

# 뉴로-퍼지 모델 기반 전력 수요 예측 시스템: 시간, 일간, 주간 단위 예측

## Neuro-Fuzzy Model based Electrical Load Forecasting System: Hourly, Daily, and Weekly Forecasting

박영진, 왕보현

(주) 옵토마인, 강릉대학교 전자공학과

Young-Jin Park and Bo-Hyeun Wang

Optomine Co. Ltd., Kangnung National University

E-mail : bhw@kangnung.ac.kr

### 요 약

본 논문은 뉴로-퍼지 모델의 구조 학습을 이용하여 단기 전력 수요 예측시스템을 개발하기 위한 체계적인 방법을 제안한다. 제안된 단기 수요 예측시스템은 1시간, 24시간, 168시간의 예측 리드 타임을 갖고 예측을 수행하기 위해서 요일 유형과 시간 별로 총 96개의 초기 구조를 미리 생성하고, 이를 초기 구조뱅크에 저장한다. 예측이 수행되는 시점에 해당하는 초기 구조를 선택하여 뉴로-퍼지 모델을 초기화하고, 학습하고, 예측을 수행한다. 제안된 예측시스템은 단지 2개의 입력 변수만을 사용하기 때문에 간단한 모델 구조를 가질 뿐 아니라 학습된 퍼지 규칙을 해석하는 것이 매우 용이하다는 장점을 갖는다. 제안된 방법의 실효성을 검증하기 위해 1996년과 1997년의 한국전력의 실제 전력 수요 데이터를 이용하여 1시간, 24시간, 168시간 앞의 전력 수요를 예측하는 모의 실험을 수행한다. 실험 결과 제안된 방법은 단지 2개의 입력 변수를 사용함에도 불구하고, 기존의 예측 방법과 비교하여 예측의 정확도와 신뢰도 측면에서 우수한 성능을 얻는다.

### 1. 서론

전력 계통의 운용 계획을 최적화하기 위해서 연간 최대 전력수요와 시간별 전력수요에 대한 장단기간의 수요 예측에 관한 연구가 활발하게 진행 중이다. 특히, 단기 수요 예측은 발전비용과 신뢰도에 크게 영향을 주며, 전력계통의 제어 및 단기계획, 경제급전, 전력조류계산 등의 입력 자료로 활용된다. 예를 들어, 1시간 앞의 전력 수요 예측은 경제 급전 및 발전 계획을 위해서 사용되고, 24시간 혹은 몇 일 앞의 수요 예측은 전력 교환 계획을 위해, 몇 주일 앞의 예측은 전력 자원의 관리 계획을 위해 사용된다 [1].

본 논문은 뉴로-퍼지 모델의 구조 학습을 이용하여 1시간, 24시간, 168시간 앞의 부하를 예측하는 단기 전력 수요 예측시스템을 개발하기 위한 체계적인 방법을 제안한다. 제안된 방법은 일반적으로 부하의 특성이 평일(화, 수, 목, 금), 월요일, 토요일, 일요일로 분류된다는 사실에 착안하여, 네 개의 요일 유형 각각에 대해 시간 별로 초기 구조를 구성한다. 초기 구조를 구

성하기 위해서 Kubat이 제안한 결정 트리 방법을 이용하고, 구성된 시간별 초기 구조는 초기 구조뱅크에 저장한다 [2]. 구조뱅크에 저장된 초기 구조 중에서 예측 시점에 필요한 초기 구조를 뉴로-퍼지 모델에 로드하여 모델을 초기화하고, 2개의 입력 변수를 토대로 구성된 학습 데이터를 이용하여 뉴로-퍼지 모델의 인자를 학습한다.

실제 상황에서 제안된 방법의 실효성을 검증하기 위해서 한국 전력에서 1996년부터 1997년까지 수집한 실제 부하 데이터를 이용하여 모의 실험을 수행한다. 특히, 일간과 주간단위의 예측 결과를 Time of Day 모델의 예측 결과와 비교하여, 제안된 뉴로-퍼지 모델의 구조 학습에 기반한 예측시스템이 적은 수의 입력 변수를 사용함에도 불구하고, 만족할 만한 성능을 얻는다는 사실을 입증한다.

