

딥러닝을 이용한 열 수요예측 모델 개발*

Development of Heat Demand Forecasting Model using Deep Learning

서한석 · 신광섭†

인천대학교 동북아물류대학원

요약

특정 지역의 고객을 대상으로 열을 공급하는 지역난방 서비스의 안정적인 운영을 위해서는 단기간의 미래 수요를 보다 정확하게 예측하고, 효율적인 방법으로 생산 및 공급하는 것이 무엇보다 중요하다. 그러나 열 소비에 영향을 미치는 요소가 매우 다양할 뿐만 아니라 개별 소비자 및 지역적 특성에 따라 소비 형태가 달라지기 때문에 일반적인 상황에도 적용될 수 있는 범용적 열 수요 예측 모형을 개발하는 것은 매우 어렵다. 따라서 본 연구에서는 실시간으로 확보할 수 있는 제한적인 정보만을 바탕으로 딥러닝 기법을 활용한 수요예측 모형을 개발하고자 한다. 해당 지역의 외기온도와 날짜로만 구성된 과거 데이터를 입력 변수로 하여 텐서플로의 인공신경망을 학습시키는 방법으로 수요 예측 모형을 개발하였다. 기존의 회귀분석 기법을 통해 예측된 수요의 정확도와와의 비교를 통해 제안된 모델의 성능을 평가하였다. 본 연구의 열 수요 예측 모델은 단기적 수요 예측을 위해 실시간으로 확보할 수 있는 제한적인 변수만으로도 수요 예측의 정확도를 높일 수 있음을 보였다. 나아가 개별 지역에서는 지역적 특수성을 추가하여 수요 예측 정확도를 높이는 데 활용할 수 있을 것이다.

■ 중심어 : 딥러닝, 인공지능, 수요예측, 텐서플로

Abstract

In order to provide stable district heat supplying service to the certain limited residential area, it is the most important to forecast the short-term future demand more accurately and produce and supply heat in efficient way. However, it is very difficult to develop a universal heat demand forecasting model that can be applied to general situations because the factors affecting the heat consumption are very diverse and the consumption patterns are changed according to individual consumers and regional characteristics. In particular, considering all of the various variables that can affect heat demand does not help improve performance in terms of accuracy and versatility. Therefore, this study aims to develop a demand forecasting model using deep learning based on only limited information that can be acquired in real time. A demand forecasting model was developed by learning the artificial neural network of the Tensorflow using past data consisting only of the outdoor temperature of the area and date as input variables. The performance of the proposed model was evaluated by comparing the accuracy of demand predicted with the previous regression model. The proposed heat demand forecasting model in this research showed that it is possible to enhance the accuracy using only limited variables which can be secured in real time. For the demand forecasting in a certain region, the proposed model can be customized by adding some features which can reflect the regional characteristics.

■ Keyword : Deep Learning, AI, Demand Forecasting, Tensorflow

2018년 11월 30일 접수; 2018년 11월 30일 수정본 접수; 2018년 12월 31일 게재 확정.

* 본 연구는 산업통상자원부(MOTIE)와한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다.(No. 2017 3010140840)

† 교신저자 ksshin@inu.ac.kr

I. 서론

장기적으로는 온실가스 감축을, 단기적으로는 일부 특정 지역을 대상으로 열을 공급하는 지역난방서비스의 경우 안정적인 열 공급 서비스를 제공하기 위해서 단기간의 미래 수요를 보다 정확하게 예측하고 효율적인 방법으로 생산 및 공급, 연계하는 것이 매우 중요하다.

특히, 2015년 12월 파리 협정이 체결되면서 국제사회는 온실가스 감축을 위해 적극적으로 노력하고 있다. 우리나라는 이명박 정부에서 제1차 에너지기본계획을 통해 에너지 정책의 기본 방향을 설정했으며, 박근혜 정부 시절 제2차 에너지기본계획에서 6대 중점 과제 중 첫 번째를 ‘수요관리 중심의 에너지정책 전환’을 내세우며¹⁾ 기존 공급관리 중심에서 수요관리로 패러다임이 변화되었다.

지역난방에서도 이와 같은 정책의 실현을 위해 ‘4세대 지역난방’ 전략을 추진하고 있다. ‘4세대 지역난방’은 도시 및 건물 분야 온실가스 감축을 위한 주요 수단 중의 하나로 에너지 신사업 육성을 위한 핵심기술로, 신재생 에너지 활용, 60°C 이하의 저온수 난방 등 기술적인 방법 이외에도 스마트 써멀 그리드(Smart Thermal Grid)를 통해 다양한 열원끼리의 열 거래를 실현하여 열 공급 사업자 간 열 연계를 활성화한다.

열 연계는 열 수요예측을 통해 공급을 계획하고 열 수송 네트워크를 통해 수요지에 열을 공급하는 것을 의미한다. 효율적인 열 연계를 구현하기 위한 가장 기본적인 기능이 바로 안정적인 열 수요예측이다. 이 때, 열 수요예측이 정확하지 않다면 효율적인 생산 계획을 수립하고 실현할 수 없다. 예를 들어 수요를 과소예측하게 되면 부족분에 대해서는 LNG와 같은 값비싼 열원을 사용하여 생산원가가 높아지게 된다. 반대

로 수요를 과대예측하게 되면 저장이 어려운 열 특성으로 인해 낭비가 발생하게 된다.

그러나 열 수요에 영향을 미치는 요인은 매우 다양하고 개별 소비자 및 지역적 특성에 따라 소비 형태가 달라지기 때문에 일반적인 상황에도 적용할 수 있는 범용적인 열 수요 예측 모델을 개발하는 것은 쉽지 않다.

