

뉴로-퍼지 모델 기반 단기 전력 수요 예측시스템: 신뢰도 계산

심현정, 박래정, 왕보현
(주) 보이스웨어, 강릉대학교 전자공학부^{**}

Neuro-Fuzzy Model based Short-Term Electrical Load Forecasting: Reliability Computation

Hyun-Jeong Shim, Lae-Jeong Park, Bo-Hyeun Wang
Voiceware Co., Ltd., Kangnung National University^{***}

Abstract - 본 논문은 뉴로-퍼지 모델의 구조 학습을 이용한 단기 전력 수요 예측시스템에서 예측치별로 신뢰도를 계산하는 체계적인 방법을 제안한다. 예측시스템의 신뢰도를 추정하는 작업은 특히 신경회로망과 같은 경험적 모델을 실제 활용하기 위해서 필수적인 연구로 인식되고 있다. 본 논문에서 제안하는 출력별 신뢰 구간 계산 방법은 지역 표현하는 뉴로-퍼지 모델의 특성을 활용하여 학습된 퍼지 규칙 각각에 대해 신뢰도를 추정하는 Local reliability measure 기법을 사용한다. 제안된 신뢰도 계산이 가능한 단기 전력 수요 예측시스템은 먼저 결정 트리를 이용하여 초기 구조를 생성하고, 이를 초기 구조 맹크에 저장한다. 저장된 초기 구조 맹크를 이용하여 뉴로-퍼지 모델을 학습하고, 학습된 퍼지 규칙의 신뢰도를 추정한다. 제안된 시스템의 실효성을 검증하기 위해서 한국 전력에서 수집한 1996년과 1997년의 실제 전력 수요 데이터를 이용하여 한 시간 앞의 수요를 예측하는 모의 실험을 수행하고 실험 결과를 비교 분석한다.

1. 서 론

전력 수요 예측시스템은 전력 계통에서 신뢰할 수 있는 운용 계획을 수립하기 위한 자료를 제공한다. 특히, 단기 수요 예측은 경제적인 발전 및 급전 계획과 전력조류 계산 등과 같은 전력시스템의 안정도를 평가하기 위한 입력 자료로 활용되기 때문에 정확하고 신뢰할 수 있어야 한다. 이러한 요구에 부응하기 위해서 비선형적인 데이터에 대해 우수한 학습 및 근사화 능력을 갖고, 유연한 입력 선택이 가능한 신경회로망을 전력 수요 예측 모델에 적용하기 위한 연구가 활발하게 수행되어 왔다 [1]. 그러나 이러한 연구에서 예측의 정확도 측면에서는 성공적인 결과를 얻었으나, 예측 시스템의 불확실성 또는 신뢰성이 관계 고려는 상대적으로 미흡한 실정이다. 특히, 신경회로망과 같이 학습에만 의존하여 구현된 경험적 모델을 실제 활용하기 위해서는 신뢰도에 관한 연구가 필수적이다. 이것을 위해 최근 신경회로망의 출력별 신뢰도 계산 연구와 지금까지의 신뢰도 계산의 결과를 비교하는 연구가 이루어지고 있다 [2-6].

본 논문은 뉴로-퍼지 모델을 이용한 단기 전력 수요 예측시스템에서 예측치 별로 신뢰 구간을 계산하는 방법을 제안한다. 기본적으로 신뢰 구간 계산이 가능한 예측 시스템을 개발을 위해서 [10]에서 제안한 뉴로-퍼지 모델의 구조 학습을 이용하여 요일별 시간별 초기 구조를 생성하고, 이를 활용하여 예측 모델을 실시간 학습하는 방법을 그대로 사용한다. 개발된 뉴로-퍼지 모델 기반 예측시스템의 출력별 신뢰 구간 계산은 [6]에서 우수한 성능이 입증된 local reliability measure (LRM) 기법을 사용한다. 지역 표현하는 신경회로망의 특성을 활용하기 위해서 고안된 LRM 방법은 뉴로-퍼지 모델에서 학습된 퍼지 규칙 각각에 대해 신뢰도를 추정하고, 이를 토대로 예측 모델의 출력에 대한 신뢰 구간을 계산하기 때문에 학습된 예측 모델의 신뢰도를 규칙 단위에서 추정할 수 있다. 제안된 방법의 타당성을 검증하기 위해서 1996년

부터 1997년까지 한국 전력에서 수집한 실제 부하 데이터를 이용하여 한시간 앞의 수요를 예측하는 예측시스템을 구현하고 예측치의 신뢰 구간을 계산하는 모의 실험을 수행한다.