본 논문의 구성은 다음과 같다. 2장에서는 뉴로-퍼지 모델에 관해서 간단히 설명하고, 3장에서는 뉴로-퍼지 모델을 이용한 단기 전력 수요 예측시스템에 관해 기술하며, 4장은 제안된 예측

시스템을 이용하여 모의 예측 실험을 수행하고, 실험 결과를 비교 분석한다. 마지막으로 4장에서는 결론을 제시한다.

### 2. 뉴로-퍼지 모델과 구조학습

퍼지 규칙 베이스, 추론기, 비퍼지화기로 구성된 퍼지 추론시스템은 일련의 퍼지 규칙으로부터 퍼지 추론을 수행한다. 규칙 베이스를 구성하는 퍼지 규칙은 다음의 형태를 갖는다:

- 규칙 1:  $(x_1 \text{ is } A^1_1) \text{ and } (x_2 \text{ is } A^1_2) \text{ and } \dots$   
 $(x_n \text{ is } A^1_n), \text{ then } y \text{ is } q^1.$
- 규칙 2:  $(x_1 \text{ is } A^2_1) \text{ and } (x_2 \text{ is } A^2_2) \text{ and } \dots$   
 $(x_n \text{ is } A^2_n), \text{ then } y \text{ is } q^2.$
- ...
- 규칙 p:  $(x_1 \text{ is } A^p_1) \text{ and } (x_2 \text{ is } A^p_2) \text{ and } \dots$   
 $(x_n \text{ is } A^p_n), \text{ then } y \text{ is } q^p.$  (1)

여기서  $x_j (1 \leq j \leq m)$ 는 입력 변수이고,  $y$ 는 출력 변수이다.  $A^j_i$ 와  $q^i (1 \leq i \leq p)$ 는 소속 함수에 의해 정의되는 퍼지 집합이며, 본 논문에서는 식 (1)에서 후건부 퍼지 집합이 상수의 형태를 갖는 간단한 구조의 퍼지 규칙을 고려한다. 그림 1은 두 개의 입력 변수와 하나의 출력 변수를 갖는 뉴로-퍼지 시스템의 구조 예이다.

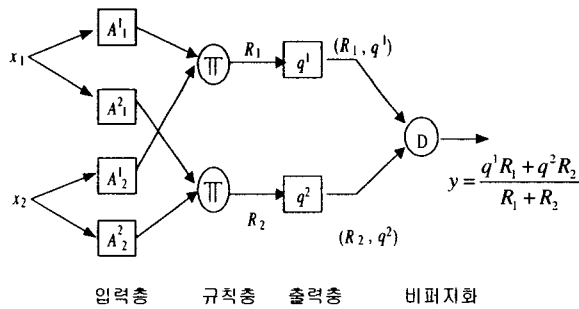


그림 1. 뉴로-퍼지 시스템의 구조.

일반적인 모델링 문제에서와 같이 뉴로-퍼지 모델링에서도 구조학습은 모델의 성능을 향상하기 위해 필수적인 과정이다. 뉴로-퍼지 모델의 구조학습은 입력 변수를 선정하는 문제와 입력 공간을 분할하는 문제로 구성된다. 효율적인 모델을 구성하기 위해서 최적의 입력 변수를 선정하는 문제가 매우 중요하지만, 본 논문에서는 [2]의 입력 공간 분할 문제를 다루는 구조학습을 이용한다. 뉴로-퍼지 모델의 구조학습에 관한 자세한 내용은 [3, 4]를 참조하기 바란다.

### 3. 뉴로-퍼지 모델을 이용한 단기 전력 수요 예측시스템

본 논문에서는 뉴로-퍼지 시스템을 실시간 학습하여 1 시간, 24 시간, 168 시간의 예측 리드 타임에 대한 전력 수요를 예측하는 단기 전력 수요 예측시스템을 제안한다. 제안하는 전력 수요 예측시스템은 그림 2와 같이 [2]에서 제안된 뉴로-퍼지 모델의 구조 학습을 이용하여 초기 구조뱅크를 설계하는 방법을 사용한다. 초기 구조뱅크는 각 예측 리드 타임에 대하여 96개의 초기 구조를 갖으며, 예측치를 계산하기 위해서 예측 리드 타임별로 예측 엔진 모듈을 따로 구성한다.