기존 연구는 지역적 특성에 따른 열 수요 예측에 영향을 미치는 다양한 변수를 모두 고려하는 모델을 제시하고 있다. 그러나 이는 해당 지역을 벗어나 타 지역에 적용할 경우 동일한 수준의 성능을 보장할 수 없다. 뿐만 아니라 다중선형회귀분석 기반의 모델은 온도에 대한 열 수요의 비선형적인 특징을 반영할 수 없다.

따라서 본 연구는 실시간으로 확보할 수 있는 제한적인 정보만으로 딥러닝 기법을 활용하여 열 수요의 비선형적인 특징을 학습하는 범용적인 열 수요예측 모델을 제안하고자 한다.

II. 기존 연구

소비자에게 안정적인 열 공급과 효율적인 열 생산 계획을 수립하기 위한 열 수요예측 모델은 다양한 연구를 통해 제안되었다

Fang, T., & Lahdelma, R. (2016)는 열 수요예측을 위해 SARIMA모형을 사용하여 성능을 평가하였다. 계절성을 고려한 자기 회귀 분석 모델과 이동평균모델이 결합된 SARIMA 기법 기반의 다양한 모델 간 예측 성능을 평가하였다. 입력변수로는 기상 정보로 외기온도와 풍속을, 사회적 요소로 일주일 사용 패턴, 일 단위 사용 패턴, 주거지역 및 상업지역, 공업지역을 구분하여 사용하였다. 제안된 모델은 개별 건물 데이터와 실시간 데이터를 바탕으로 열 수요예측을 수행한다. 그러나 이는 개별 건물과 같은 작은

1) 3차 에너지 기본 권고안, ‘셀 틈 없는 수요관리’ 추진, 한국에너지, 2018.11.12., <http://www.koenergy.co.kr/news/articleView.html?idxno=103381> 접속날짜:2018.11.24.

단위에 사용 가능하고 지역 단위로 넘어갈 경우 성능에 문제가 생길 수 있다. 또한 저자가 선행적으로 시격을 설정하여, 해당 지역에는 성능이 좋을 수 있으나 다른 지역에 적용 시 이 또한 문제가 생길 수 있다.

Johansson, C. et al.(2017)은 실제 일기예보를 입력변수로 Extra-Trees Regressor(ETR)와 Extreme Learning Machines(ELM)을 이용한 온라인 기계 학습 예측 알고리즘을 제시하였다. 학습 데이터 내에 있는 시나리오에서는 좋은 결과를 보였으나 예외적인 상황에서는 성능이 크게 악화되었다. 또한 단순히 기상 정보만을 입력변수로 사용하여 같은 온도에서 다른 수요가 나타나는 것을 설명하지 못하는 단점이 있다.

Provatas, S. et al.(2015)는 열 부하 예측을 위해 온라인 기반 머신러닝 알고리즘을 개발하였다. 외기온도와 학교, 상업용 건물, 주거용 건물의 열 수요를 Decision-tree 기반 Fast Incremental Model Trees with Drift Detection(FIMT-DD) 알고리즘을 사용하여 통계적 분석을 수행했다. 실험 결과 회귀 분석을 활용하는 것에 비해 성능이 우수한 것으로 나타났다. 그러나 단순히 용도별 건물의 외기온도에 따른 열 수요를 예측한다는 한계가 있다.

김향민(2017)은 고양시의 전일 열 수요량, 평균기온, 풍속, 강수량 데이터를 사용하여 동절기, 하절기, 춘추절기로 나누어 회귀 분석을 통해 열 수요예측 모델을 제시하였다. 그러나 이는 열 수요의 비선형성을 반영하지 못한다.

이 밖에도 Sandberg, A. et al(2017)는 13개의 입력변수를 통해 상업용 건물의 열 수요를 예측하는 자기 회귀 신경망 모델을 사용하였고, Ahmad, T. et al.(2018)은 4개의 입력변수를 통해 수요예측 모델을 개발하였다.

기존 연구에서의 문제점을 정리하면 다음과 같다. 첫째, 건물 혹은 일부 특정 지역에 국한된 예측을 실행하고 있으며 둘째, 열 수요의 비선

형성을 반영하지 못하는 한계가 존재한다. 마지막으로 해당 지역의 특수성을 반영하기 위해 다양한 입력변수를 모두 고려하여 타 지역에서 사용할 수 없는 범용성 측면의 제약이 존재한다. 따라서 본 연구는 일부 지역의 안정적인 열 공급을 위해 열 수요의 비선형성을 학습하는 범용적인 열 수요예측 모델을 제시하고자 한다.

III. 데이터 분석

3.1 데이터 구성

본 연구는 실시간으로 확보할 수 있는 제한적인 정보만을 바탕으로 텐서플로를 이용하여 딥러닝의 인공신경망 기법(Neural Network) 중 Multi-Layer Perceptron(MLP)을 활용하여 범용적인 열 수요예측 모델을 제안하고자 한다.

제한적인 정보만을 사용하는 이유는 바로 범용성을 확보하기 위해서이다. 개별 소비자와 지역적인 특성을 고려한 모델은 해당 지역의 소비자에 국한되어 수요를 정확하게 예측할 수는 있다. 그러나 타 지역에 해당 모델을 적용할 경우 동일한 수준의 성능을 보장할 수 없다. 개별 소비자 및 지역적인 특성보다는 열 수요에 큰 영향을 미치며, 일반적인 상황에서도 확보가 가능한 보편적인 변수를 사용해야 범용성을 확보할 수 있다.