본 논문의 구성은 다음과 같다. 2장에서는 뉴로-퍼지 모델과 구조 학습 그리고 뉴로-퍼지 모델의 출력별 신뢰 구간을 계산하기 위해 적용된 방법에 관해서 소개하고, 3장에서는 예측과 신뢰도를 동시에 제공하는 뉴로-퍼지 기반 전력 수요 예측시스템을 설명한다. 4장에서는 실제 한국전력의 부하 데이터를 이용한 모의 실험을 수행하고 실험 결과를 분석한다. 마지막으로 5장에서 결론을 제시한다.

2. 뉴로-퍼지 모델의 출력별 신뢰도 계산 방법

2.1 뉴로-퍼지 모델과 구조 학습

본 절에서는 단기 전력 수요 예측시스템의 예측 엔진을 구현하는 뉴로-퍼지 모델에 관하여 간략하게 소개한다. 뉴로-퍼지 모델은 다음과 같은 형태의 퍼지 규칙을 학습하고 추론한다:

- 규칙 1: $(x_1 \text{ is } A_{11}^1) \text{ and } (x_2 \text{ is } A_{12}^1) \text{ and } \dots$
and $(x_n \text{ is } A_{1n}^1)$, then $y \text{ is } w^1$.
- 규칙 2: $(x_1 \text{ is } A_{21}^2) \text{ and } (x_2 \text{ is } A_{22}^2) \text{ and } \dots$
and $(x_n \text{ is } A_{2n}^2)$, then $y \text{ is } w^2$. (1)

- 규칙 p : $(x_1 \text{ is } A_{p1}^p) \text{ and } (x_2 \text{ is } A_{p2}^p) \text{ and } \dots$
and $(x_n \text{ is } A_{pn}^p)$, then $y \text{ is } w^p$.

여기서 x_j ($1 \leq j \leq n$)는 입력 변수, y 는 출력 변수이다. A_i^j 와 w^i ($1 \leq i \leq p$)는 소속 함수에 의해 정의되는 퍼지 집합이다. 임의의 입력 x 가 주어지면 뉴로-퍼지 모델의 출력은 다음 식으로 계산된다:

$$F(x, w) = \frac{\sum_{i=1}^p w^i R_i(x)}{\sum_{i=1}^p R_i(x)} \quad (2)$$

여기서 Gaussian 함수로 전건부 소속 함수 A_i^j 를 구현하면, i 번째 규칙의 적합도 $R_i(x)$ 는 다음과 같이 구해진다:

$$R_i(x) = \prod_{j=1}^n \exp \left[- \left(\frac{x_j - c_{ij}}{\sigma_{ij}} \right)^2 \right] \quad (3)$$

뉴로-퍼지 시스템의 학습은 학습 데이터를 이용하여 입력 공간을 분할하는 구조 학습과 전건부 소속 함수 A_i^j 와 후건부 인자 w^i 를 설정된 목적 함수를 최소화하도록 정하는 인자 학습으로 구성된다 [7]. 본 논문은 결정 트리를 이용하여 입력 공간을 분할하고 [8], 오차 역전파 학습을 이용하여 인자 학습을 수행한다.

2.2 Leonard의 local reliability measure

신뢰도 개념을 이해하기 위해 신경회로망 모델의 함수 근사화 문제를 고려하자. 근사 함수 $F(x, w)$, $x \in R^n$ 가 비지의 연속 함수 $f(x)$ 를 가능한 잘 표현하도록 선정한 후 학습 데이터를 이용하여 근사 함수의 인자 w 를 학습한다. 근사 함수의 학습을 위하여 다음과 같이 m 개의 데이터로 구성된 학습 집합을 고려하자:

$$L = \{(x_i, f(x_i)) | i=1, 2, \dots, m\} \quad (4)$$

모델의 특정한 입력에 대한 모델의 출력별 신뢰도를 계산하기 위해서 통계학의 구간 추정 이론에 기반한 신뢰 구간을 이용한다 [9]. 신뢰 구간은 특정한 입력에 대한 모델 출력의 오차 범위를 추정한다. 학습된 근사 함수에 입력 $x \in R^n - L$ 를 가하고, 연속 함수 $f(x)$ 가 오차 구간에 존재할 확률을 r 이라 가정하자:

$$\Pr[F(x, w^* \leftarrow L) - CL \leq f(x) \leq F(x, w^* \leftarrow L) + CL] = r \quad (5)$$

여기서 확률 r 을 신뢰 상수라 하고, 오차 구간 $[F(x, w^* \leftarrow L) - CL, F(x, w^* \leftarrow L) + CL]$ 를 $(r \times 100)\%$ 신뢰 구간이라 한다. 신뢰 구간의 추정은 주어진 r 에 대하여 CL 을 구하는 작업이다. 본 논문에서 수행하는 모의 실험은 편의상 95% 신뢰 구간을 계산한다.

