

예측율 제고를 위한 사계절 혼합형 열수요 예측 신경망 모델

최승호^{1*} · 이재복² · 김원호³ · 홍준희³

가천대학교 ¹학생, ²연구원, ³교수

(2019년 11월 1일 접수, 2019년 12월 4일 수정, 2019년 12월 9일 채택)

A Model of Four Seasons Mixed Heat Demand Prediction Neural Network for Improving Forecast Rate

Seungho Choi¹ · Jaebok Lee² · Wonho Kim³ · Junhee Hong³

Gachon University ¹Student, ²Researcher, ³Professor

(Received 1 November 2019, Revised 4 December 2019, Accepted 9 December 2019)

요 약

본 연구에서는 기존 열수요 예측 시스템이 공휴일과 같은 특정 일자의 열수요 예측율이 저하되는 문제점을 개선하기 위해 새로운 모델을 제안한다. 제안된 모델은 사계절 혼합형 신경망 모델(Four Season Mixed Heat Demand Prediction Neural Network Model)로서 열수요 예측율 상승하였고, 특히 예측일 유형별(평일/주말/공휴일) 열수요 예측율이 크게 증가하였다. 제안된 모델은 다음과 같은 과정을 통해 선정되었다. 특정 계절에 예측일 유형별로 고른 오차를 갖는 모델을 선정하여 전체 예측 모델을 구성한다. 학습 시간의 단축과 과도학습을 방지하기 위해 구조적으로 단순화된 서로 다른 4개의 모델을 각각 학습한 후에 다양한 조합을 통해 최적의 예측 오차를 보여주는 모델을 선정하였다. 모델의 출력은 예측일의 24시간의 시간대별 열수요이며 총합은 일일 총열수요이다. 이 예측값을 통해 효율적인 열공급 계획을 수립 할 수 있으며, 목적에 따라 출력값을 선택하여 활용할 수 있다. 제안된 모델의 일일 열 총수요 예측의 경우, 전체 MAPE(Mean Absolute Percentage Error, 평균 절대비율 오차)가 개별 모델의 5.3~6.1%에서 5.2%로 향상되었고, 공휴일 열수요예측은 4.9~7.9%에서 2.9%로 크게 개선되었다. 본 연구에서는 한국 지역난방공사에서 제공한 특정 아파트 단지의 34개월 분량의(2015년 1월~ 2017년 10월) 시간단위 열수요 데이터를 활용하였다.

주요어 : 열수요, 수요 예측, 신경망 모델, 혼합형 모델

Abstract - In this study, a new model is proposed to improve the problem of the decline of predict rate of heat demand on a particular date, such as a public holiday for the conventional heat demand forecasting system. The proposed model was the Four Season Mixed Heat Demand Prediction Neural Network Model, which showed an increase in the forecast rate of heat demand, especially for each type of forecast date (weekday/weekend/holiday). The proposed model was selected through the following process. A model with an even error for each type of forecast date in a particular season is selected to form the entire forecast model. To avoid shortening learning time and excessive learning, after each of the four different models that were structurally simplified were learning and a model that showed optimal prediction error was selected through various combinations. The output of the model is the hourly 24-hour heat demand at the forecast date and the total is the daily total heat demand. These forecasts enable efficient heat supply planning and allow the selection and utilization of output values according to their purpose. For daily heat demand forecasts for the proposed model, the overall MAPE improved from 5.3~6.1% for individual models to 5.2% and the forecast for holiday heat demand greatly improved from 4.9~7.9% to 2.9%. The data in this study utilized 34 months of heat demand data from a specific apartment complex

[†]To whom corresponding should be addressed.

Tel : +82-31-750-8638, E-mail: chltmdgh89@gc.gachon.ac.kr

provided by the Korea District Heating Corp. (January 2015 to October 2017).

Key words : Heat Demand, Demand Prediction, Neural Network, Mixed Model

1. 서론

열수요 예측에 대한 국내의 기존 연구들은 출력을 입력의 선형함수 또는 단순한 비선형함수로 설정한 후, 축적된 데이터를 이용하여 계수와 상수를 계산하는 전통적인 회귀모형 모델을 이용하였다 [1][2]. 회귀모형을 이용한 모델의 경우 목적 시스템의 내재된 비선형성을 충분히 반영하지 못하여 오차가 커지는 단점이 있으며, 예측시스템의 확장이나 개선 등에 한계점을 가지고 있다.

해외 사례의 경우 신경망(Neural Network)을 이용한 열수요 예측에 관한 다양한 연구가 존재한다[3-5]. 신경망의 경우 매우 다양하고 검증된 Open Source들이 존재하며, 회귀모형에 비하여 시스템의 비선형성을 충분히 반영할 수 있어 예측 오차가 상대적으로 작은 장점을 가지고 있다. 또한 복잡한 수식보다는 신경망의 입출력 구조에만 연구 역량을 집중하면 되기 때문에 예측시스템의 확장이나 개선이 매우 간편하다. 이에 따라 본 연구에서는 열수요 예측 모델에 신경망 모델을 적용하여 국내외의 기존 연구들의 열수요 예측을 개선한 사계절 혼합형 모델을 제안한다. 제안된 모델은 전체 예측율과 예측일 유형별(평일/주말/공휴일) 열수요 예측율이 개선된 결과를 나타낸다.

Fig. 1은 특정 아파트 단지의 2015년의 연간 일별 총열수요를 나타내는 그래프다. 계절별 온도 특성에 맞게 겨울철에 열수요가 약 43Gcal로 정점을 그리고 봄철에는 하향하다가 여름철에는 최저점에 머무르다가 가을철에는 시간이 갈수록 증가하는 추세를 보여 준다. 이것은 열수요가 온도에 가장 큰 영향을 받는다는 것을 나타낸다.

하루 중 수요 피크가 언제 존재하는 가를 예측하고 효율적인 운영 계획을 수립하는 것은 열에너지의 생산과 저장 및 공급의 과정에서 에너지 사용의 최적화를 위하여 매우 중요하다. Fig. 2는 겨울철 평균 일일 시간대별 열수요로서 8~10시 및 19~23시에 열수요 피크값이 존재하는 것을 알 수 있다.