첫 번째로 고려할 수 있는 변수는 바로 외기 온도이다. 외기온도는 이미 여러 연구에서 다른 바와 같이 열 수요에 가장 큰 영향을 주는 변수로, 열 수요와 반비례의 관계를 갖는다. 이는 일정 지역만의 특징이 아닌 보편적인 특성으로 열 수요예측 모델의 범용성을 보장할 수 있다.

그러나 많은 선행연구와 달리 외부 환경에 의해 열 수요에 영향을 주는 변수를 외기온도로 제한한 이유는 상기한 선행연구에 사용된 이슬점, 체감온도 등은 이미 외기온도에 의해 결정

되는 변수이기 때문이다[2].

외부에서 영향을 주는 변수 이외에도 보편적으로 열 수요 영향을 주는 변수는 소비자의 사회적 행동 패턴과 심리적 요인이다. 먼저, 소비자의 사회적 행동 패턴을 정의하여 구분할 필요가 있다. 여기서 정의하는 소비자의 사회적 행동 패턴은 소비자가 사회적 요인에 의해 행동하게 되는 일정한 패턴을 말한다. 소비자는 사회적 요인에 의해 일정하게 행동하고 그러한 행동은 열 소비 패턴으로 나타나게 된다. 따라서 소비자의 보편적인 행동 패턴에 영향을 주는 변수를 입력변수로 사용하여 범용성을 확보한다.

다음은 심리적 요인으로, 같은 외기온도라 하더라도 열 수요가 다른 결과를 보이기도 한다. 이러한 결과의 원인으로는 소비자의 심리적 요인을 들 수 있다. 외기온도와 사회적 패턴 이외에도 소비자의 심리적 요인에 의해 영향을 받기 때문이다. 따라서 본 연구에서는 소비자의 열 수요에 영향을 주는 심리적 요인을 보편성 있는 변수로 도출하여 사용한다.

본 연구는 실시간으로 확보할 수 있는 제한적인 정보만을 바탕으로 범용성 있고 높은 성능의 열 수요예측 모델을 제안하는 것이기 때문에 데

이터는 외기온도와 날짜 데이터만을 사용하고 이를 가공하여 상기한 3가지를 요인을 입력변수로 사용한다.

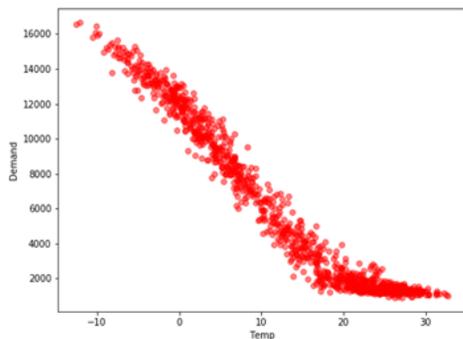
3.2 입력변수 도출

온도와 열 수요는 대체적으로 반비례 관계를 갖으나, 일정 온도 이상이 되면 열 수요는 수렴하는 아래 <그림 1>과 같은 비선형성을 보인다. 따라서 온도와 열 수요의 비선형적인 관계를 학습할 수 있는 기법이 필요하다.

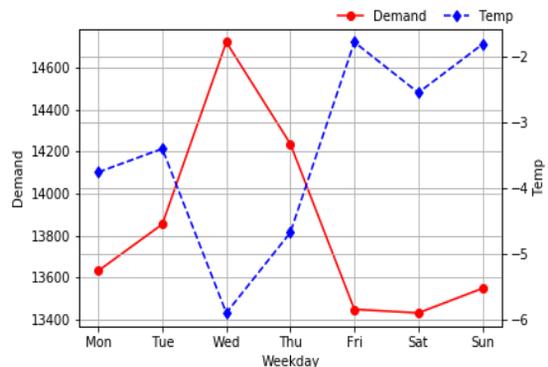
단순히 열 수요가 전적으로 외기온도에 의해 결정된다고 말할 수 없다. 외기온도에 가장 큰 영향을 받지만 같은 온도라고 하더라도 소비자의 사회적 행동 패턴에 따라 상이한 열 수요를 갖는 경우도 있다.

<그림 2>의 일요일의 경우, 금요일과 비슷한 온도임에도 불구하고 열 수요는 증가하였다.

이는 소비자의 사회적 행동 패턴에 의해 결정된다. 대부분 소비자는 주중에는 직장에 있는 시간으로 인해 가정에 머무는 시간이 길지 않다. 반대로 공휴일을 포함하여 주말에는 주중에 비해 가정에 머무는 시간이 길다. 따라서 본 연구에서는 소비자의 사회적 행동 패턴에 영향을 가



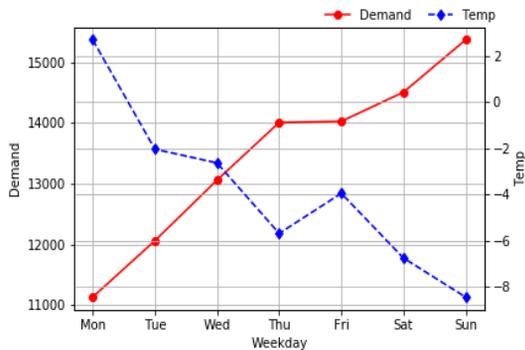
<그림 1> 외기온도와 열 수요 산점도



<그림 2> 요일별 온도와 열 수요 분포

장 큰 영향을 주는 변수로 주중 및 공휴일을 포함한 주말로 구분한다.

