

뉴로-퍼지 모델의 구조 학습을 이용한 단기 전력 수요 예측 시스템

박영진* 심현정** 왕보현**
(주)옵토마인*, 강릉대학교 전자공학과**

Short-Term Electrical Load Forecasting
using Structure Identification of Neuro-Fuzzy Models

Young-Jin Park*, Hyun-Jeong Shim**, Bo-Hyeun Wang**
OptoMine Co.,Ltd.*, Kangnung National University**

Abstract - 본 논문은 뉴로-퍼지 모델의 구조학습을 이용하여 한 시간 앞의 전력 수요를 예측하는 체계적인 방법을 제안한다. 제안된 예측시스템은 시간 단위로 뉴로-퍼지 모델을 재학습하기 위해서 필요한 초기 구조를 요일 유형과 시간 별로 미리 생성하고, 이를 초기 구조뱅크에 저장한다. 예측이 수행되는 시점의 요일 유형에 따라 선택된 초기 구조를 이용하여 뉴로-퍼지 모델을 초기화하고, 학습하고, 예측을 수행한다. 제안된 방법의 실효성을 검증하기 위해 1996년과 1997년의 실제 전력 수요 데이터를 이용하여 모의 실험을 수행한다. 실험 결과 제안된 방법은 기존의 다층 퍼셉트론을 이용한 방법과 비교하여 예측의 정확도 측면과 신뢰도 측면에서 모두 향상된 결과를 얻는다.

1. 서 론

전력 계통의 운용 계획을 최적화 하기 위해서 연간 최대 전력수요와 시간별 전력수요에 대한 장단기간의 수요 예측에 관한 연구가 활발하게 진행중이다. 특히, 단기 수요 예측은 발전비용과 신뢰도에 크게 영향을 주며, 전력계통의 제어 및 단기계획, 경제급전, 전력조류계산 등의 입력자료로 활용되기 때문에 정확한 예측시스템의 개발이 절실하게 요구된다 [1]. 그러나 지수평활화법 또는 상태공간재구성기법과 같은 단기 수요 예측을 위한 전통적인 방법으로는 날씨와 같이 부하특성에 영향을 미치는 여러 가지 요인을 동시에 고려하고자 할 때 모델링 과정이 매우 복잡해지고, 주어진 문제의 비선형성이 증가하는 경우 예측의 정확도가 떨어지는 단점이 있다.

최근 이와 같은 문제를 극복하고자 신경회로망, 특히 다층 퍼셉트론 (Multilayer Perceptron, MLP)을 전력 수요 예측에 활용하는 연구가 집중적으로 수행되고 있다 [2-5]. 이들 연구는 MLP가 어떠한 비선형 함수도 근사화 할 수 있고, 유연한 입력 선택이 가능하며, 주어진 데이터로부터 학습에 의해 예측모델을 비교적 용이하게 구할 수 있다는 장점을 기반으로 한다. 1992년에 Park은 MLP를 이용하여 단기 전력 수요 예측시스템을 구현할 수 있다는 가능성을 입증하였고 [2], 이후 온도 등과 같은 날씨 요인을 입력 변수로 활용하여 예측시스템의 성능을 향상하는 시도가 있었다 [3]. 최근에는 매우 어려운 문제로 인식되고 있는 특수일의 부하 예측을 위해서 다중 모듈 구조를 갖는 예측시스템에 관한 연구가 시도되고 있다 [4, 5].

그러나, MLP를 기반으로 개발된 비선형 예측시스템은 기본적으로 다음과 같은 단점을 갖는다:

- MLP가 black box이기 때문에 신경회로망으로부터 얻어진 예측결과를 해석하는 것이 불가능하게 되고, 결국 예측시스템의 실제 사용자는 예측결과의 신뢰성에 대해 지속적으로 의심하게 된다.
- 최적의 성능을 얻기 위한 MLP의 은닉층의 수와 각 은닉층의 노드 수를 결정하는 효과적이며 체계적인 방법이 존재하지 않는다. 구조결정을 위한 체계적인 방법이 없기 때문에 MLP의 학습은 필연적으로 시행착오의 과

정을 반복하여야 한다.