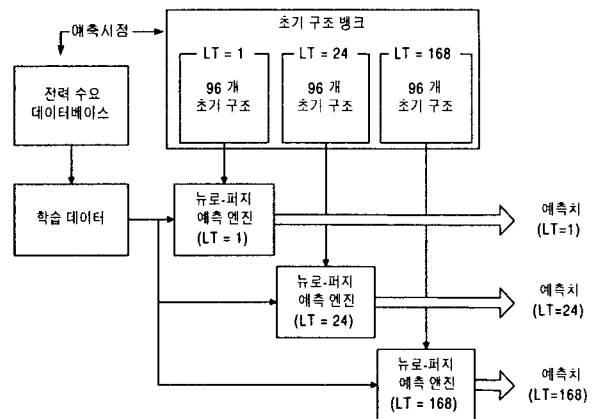


그림 2. 제안된 단기 전력 수요 예측 시스템.

예측시스템의 설계는 예측 모형의 입력 변수를 선정하는 작업에서 출발한다. 입력 변수를 선정하는 작업은 예측시스템의 성능 향상에 결정적인 역할을 한다. 그러나, 최적의 입력 변수를 선정하는 문제는 일반적으로 매우 어려운 문제로 간주된다 [5, 6]. 또한 본 논문의 목적이 적은 입력 변수를 사용하여 모델의 입력 구조를 간단히 하여도 효과적인 구조 학습이 가능하다는 것을 입증하는 것이므로, [7]에서 1 시간 앞의 전력 수요를 예측하는데 사용했던 2개의 입력 변수를 토대로 표 1과 같이 예측시스템의 입력 변수를 선정하였다. 입력 변수의 선정에서 다음의 두 가지 기준이 적용되었다:

- 첫째, 현재 시점에서 얻을 수 있는 가장 최근의 데이터를 입력 변수로 활용한다.
- 둘째, 가장 최근 수집된 같은 시각의 데이터를 입력변수로 활용한다.

Lead Time	입력 변수	출력 변수
1시간	$L(d-1, t+1), L(d, t)$	$L'(d, t+1)$
24시간	$L(d, h), L(d, 24)$	$L'(d+1, h)$
168시간	$L(w, k), L(w, 168)$	$L'(w+1, k)$

표 1. Lead Time에 따른 제안된 입력 변수

표 1에서  $d$ 는 현재일,  $t$ 는 현재 시간,  $h$ 는 24 시간중의 한시간,  $n$ 는 현재 주일,  $k$ 는 168시간중의 한시간을 의미한다. 입력 변수가 결정되면, 모델의 학습에 필요한 학습 데이터를 구성한다. 학습 데이터는 전력 수요 예측시스템의 경우 1주일의 주기를 갖고 구성되기 때문에, 만약 50개의 학습 데이터를 사용한다면, 약 50주 동안 수집된 데이터가 필요하게 된다. 그림 3은 각 리드타임에 따른 학습 데이터의 생성 방법을 나타낸 것이며, 학습 데이터 생성시 특수일의 데이터가 들어가지 않도록 구성한다.

제한하는 예측 시스템의 초기 구조 은행을 구축하기 위해서 표 2에서 보여지는 것처럼 97년 1월 11일부터 1월 20일에 해당하는 학습 데이터를 사용했다. 평일 유형의 초기 구조를 학습하기 위해서 200개의 학습 데이터가 사용되었고, 나머지 유형의 초기 구조를 학습하기 위해서는 100개의 학습 데이터를 사용하였다. 구조 학습을 위한 학습 데이터를 사용하여 [2]의 초기구조 은행 설계 방법에 따라 96개의 초기 구조를 리드 타임 별로 결정한다.