열수요 예측의 목적은 열병합발전소의 이익 최대화를 위한 전력 및 열생산 계획의 수립과 에너지 사용의 최적화를 위한 일별 수요 피크예측에 있다. 화석연료를 연소하여 전력과 열을 생산하는 열병합발전소는 전력과 열을 모두 판매한다. 따라서 열수요를 예측하게 되면 판매 가능한 전력량도 예측할 수 있으며, 전력의 가격 변동에 따라 이익이 최대화되도록, 열병합발전을 통한 열생산 계획을 수립할 수 있다. Fig. 3은 전력거래소의 전력거래 절차로서 익일공급가능 전력의 입찰을 오전 10시에 마감하도록 되어 있다. 이는 익일의 열




Fig. 2. Average daily heat demand by time for winter




Fig. 1. Total daily heat demand for year(January 2015-January 2016)

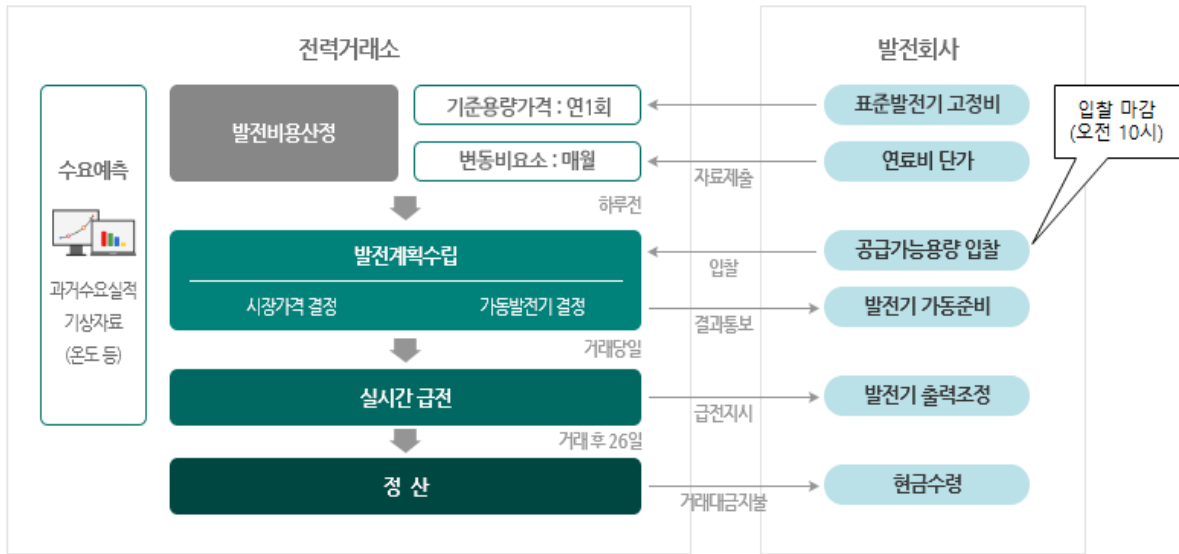


Fig. 3. Power Exchange Procedure(KPX)

수요를 오전 10시 이전에 예측하여야 함을 알 수 있다.

본 연구에서는 일일 열 총수요뿐만 아니라 일일의 24시간 시간대별 열수요까지 예측한다. 이는 하루 중 열수요 피크 시간대를 예측하여 열에너지의 생산과 저장 및 공급의 과정에서 에너지 사용의 최적화를 위한 운영 계획을 수립하도록 하기 위함이다.

2. 열수요 예측 단독 신경망 모델

2.1 신경망 모델의 구조

열수요에 영향을 주는 요소는 기후와 사용자의 생활 패턴이라는 것이 여러 선행 연구들에서 이미 규정되었으며[6-8], 기존의 시계열 회귀모델에 관한 여러 연구들에서 열수요의 과거값 중 하루 전, 일주일전 값이 예측 값에 영향도가 크다는 것이 밝혀져 있다 [3][5]. 이는 열수요의 일일 패턴과 주중 요일별 패턴이 존재함을 암시한다. 단독 모델들은 외기온도와 하루 전 열수요 값과 일주일 전 열수요 값을 공통 입력 값으로 사용한다.

2.1.1 외기온도 기반 모델

Fig. 4는 외기온도기반 열수요 예측 신경망 모델이다. 예측일의 24시간 외기온도가 입력을 구성하며, 하루 전 24시간 열수요와 일주일전 24시간 열수요를 입력으로 사용한다. 다만, Fig. 4의 하단에서 보이듯이 9시에 익일 열수요를 예측하므로, 9시~23시 사이의 열수요는 아직 결정되지 않았기 때문에 이를 전 열수요를 입력한다.

예측 모델의 출력은 예측일의 24시간 열수요이며, 모델의 은닉층(Hidden Layer)은 동일한 뉴런 개수를 갖는 2개 층으로 구성하였다.

2.1.2 일조량 추가모델

외기온도기반 모델의 입력 변수에 일조량과 구름양을 입력 변수로 추가한 모델이다. 특정 지점에 도달하는 일조량은 태양의 복사에너지이며, 태양광의 일조 각도에 따라 변하며, 연중 일자 그리고 하루 중 시간이 변수로서 작용한다. 또한 특정 지점의 구름양이 입력변수로서 작용하여 실제 도달 일조량을 반영하도록 한다. 일조량은 건물의 온도를 높이는 기후적 작용과[3] 휴일 나들이의 지표로서 생활 패턴적 작용을 기대할 수 있다.

2.1.3 공휴일 모델

일주일 전 열수요를 입력으로 채용하여 매주 돌아오는 주말의 열수요는 예측할 수 있는 반면에, 삼일절과 같은 비정기적인 공휴일은 동일한 방식으로 예측이 어렵다. 따라서 공휴일의 경우에는 가장 최근 주말 또는 공휴일의 열수요를 일주일 전과 하루 전 열수요 대신 입력으로 사용하였다. 예측 결과만 좋다면 모델의 복잡도를 증가시키지 않고 외기온도기반 모델의 구조를 그대로 사용할 수 있다는 장점이 있다.