신경회로망의 학습능력과 퍼지시스템의 구조적 지식 표현 능력을 융합하는 뉴로-퍼지 모델은 MLP의 단점을 극복하기 위한 효과적 대안으로 인식되고 있다. 1995년에 Bakirtzis는 뉴로-퍼지 모델의 장점을 단기 전력 수요 예측에 활용하기 위해 요일별, 시간별로 학습된 168개의 뉴로-퍼지 모듈을 사용하여 일일의 부하를 예측하였다 [6]. 이후 Mori는 36개의 퍼지 규칙을 갖는 뉴로-퍼지 모델을 이용하여 한 시간 앞의 전력수요를 예측하는 연구를 수행하였다 [7]. 그러나, 이들 연구는 예측을 위해 필요한 규칙의 수와 학습을 위한 초기 인자 값을 결정하는 구조학습에 관해 전혀 고려하지 않았다.

효과적인 뉴로-퍼지 모델을 구성하기 위해서는 체계적인 구조학습이 필수적이다. 뉴로-퍼지 모델의 구조학습은 관련된 입력 변수를 선정하는 문제와 입력 공간을 분할하는 문제로 구성된다. 입력 공간 분할 문제는 학습 데이터를 이용하여 가능한 적은 수의 규칙으로 요구되는 정확도를 확보할 수 있도록 뉴로-퍼지 모델의 초기 인자 값을 구하는 것이다 [8, 9, 10].

본 논문은 뉴로-퍼지 모델의 구조학습을 이용하여 한 시간 앞의 전력 수요를 예측하는 단기 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 매 시간 별로 총 96개의 초기 구조를 구성한다. 초기 구조를 구성하기 위해서 Kubat이 제안한 결정 트리 방법을 이용하고 [10], 구성된 시간별 초기 구조는 초기 구조뱅크에 저장한다. 구조뱅크에 저장된 초기 구조 중에서 예측 시점에 필요한 초기 구조를 뉴로-퍼지 모델에 로드하여 모델을 초기화한다. 실제 상황에서 제안된 방법의 실효성을 검증하기 위해서 한국전력의 1996년과 1997년 실제 부하 데이터를 이용하여 모의 실험을 수행한다. 또한, MLP를 이용하여 구현한 예측시스템의 예측 결과와 비교하여 뉴로-퍼지 모델의 구조학습을 이용한 예측시스템이 향상된 성능을 얻는다는 것을 입증한다.

본 논문의 구성은 다음과 같다. 2장에서는 뉴로-퍼지 모델과 구조학습에 관해서 소개하고, 3장에서는 제안된 뉴로-퍼지 기반 전력 수요 예측시스템을 설명한다. 4장에서는 제안된 방법의 타당성을 검증하기 위해 모의 실험을 수행하고 실험 결과를 분석한다. 마지막으로 5장에서 결론을 제시한다.

2. 뉴로-퍼지 모델과 구조 학습

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: $(x_1 \text{ is } A_1^2) \text{ and } (x_2 \text{ is } A_2^2) \text{ and } \dots$
 $(x_n \text{ is } A_n^2), \text{ then } y \text{ is } q^2.$
 \dots (1)

규칙 p: $(x_1 \text{ is } A_1^p) \text{ and } (x_2 \text{ is } A_2^p) \text{ and } \dots$
 $(x_n \text{ is } A_n^p), \text{ then } y \text{ is } q^p.$

여기서 $x_j (1 \leq j \leq n)$ 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.

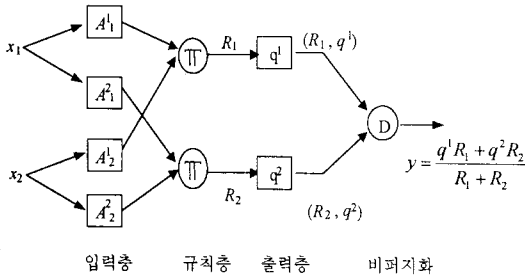


그림 1 뉴로-퍼지 시스템의 구조

그림 1은 두 개의 입력 변수와 하나의 출력 변수를 갖는 뉴로-퍼지 시스템의 구조이다. 두 개의 퍼지 규칙을 표현한 그림 1의 구조에서 입력 층의 입력 노드는 퍼지 규칙의 전건부 소속 함수 A_j^i 를 표현하며, 출력 층의 출력 노드는 후건부 소속 함수 q^i 를 표현한다. 입력 층의 입력 노드는 x 를 입력으로 받아 입력과 소속 함수와의 적합도를 계산한다. 만약 소속 함수로 Gaussian 함수를 사용하면, 적합도는 다음 식으로 계산된다:

$$\mu_{A_j^i}(x_j) = \exp \left[- \left(\frac{x_j - c_j^i}{\sigma_j^i} \right)^2 \right] \quad (2)$$