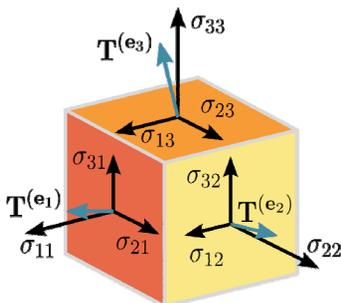
다른 기간의 예를 들면, <그림 3>의 목요일과 금요일의 경우, 온도는 상승했음에도 불구하고 열 수요는 전일과 큰 차이가 없었다. 이는 소비자의 심리적 요인이 작용하여 수요가 크게 변동하지 않았기 때문이다. 따라서 본 연구에서는 소비자의 심리적 요인을 반영하기 위해 전일 온도차를 이용하여 학습한다.



<그림 3> 요일별 온도와 열 수요(심리 요인)

IV. 딥러닝의 구조적 특성

딥러닝은 기계학습의 한 분야로 Neural Network를 기반으로 발전한 기술이다. 본 연구는 텐서플로(Tensorflow) 기반으로 인공신경망을 사용하여 딥러닝을 수행한다. 텐서플로는 구글이

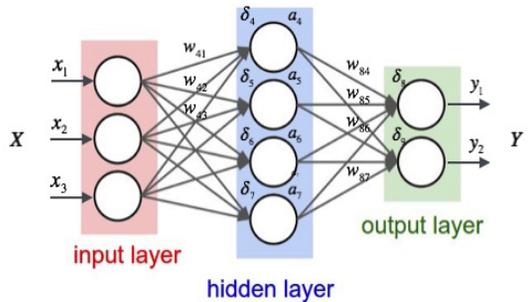


<그림 4> 텐서 구조

2015년 11월에 오픈소스로 공개한 이후 세계에서 가장 각광받는 기계학습으로 자리 잡았다[7].

텐서(Tensor)는 연산 그래프를 구동하기 위한 자료 구조를 말한다. n차원 행렬 형태를 가지고 있으며, 차원은 데이터의 형태에 따라 결정된다.

텐서에 변수를 선언하고 플레이스홀더(Placeholder)에 투입하여 연산 그래프를 실행한다. 연산 그래프를 구성하는 연산 게이트는 활성화 함수를 사용한다. 활성화 함수는 텐서에 적용되는 비선형 연산으로 그래프에 비선형성을 도입하는 것을 주된 개념으로 볼 수 있다. sigmoid, relu, tanh, softmax 등 다양한 활성화 함수가 있으며 자신의 문제에 가장 적합한 활성화 함수를 적용하면 된다. 활성화 함수를 통해 출력된 값을 비용함수를 통해 계산하고 이를 최적화 함수를 사용하여 비용을 최소화하는 방식으로 연산된다.



<그림 5> 인공신경망 구조

인공신경망의 기본적인 구조는 input layer, hidden layer, output layer로 구성된다. input layer에는 텐서에 선언한 변수를 플레이스홀더에 투입한다. hidden layer는 학습을 위한 구조로, single layer와 multi layer, 해당 layer마다 게이트의 수를 조정하여 구성한다. 연산은 바로 hidden layer에서 이뤄진다. 마지막으로 output layer는 연산된 결과가 출력되는 곳이다.

V. 실험 및 결과 분석

5.1 실험의 설계

수요 예측과 성능 분석을 위해 일부 지역의 2012년 1월 1일부터 2015년 1월 31일까지의 열 수요 데이터와 해당 지역 동 기간의 외기온도를 사용하였다. 2012년 1월 1일부터 2014년 12월 31일까지 3년간의 데이터를 training data로 사용하여 학습하였으며, test data로 2015년 1월 1일부터 2015년 1월 31일의 열 수요가 가장 많은 동절기 데이터를 사용하여 검증하였다.

Hidden Layer는 총 4개의 층으로, 1층은 128개, 2층은 256개, 3층은 128개, 4층은 64개로 구성하였다. 충분한 학습을 위해 Epoch은 2000회로 설정하였다.

본 연구에서는 열 수요의 비선형성을 학습하기 위해 활성화 함수로 relu 함수를 사용하였으며, 최적화 함수로는 AdamOptimizer를 사용하였다.

본 연구에서 제안하는 범용성을 확보할 수 있는 수요 예측 모델을 설계하기 위해서 앞서 설명한 입력변수의 조합에 따라 <표 1>과 같이 세 가지 모델을 구성하였다.

<표 1> 수요예측 모델 설계

구분	입력변수		
	외기 온도	주중&주말	전일 온도차
외기온도모형	O		
행동 패턴 모형	O	O	
심리 모형	O	O	O
다중회귀 모형 (대조군)	O		

학습 결과를 나타내기 위해 선형 회귀분석인 MLR(Multiple Linear Regression)과 제안하는 모델의 R^2 , MAPE를 사용하였다.

$$R^2 = 1 - \frac{SSE}{SST} \quad (1)$$

$$SST = \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad (2)$$

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

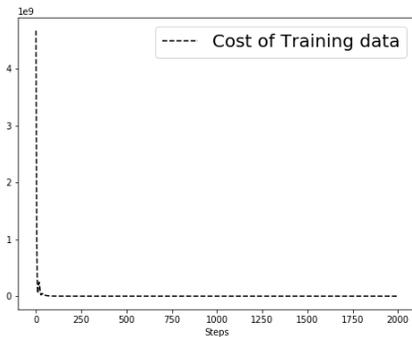
R^2 는 결정계수로 설명된 변동의 비율에 대한 척도이다. SST는 반응 값의 변동으로 모형에 의해 모두 설명될 수 있는 변동을 나타내며, SSE는 오차에 의한 변동, 즉 설명되지 않는 변동을 나타낸다.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (4)$$

MAPE(Mean Absolute Percentage Error)는 절대오차의 평균을 백분율로 나타낸 것이다.