1992년에 Leonard는 뉴로-퍼지 모델과 같이 지역 표현에 기반한 신경회로망의 각 지역에 해당하는 베이시스 함수에 대한 지역 신뢰 구간을 계산하고, 임의의 테스트 입력에 대해서 해당하는 베이시스 함수의 신뢰 구간의 가중 평균을 모델 출력의 신뢰 구간으로 출력하는 local reliability measure 방법을 제안하였다.

뉴로-퍼지 모델을 식 (4)와 같이 주어진 학습 집합을 이용하여 학습하고, 모델의 오차를 구한다:

$$e(x_i) = F(x_i, w^* \leftarrow L) - f(x_i), \text{ for } x_i \in L, i=1, 2, \dots, m \quad (6)$$

여기서 모델의 오차 $e(x_i)$ 는 Gaussian 랜덤 변수라 가정한다. 구해진 m 개의 오차 샘플을 이용하여 h 번째 퍼지 규칙에 대한 모델 오차의 지역 평균과 지역 분산을 추정한다:

$$\hat{\mu}_h = \frac{1}{n_h} \sum_{i=1}^{n_h} R_h(x_i) e(x_i) \quad (7)$$

$$s_h^2 = \frac{1}{(n_h - 1)} \left[\sum_{i=1}^{n_h} R_h(x_i) e^2(x_i) \right] \quad (8)$$

여기서 n_h 는 h 번째 규칙과 연관된 입력 데이터의 수를 의미하며 다음과 같이 계산된다:

$$n_h = \sum_{i=1}^{n_h} R_h(x_i) \quad (9)$$

h 번째 규칙에 대한 모델 오차의 지역 평균을 0이라 가정하면, 식 (10)와 같이 정의된 랜덤 변수 t 의 자유도가 $(n_h - 1)$ 인 Student t -분포를 따른다:

$$t(n_h - 1) \sim \frac{\hat{\mu}_h - \mu_h}{s_h / \sqrt{n_h}} = \frac{-\mu_h}{s_h / \sqrt{n_h}} \quad (10)$$

여기서 μ_h 는 h 번째 규칙에 대한 모델 오차의 실제 지역 평균이다. h 번째 규칙에서 모델 오차의 실제 지역 평균값이 존재할 95% 신뢰 구간은 h 번째 규칙과 연관된 모델 오차의 샘플 평균 $\hat{\mu}_h$ 의 분산 s_h^2 / n_h 을 이용하

여 다음과 같이 구할 수 있다:

$$CI_h = [\hat{\mu}_h - CL_h \leq \mu_h \leq \hat{\mu}_h + CL_h] \quad (11)$$

여기서 $CL_h = t_{0.95} \frac{s_h}{\sqrt{n_h}}$ 이고, $t_{0.95}$ 는 Student t -분포에서 $(n_h - 1)$ 자유도를 갖는 95% 신뢰도의 결정 값이다.

일반적으로 모델 오차의 평균에 대한 신뢰 구간보다 우리는 임의의 입력에 대한 모델의 출력 오차에 대한 신뢰 구간이 필요하다. 이를 위해서 평균의 분산과 모델 오차의 분산의 합을 사용하여 h 번째 규칙에 대한 오차 한계를 계산한다:

$$CL'_h = t_{0.95} s_h \sqrt{(1 + 1/n_h)} \quad (12)$$

임의의 테스트 입력 x 에 대한 모델의 오차 한계는 각 규칙에 대하여 식 (14)에서 계산한 규칙별 오차 한계를 가중 평균하여 계산된다:

$$CL(x) = \frac{\sum_{h=1}^H CL'_h R_h(x)}{\sum_{h=1}^H R_h(x)} \quad (13)$$

모델의 오차 한계를 이용하여 실제 출력 $f(x)$ 가 존재하는 95% 신뢰 구간을 다음과 같이 추정한다:

$$CI = [F(x, w^* \leftarrow L) - CL(x) \leq f(x) \leq F(x, w^* \leftarrow L) + CL(x)] \quad (14)$$

식 (13)와 식 (14)에서 알 수 있듯이 모델의 출력 오차에 대한 신뢰 구간은 각 퍼지 규칙의 신뢰 구간을 가중 평균하여 구할 수 있으며, 뉴로-퍼지 모델에 은닉층을 공유하는 별도의 출력층을 추가하여 그림 1과 같이 간단하게 구현할 수 있다.