규칙 층의 규칙 노드는 계산된 적합도를 입력으로 받아 각 규칙의 발화 강도를 계산한다. 예를 들어, i 번째 규칙 노드의 출력은 다음 식에 의해 구해진다:

$$R_i(x) = \prod_{j=1}^n \mu_{A_j^i}(x_j) \quad (3)$$

뉴로-퍼지 시스템의 마지막 층은 비퍼지화 작업을 수행한다. 만약 퍼지 추론에서 무게중심법에 기반한 비퍼지화를 수행한다고 가정하면, 뉴로-퍼지 시스템의 최종 출력은 다음 식과 같다:

$$y = \frac{\sum_{i=1}^p R_i q^i}{\sum_{i=1}^p R_i} \quad (4)$$

식 (2)-식 (4)와 같이 주어진 뉴로-퍼지 시스템에서 출력을 구하는 과정은 주어진 퍼지 규칙으로부터 퍼지 추론을 수행하는 과정과 동일하게 된다. 뉴로-퍼지 시스템의 인자 학습은 주어진 학습 데이터로부터 입력 노드의 전건부 소속 함수 A_j^i 와 출력 노드의 후건부 인자 q^i 를 설정된 목적 함수를 최소화하도록 정하는 것이다. 본 논문에서는 이를 위해 오차 역전파 학습을 이용한다 [11].

일반적인 모델링 문제에서와 같이 뉴로-퍼지 모델링에

서도 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 입력 공간 분할 문제를 주로 다루기로 한다. 지역 표현을 기반으로 하는 뉴로-퍼지 모델에서 입력 공간 분할 문제는 모델에서 사용하는 퍼지 규칙의 수와 초기 인자 값을 결정하는 문제로 귀결된다.

뉴로-퍼지 시스템에 저장된 일련의 퍼지 규칙은 입력 공간을 고차직사각형 (hyper-rectangle)으로 분할한다. n 개의 퍼지 규칙을 저장하는 구조의 뉴로-퍼지 시스템은 n 개의 고차직사각형을 이용하여 입력 공간을 분할한다고 해석할 수 있다.

만약 초기 입력 공간 분할에 대한 심각한 고려 없이 뉴로-퍼지 시스템을 학습하는 경우 우리는 일반적으로 필요한 퍼지 규칙의 수를 적당히 정하고, 인자 값을 랜덤하게 초기화하여 학습을 수행하게 된다. 이 경우 학습된 모델의 성능은 초기 인자 값에 영향받게 되고, 학습된 퍼지 규칙은 서로 중복되거나 모순되어 뉴로-퍼지 모델의 구조적 지식 표현이라는 장점을 상실하게 된다 [9].

이와 같은 문제를 해결하기 위해서 1993년에 Sugeno는 뉴로-퍼지 모델링에서 구조학습에 관한 연구를 처음 시도하였다 [8]. 이후 Sugeno 방법의 문제를 해결하고자 진화 연산을 이용한 입력 공간 분할 방법이 Wang에 의해 제안되었다 [9]. 한편 Kubat는 RBFN을 분류 문제에 적용하는 경우에 결정트리를 이용하여 입력 공간을 분할하는 방법을 제안하였다 [10]. 본 논문에서는 결정트리를 구성하는 작업이 매우 체계적이고 빠르다는 장점을 활용하기 위해 Kubat의 방법을 단기 주요 예측 문제에 적용하고자 한다. 뉴로-퍼지 모델의 구조학습에 관한 자세한 내용은 [9, 10]을 참조하기 바란다.