2.1.4 일조량 및 공휴일 결합 모델

일조량이 건물의 온도를 높일 뿐만 아니라, 거주자들의 휴일 나들이 정도에 영향을 줄 수 있다는 가정 하에 공휴일의 예측 에러를 낮추기 위하여 일조량 모델과 공휴일 모델을 결합하였다. 한 모

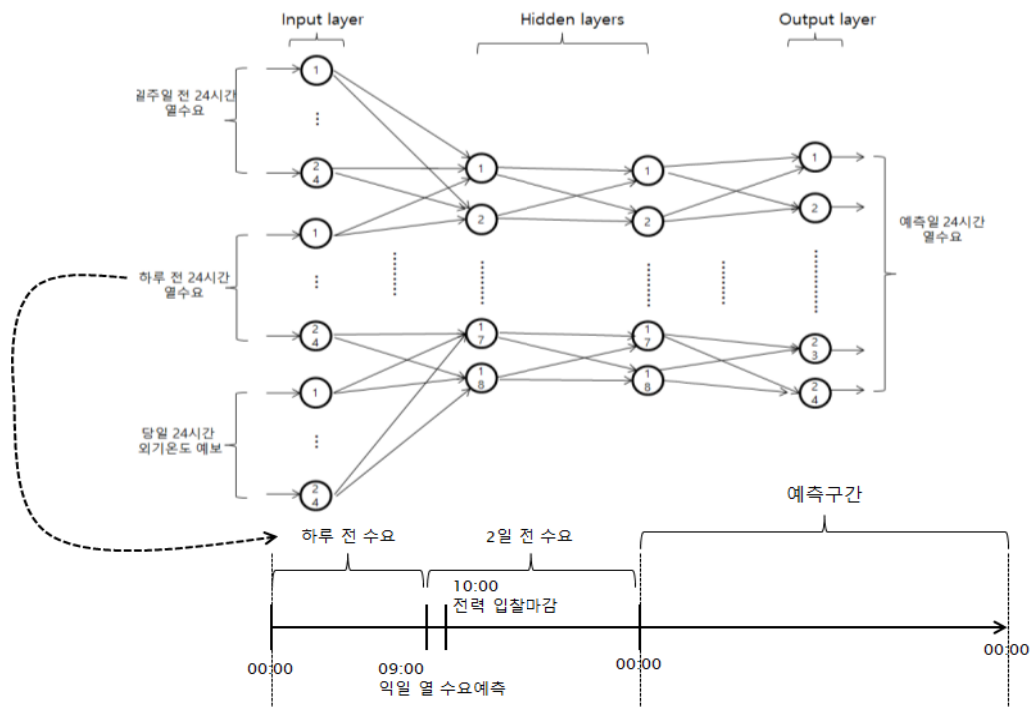


Fig. 4. Neural network model for predicting heat demand by outdoor air temperature

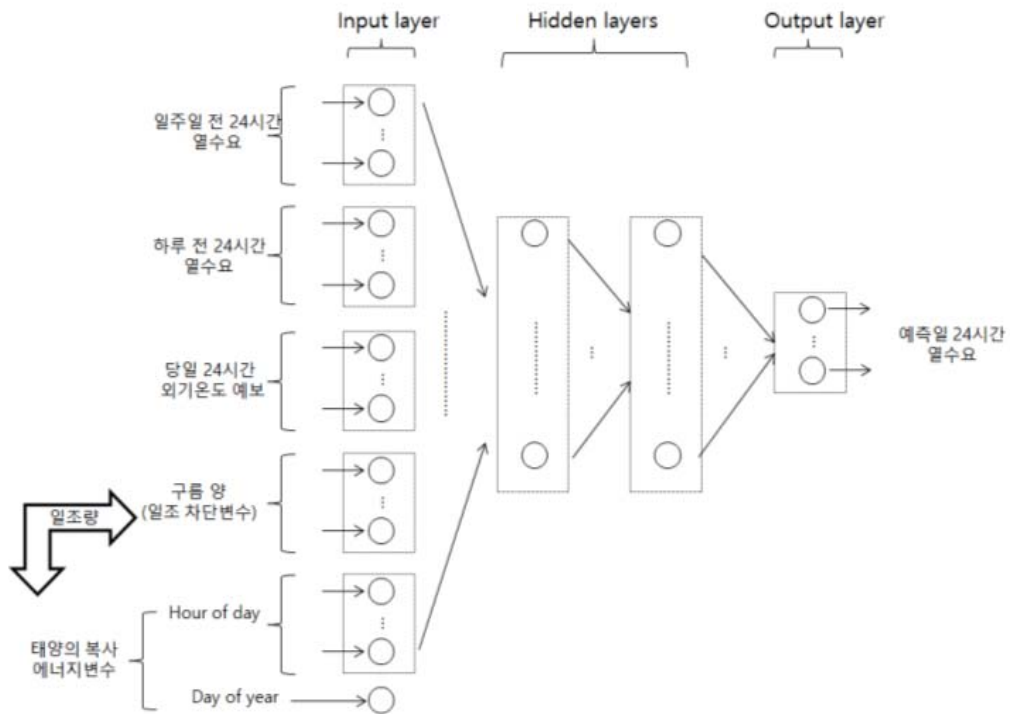


Fig. 5. Additional sunshine neural network model for predicting heat demand

텔이다.

공휴일의 경우 일주일 전 및 하루 전 열수요 대신 가장 최근 주말 또는 공휴일의 24시간 열수요

를 입력으로 사용한다. 이 모델은 외기온도기반 모델, 일조량 추가모델, 공휴일 모델 등 3개 모델의 입력을 모두 결합한 모델이다.