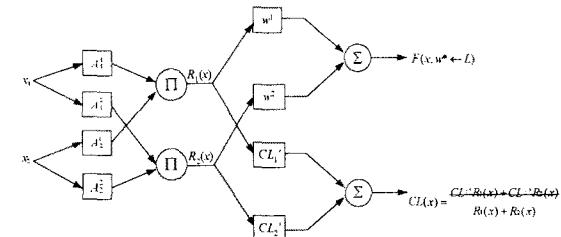


그림 1. Leonard의 local reliability measure

3. 출력별 신뢰도 계산이 가능한 단기 전력 수요 예측시스템

본 논문은 [10]에서 제안된 뉴로-퍼지 모델을 그대로 이용하여 한 시간 앞의 전력 수요를 예측한다. 또한 계산된 예측치에 대해 local reliability measure를 적용하여 계산된 신뢰 구간을 예측치와 함께 제공하는 단기 전력 수요 예측시스템을 제안한다. 그림 2가 제안하는 예측시스템을 나타낸 것이다.

그림 2에서 초기 구조 맹크는 뉴로-퍼지 모델의 초기화에 필요한 초기 구조를 저장한다. 본 논문에서의 초기 구조 맹크의 생성을 위한 학습 데이터 준비와 초기 구조 생성 알고리듬은 [10]에서의 방법을 그대로 사용한다. 하나의 초기 구조를 생성하는데 필요한 학습 데이터는

해당 요일 유형 및 해당 시간을 참조하여 개별적으로 수집된다. 초기 구조 생성을 위한 학습 데이터가 준비되면, 먼저 군집의 수를 2로 하고, 결정트리를 이용하여 초기 구조를 만든다. 만약 생성된 규칙의 수가 허용 규칙의 수보다 적으면, 뉴로-퍼지 모델을 초기화하고 학습한다. 학습된 뉴로-퍼지 모델의 오차가 허용 오차보다 작을 경우 작업을 종료하고, 그렇지 않은 경우 군집의 수를 하나 늘려 초기 구조를 다시 만든다. 만약 규칙의 수가 허용 규칙의 수보다 크면, 결정트리를 pruning하여 허용 규칙의 수보다 적은 수의 퍼지 규칙을 갖는 초기 구조를 만들고, 뉴로-퍼지 모델을 학습한 후 작업을 종료한다.

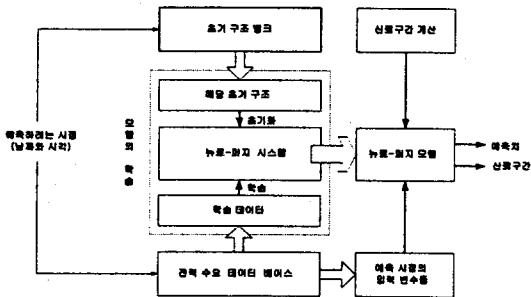


그림 2. 제안된 뉴로-퍼지 기반 전력 수요 예측 시스템의 구조.

예측시스템의 입력 변수 설정은 예측 모델의 성능을 좌우한다. 본 논문에서 단지 두 개의 입력 변수만으로 예측의 정확도 측면에서 비교할 만한 수준의 결과를 얻었다. 선정된 입력 변수는 $p(i, t-1)$ 과 $p(i-1, t)$ 이고 출력 변수는 $p(i, t)$ 이다. 여기서 i 는 예측이 수행되는 날을, t 는 예측하는 시점을 각각 의미한다.