유형	날짜	기간	학습 데이터수
평일 (화, 수, 목, 금)	97년 01월 14일 -97년 1월 17일	4일	200
토요일	97년 01월 11일 97년 01월 18일	2일	100
일요일	97년 01월 12일 97년 01월 19일	2일	100
월요일	97년 01월 13일 97년 01월 20일	2일	100

표 2. 초기 구조 은행을 위한 학습 데이터


#### 4. 단기 전력 수요 예측 실험 및 분석

예측을 수행하고자 하는 요일의 유형 및 시각에 해당하는 초기 구조를 선택하여 뉴로-퍼지 모델의 구조와 인자 값을 초기화한다. 준비된 50개의 학습 데이터를 이용하여 초기화된 뉴로-퍼지 모델을 학습하고, 구축된 예측시스템을 사용하여 예측을 수행하였다. 구축된 예측시스템의 성능을 1997년 1월 21일부터 1997년 12월 31일까지 리드 타임별로 테스트하여 예측시스템의 성능을 분석하였다. 본 논문에서 개발한 예측시스템은 특수일에 대해 전혀 고려하지 않았기 때문에, 특수일에 대한 예측 결과를 제외하고 성능을 분석하였다. 예측 모델의 성능 평가를 위해서 평균 퍼센트 오차(Mean Absolute Percentage Error, MAPE)를 사용하였다:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\text{실제부하값} - \text{예측값}}{\text{실제부하값}} \right| \times 100 \quad (2)$$

N개의 학습 데이터


예측 N 주일 전 시점에 해당하는 입력 데이터	$L(d-7N, t+1)$
예측 (N-1) 주일 전 시점에 해당하는 입력 데이터	$L(d-7(N-1), t+1)$
⋮	⋮
예측 2 주일 전 시점에 해당하는 입력 데이터	$L(d-14, t+1)$
예측 1 주일 전 시점에 해당하는 입력 데이터	$L(d-7, t+1)$



(a)

N개의 학습 데이터


예측 N 주일 전 시점에 해당하는 입력 데이터	$L(d-7N+1, h)$
예측 (N-1) 주일 전 시점에 해당하는 입력 데이터	$L(d-7(N-1)+1, h)$
⋮	⋮
예측 2 주일 전 시점에 해당하는 입력 데이터	$L(d-13, h)$
예측 1 주일 전 시점에 해당하는 입력 데이터	$L(d-6, h)$



(b)

N개의 학습 데이터

예측 N 주일 전 시점에 해당하는 입력 데이터	$L(w-(N-1), k)$
예측 (N-1) 주일 전 시점에 해당하는 입력 데이터	$L(w-(N-2), k)$
⋮	⋮
예측 2 주일 전 시점에 해당하는 입력 데이터	$L(w-1, k+1)$
예측 1 주일 전 시점에 해당하는 입력 데이터	$L(w, k)$



(c)

그림 3. 학습 데이터의 생성방법.

(a) Lead Time이 1시간인 경우, (b) Lead Time이 24시간인 경우, (c) Lead Time이 168시간인 경우.

#### 4.1 시간 단위 전력 수요 예측 모델

표 3은 표 1에서 언급한 리드 타임이 1시간인 입력 변수를 사용하여 97년 전체에 걸쳐 실험한 결과를 월별로 요약한 것이다. 1시간 앞의 전력 수요를 예측하는데 제안된 예측시스템은 MAPE의 평균이 1.12%, MAPE의 표준편차는 1.20의 결과를 얻었다. 특히 계절적으로 여름철과 여름철을 전후한, 6월, 7월, 8월, 9월에 대한 예측 결과가

좋지 않았으며, 이러한 현상은 겨울철에 해당하는 1월과 2월에도 관찰되었다.