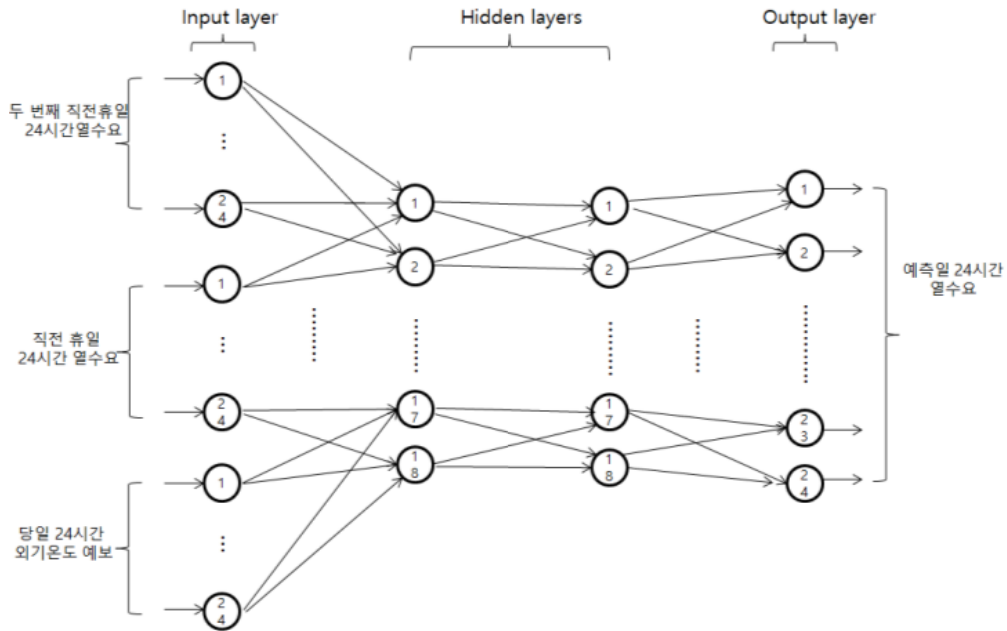


Fig. 6. Neural network model for predicting heat demand for holidays

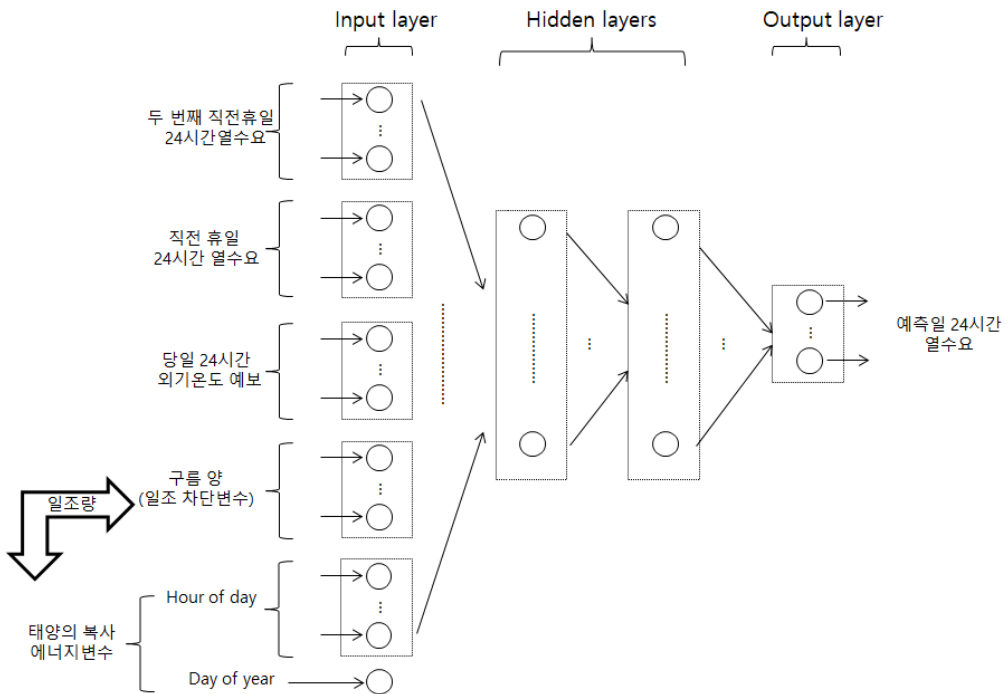


Fig. 7. Sunshine and holiday combination model

2.2 학습 및 검증 결과

34개월 열수요 데이터 중 24개월(2015~2016년)을 신경망 학습에 사용하였으며, 나머지 10개월(2017년 1월~2017년 10월) 데이터를 검증용으로 사용하였다.

Table 1은 예측 시스템의 성능을 표시하는 대표적인 지표를 보여 준다. 다만 평균 제곱근 편차(RMSE)와 평균 절대 편차(MAE)는 열수요 값이 커지면 같이 커지는 특징이 있다. 즉, 열수요 값이 큰 겨울엔 커지고 여름엔 작아지지만, 여름철 열수요 예측 결

Table 1. Verification indicator

지표	수식	특징
RMSE (Root Mean Square Error)	$\sqrt{\frac{1}{N} \sum (\hat{P}(t) - P(t))^2}$	예측변수와 동일한 단위를 갖는다. 예측변수의 범위에 따라 값이 달라진다. 여름에는 작고 겨울에는 커진다.
MAE (Mean Absolute Error)	$\frac{1}{N} \sum (\hat{P}(t) - P(t)) $	예측변수와 동일한 단위를 갖는다. 예측변수의 범위에 따라 값이 달라진다. 여름에는 작고 겨울에는 커진다. 오차가 큰 경우, RMSE에 비해 민감도가 작다.
MAPE (Mean Absolute Percentage Error)	$\frac{1}{N} \sum \left \frac{(\hat{P}(t) - P(t))}{P(t)} \right $	단위는 %이며, 서로 다른 시스템의 결과를 비교할 때 사용할 수 있는 기준 지표이다.