한 시간 앞의 전력 수요를 예측하는 예측시스템을 학습하기 위해서 먼저 초기 구조 백크에 미리 저장된 초기 구조 중에서 예측 시점에 해당하는 초기 구조를 로드하여 뉴로-퍼지 모델을 초기화한다. 그림 3과 같이 m 개의 학습 데이터로 구성된 학습 집합을 이용하여 초기화된 뉴로-퍼지 모델의 인자를 학습한다. 이 과정에서 뉴로-퍼지 모델의 전건부 인자와 후건부 인자가 모두 학습된다. 인자 학습이 완료된 뉴로-퍼지 모델에서 학습 집합 L 을 이용하여 그림 3과 같이 m 개의 모델 오차를 확보한다:

$$e_k = p(i, t) - F(x_k, w^* \leftarrow L) \text{ for } k=1, 2, \dots, m \quad (15)$$

여기서 뉴로-퍼지 모델의 입력 x_k 는 $[p(i-1, t), p(i, t-1)]$ 이다. 확보한 m 개의 모델 오차와 식 (7), (8), (9)와 (12)를 이용하여 h 번째 퍼지 규칙에 대한 오차 한계 CL_h 를 계산한다. 계산된 CL_h 를 이용하여 임의의 입력에 대한 예측치의 신뢰 구간을 그림 1과 같은 구조를 갖는 뉴로-퍼지 모델을 이용하여 추정한다.

제안된 예측시스템에서 한 시간 앞의 전력 수요를 예측하기 위해서 매 시간 뉴로-퍼지 모델을 초기화하고, 인자 학습 및 신뢰 구간 추정 과정을 반복하여 수행한다. 이 과정을 수행하기 위해 필요한 학습 데이터는 앞에서 언급한 2개의 입력 변수를 기초로 전력 수요 데이터 베이스에서 구성한다. 학습 데이터의 수는 임의로 정할 수 있지만 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.

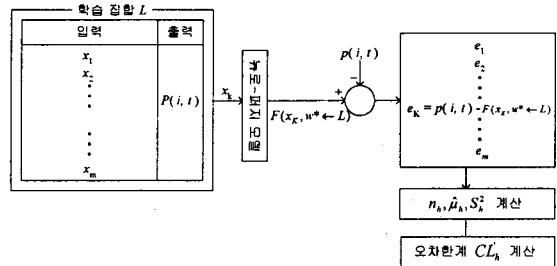


그림 3. 예측시스템의 출력별 신뢰도 계산 방법.

4. 모의 실험 결과 및 분석

제안된 예측시스템의 실현성을 검증하기 위해서 97년 1월부터 97년 12월까지의 전력 수요를 예측하였다. 매 시간 뉴로-퍼지 모델을 학습하기 위해서 본 논문 3장에 제시한 입출력 변수를 토대로 50개의 학습 데이터를 시간 별로 구성하였다 [10]. 평일, 토, 일, 월 구조의 각각 24시간에 대한 96개의 초기 구조를 학습하는데 필요한 학습 데이터는 시간 별로 준비된 학습 집합 중에서 97년 1월 11일부터 1월 20일에 해당되는 학습 집합을 이용하여 표 1와 같이 구성하였다.

초기구조 생성 알고리듬에서 허용 규칙의 수를 10, 허용 오차를 1%로 정하고, 초기 구조 학습 데이터를 이용하여 초기 구조 백크를 생성하였다. 표 2는 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 3.5개의 규칙을 갖고 토요일, 일요일, 월요일 유형에 대해서는 평균 4.2, 4.2, 4.4개의 규칙을 갖는다. 모델의 성능 평가를 위해서 식 (16)의 평균 퍼센트 오차 (Mean Absolute Percentage Error, MAPE)를 사용하였다.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\text{실제부하값} - \text{예측값}}{\text{실제부하값}} \right| \times 100(%) \quad (16)$$

표 1. 초기 구조 백크를 위한 학습 데이터

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

예측을 수행하고자 하는 요일 유형 및 시각에 해당하는 초기 구조를 선택하여 뉴로-퍼지 모델의 구조와 인자를 초기화한다. 준비된 50개의 학습 데이터를 이용하여 초기화된 뉴로-퍼지 모델을 학습하면, 뉴로-퍼지 모델의 전건부와 후건부 인자가 결정된다. 학습이 완료된 뉴로-퍼지 모델에 50개의 학습 데이터를 가하고 모델 오차를 확보한다. 확보된 모델 오차를 이용하여 그림 1에서 퍼지 규칙의 오차 한계를 표현하는 인자 CL_h 를 구하고 신뢰도 계산이 가능한 예측시스템의 구축을 완료한다.

구축된 예측시스템을 사용하여 한 시간 앞의 부하를 예측하고, 계산된 예측치의 신뢰 구간을 추정하여 제안된 예측시스템의 성능을 분석하였다. 이를 위하여 97년 1월 21일부터 97년 12월 31일까지의 테스트 결과와

신뢰구간의 계산 결과를 월별, 요일별, 시간별로 표 3, 4, 5에 요약하였다. 본 논문에서 개발한 예측시스템은 특수일에 대해 전혀 고려하지 않았기 때문에, 특수일에 대한 예측 결과를 제외하고 성능을 분석하였다.