월	Ave(%)	Std
1	1.17	0.77
2	1.01	0.90
3	0.67	0.61
4	0.69	0.61
5	0.71	0.66
6	1.45	1.26
7	2.00	1.91
8	2.13	1.72
9	1.16	1.15
10	0.79	0.72
11	0.80	0.72
12	0.80	0.70

표 3. 모의 실험 결과 분석 (Lead Time =1, 월별 분석)

일반적으로 1시간 앞의 전력 수요를 예측할 때 요구되는 오차율이 1%정도 수준인 점을 고려하면, 향후 계절적 요인에 대한 예측 성능 향상 방법을 이용하여 보완한다면 제안된 예측시스템의 실용화가 가능할 것으로 판단된다.

4.2 일 단위 전력 수요 예측 모델

그림 4는 표 1의 리드 타임이 24시간인 입력 변수를 사용한 예측 모델을 도식화한 것이다. 그림 4의 예측 모델을 사용하여 테스트한 결과를 월별로 정리하여 표 4에 요약하였다. 예측 성능 분석 결과 MAPE의 평균이 1.48%, 표준편차가 1.40, 최대오차가 9.71%로서, 평균 MAPE이 약 1.5%대인 예측 성능을 보였다. 월별로는 여름철과 여름철 전후의 6, 7, 8, 9월의 예측 결과가 좋지 않았으며, 특히 7월과 8월의 예측 결과가 좋지 않았다.




그림 4. 제안하는 예측 모델 (Lead Time=24).

월	Ave(%)	Std	Max(%)
1	1.29	0.88	4.36
2	1.39	1.24	7.47
3	1.07	1.09	5.82
4	0.98	0.99	8.33
5	1.06	0.89	5.00
6	1.77	1.42	7.12
7	2.29	1.89	9.71
8	2.86	1.96	9.15
9	1.59	1.45	7.75
10	1.01	0.81	4.94
11	1.24	1.03	6.54
12	1.38	1.17	8.15

표 4. 모의 실험 결과 분석 (Lead Time =24, 월별 분석)

4.3 주간 단위 전력 수요 예측 모델

표 1의 리드 타임이 168시간인 입력 변수를 사용하여 모의 실험한 결과를 표 5에 요약하였다. 평균이 2.30%, 표준편차가 2.13, 최대오차가 13.71%로서, 평균 MAPE이 약 2.3%대인 예측 성능을 보였다. 월별로는 여름철인 6, 7, 8월의 예측 결과가 좋지 않았다. 표 6의 요일별 성능 분석에서 알 수 있듯이 주간 단위 예측의 시작점인 월요일을 기준으로 요일이 지남에 따라 예측의 성능이 점차 저하되었다.

시간 단위, 일 단위, 주간 단위 예측 결과로부터 예측 리드 타임이 늘어나면, 예측의 정확도가 떨어짐을 알 수 있다. 이는 예측 리드 타임이 늘어나면서, 예측 시점에서 더 멀리 떨어진 입력 데이터를 사용하는데 기인한다.

월	Ave(%)	Std	Max(%)
1	2.37	1.55	9.83
2	2.03	1.75	13.13
3	1.31	1.15	8.42
4	1.42	1.10	6.55
5	1.36	1.24	7.36
6	3.49	2.76	13.53
7	3.14	2.46	12.79
8	4.58	3.04	13.71
9	2.67	2.26	12.94
10	1.71	1.31	8.82
11	1.92	1.55	8.77
12	2.04	1.63	8.34

표 5. 모의 실험 결과 분석 (Lead Time =168, 월별 분석)

[감사의 글]

본 연구가 가능하도록 전력 수요 데이터를 제공해준 한국 전력에 감사드립니다.

요일	Ave(%)	Std	Max(%)
월	1.95	1.88	12.94
화	2.16	1.95	11.91
수	2.21	2.16	12.46
목	2.33	2.21	13.53
금	2.20	2.04	12.22
토	2.59	2.43	13.71
일	2.69	2.16	12.07

표 6. 모의 실험 결과 분석  
(Lead Time =168, 요일별 분석)

5. 결론

본 논문에서는 MLP와 같은 신경회로망의 단점을 극복하는데 효과적인 대안으로 인식되고 있는 뉴로-퍼지 모델의 구조 학습을 이용하여 예측 리드 타임이 1시간, 24시간, 168시간에 대해서 전력 수요를 예측하는 체계적인 방법을 제안하였다.