3. 뉴로-퍼지 모델을 이용한 단기 전력 수요 예측

본 논문에서는 뉴로-퍼지 시스템을 실시간 학습하여 1시간 앞의 전력 수요를 예측하기 위한 단기 전력 수요 예측시스템을 제안한다. 특히, 뉴로-퍼지 시스템의 구조 학습을 전력 수요 예측시스템에 적용하기 위해서 초기 구조 बैं크를 이용하는 방법을 제안한다. 뉴로-퍼지 모델을 학습하여 예측시스템을 구축하기 위해서 그림 2와 같이 초기 구조 बैं크에 미리 저장된 초기 구조 중에서 예측 시점에 해당하는 초기 구조를 로드하여 뉴로-퍼지 모델을 실시간 초기화하고 학습하고 예측을 수행한다.

표 1 입력 변수와 출력 변수

입력 변수	$p(i, t-1)$ $p(i, t-1) - p_{\text{mean}}(t-1)$ $p_{\text{mean}}(t-1) - p_{\text{mean}}(t)$
출력 변수	$p(i, t)$

예측 시스템의 입력변수는 [7]에서 사용한 3개의 입력 변수를 그대로 사용한다. 표 1은 본 논문에서 사용한 입력 변수를 요약한다. i 는 예측하는 날을, t 는 예측하는 시점을 각각 의미한다. 그러므로, $p(i, t)$ 는 i 날 t 시의 전력 수요가 된다. 여기서 $p_{\text{mean}}(t-1)$ 와 $p_{\text{mean}}(t)$ 는 식 (5)와 같다.

$$p_{\text{mean}}(t-1) = [p(i-7, t-1) + p(i-14, t-1) + p(i-21, t-1)]/3 \quad (5)$$

$$p_{\text{mean}}(t) = [p(i-7, t) + p(i-14, t) + p(i-21, t)]/3$$

일반적으로 하루 동안의 전력 수요 패턴은 화, 수, 목, 금의 평일, 월요일, 토요일, 일요일, 특수일의 유형으로 분류된다 [1]. 이와 같은 사실을 기초하여 본 연구에서는 특수일을 제외한 4개의 수요 패턴 유형에 대한 초기 구조 बैं크를 구축한다. 4개의 요일 유형에 대해서 시간별로 24개의 서로 다른 초기 구조를 갖기 때문에 초기 구조 बैं크는 모두 96개의 초기 구조로 구성된다. 하나의 초기 구조를 생성하기 위해서 필요한 학습 데이터는 해당 요일 유형 및 해당 시간에 대해 개별적으로 수집한다. 예를 들어, 평일 유형 01시에 대한 초기 구조를 만들기 위한 학습 데이터는 어느 특정한 한 주의 화, 수, 목, 금요일의 01시에 대한 학습 데이터를 모두 합하여 구성한다. 나머지 유형(토, 일, 월)의 초기 구조를 위한 학습 데이터는 2주의 데이터로부터 준비한다.

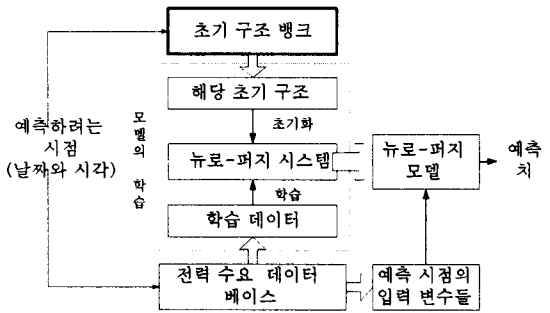


그림 2 뉴로-퍼지 모델을 이용한 전력 수요 예측 시스템의 구조

일단 초기 구조 생성을 위한 학습 데이터가 준비되면, 그림 3의 초기 구조 선정 알고리즘에 의하여 초기 구조 96개를 생성한다. 초기 구조 बैं크를 설계하기 위한 자세한 방법은 [12]를 참조하기 바란다.

한 시간 앞의 부하를 예측하기 위해 뉴로-퍼지 모델을 매 시간 학습한다. 이를 위해 매 시간 해당되는 초기 구조를 초기 구조 बैं크에서 다운 로드 받아 뉴로-퍼지 시스템을 초기화한다. 초기화된 뉴로-퍼지 모델을 학습하기 위해서 표 1에서 제시한 3개의 입력변수를 기초로 그림 4와 같이 학습 데이터를 수집한다. 본 논문 4장의 모의 실험에서는 50개의 학습 데이터를 사용하였다. 만약 학습 데이터를 준비할 때, 데이터가 특수일에 속하게 되는 경우에는 한 주일 전의 데이터로 대체한다. 이것은 모순되는 데이터의 학습을 피하기 위해서이다.

