

스마트 팜 에너지 소비량 예측 모델 개발에 관한 연구

임청룡, 박영준, 이철성*
한국농어촌공사 농어촌연구원

A Study on the Development of Smart Farm Energy Consumption Prediction Model

Cheong-Ryong Lim, Young-Jun Park, Chul-Sung Lee*
Rural Research Institute, Korea Rural Community Corporation

요약 이 연구에서는 스마트 팜 경영비용 중 많은 부분을 차지하고 있는 에너지 소비량에 대한 예측 모델을 구축하고자 하였으며, 분석 결과를 다음과 같이 요약할 수 있다. 첫째, 예측력이 우수한 모델을 구축하기 위해 전통적인 시계열 분석 모형인 VAR모형과, 딥러닝 모델인 RNN, LSTM, GRU모형을 추정하였다. 둘째, 4가지 모델 예측력에 대한 비교결과 RMSE 통계량을 활용한 경우와 실측값과 예측값 평균 차이를 비교한 예측력 전반에 있어서 모두 GRU모형이 가장 우수한 것으로 나타났으며, 다음으로 LSTM, RNN, VAR 순으로 나타났다. 이러한 분석 결과로부터 다음과 같은 시사점을 도출할 수 있다. 첫째, 분석 목적이 에너지 소비에 영향을 미치는 요인 확인일 경우 모수적 통계기법이 적합할 수 있으며, 예측 정확도를 목적으로 할 경우 딥러닝 모델 활용이 보다 적합할 수 있다. 둘째, 딥러닝 모델별 예측력에도 차이 있으므로, 다양한 모델 적합 이후 최적 모델 선택하는 것이 보다 효과적일 수 있다. 우수한 딥러닝 모델 구축을 위해서는 적절한 하이퍼 파라미터에 대한 설정이 필요하다.

Abstract In this study, a predictive model for energy consumption, which accounts for a large portion of smart farm management costs, was established. The analysis can be summarized as follows. First, the vector autoregressive (VAR) model which is a traditional time series analysis model, and the recurrent neural network (RNN), long short-term memory (LSTM), and gated recurrent unit (GRU) models which are deep learning models, were used to build a model with excellent predictive power. Second, a comparison of the four models showed their predictive power to be in the order of GRU>LSTM>RNN>VAR. The following implications can be drawn from the results of the analysis: First, if prediction accuracy is not a factor that affects energy consumption, it is appropriate to use a deep learning model. Second, since the predictive power of each deep learning model is different, it would be effective to select an optimal model after fitting the data to various models. To build a better deep learning model, it is necessary to set the appropriate hyperparameters.

Keywords : Energy Consumption, Prediction Model, GRU, LSTM, RNN

본 논문은 농림식품기술기획평가원의 농업에너지 자립형 산업모델 기술개발사업의 지원을 받아 연구되었음.(과제번호: 120095031CG000)

*Corresponding Author : Chul-Sung Lee(Rural Research Institute, Korea Rural Community Corporation)

email: csleekor@ekr.or.kr

Received August 2, 2022

Accepted November 4, 2022

Revised September 16, 2022

Published November 30, 2022

1. 서론

농산물 시장 개방에 따라 식량자급률은 지속적으로 하락하고 있으며, 생산비 증가로 인한 농업소득의 정체와 농가인구의 지속적인 감소와 고령 인구 비율의 증가 및 경지면적의 감소 등 여러 요인들이 농업경쟁력 약화를 유발하고 있다.

통계청 자료에 따르면 '03년 대비 '20년 농업소득은 12% 증가한 반면 농업경영비는 86%나 증가하였다. 동 기간 농업소득은 매년 평균 1.4% 증가한 반면 농업경영비는 연평균 3.8% 증가하여 농업소득의 증가율이 크게 감소하였다. 향후 농업경영비의 지속적인 증가에 따라 농업소득은 지속적으로 감소할 것으로 여겨진다.