Table 2. Summary of verification results by independent models

Model	MAE	MAPE(%)	DMAE*	DMAPE(%)
Temperature	0.07	8.3	0.57	5.3
Irradiation	0.08	8.9	0.63	6.1
Near_Off_Day	0.07	8.2	0.55	5.3
Irrad_Nearest	0.07	8.5	0.57	5.8

DMAE* : 일간 총 열수요 예측의 MAE

과가 더 정확하다고 말할 수는 없다. 계절별 또는 서로 다른 열수요 데이터를 사용하여 개발한 예측 모델 간의 성능비교에는 RMSE와 MAE를 사용할 수 없다. 반면에 평균 절대 백분율 편차(MAPE)는 서로 다른 모델이나, 계절간 성능 비교에 사용할 수 있는 기준지표가 된다. 따라서 본 논문에서는 MAPE를 검증지표로 사용한다.

Table 2는 프로그램을 통해 각 단독 모델의 검증결과를 분석한 결과를 나타낸 것으로 시간대별 열수요 예측의 MAPE는 공휴일 모델(Near_Off_Day)가 가장 낮은 8.2%, 일조량 추가 모델(Irradiation)이 가장 높은 8.9%를 나타냈다.

일간 총 열수요 예측의 MAPE(DMAPE)의 경우, 외기온도기반 모델(Temperature)과 공휴일 모델(Near_Off_Day)이 가장 낮은 5.3%, 일조량 모델이 가장 높은 6.1%의 MAPE를 기록했다.

2.2.1 일일 시간대별 열수요예측 결과

4계절의 모델별 MAPE를 정리한 Table 3을 보면 봄(3~5월)에는 일조량 및 공휴일 결합 모델(Irrad_Nearest)이 낮고 예측일 유형(평일, 주말, 공휴일)

별로 고른 MAPE의 분포를 갖는다는 것을 알 수 있다. 여름(6~8월)에는 공휴일 모델(Near_Off_Day)이 낮고 고른 MAPE 분포를 보여 주고 있다. 그러나 서두에서 보았듯 여름철 열수요는 매우 작은 값을 가지므로 작은 오차 값에도 MAPE가 커지는 경향이 있다. 가을(9~11월)에는 공휴일 모델(Near_Off_Day)이 낮고 고른 MAPE 분포를 보여 주고 있다. 겨울(12~2월)에는 외기온도 기반 모델과 일조량 및 공휴일 결합모델이 낮고 고른 MAPE 분포를 보여 주고 있다. 이것은 외기온도와 12~2월 사이 많은 공휴일의 수가 열수요에 큰 영향을 미치는 것으로 추론할 수 있다.

Fig. 8은 각 모델별 시간대별 MAPE이다. 봄/가을에는 6~7시, 19~20시 사이에 MAPE가 높고, 겨울에는 10~16시 사이의 MAPE가 높은 것을 알 수 있다.

Fig. 9는 오차가 큰 일자의 MAPE, 예측 수요(NNOutput), 실제 수요(RealOutput)를 표시한 그래프이다. 그림에 나타나듯이 실제 수요 곡선이 주기적 패턴을 갖지 않고 급격하게 변하는 부분이 존재한다. 이것은 특정 시간의 열수요가 누락

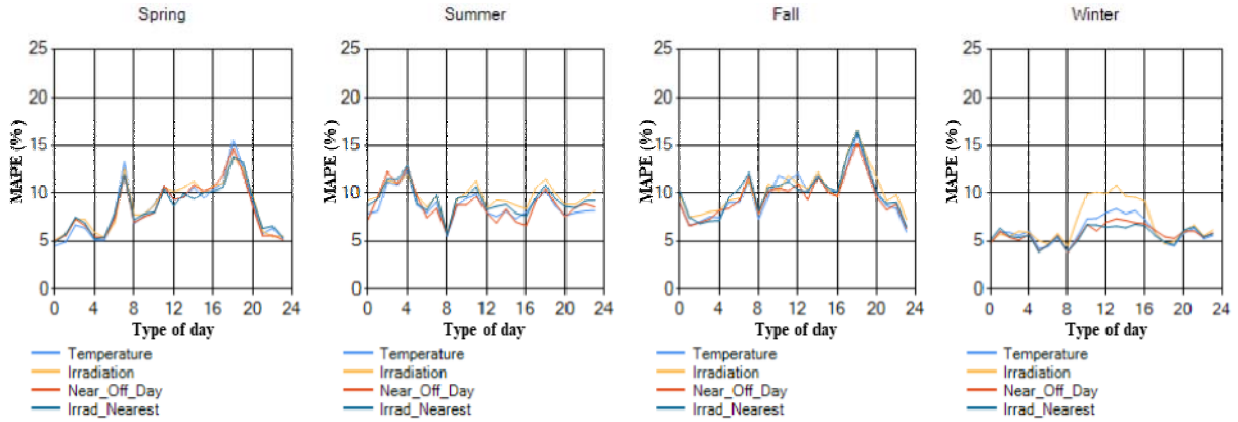


Fig. 8. MAPE by hourly




Fig. 9. MAPE with large error, predictive and actual demand (April 2017)