4. 모의 실험 결과 및 분석

제한된 예측시스템의 성능을 평가하기 위하여 97년 1월에서 12월까지의 전력 수요를 예측하였다. 뉴로-퍼지 모델을 매 시간 학습하기 위해서 표 1에서 제시한 입력 변수를 토대로 그림 4와 같이 50개의 학습 데이터를 구성했다. 50개의 학습 데이터를 준비하기 위해서는 보통 예측 시점부터 과거 약 1년 정도의 데이터가 필요하다.

초기 구조 बैं크를 구축하기 위해서 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 그림 3에서 제시한 초기 구조 बैं크 설계 방법에 따라 96개의 초기 구조를 결정한다. 표 2는 허용 규칙의 수를 10, 허용 오차를 1%로 하여 생성한 초기 구조의 규칙 수와 결정된 초기 구조를 이용하여 뉴로-퍼지 모델을 학습한 경우 얻어진 학습 데이터에 대한 오차를 나타낸다. 평일 유형에

대한 초기 구조는 평균 3.8개의 규칙을 갖고 토요일, 일요일, 월요일 유형에 대해서는 평균 4.2, 3.8, 4.1개의 규칙을 갖는다. 모델의 성능 평가를 위해서 평균 퍼센트 오차(Mean Absolute Percentage Error, MAPE)를 사용하였다:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\text{실제부하값} - \text{예측값}}{\text{실제부하값}} \right| \times 100 \quad (6)$$

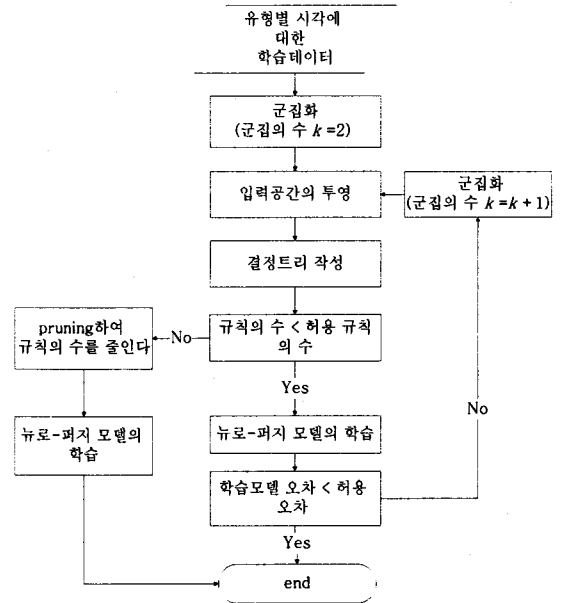


그림 3 초기 구조 생성 알고리즘

N개의 학습 데이터

예측 N 주일 전 시점에 해당하는 입력 데이터	$\mu(t-N, t)$
예측 (N-1) 주일 전 시점에 해당하는 입력 데이터	$\rho(t-(N-1), t)$
⋮	⋮
예측 2 주일 전 시점에 해당하는 입력 데이터	$\mu(t-14, t)$
예측 1 주일 전 시점에 해당하는 입력 데이터	$\mu(t-7, t)$

개별 학습 데이터의 구성

$\mu(i, t-1)$	$\rho(i, t-1) - \rho_{\text{mean}}(t-1)$	$\rho_{\text{mean}}(t-1) - \rho_{\text{mean}}(t)$	$\rho(i, t)$
입력 데이터			출력 데이터

그림 4 학습 데이터의 생성 방법

예측을 수행하고자 하는 요일의 유형 및 시간에 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 테스트하여 월별, 시간별로 표 3, 4에 요약하였다. 본 논문에서 개발한 예측시스템은 특수일에 대해 전혀 고려하지 않았기 때문에, 특수일에 대한 예측 결과를 제외하고 성능을 분석하였다.

