~ 24*8)
11	1.03	1.12	1월(24*3+1 ~ 24*8)
12	1.20	1.03	1월(24*3+1 ~ 24*8)

표 3에서는 리드시간(lead time)이 168시간인 경우의 결과를 나타낸다. 여기서 리드 시간이 168시간인 경우, 두 입력 중, 하나의 입력과 출력의 차이가 168시간 차이가 나도록 설정하였다. 즉, 출력이 $i + 168$ 번째 시각의 데이터이면 입력 중 하나는 i 번째 시각의 입력을 사용하는 것이다. 두 번째 입력은 $\text{ceil}(i/168)*168$ 번째 입력을 이용한다. 그리고 MAPE의 평균치는 각각 리드시간이 1시간, 하루, 주별로 보면 각각 1.28, 1.19, 1.17%로 우수하게 나타났다.

표 3. 리드타임이 168시간인 경우 각 월별 MAPE
Table 3. The MAPE per each month for the weekly prediction

월	MAPE (1997)	MAPE (1998)	학습월일기간
1	1.20	0.96	97년:24*3+1 ~ 24*8(1월) 98년:24*1+1 ~ 24*5(1월)
2	0.82	0.91	위와 같음
3	1.18	1.34	위와 같음
4	1.16	1.05	위와 같음
5	1.08	1.22	위와 같음
6	1.24	1.48	위와 같음
7	1.32	1.49	위와 같음
8	1.51	1.32	위와 같음
9	0.99	1.25	위와 같음
10	1.36	1.12	위와 같음
11	1.07	1.01	위와 같음
12	0.96	0.92	위와 같음

5.4 지역부하 예측 실험

본 논문에서는 전력부하데이터를 이용한 지역 부하 예측을 실험하였다 표 4에서 보듯이 전라북도와 전라남도를 입력으로 이용하고 강원도를 출력으로 이용하면 MAPE 값이 3.1627%가 된다. 이때 세 지역의 선택은 계통수(dendrogram)[13]에서 전라북도와 전라남도는 유사도가 가장 높다. (그림 5참조) 그리고 출력으로 사용하는 강원도는 앞의 두 지역과 가장 유사도가 큰 지역을 택하였다. 이때 세 대수를 200세대로 각 세대의 크기를 6으로 선택했다. 교배확률 $P_c = 0.3$ 이고 돌연변이 확률 $P_m = 0.01$ 로 설정하였다. 학습을 위한 데이터는 1996년부터 2003년 월 데이터를 사용하였으며 출력은 2004년부터 2005년 8월까지 예측하였다.

표 4 유전자 알고리즘에 의한 MAPE
Table 4 The MAPE by the genetic algorithm

지역	유전자알고리즘
전라북도와 전라남도-강원도	3.1627
부산광역시와 인천광역시-충청북도	2.9117
광주광역시와 대전광역시-제주도	3.8919
부산광역시와 인천광역시-충청남도	3.6901

6. Graphic User Interface(GUI)

본 절에서 설명하는 Graphic user interface는 유전자 알

고리즘을 이용하고 특수일 외에 토요일, 일요일, 월요일등의 메뉴를 추가하고 exit버튼도 설치하였다. 또한 지역 부하 예측 시스템의 GUI를 나타내었다.

6.1 평일 예측 시스템의 GUI

그림 4에서는 1997년 1월 데이터의 예측 시스템을 보여주고 있다. 이 GUI의 특징은 리드 타임이 1시간, 24시간, 168시간의 메뉴를 리스트 박스(listbox)로 구현 하였다. MAPE는 1.3835%로 보여준다. 그림 4는 1월 데이터를 이용하고 유전자 알고리즘으로 예측하는 화면이다.