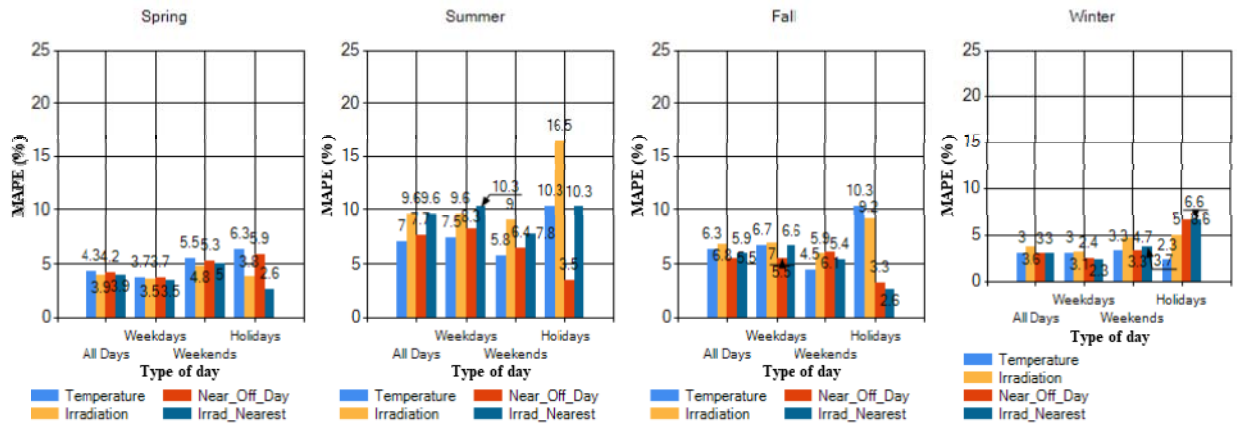


Fig. 10. MAPE of total daily heat demand by type of forecast day for four season

되어 다음 시간대에 누적된 결과로 추정되며, 검증 데이터에 상당 부분 존재하여 일일 열 총수요 값에는 영향이 작지만, 시간대별 열 수요 예측에는 오차를 크게 발생시키는 원인이 되고 있다. 열 수요 데이터 수집 시스템의 개선이 요구된다.

2.2.2 일일 열 총수요 예측 검증 결과

Fig. 10과 Table 4를 통해 알 수 있듯이, 봄(3~5월)에는 일조량 및 공휴일 결합 모델(Irrad_Nearest)이 낮고 예측일 유형(평일, 주말, 공휴일)별로 고 MAPE의 분포를 갖는다. 여름(6~8월)에는 외기온도기반 모델과 공휴일 모델(Near_Off_Day)이

Table 3. MAPE of 24-hour heat demand by seasonal by type of forecast day

계절	구분	전체(%)	평일(%)	주말(%)	공휴일(%)
봄 (3~5월)	외기온도기반모델	8.4	8.2	8.8	10.3
	일조량 추가모델	8.7	8.6	8.6	9.2
	공휴일 모델	8.4	8.4	8.4	8.2
	일조량 및 공휴일 결합모델	8.4	8.5	8.3	7.4
여름 (6~8월)	외기온도기반모델	8.7	8.8	8.4	10.5
	일조량 추가모델	9.6	9.7	9.3	11.3
	공휴일 모델	8.8	8.8	8.7	8.9
	일조량 및 공휴일 결합모델	9.3	9.4	9.1	9.8
가을 (9~11월)	외기온도기반모델	9.9	9.7	9.9	10.6
	일조량 추가모델	10.3	10.4	10.6	10.4
	공휴일 모델	9.6	9.6	9.9	8.9
	일조량 및 공휴일 결합모델	10.1	9.9	10.6	10.0
겨울 (12~2월)	외기온도기반모델	6.0	6.0	6.3	4.8
	일조량 추가모델	6.9	6.5	7.8	6.5
	공휴일 모델	5.8	5.6	6.2	6.5
	일조량 및 공휴일 결합모델	5.7	5.4	6.1	6.3

Table 4. MAPE of total daily heat demand by seasonal by type of forecast day

계절	구분	전체(%)	평일(%)	주말(%)	공휴일(%)
봄 (3~5월)	외기온도기반모델	4.3	3.7	5.5	6.3
	일조량 추가모델	3.9	3.5	4.8	3.8
	공휴일 모델	4.2	3.7	5.3	5.9
	일조량 및 공휴일 결합모델	3.9	3.5	5.0	2.6
여름 (6~8월)	외기온도기반모델	7.0	7.5	5.8	10.3
	일조량 추가모델	9.6	9.6	9.0	16.5
	공휴일 모델	7.7	8.3	6.4	3.5
	일조량 및 공휴일 결합모델	9.6	10.3	7.8	10.3
가을 (9~11월)	외기온도기반모델	6.3	6.7	4.5	10.3
	일조량 추가모델	6.8	7.0	5.9	9.2
	공휴일 모델	5.5	5.5	6.1	3.3
	일조량 및 공휴일 결합모델	5.9	6.6	5.4	2.6
겨울 (12~2월)	외기온도기반모델	3.0	3.0	3.3	2.3
	일조량 추가모델	3.6	3.1	4.7	5.0
	공휴일 모델	3.0	2.4	3.3	6.6
	일조량 및 공휴일 결합모델	3.0	2.3	3.7	6.5

낮고 고른 MAPE 분포를 보여 주고 있다. 가을(9~11월)에는 공휴일 모델(Near_Off_Day)과 일조량과 공휴일 결합 모델(Irrad_Nearest)이 비슷한 정도로 낮고 고른 MAPE 분포를 보여 주고 있다. 겨울(12~2월)에는 외기온도 기반 모델이 낮고 고른 MAPE 분포를 보여 주고 있다. 이것은 외기온도가 일일 열 총수요에 미치는 영향력이 압도적임을 알 수 있다.

3. 혼합형 신경망 모델

2절에서 분석한 결과에서 나타난 것처럼 계절별로 각 모델의 예측 성능이 다르다. 이는 계절별로 열수요에 영향력이 큰 주요 요인이 다르다는 것을 의미하며, 각 단독모델(외기온도기반 모델, 일조량 추가 모델, 공휴일 모델, 일조량 및 공휴일 결합 모델)들의 입력 변수(외기온도, 일조량, 공휴일 등)를 모두 통합한 단일 모델을 고려해 볼 수 있으나, 이에 해당하는 일조량 및 공휴일 결합모델의 경우 봄, 가을에 우수한 성능을 보이고 특히 겨울철에는 외기온도 기반 모델에 비하여 성능이 떨어진다.

Table 5는 2절에서 분석한 계절 및 예측 단위별 성능이 우수한 모델을 정리한 것이다. 일일 열 총수요는 24시간 열수요의 총합이므로 단일 시스템에서 두 개의 예측단위에 대하여 일괄 처리할 수

있다. 따라서 두 개의 예측 단위에서 공통적으로 성능이 우수한 계절별로 선정하여 혼합형 모델을 구성하는 것이 합리적이다. 즉, 봄에는 일조량 및 공휴일 결합 모델, 여름과 가을은 공휴일 모델 그리고 겨울은 외기온도기반 모델로 각각 구성한다.