제한한 예측시스템의 성능을 기존의 방법과 비교하여

검증하기 위해서 MLP를 이용한 예측시스템과 성능을 비교하였다. 공정한 비교를 위하여 MLP 기반 예측시스템의 입력 변수는 뉴로-퍼지 기반 예측시스템에서 사용한 3개의 입력 변수를 동일하게 사용하였다. MLP의 구조는 2개의 은닉 층을 갖는 14-5-3-1 구조를 사용하였으며, MLP를 학습하기 위한 학습 데이터는 뉴로-퍼지 기반 예측 시스템과 동일한 학습 데이터 50개를 사용하였다.

표 2 결정된 초기구조의 규칙 수와 학습 오차율

시간	평일		토요일		일요일		월요일	
	규칙 수	학습 오차율	규칙 수	학습 오차율	규칙 수	학습 오차율	규칙 수	학습 오차율
1	4	0.71	6	0.90	9	0.90	4	0.81
2	4	0.75	2	0.65	4	0.82	2	0.69
3	2	0.72	4	0.70	4	0.67	2	0.79
4	6	0.61	4	0.64	4	0.71	2	0.76
5	6	0.74	2	0.68	2	0.67	4	0.70
6	4	0.67	4	0.62	4	0.69	4	0.76
7	4	0.76	4	0.73	4	0.62	4	0.81
8	2	0.84	4	0.78	7	0.86	7	0.92
9	5	0.86	5	0.91	4	0.86	8	0.87
10	4	0.72	4	1.27	4	0.87	8	1.38
11	2	0.74	2	0.78	2	0.83	4	0.78
12	2	0.70	4	0.72	2	0.77	5	0.74
13	4	0.74	2	0.83	2	0.84	4	0.76
14	2	0.84	4	0.80	2	0.84	5	0.82
15	2	0.79	4	0.69	2	0.84	2	0.74
16	4	0.72	4	0.77	4	0.76	2	0.71
17	4	0.81	4	0.79	5	0.85	4	0.73
18	8	1.17	10	0.80	6	0.85	6	0.86
19	5	0.86	6	0.72	4	0.90	7	0.78
20	6	0.86	6	0.82	4	0.92	5	0.96
21	2	0.72	5	0.77	4	0.85	4	0.68
22	4	0.59	2	0.60	4	0.67	2	0.65
23	2	0.72	4	0.70	2	0.80	2	0.72
24	4	0.73	4	0.70	2	0.76	2	0.70
Ave	3.8	0.77	4.2	0.77	3.8	0.80	4.1	0.80

월별 예측 결과를 요약한 표 3에서 알 수 있는 것과 같이 예측의 성능이 여름철 (6,7,8,9월)을 제외하면 한 시간 앞의 전력 수요를 예측할 때 요구되는 오차율인 1% 미만이었다. 이 결과로부터 여름철 전력 수요 예측의 정확도를 향상하기 위한 연구가 요구됨을 알 수 있다. 시간별 예측 결과를 보면 출근시간 (8시, 9시, 10시)과 퇴근시간(18시, 19시, 20시)에 비교적 예측 성능이 저하되었다. 또한, 시간별 예측 결과로부터 초기 구조의 학습 과정에서 얻어진 학습 성능 (표 2 참조)이 예측 시스템의 실제 결과를 잘 반영하고 있음을 알 수 있다.

표 3에서 알 수 있듯이 제안된 방법이 매월 평균 MAPE에서 MLP 예측시스템보다 우수했다. 특히, 제안된 예측시스템의 MAPE의 표준 편차가 MLP 기반 예측시스템보다 우수함을 알 수 있었다. 특히, 이 같은 성능의 향상은 계절적 요인으로 예측이 어려운 여름철에 대해서 더욱 확실하게 나타났다. 또한 이러한 결과를 표 4에서 요약한 시간별 분석 결과에서도 확인할 수 있었다. 이와 같이 향상된 성능을 얻게 되는 주된 이유는 제안된 구조 학습 방법이 학습된 신경회로망에서 overfitting을 줄일 수 있기 때문이라 판단된다. 결론적으로 보다 더 신뢰할 수 있는 예측시스템을 개발하기 위해 제안된 구조학습이 필수적이라는 사실을 본 비교 실험에서 확인할 수 있다.