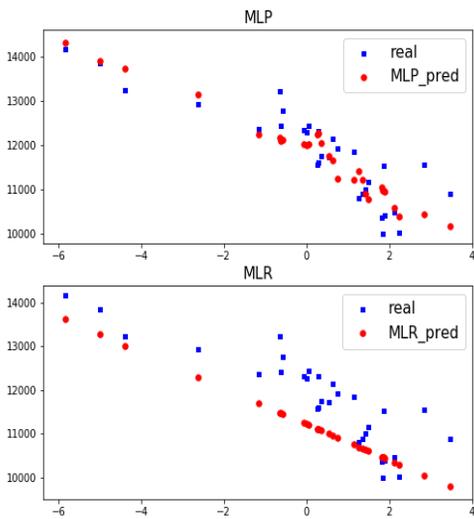
5.2 외기온도 모형

입력변수는 열 수요에 가장 큰 영향을 미치는 외부 요인인 외기온도만으로 구성하였다.



<그림 6> Epoch에 따른 Cost(외기온도 모형)

<그림 6>에서의 Cost는 Training Data 학습에 따른 오차를 나타낸다. Cost가 일정 값으로 수렴한다면 학습이 종료되었다는 것을 의미한다. <그림 6>과 같이 Cost는 아주 빠르게 수렴하였으며, 학습이 빠르게 이루어지는 것을 알 수 있었다.



<그림 7> 외기온도 모형 수요 예측 산점도

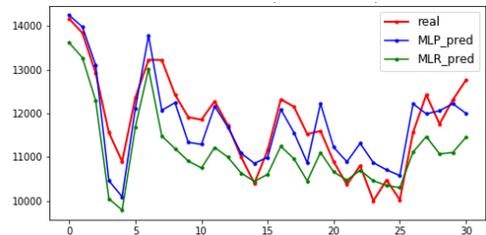
<그림 7>에서 알 수 있듯이 MLP로 학습한 경우 MLR로 학습한 것에 비해 온도 변화를 비선형적으로 예측하는 것을 알 수 있다. 이는 단순히 외기온도만을 데이터로 학습하였음에도 불구하고 해당 외기온도에서의 열 수요에 대한 비선형적인 특징을 잘 반영한 것을 보여준다. 하지만 해당 모델은 비슷한 외기온도에서 다른 수요가 나타나는 것은 설명이 불가하다.

<표 2> 외기온도 모형의 예측 정확도 비교

구분	MLP	MLR
R ²	0.76	0.33
MAPE(%)	3.76	6.11

<표 2>는 외기온도 모형의 성능을 평가한 결과로 R², MAPE가 모두 향상된 것을 알 수 있다. 특히 MAPE는 MLR의 경우 6.11%인 것에 비해 MLP는 3.76%으로 성능이 크게 좋아졌다.

<그림 8>은 2015년 1월 1일부터 동월 31일까지의 데이터를 기반으로 외기온도 모형을 통해 열수요 예측 결과를 보여준다. MLR의 열 수요 예측은 대부분의 열 수요를 과소예측한 것에 비해 상단의 MLP는 실적 데이터의 추세에 더 적합한 예측을 한 것을 보여준다. 하지만 실적 데이터가 평이한 열 수요를 보인 반면 MLP의 예측은 과소예측한 구간도 있으며, 실적 데이터가 증감을 보일 때 MLP는 평이한 열 수요를 예측한 것으로 보아, 열 수요는 단순히 외기온도만이 아니라 어떠한 다른 변수에 의해서 소비자의 소비 패턴이 영향을 주는 것을 알 수 있다.



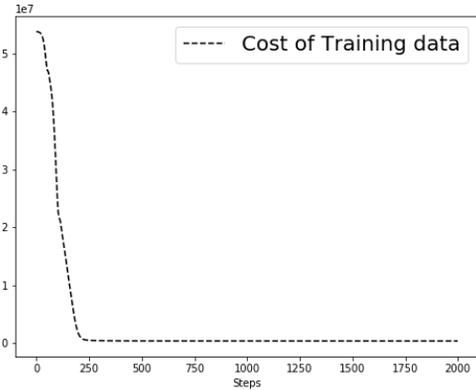
<그림 8> 외기온도 모형 수요 예측 결과

5.3 행동 패턴 모형

단순히 외기온도만을 사용하여 MLP로 예측한 결과, 성능이 크게 향상되는 것을 알 수 있었으나, 예측 값이 실적 데이터에 비해 과소예측 및 과대예측하는 구간이 있었음을 알 수 있었다. 즉, 단순히 외기온도에만 영향을 받아 열 수요가 변화하는 것이 아니라 다른 요인 또한 열 수요에 영향을 미치는 것을 알 수 있다.