제안된 방법은 다양한 예측 리드 타임(1시간, 24시간, 168시간)에 대해 2개의 변수를 갖는 간단한 입력 구조와 뉴로-퍼지 모델의 구조 학습을 이용한다. 이는 예측시스템에서 학습한 규칙을 용이하게 해석할 수 있다는 것을 의미하며, 이를 통하여 예측시스템의 사용자는 예측 결과를 보다 쉽게 이해할 수 있다는 장점으로 활용되리라 기대된다.

제안된 예측시스템의 성능을 검증하기 위해서 한국 전력의 실제 전력 수요 데이터를 이용하여 모의 실험을 수행하였다. 실험 결과 단지 2개의 입력 변수만을 사용하였음에도 불구하고, 예측 리드 타임이 1시간, 24시간, 168시간에 대하여, MAPE의 평균이 약 1.12%, 1.48%, 2.30% 정도의 성능을 얻었다. 또한 Time of Day 모델의 예측 성능과 비교하여 예측 리드 타임이 24시간인 경우에는 제안된 뉴로-퍼지 예측시스템이 정확도와 신뢰도 면에서 모두 우수하였고, 168시간인 경우에 대해서는 정확도가 약간 떨어졌으나, 신뢰도 면에서 우수하였다. 만약 온도 등의 날씨에 관한 변수를 고려하여 모델을 구현한다면 보다 실용적인 모델을 구현할 수 있을 것이다.

향후 진행되어야 할 연구 방향은 다음의 두 가지로 요약된다. 첫째, 예측시스템의 실용화를 위해 온도 변수를 고려하여 다른 계절에 비해 상대적으로 예측이 어려운 여름에 대한 예측 성능을 높이는 방법과 특수일에 대한 초기 구조를 결정하는 방법을 연구할 예정이다. 둘째, GMDH(Group Method for Data Handling)와 같은 방법[8, 9]으로 유용한 소수의 입력 변수를 선정하여 신뢰도를 향상시킬 계획이다.

6. 참고문헌

- [1] G. Gross, F. D. Galiana, "Short-Term Load Forecasting," *Proceedings of IEEE*, Vol.75, No.12, pp. 1558-1573, Dec. 1987.
- [2] 박영진, 심현정, 왕보현, "뉴로-퍼지 모델을 이용한 단기 전력 수요 예측시스템," *대한전기학회 논문집*, pp. 107-117, 2000.
- [3] M. Sugeno and T. Yasukawa, "A fuzzy logic based approach to qualitative modeling," *IEEE Trans. Fuzzy Systems*, vol. 1, no. 1, pp. 7-31, Feb. 1993.
- [4] M. Kubat, "Decision Trees can Initialize Radial Basis Function Networks," *IEEE Trans. Neural Networks*, Vol. 9, No. 5, pp. 813-821, Sept. 1998.
- [5] M. Sugeno and T. Yasukawa, "A Fuzzy Logic Based Approach to Qualitative Modeling," *IEEE Trans. Fuzzy Systems*, Vol. 1, No. 1, pp. 7-31, Feb. 1993.
- [6] L. Wang, R. Langari, and J. Yen, "Principal Components, B-splines, and Fuzzy System Reduction," in *Proc. Fuzzy Logic for the Applications to Complex Systems*, W. Chiang and J. Lee, Ed. World Scientific, 1995.
- [7] D. C. Park, M. El-Sharkawi, R. Marks, A. Atlas, and M. Damborg, "Electrical Load Forecasting Using an Artificial Neural Network," *IEEE Trans. on Power Systems*, Vol. 6, No. 2, pp. 442-449, May 1991.
- [8] A. G. Ivakhnenko, *Polynomial Theory of Complex Systems*, *IEEE Trans. Syst., Man, Cyberm.*, Vol. SMC-12, pp. 364-378, 1971.
- [9] S. Farlow, ed., *Self Organizing Methods in Modeling : GMDH-Type Algorithm*, Marcel Dekker, Inc., New York, 1984.