비교 실험을 통해서 다음과 같은 결론에 도달할 수 있

었다. 첫째, 제안된 구조학습 기반 뉴로-퍼지 예측시스템의 성능이 MLP에 의한 방법보다 우수하다. 특히, MAPE의 평균뿐만 아니라 MAPE의 표준 편차가 다른 방법과 비교해서 매우 향상되었다. 이는 제안된 방법으로 신뢰성이 향상된 예측시스템을 구현할 수 있음을 의미한다. 둘째, 제안한 모델에서 예측 성능의 계절 요인에 대한 의존도가 MLP를 이용한 모델과 비교하여 낮았다. 셋째, 계절별로는 여름 (6,7,8월)이 다른 계절보다 예측이 어렵고, 시간별로는 출퇴근시간에 대한 예측이 어렵기 때문에 MAPE의 평균과 표준편차 모두 크게 나오게 된다. 이러한 현상은 MLP 기반 예측시스템에서 도 관찰되었다.

표 3 모의 실험 결과 (월별 분석)

월	MLP		제안된 방법	
	Ave	Std	Ave	Std
1월	1.46	1.58	1.12	0.89
2월	1.60	3.47	1.01	0.93
3월	0.96	1.42	0.67	0.66
4월	0.92	1.15	0.66	0.60
5월	0.92	1.25	0.64	0.60
6월	2.09	2.81	1.38	1.56
7월	3.62	12.76	1.81	1.70
8월	4.70	11.79	1.77	1.45
9월	3.57	6.63	1.33	1.28
10월	1.22	1.90	0.85	0.85
11월	1.20	2.46	0.78	0.69
12월	1.03	1.25	0.71	0.60

표 4 모의 실험 결과 (시간별 분석)

시간	MLP		제안된 방법	
	Ave	Std	Ave	Std
1	1.66	3.05	0.93	0.88
2	1.30	1.51	1.08	1.06
3	1.81	5.19	0.75	0.80
4	1.51	2.23	0.68	0.74
5	1.55	2.54	0.82	0.91
6	1.56	4.28	0.80	0.72
7	1.26	1.32	0.74	0.65
8	2.09	5.18	1.03	0.90
9	3.12	7.53	1.34	1.13
10	4.48	13.18	1.88	2.09
11	1.51	3.71	0.97	1.01
12	1.60	2.33	0.95	1.07
13	1.60	2.19	1.12	1.16
14	1.51	2.03	1.06	1.10
15	1.58	2.92	1.09	1.14
16	1.31	2.29	1.04	1.10
17	1.35	1.97	1.01	1.10
18	4.79	18.33	1.99	1.94
19	2.31	4.06	1.44	1.14
20	2.40	4.01	1.34	1.16
21	2.58	8.92	1.10	1.05
22	2.02	5.40	0.82	0.95
23	1.28	1.70	0.83	0.81
24	1.33	1.97	0.74	0.75

5. 결론

본 논문에서는 MLP의 단점을 극복하기 위한 효과적인 대안으로 인식되고 있는 뉴로-퍼지 모델을 이용하여 한 시간 앞의 전력 수요를 예측하기 위한 체계적인 방법을 제안하였다. 특히, 한 시간마다 뉴로-퍼지 모델을 학

습할 때 구조 학습을 반복해야 하는 문제를 해결하기 위해서 4개의 요일 유형에 대해 시간별 초기 구조를 미리 학습하고, 이를 초기 구조 बैं크에 저장하는 방법을 제안하였다. 제안된 방법에서는 초기 구조 बैं크에서 예측 시점에 해당되는 초기 구조를 선택하여 뉴로-퍼지 모델을 초기화하기 때문에, 초기화된 뉴로-퍼지 모델의 인자 학습 과정만을 매 시간 반복하게 된다.

제안된 방법의 효용성을 검증하기 위해서 1996년과 1997년 한국 전력의 실제 데이터를 이용하여 모의 실험을 수행하였다. 모의 실험 결과 제안된 방법은 MAPE의 평균이 1.06% 수준이었고 MAPE의 표준편차는 평균적으로 0.82 정도였다. 한시간 앞의 전력 수요 예측 시스템에서 실용화가 가능한 MAPE의 평균이 보통 1% 미만인 점을 고려하면, 본 논문에서 제안한 방법이 실용화 측면에서도 만족할 만한 성능을 얻는다는 것을 알 수 있었다.