테스트 데이터에 대한 성능 분석 결과 MAPE의 평균은 1.12이고, MAPE의 표준 편차는 1.20정도의 결과를 보였다. 표 3의 월별 분석 결과에서 알 수 있듯이 여름철의 6월과 7월에서 MAPE의 평균이 특히 나빠지는 것을 알 수 있다. 이는 제안된 수요 예측시스템의 성능을 향상하기 위해서 여름철의 수요 예측에 대한 보완책이 필요함을 입증하는 결과이다. 또한 동일한 예측시스템 설계 방법으로 3개의 입력 변수를 사용한 [10]의 결과와 비교하면, 2개의 입력 변수를 사용하여 얻은 결과가 3개의 입력 변수를 사용한 모델의 성능에는 조금 못 치지만 비교할 만한 결과를 얻음을 알 수 있다.

시간별로 뉴로-퍼지 모델을 학습하고 예측치를 구함과 동시에 예측치에 대한 신뢰 구간을 추정한다. 표 3, 4, 5에서 정량적 결과는 예측치 별로 추정된 95% 신뢰 구간의 정량적 분석 결과이다. 신뢰 구간의 정량적 분석은 실제 부하 값이 신뢰 구간에 포함되는 확률을 계산하여 수행하였다. 97년 1월 21일부터 12월 31일까지 계산된 신뢰 구간에 실제 부하가 존재하는 확률은 87.88%이다. 이것은 95%로 계산된 실제 신뢰 구간보다는 tight하게 추정된 것을 의미한다. 표 3은 예측시스템의 정확도 측면의 성능과 추정된 신뢰 구간의 정확성이 서로 연관되어 있음을 보인다. MAPE의 평균이 2% 수준 까지 높아지는 7월과 8월에서는 신뢰 구간이 매우 부정확하게 추정되었음을 알 수 있다. 또한 6월과 9월 그리고 1월과 2월에서도 이와 비슷한 경향을 관찰 할 수 있다.

표 2 결정된 초기구조의 규칙 수와 학습 오차율

유형	평일		토요일		일요일		월요일	
	규칙	학습	규칙	학습	규칙	학습	규칙	학습
시각	수	오차율	수	오차율	수	오차율	수	오차율
1	2	0.55	4	0.90	7	0.88	4	0.73
2	2	0.50	2	0.48	5	0.52	2	0.49
3	2	0.57	4	0.57	4	0.46	2	0.64
4	2	0.45	4	0.43	4	0.36	2	0.59
5	2	0.53	2	0.51	2	0.50	5	0.48
6	6	0.47	4	0.47	4	0.46	6	0.57
7	2	0.57	4	0.57	4	0.41	4	0.65
8	2	0.81	6	0.60	8	0.85	5	0.78
9	8	0.81	4	0.88	4	0.92	8	1.02
10	2	0.96	7	1.10	4	0.80	7	0.65
11	4	0.61	2	0.67	2	0.64	2	0.56
12	4	0.42	4	0.64	2	0.53	2	0.69
13	4	0.62	2	0.82	2	0.64	6	0.78
14	2	0.73	4	0.82	2	0.65	2	0.70
15	2	0.63	4	0.73	2	0.65	2	0.60
16	2	0.53	4	0.55	4	0.57	4	0.53
17	6	0.54	3	0.77	5	0.77	4	0.40
18	8	0.76	7	0.85	7	0.94	8	0.87
19	6	0.85	6	0.94	6	1.15	6	1.00
20	2	1.11	6	0.86	9	0.98	8	0.86
21	4	0.70	7	0.69	4	0.81	6	0.83
22	4	0.41	2	0.40	4	0.55	2	0.49
23	4	0.51	4	0.64	2	0.81	2	0.53
24	2	0.63	4	0.70	2	0.82	4	0.47
평균	3.5	0.64	4.2	0.69	4.2	0.69	4.4	0.66

표 3 모의 실험 및 신뢰 구간 계산 결과(월별 분석)

월	1월	2월	3월	4월	5월	6월
Ave.	1.17	1.01	0.67	0.69	0.71	1.45
Std.	0.77	0.90	0.61	0.61	0.66	1.26
정량적 결과(%)	83.7	91.7	98.0	97.9	98.2	76.4
월	7월	8월	9월	10월	11월	12월
Ave.	2.00	2.13	1.16	0.79	0.80	0.80
Std.	1.91	1.72	1.15	0.72	0.72	0.70
정량적 결과(%)	68.1	63.2	89.3	96.0	97.0	96.0