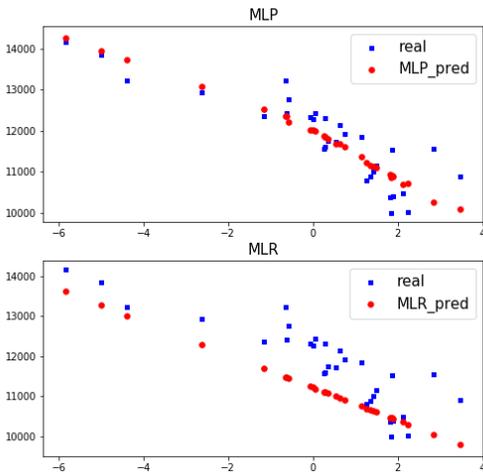
Dotzauer, E.(2002)은 난방 전력수요를 예측하는 연구에서 외기온도 이외에 가장 큰 영향을 주는 변수는 소비자의 사회적 행동 패턴이 꼽았

으며, 이를 주중과 공휴일을 포함하는 주말로 구분하여 연구하였다. 따라서 주중과 공휴일을 포함한 주말을 구분하여 학습을 진행하였다.



<그림 9> 행동 패턴 모형의 학습곡선

<그림 9>는 행동 패턴 모형의 학습 속도를 나타내는 것으로, 입력 데이터가 증가하였기 때문에 Cost가 외기온도 모형에 비해 느리게 수렴하였다. 즉, 학습 속도는 조금 떨어졌다.



<그림 10> 행동 패턴 모형 수요 예측 산점도

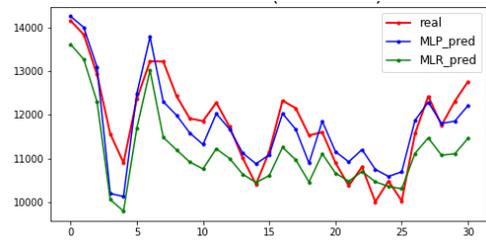
<그림 10>에서 확인할 수 있듯이 MLP 열 수요 패턴은 선형적인 특징을 보였다. 이는 해당

외기온도에 대한 열 수요를 주중 및 공휴일을 포함한 주말로 단순화하여 패턴을 학습했기 때문이다. 그러나 MLR은 해당 외기온도에 대한 열 수요를 대체적으로 과소예측하는데 반해, MLP는 실적 데이터에 더 적합한 추세를 보이고 있다.

<표 3> 행동 패턴 모형의 예측 정확도 비교

구분	MLP	MLR
R^2	0.78	0.33
MAPE(%)	3.48	6.11

외기온도 모형에 비해 R^2 은 0.76에서 0.78로 0.02 상승하였고, MAPE는 3.76%에서 3.48%로 0.28% 향상되었음을 알 수 있다.

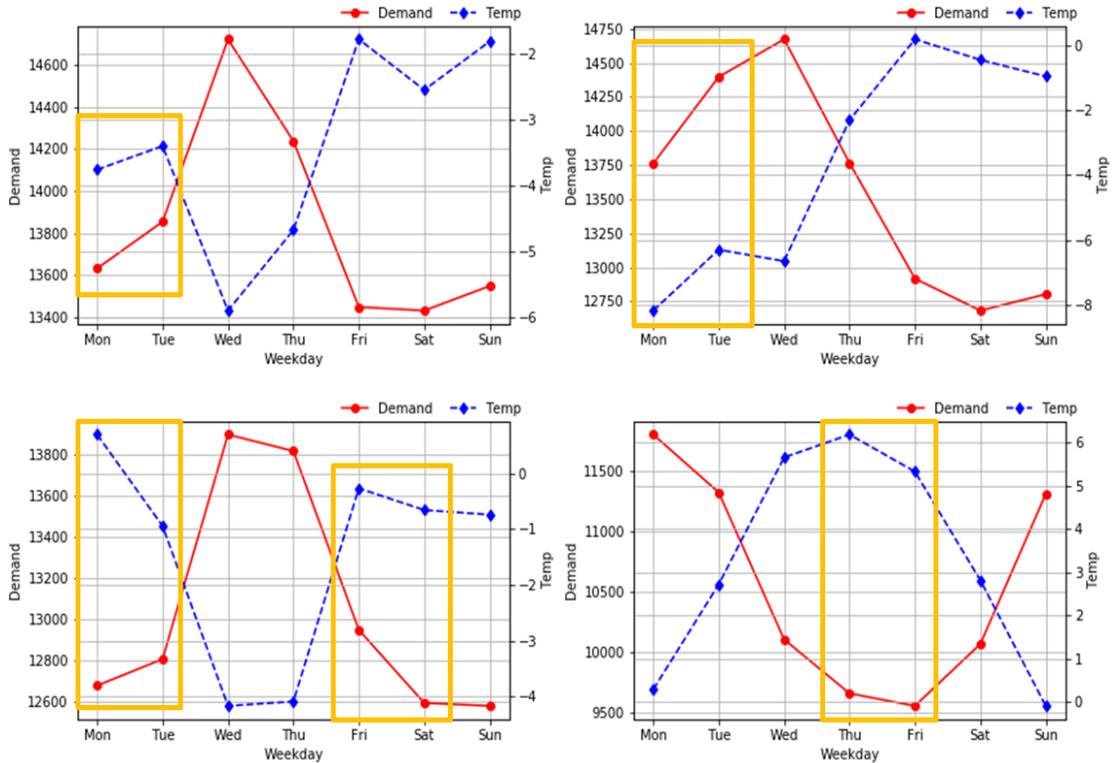


<그림 11> 행동 패턴 기반 수요 예측 결과

외기온도 모형과 비교하였을 때 실적 데이터에 대한 과소예측 및 과대예측이 줄고 열 수요 예측 패턴이 실적 데이터의 추세에 더 적합한 모습을 보였다. 그림에도 불구하고 여전히 오차가 있음을 알 수 있었다. 이는 소비자의 사회적 행동 패턴뿐만 아니라 다른 요소가 열 수요에 영향을 줄을 방증한다.