제안된 방법의 성능을 기존의 방법과 비교하기 위해서 MLP를 이용한 예측시스템을 구현하여 동등한 조건에서 성능의 비교 평가를 수행하였다. 제안된 방법의 성능이 MAPE의 평균과 MAPE의 표준편차 측면에서 모두 우수한 결과를 보였으며, 이로부터 제안된 방법이 보다 정확하고 신뢰할 수 있는 예측시스템을 구현할 수 있다고 결론지을 수 있었다.

향후 진행되어야 할 연구의 방향은 크게 두 가지로 요약된다. 첫째, 본 논문에서는 다루지 않았지만, 전력 수요 예측시스템 개발에서 매우 중요한 고려 사항인 계절(온도) 요인과 특수일에 대한 연구를 수행할 예정이다. 특히, 계절별 요인에 대해 향상된 예측시스템을 구성하기 위해서, 초기 구조를 학습할 때 1년치의 학습 데이터를 모두 사용하지 않고, 계절별로 제한된 학습 데이터만을 이용하여 계절별 초기 구조를 구성하는 방법을 연구할 예정이다. 이 경우 계절별로 초기 구조 बैं크를 재학습하는 문제를 해결해야 한다. 둘째, 예측 문제의 범위를 확장할 계획이다. 제안된 방법은 1시간 앞의 전력 수요를 예측하는 문제뿐만 아니라, 다음날 24시간 전체의 전력 수요를 예측하는 문제 또는 향후 일주일 168시간의 전력 수요를 예측하는 문제 등과 같이 다양한 수요 예측 문제에서도 매우 효과적일 것으로 기대된다.

(감사의 글)

본 연구가 가능하도록 전력 수요 데이터를 제공해준 한국전력에 감사드립니다. 본 논문은 2000년도 두뇌한국21 사업에 의하여 지원되었으며 이에 감사드립니다.

(참 고 문 헌)

- [1] 김형수, 문경준, 황기현, 박준호, 이화석, "신경회로망을 이용한 단기전력부하 예측용 시스템 개발," 대한전기학회 하계학술대회 논문집, pp. 24-26, 1999.
- [2] 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.
- [3] T. W. Chow and C. T. Leung, "Neural Network Based Short-Term Load Forecasting Using Weather Compensation," IEEE Trans. on Power Systems, Vol. 11, No. 4, pp. 1736-1742, Nov. 1996.
- [4] K. H. Kim, J. K. Park, K. J. Hwang, and S. H. Kim, "Implementation of Hybrid Short-Term Load Forecasting System Using Artificial Neural Networks and Fuzzy Expert Systems," IEEE Trans. on Power Systems, Vol. 10, No. 3, pp. 1534-1539, Aug. 1995.
- [5] A. Khotanzad, R. C. Hwang, A. Abaye, and D. Maratukulam, "An Adaptive Modular Artificial Neural Network Hourly Load Forecaster and its

Implementation at Electric Utilities," IEEE Trans. on Power Systems, Vol. 10, No. 3, pp. 1716-1722, Aug. 1995.

- [6] A. G. Bakirtzis, J. B. Theoharis, S. J. Kiartzis, and K. J. Satsios, "Short Term Load Forecasting Using Fuzzy Neural Networks," IEEE Trans. on Power Systems, Vol. 10, No. 3, pp. 1518-1524, Aug. 1995.
- [7] H. Mori and H. Kobayashi, "Optimal Fuzzy Inference for Short-Term Load Forecasting," IEEE Trans. on Power Systems, Vol. 11, No. 1, pp. 390-396, Feb. 1996.
- [8] 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.
- [9] B. H. Wang and H. J. Cho, "Structure Identification of Neuro-Fuzzy Models Using Genetic Algorithms," submitted to IEEE Trans. Fuzzy Systems, 1998.
- [10] M. Kubat, "Decision Trees can Initialize Radial Basis Function Networks," IEEE Trans. Neural Networks, Vol. 9, No. 5, pp. 813-821, Sept. 1998.
- [11] P. Wasserman, Advanced Methods in Neural Computing, Van Nostrand Reinhold, 1993.
- [12] 박영진, 심현정, 왕보현, "뉴로-퍼지 모델을 이용한 단기 전력 수요 예측시스템," 대한전기학회 논문지, 49-A권, 3호, pp. 107-117, 2000.