표 4 모의 실험 및 신뢰 구간 계산 결과(요일별 분석)

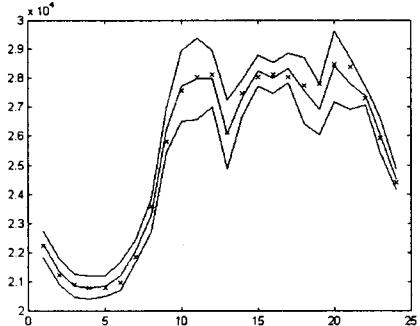
요일	월	화	수	목	금	토	일
Ave	1.23	1.00	1.10	1.08	1.12	1.14	1.18
Std	1.35	1.02	1.33	1.13	1.28	1.13	1.13
Max	15.34	6.81	9.42	7.47	10.27	6.90	5.84
정량적 결과(%)	84.5	90.8	83.8	80.3	77.5	73.4	67.4

표 5 모의 실험 및 신뢰 구간 계산 결과(요일별 분석)

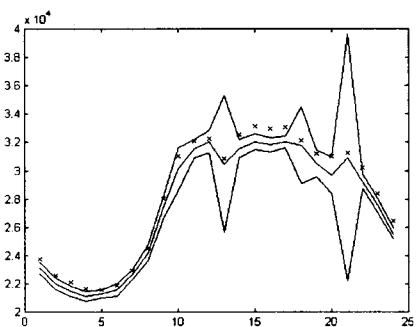
시각	1	2	3	4	5	6	7	8
Ave	0.91	0.88	0.82	0.78	0.71	0.86	0.79	1.17
Std	0.86	0.86	0.88	0.89	0.77	0.77	0.71	0.90
Max	5.11	5.68	6.36	5.90	5.23	4.67	4.59	4.11
정량적 결과(%)	87.9	85.9	85.2	84.9	84.9	86.6	84.9	79.9
시각	9	10	11	12	13	14	15	16
Ave	1.48	1.20	0.99	1.00	1.53	1.04	1.00	0.94
Std	1.10	1.04	1.09	1.18	1.92	1.07	1.13	1.12
Max	5.39	5.17	7.47	8.83	20.54	6.64	6.60	7.33
정량적 결과(%)	90.9	92.0	91.3	90.6	95.3	86.6	84.9	83.9
시각	17	18	19	20	21	22	23	24
Ave	1.07	1.97	1.50	1.58	1.47	0.87	1.06	0.87
Std	1.20	2.30	1.37	1.51	1.36	1.04	1.17	0.88
Max	6.81	16.91	9.11	8.94	8.23	6.60	6.75	5.73
정량적 결과(%)	86.2	93.6	94.6	92.0	93.3	83.6	87.3	85.2

그림 4은 특정일 24시간에 대한 예측 결과와 추정된 신뢰 구간을 보인다. 제안된 예측시스템의 특성을 파악하기 위해서 비교적 정확한 예측이 이루어진 경우 (그림 4 (a))와 그렇지 못한 경우 (그림 4 (b))를 선택하였다. 그림 4에서 가로축은 시간을 세로축은 종 부하를 나타낸다. 또한 ×로 표시된 것이 실제 수요이고, 신뢰 구간내의 실선은 예측된 수요를 의미한다. 그림 4의 (a)에서 알 수 있듯이 예측 오차가 큰 경우 신뢰 구간 또한 넓게 추정되기 때문에, 시스템 사용자가 추정된 신뢰 구간을 예측의 정확도에 대한 지표로 활용할 수 있다. 그

러나 그림 4의 (b)의 경우에서는 추정된 신뢰 구간이 예측치의 정확도를 잘 반영하고 있지 못하며, 결국 예측 성능에 대한 신뢰도 정보를 제공하지 못하게 된다.



(a) 4월 29일 화요일
MAPE = 0.76% 정량적 결과 = 96%



(b) 6월 17일 화요일
MAPE = 1.63%, 정량적 결과 = 46%

그림 4. 예측성능과 정량적 결과에 대한 신뢰구간.