5.4 심리 요인

처음에는 열 수요와 가장 밀접한 관계를 갖는 외기온도를 통해 학습하였고, 다음으로 소비자의 사회적 행동을 주중과 공휴일을 포함한

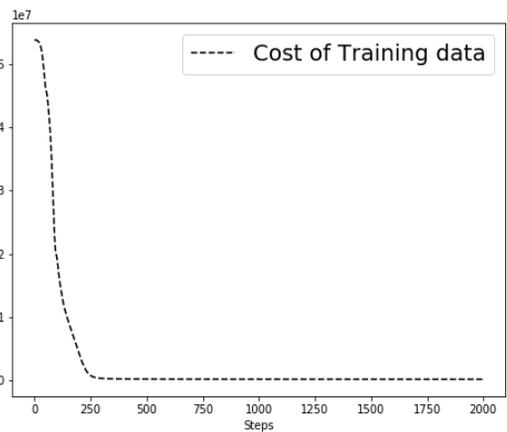


〈그림 12〉 일반적인 수요 패턴을 벗어난 경우

주말로 나누어 정의하여 학습하였다. 그러나 열 수요는 그뿐만 아니라 소비자의 심리적 요인에 의해서도 영향을 받는다. 특히 전 날의 외기온도에 의해서 심리적 영향을 받아 외기온도의 변화와는 다른 행동 패턴을 보인다.

〈그림 12〉의 표시된 곳을 보면 외기온도의 변화에 대한 기존의 열 수요 변화와 다른 패턴을 보인다. 이는 단순히 외기온도에 따른 변화가 아닌 소비자의 심리적 요인이 작용하였기 때문이다. 따라서 심리적 요인을 반영할 수 있는 전일 온도차를 추가하여 학습한다.

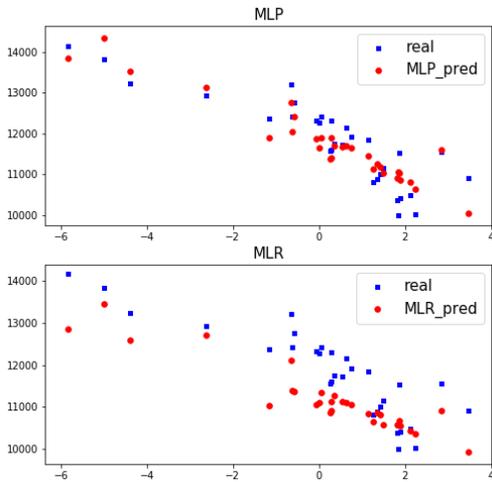
행동 패턴 모형과 마찬가지로 250회에서 Cost가 수렴하였다. 전일 온도차를 반영하였음에도 불구하고 학습속도에는 큰 영향을 주지 않았다.



〈그림 13〉 심리 모형의 학습곡선

〈그림 14〉의 MLP 예측치를 보면 비선형적인 추세를 보였다. 이는 행동 패턴 모형에서 주중 및 공휴일을 포함한 주말로 단순화되어 선형적

인 추세를 보였던 것과 달리, 전일 온도차가 추가됨으로 인해 비선형적 추세를 나타낸 것으로 보인다.

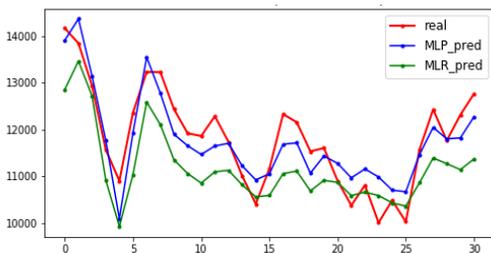


〈그림 14〉 심리 모형 수요 예측 산점도

〈표 4〉 심리 모형의 예측 정확도 비교

구분	MLP	MLR
R^2	0.80	0.37
MAPE(%)	3.13	5.96

상기한 모델에 비해 모든 지표가 향상되었다. 특히 MAPE는 행동 패턴 학습에 비해 0.35% 떨어진 3.13%로 성능이 향상했음을 알 수 있다.



〈그림 15〉 심리 모형 수요 예측 결과

기존 과소예측을 하던 구간이 크게 향상되었으며 외부 요인과 행동 패턴 학습에서 실적 데이터 패턴과 달라 변동이 심했던 구간도 줄어들었다. 즉, 심리적 요인을 추가적으로 학습했을 때 실적 데이터 패턴과 가장 유사한 예측 패턴이 나타났다.

VI. 결론 및 향후 연구

본 연구에서는 열 수요예측을 위해 입력변수를 하나씩 추가해가며 세 가지 모델을 설계하였고, 각 모델 간의 예측 정확도를 실제 데이터와를 기반으로 비교·평가하였다.

기본적으로는 열 수요에 가장 큰 영향을 주는 외기온도만을 입력변수로 사용하였으며, 여기에 소비자의 사회적 행동 패턴을 구분하기 위한 주중 및 공휴일을 포함한 주말 변수를 추가하였다. 마지막으로 소비자의 심리적 요인을 반영할 수 있는 전일 온도차를 넣어 실험을 진행하였다.

외기온도 모형은 열 수요의 비선형적인 특징을 반영하여 MLR에 비해 크게 향상된 성능을 보였으나 비슷한 온도에서 열 수요가 다른 점을 설명할 수 없었다.