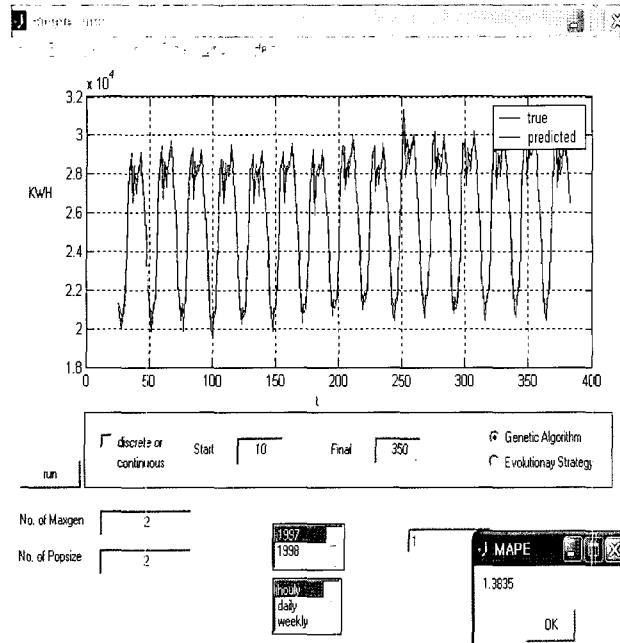


그림 4. 리드 타임이 1시간, 24시간, 168시간이 있는 GUI 메뉴 (1월, 1시간 예측)

Fig. 4. The GUI Menu having hourly, daily and weekly prediction (January and hourly prediction)

6.2 지역 부하 예측 시스템의 GUI

지역 부하 예측 GUI의 첫 실행화면을 그림 5에 나타냈다. 처음 실행할 때 지역부하 시계열의 계통관계를 계층적으로

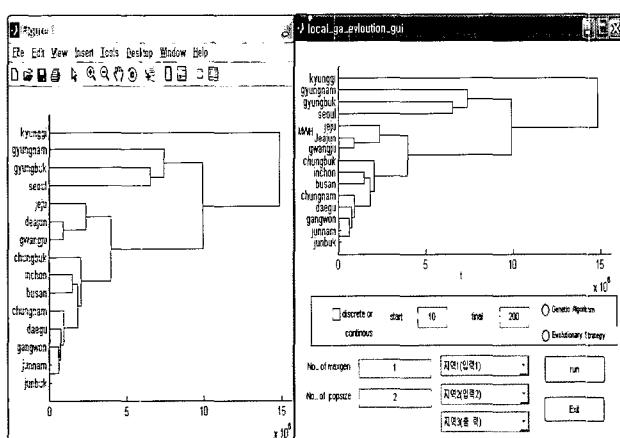


그림 5. 첫 실행 화면

Fig. 5. The first screen when running GUI

보여준다. 계통 관계에 따라 입력을 정할 수 있고, 계통관계가 친밀한 입력일수록 더 나은 결과 값을 얻을 수 있다. 그림 6에서는 두 입력지역을 선택하고 하나의 출력지역을 선택하여 유전자알고리즘을 택한 후 세대수와 세대내 개체수를 입력하면 출력력을 얻을 수 있다.

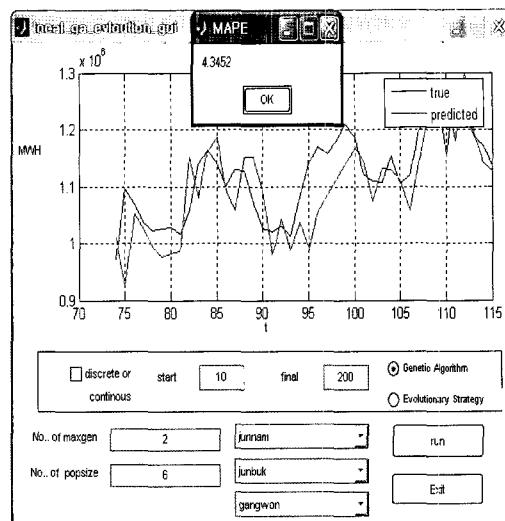


그림 6. 지역-전남, 지역-전북, 지역-강원의 출력 화면
Fig. 6. GUI output of Regions: Junnam, Junbuk, and Gangwon

7. 결 론

본 논문에서는 소속함수의 개수가 고정되어 있을 때 균등한 퍼지 소속함수에서 최적의 퍼지 소속함수를 구함으로서 시계열을 정확히 예측할 수 있음을 보였다. 소속함수의 변형을 만들 때 유전자알고리즘을 이용하여 우수한 특성을 나타내었다. 단기부하예측과 지역부하를 이용한 지역부하예측 실험을 실행하였다. 또한 graphic user interface도 구현하였다.