3.1 4계절 혼합형 신경망 모델의 구조

본 논문에서 제안하는 4계절 혼합형 신경망 모델은 각 단일 모델의 계절별 예측일 유형별 장점을 분석하여 계절별로 다른 단일 모델을 적용하여 구성된 모델로서, Fig. 11과 같은 구조를 가지고 있다. 프로그램의 데이터 입력부에서 예측일이 4계절 중 어디에 해당하는지 판단하여 입력 데이터를 해당 모델로 보내 준다.

3.2 검증 결과

Table 6은 4계절 혼합형 신경망 모델(Mixed_IN_NO_NO_T)의 검증 결과를 요약한 것으로 일일 시간대별 수요예측의 경우 외기 온도기반 모델(Temperature)의 8.3%, 일조량 및 법정공휴일 모델(Irrad_Nearest)의 8.5%, 법정공휴일 모델(Near_Off_Day)의 8.2%의 총괄적 MAPE에 비하여 8.3%를 기록하였고, 이는 단일 모델들의 평균 수준을 약간 상회한다.

일일 열 총수요예측(DMAPE)의 경우 외기온도기반 모델의 5.3%, 일조량 및 법정공휴일 모델의

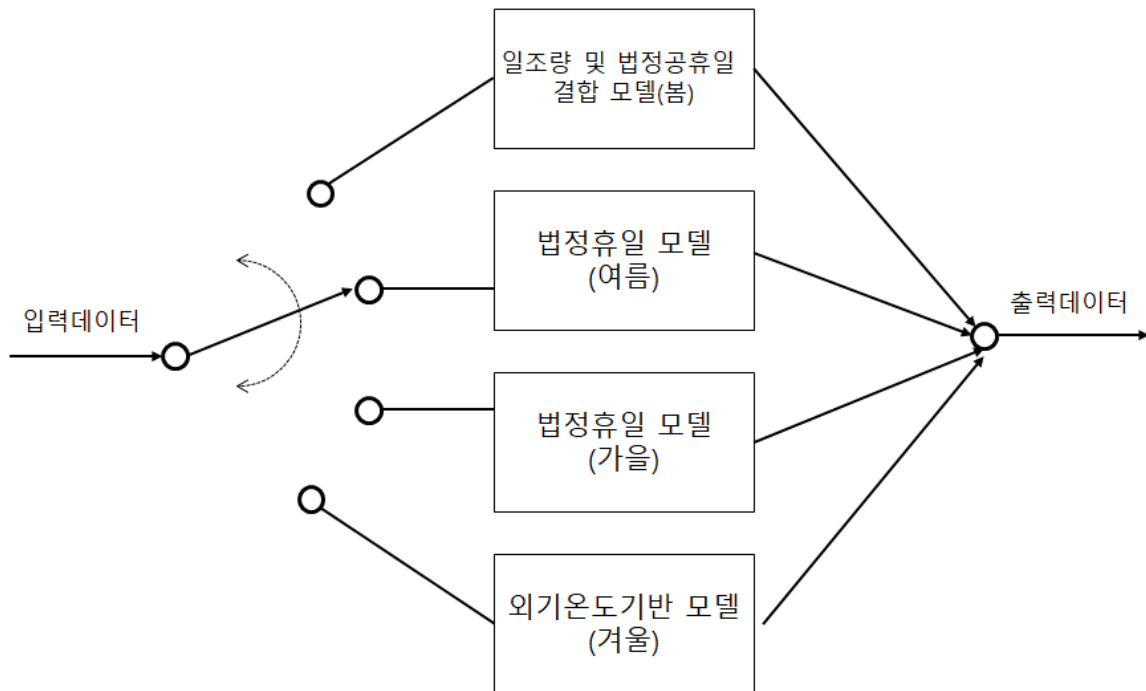


Fig. 11. Structure of mixed neural network model

Table 5. Model with low and even MAPE by seasonal

예측 단위	계절	선정 모델	전체(%)	평일(%)	주말(%)	공휴일(%)
24시간 열수요	봄	일조량 및 공휴일 결합모델	8.4	8.4	8.4	8.2
	여름	공휴일 모델	8.8	8.8	8.7	8.9
	가을	공휴일 모델	9.6	9.6	9.9	8.9
	겨울	외기온도기반모델	6.0	6.0	6.3	4.8
		일조량 및 공휴일 결합모델	5.7	5.4	6.1	6.3
일일 총수요	봄	일조량 및 공휴일 결합모델	3.9	3.5	5.0	2.6
	여름	외기온도기반모델	7.0	7.5	5.8	10.3
		공휴일 모델	7.7	8.3	6.4	3.5
	가을	공휴일 모델	5.5	5.5	6.1	3.3
		일조량 및 공휴일 결합모델	5.9	6.6	5.4	2.6
겨울	외기온도기반모델	3.0	3.0	3.3	2.3	

Table 6. Verification results of the four season mixed neural network model

Model	MAE	MAPE(%)	DMAE	DMAPE(%)
Mixed_IN_NO_NO_T	0.07	8.3	0.55	5.2
Temperature	0.07	8.3	0.57	5.3
Irad_Nearest	0.07	8.5	0.57	5.8
Near_Off_Day	0.07	8.2	0.55	5.3

Table 7. MAPE of 24-hour heat demand by type of forecast day

구분	전체(%)	평일(%)	주말(%)	공휴일(%)
외기온도기반모델	8.3	8.2	8.5	8.9
일조량 추가모델	8.9	8.9	9.0	9.2
공휴일 모델	8.2	8.2	8.4	8.0
일조량 및 공휴일 결합모델	8.5	8.4	8.6	8.4
4계절 혼합형 모델	8.3	8.3	8.4	7.4

5.8%, 법정공휴일 모델의 5.3%의 MAPE에 비하여 5.2%를 기록하였고 이는 단독 모델들보다 우수한 예측 성능을 가지고 있음을 알 수 있다.