소비자의 사회적 행동 패턴을 반영하기 위해 주중 및 공휴일을 포함한 주말 구분을 추가하여 학습했을 때, 비슷한 온도에 대해 주중 및 공휴일을 포함한 주말, 두 가지로 패턴으로 단순화되어 선형적인 추세를 보이며, 외부 요인만을 학습했을 때에 비해 MAPE가 0.28% 향상하였다.

마지막으로 소비자의 심리적 요인을 반영하기 위해 전일 온도차를 추가하였다. 행동 패턴 모형에서 선형적인 특징을 보였다면, 심리 모형에서는 전일 온도차에 따라 비선형적인 특징을 보였다. 단순히 외기온도만은 학습하여 비선형적으로 나타나는 추세를 설명하기 어려웠지만, 심리적 요인을 추가적으로 학습했을 때에는 전

일 온도차에 따라 해당 온도에서 수요가 다른 것에 대해 설명이 가능하다. 마찬가지로 행동 패턴 학습에 비해 MAPE가 0.35% 향상했다.

본 연구는 실시간으로 확보할 수 있는 제한적인 데이터를 이용하여 범용성 있고 높은 성능의 모델을 통해 단기 열 수요를 예측하는 모델을 제안하였다. 외기온도와 날씨 데이터를 기반으로 열 소비에 영향을 미치는 사회적 요인과 심리적 요인을 반영하기 위해 기존 데이터로부터 파생되는 데이터를 활용하여 높은 수준의 정확도를 보장할 수 있다는 점이 기존 연구와의 차별점이라 할 수 있다.

향후 연구로는 첫째, 제시하는 모델보다 시계열 데이터 분석에 적합한 Recurrent Neural Network(이하 RNN)를 사용하여 성능을 향상시킬 필요가 있다. 전통적으로 시계열 데이터 분석은 사람이 선형적으로 판단하여 기간을 지정하기 때문에 지엽적인 문제에는 적합할 수 있으나 범용성을 가지기에는 무리가 있다. 이와 달리 RNN은 사람이 지정하는 것이 아니라 데이터 속에서 학습하여 시계열 데이터를 분석하기 때문에 범용성을 가지기에 충분하다. 따라서 해당 데이터를 RNN을 통해 분석하여 성능을 향상할 필요가 있다. 둘째, 해당 모델이 타 지역에 적용이 가능한 것인가에 대한 검증이 필요하다. 현재는 해당 지역에 대한 데이터로만 실험하였기 때문에 해당 모델이 타 지역 데이터를 사용하여 검증할 필요가 있다.

참 고 문 헌

- [1] Ahmad, T., Chen, H., Guo, Y., & Wang, J., "A comprehensive overview on the data driven and large scale based approaches for forecasting of building energy demand: A review". *Energy and Buildings*, Vol.165, pp.301-320, 2018.
- [2] Dotzauer, E., "Simple model for prediction of loads in district-heating systems", *Applied Energy*, Vol.73, No.3-4, pp.277-284, 2002.
- [3] Fang, T., and Lahdelma, R., "Evaluation of a multiple linear regression model and SARIMA model in forecasting heat demand for district heating system", *Applied Energy*, Vol.179, pp.544-552 2016.
- [4] Hippert, H. S., Pedreira, C. E., and Souza, R. C., "Neural networks for short-term load forecasting: A review and evaluation", *IEEE Transactions on Power Systems*, Vol.16, No.1, pp.44-55, 2001.
- [5] Idowu, S., Saguna, S., Åhlund, C., and Schelén, O., "Applied machine learning: Forecasting heat load in district heating system", *Energy and Buildings*, Vol.133, pp.478-488, 2016.
- [6] Johansson, C., Bergkvist, M., Geysen, D., De Somer, O., Lavesson, N., and Vanhoudt, D., "Operational demand forecasting in district heating systems using ensembles of online machine learning algorithms", *Energy Procedia*, Vol.116, pp.208-216, 2017.
- [7] McClure, N., 황정동, "TensorFlow machine learning cookbook : 다양한 텐서플로 예제를 실행해 보면서 빠르게 익히는 머신 러닝", 에이콘, 2017.
- [8] Provas, S., Lavesson, N., & Johansson, C., "An online machine learning algorithm for district heating systems heat load forecasting", *EUROHEAT AND POWER*, 2015.
- [9] Sandberg, A., Wallin, F., Li, H., & Azaza, M., "An analyze of long-term hourly district heat demand forecasting of a commercial building using neural networks", *Energy Procedia*, Vol. 105, pp.3784-3790, 2017.
- [10] 김향민, "열병합발전을 위한 열수요 예측모델 개발", 숭실대학교 대학원 석사학위논문, 2017.

- [11] 송기범, 박진수, 김윤배, 정철우, 박찬민. “지역 난방을 위한 열 수요예측”. 산업공학 (IE Interfaces), 제24권, 제4호, pp.373-378, 2011.

저자 소개



서한석(Han-Seok Seo)

- 2017년 9월 ~ 현재 : 인천대학교 동북아물류대학원 (석사)
- 관심분야 : 빅데이터, 딥러닝, AI



신광섭(KwangSup Shin)

- 2003년 2월 : 서울대학교 산업공학과 (공학사)
- 2006년 2월 : 서울대학교 산업공학과 (공학석사)
- 2012년 2월 : 서울대학교 산업공학과 (공학박사)
- 2012년 2월 ~ 현재 : 인천대학교 동북아물류대학원 교수
- 관심분야 : 빅데이터, 물류 및 SCM, 위험 관리