참 고 문 헌

- [1] 김인택, 공창욱, "시계열예측을 위한 퍼지 학습 알고리즘," 퍼지 및 지능시스템학회 논문지, 제7권 제3호, pp.34-42. 제7권 제3호, 1997.
- [2] R. M. Tong, "The evaluation of Fuzzy Models derived from Experimental Data," Fuzzy sets and Systems, vol. 4, pp. 1-12, 1980.
- [3] W. Pedrycz, "Fuzzy Control & Fuzzy Systems," John Wiley & Sons, 1989.
- [4] K. Hornik, M. Stinchcombe and H. White, "Multilayer feedback networks are universal approximators," Neural Network, vol. 2, pp. 359-366, 1989.
- [5] Wang, L. E., "Fuzzy systems are universal approximators," Proc. IEEE International Conf. on Fuzzy Systems, San Diego, pp. 1163-1170, 1992.
- [6] L.X. Wang & J. M. Mendel, "Generating fuzzy rules by learning from examples," IEEE Trans

- Syst., Man, Cybern., vol. 22, pp. 1414-1427, 1992.
- [7] J. R. Jang & C. Sun, "Prediction Chaotic Time series with Fuzzy If_Then rules," Second IEEE International Conference on Fuzzy Systems, San Francisco, pp. 1079-1084, 1993.
- [8] Z. Ye & L. Gu, "A fuzzy system for trading the shanghai stock market," Trading on the Edge, Neural, Genetic, and Fuzzy Systems for Chaotic Financial Markets, G. J. Deboeck, Ed. New York: Wiley, 1994. pp. 207-214.
- [9] D. Benachenhou, "Smart trading with (FRET)," in Trading on the Edge, Neural, Genetic, and Fuzzy Systems for Chaotic Financial Markets, G. J. Deboeck, Ed., New York: Wiley, 1994, pp. 215-242.
- [10] 이성록, 김인택, "A study on new fuzzy time series prediction method," pp. 565-569, 명지대학교 산업 기술연구소 논문집 vol. 19, 1999.
- [11] Zbigniew Michalewicz, "Genetic Algorithms+ Data Structures=Evolution Programs," Springer Verlag, 1994.
- [12] 임영도, 이상도, 퍼지, 신경망, 유전진화, pp. 215-216, 1996, 도서출판 영과 일,
- [13] Michalis Vlachos, "Practical Time_Series Tutorial with Matlab," 16th European conference on machine learning, Oct. 3-7, Porto, 2005.
- [14] 박종진, 최규식, 퍼지 제어 시스템 유전, 교우사, 2005.
- [15] 박영진 왕보현, "뉴로-퍼지 모델 기반 전력 수요 예측 시스템: 시간, 일간, 주간 단위 예측," 퍼지 및 지능시스템 학회 논문지, Vol. 14, No. 5, pp. 533-538, 2004.

저자 소개



강환일(Hwan Il Kang)

1980년 : 서울대학교 전자공학과 졸업
1982년 : KAIST 전기및 전자공학과 졸업
(공학석사)
1992년 : 미국 위스콘신매디슨 대학 전기공
학과 졸업(공학박사)
1996년 ~ 현재 : 명지대학교정보공학과 교수
2003년 : 미국 페듀대학교 방문교수
2004년 : 카나다 토론토 대학 단기 방문교수

관심분야 : 퍼지 이론 및 응용, 유전알고리즘, 시계열 예측
Phone : 031-330-6757
Fax : 031-321-6478
E-mail : hwan@mju.ac.kr



장우석(Woo Seok Jang)

2005년 : 미국 일리노이 공과대학 IT
연수과정 수료
2006년 : 명지대 정보공학과 졸업.
2006년 ~ 현재 : 동 대학원 정보공학과 석
사과정

관심분야 : 퍼지 시스템, 패턴인식, Evolutionary
Computation, 이족로봇 결음걸이 알고리즘 구현
Phone : 031-330-6757
Fax : 031-321-6478
E-mail : drunkenws@nate.com