3.2.1 일일 시간대별 열수요예측 검증 결과

Table 7은 각 모델의 시간대별 수요예측에 대한 MAPE를 비교한 것으로 4계절 혼합형 신경망 모

델(Mixed_IN_NO_NO_T)이 계절별로 예측일 유형별 MAPE가 낮고 고른 분포를 갖고 있음을 알 수 있다. 즉, 4개 모델의 전체 MAPE의 범위인 8.2~8.9% 내에서는 평균보다 우수한 8.3%로 나타났다. 특히 공휴일의 MAPE의 경우 7.4%로 오차율이 가장 낮게 나타났다.

Table 8. MAPE of total daily heat demand by type of forecast day

구분	전체(%)	평일(%)	주말(%)	공휴일(%)
외기온도기반모델	5.3	5.3	5	7.1
일조량 추가모델	6.1	6.0	6.3	7.9
공휴일 모델	5.3	5.2	5.4	4.8
일조량 및 공휴일 결합모델	5.8	6.0	5.7	4.9
4계절 혼합형 모델	5.2	5.3	5.3	2.9

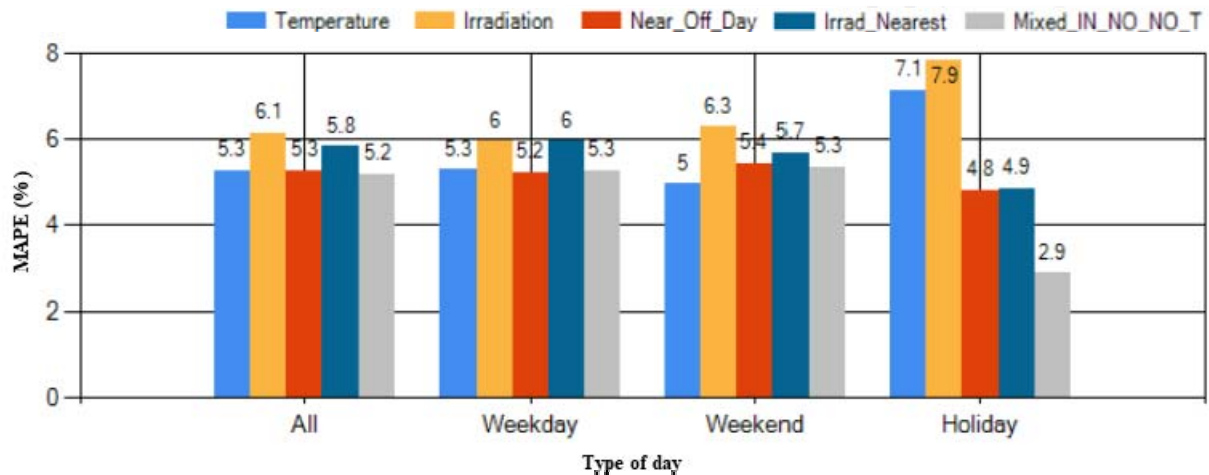


Fig. 12. MAPE of total daily heat demand for type of forecast day

3.2.2 일일 열 총수요예측 검증 결과

Table 8과 Fig. 12를 보면 각 모델의 일일 총수요예측에 대한 MAPE를 비교것을 볼 수 있으며, 4계절 혼합형 신경망 모델(Mixed_IN_NO_NO_T)이 계절별로 예측일 유형별 MAPE가 낮고 고른 분포를 갖고 있음을 알 수 있다. 즉, 전체 MAPE가 개별 모델의 5.3~6.1%에서 5.2%로 향상되었고, 공휴일 열수요예측은 4.9~7.9%에서 2.9%대폭 개선되었다.

개선의 가능성을 높일 수 있다. 특히 제안된 모델의 일일 열 총수요의 MAPE는 5.2%로 서로 다른 환경과 조건의 예측 시스템이지만 기존 연구[3]의 6.4%로 보다도 더욱 개선된 결과를 나타냈다.

사 사

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (No. 20172010000190)

4. 결론

단일 모델들(외기온도 기반 모델, 일조량 추가 모델, 공휴일 모델, 일조량 및 공휴일 결합 모델)에 비하여 혼합형 모델이 전체 예측을 뿐만 아니라 예측일 유형별(평일/주말/공휴일) 예측을 역시 개선된 결과를 나타냈음을 알 수 있었다. 즉 4계절의 기후 차이가 뚜렷한 우리나라에서의 열수요예측 모델은 계절별로 우수한 서로 다른 단일 모델을 적용한 혼합형으로 구성하는 것이 예측을

References

1. Seo, B. S., Shim, S. Y., 2012, Forecasting the Demand for Local District-Heating Systems, Korean Energy Economic Review, Vol. 11, No. 2, pp. 27-55
2. Baek, J. K., Han, J. H., 2011, Forecasting of Heat Demand in Winter Using Linear Regression Models for Korea District Heating Corpo-

- ration, Korean Academy Industrial Cooperation Society, Vol. 12, No. 3, pp. 1488-1494
3. Magnus Dahl, Adam Brun, Oliver S. Kirsebom, Gorm B. Andersen, 2018, Improving Short-Term Heat Load Forecasts with Calendar and Holiday Data, *energies*, Vol. 11, No. 7, pp. 1-16
 4. Krzysztof Wojdyga, 2014, Predicting Heat Demand for a District Heating Systems, *International Journal of Energy and Power Engineering*, Vol. 3, No. 5, pp. 237-244
 5. Vincent Bakker, Albert Molderink, Johann L. Hurink and Gerard J.M. Smit, 2008, Domestic Heat Demand Prediction Using Neural Networks, 19th International Conference on Systems Engineering, pp. 189-194
 6. Etienne Saloux, Jose A. Candanedo, 2018, Forecasting District Heating Demand Using Machine Learning Algorithms, 16th International Symposium on District Heating and Cooling, *Energy Procedia*, Vol. 149, pp. 59-68
 7. Kimburn Song, Jinsoo Park, Yun-Bae Kim, Chul-Woo Jung and Chan-Min Park, 2011, Heat Demand Forecasting for Local District Heating, *IE Interfaces*, Vol. 24, No. 4, pp. 373-378
 8. Eriksson, Niclas, 2012, Predicting demand in districtheating systems: A neural network approach, Uppsala University Publications, pp. 43