5. 결 론

본 논문은 예측시스템의 실용화를 위해서는 신뢰도 계산이 필수적이라는 인식 하에 뉴로-퍼지 모델 기반 단기 전력 수요 예측시스템에서 예측치별로 신뢰도를 계산하는 체계적인 방법을 제안하였다. 이를 위해 먼저 뉴로-퍼지 모델의 구조 학습을 설명하고, 모델의 신뢰도를 나타내는 신뢰 구간의 개념과 출력별 신뢰 구간 계산 방법을 설명하였다. 출력별 신뢰 구간 계산 방법은 지역 표현하는 뉴로-퍼지 모델의 특성을 활용하여 학습된 퍼지 규칙 각각에 대해 신뢰도를 추정하는 local reliability measure 기법을 사용하였다.

제안된 모델의 실효성을 검증하기 위해 한국 전력에서 1996년부터 1997년까지 수집한 실제 부하 데이터를 이용하여 한 시간 앞의 총 부하와 신뢰 구간을 추정하는 모의실험을 수행하였다. 예측치의 정확도와 추정된 신뢰 구간을 분석하여 제안된 예측 모델의 성능을 평가하였다. 모의 실험 결과 예측 성능은 MAPE의 평균이 1.12, MAPE의 표준 편차의 평균이 1.20, 최대 MAPE은 15.34를 얻었다. 특히 여름철에 해당되는 6월과 7월의 경우 상대적으로 매우 높은 MAPE을 얻었는데, 향후 온도와 같은 날씨 변수를 사용하여 단기 전력 수요 예측시스템의 성능을 향상시킬 수 있을 것이라 생각된다. 신뢰구간에 대한 성능 분석의 경우 전체 테스트 데이터에 대해 실제 수요가 추정된 신뢰 구간에 존재할 확률은 87.88% 이었다. 이것은 계산된 95% 신뢰 구간이 실제 95% 신뢰 구간보다 더 tight하게 추정된 것을 의미한다.

실용화 측면에서 제안된 예측시스템은 예측치 뿐만 아니라 예측치에 대한 신뢰 구간을 동시에 제공하기 때문에, 예측시스템의 사용자가 예측이 수행된 시점에서 예측치가 존재하는 범위를 미리 추정할 수 있게 된다. 만약 추정된 신뢰 구간이 매우 넓다면, 계산된 예측치를 신뢰 할 수 없다는 경고로 활용할 수 있다. 이를 위해서 향후 예측시스템의 출력별 신뢰 구간과 함께 예측의 정확도와 신뢰 구간 사이의 상관 관계를 이용하여 예측 결과에 대한 불확실성을 알릴 수 있는 체계적인 방법이 연구되어야 할 것이다.

[감사의 글]

본 연구가 가능하도록 전력 수요 데이터를 제공해준 한국전력에 감사드립니다. 본 연구는 교육부 두뇌 한국 21 사업의 지원으로 수행되었으며 이에 감사드립니다.

(참 고 문 헌)

- [1] A. G. Bakirtzis, J. B. Theocaris, 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.
- [2] D. H. Wolpert, "Stacked Generalization," Neural Network 5, pp. 241-259, 1992.
- [3] K. Kim. and E. B. Bartlett, "Error Estimation by Series Association for Neural Network Systems," Neural Computation 7, pp. 799-808, 1995.
- [4] D. Lowe and K. Zapart, "Point-wise Confidence Interval Estimation by Neural Networks: A Comparative Study based on Automotive Engine Calibration," Technical Report NCRG/98/007 10, 1998.
- [5] J. A. Leonard, M. A. Karmer and L. H. Ungar, "A Neural Network Architecture that Compute Its Own Reliability," Computer Chem. Engng. Vol. 16, No. 9 pp. 819-835, 1992.
- [6] 심현정, 박래정, 왕보현, "뉴로-퍼지 모델의 신뢰도 계산: 비교 연구," 한국 퍼지 및 지능 시스템 학회 논문지, 제 출중, May 2001.
- [7] B. H. Wang and H. J. Cho, "Structure Identification of Neuro-Fuzzy Models Using Genetic Algorithms," submitted to IEEE Trans. Fuzzy Systems, 1998.
- [8] M. Kubat, "Decision Trees can Initialize Radial Basis Function Networks," IEEE Trans. Neural Networks, Vol. 9, No. 5, pp. 813-821, Sept. 1998.
- [9] H. Stark and J. W. Wood, "Probability, Random Process and Estimation Theory for Engineers," pp. 270-288, 1994.
- [10] 박영진, 심현정, 왕보현, "뉴로-퍼지 모델을 이용한 단기 전력 수요 예측 시스템," 대한전기학회 하계학술대회 논문집, A권, pp. 102-106, July 2000.