농촌 위기 극복 방안으로 4차 산업혁명 핵심기술인 스마트 팜이 빠르게 확산되고 있다. 생산성이 높은 스마트 팜의 확산을 통해 농촌의 경쟁력 향상 및 지속가능한 발전에 기여하게 된다. 스마트 팜 재배작물은 주로 시설채소이며 재배면적은 46,089ha에 달한다. 이 중 무가온 온실이 66%, 가온온실이 34%로 조사되었다. 가온온실의 사용연료는 대부분 유류로 나타났으며, 등유 및 경유를 가장 많이 소비하고 있다. 난방비는 전체 경영비의 30%~40%(최고 60%)로 비중이 매우 높다.

에너지 비용은 국제 유가의 영향을 받아 농가 경영비 불확실성을 키우며, 에너지 비용의 절감은 농가 소득 개선 및 경영안정화에 기여할 수 있으므로 에너지 소비 절감이 필요하다.

스마트 팜의 효과적인 에너지 절감을 위해 에너지 소비량에 대한 예측이 필요하며, 관련된 선행연구들을 스마트 팜 에너지와 에너지 예측 두 분야로 구분하여 정리하면 다음과 같다. 스마트 팜 에너지 관련하여 에너지 분석 모델을 활용하여 냉방 패키지 성능 분석 결과를 제시한 연구[1], 스마트 팜의 에너지 사용량을 줄이기 위한 효율적인 재배 환경 제어 방법을 제안한 연구[2], 스마트 팜에서 지열원과 수열원으로 구성된 복합 열원 히트 펌프 시스템의 에너지 성능 평가 연구와 식물공장 적용 액체식 재배 시스템의 에너지 절감 효과 분석 연구들이 수행되었다[3].

에너지 예측 관련 선행연구 중 지역난방 열에너지 DB를 사용하여 수도권 도시의 시간 단위 열에너지 수요 패턴을 분석한 연구[4], 통계분석을 통한 주거용 건물의 주택 유형별 에너지 예측 모델 개발연구[5] 및 하계 전력수요 예측을 위한 딥러닝 입력 패턴에 관한 연구들이 수행되었다[6].

선행연구에서 스마트 팜 에너지 또는 에너지 예측 관련한 다양한 연구들이 수행되었지만 스마트 팜 에너지 예측을 위한 연구들은 미비한 실정으므로 스마트 팜이 급속히 확장되는 현 시점에서 스마트 팜 에너지 효율적 이용을 위해서 스마트 팜 에너지 소비량 예측 모델에 대한 연구가 필요한 것으로 여겨진다. 따라서 이 연구에서는 다수의 스마트 팜 에너지 소비량 예측 모델 개발 이후 최적 모델 선택을 통해 스마트 팜 에너지 효율적 이용을 도모하고자 한다.

2. 스마트 팜 확산

청년 유입 및 농업경쟁력 확보를 위해 스마트 팜 혁신 밸리 조성과 같은 다양한 스마트 팜 도입 정책을 추진하고 있다. 2014년부터 2018년 사이 스마트 팜 시장규모 연평균 10% 성장하고 있으며 관련 정부 지원 예산도 36% 증가한 것으로 나타났다.

지난 15년간 일반 소비자 물가 상승률은 평균 2.1%씩 증가하였으나 농업소득 증가율이 물가 상승률에 비해 매년 평균 1% 이상 낮게 나타나 농업생산력 저하 및 신규 농업인력 유입을 가로막는 원인이 되고 있다. 농촌인구 또한 연간 2.5% 이상씩 지속적으로 감소하고 있으며, 특히 20대~50대 가용 노동인구가 매년 크게 감소하고 있다. 반면 60대 이상 고령농가의 비율은 지속적으로 증가하고 있으며, '19년에는 20대 이상 농민의 60%를 넘어섰다.

스마트 팜은 복합환경제어시스템을 기반으로 온도나 습도, 영양공급 등 작물의 생산관리 조건을 정밀·자동 제어하여 최적화할 수 있는 최첨단 온실을 이용하는 방법을 가리킨다.

스마트 팜은 복합환경제어시스템이 실시간으로 데이터를 입력받아 설정온도를 맞추기 위해 내부 장치를 제어하게 된다.

입력받는 데이터는 외부환경 및 내부환경 데이터이며, 이러한 데이터들은 다양한 센서를 통해 측정되어 복합환경제어시스템으로 전송된다. 복합환경제어시스템 사전에 설정된 온도 및 습도를 유지시키기 위해 다양한 장치를 제어하게 된다.

3. 에너지소비량 예측방법 및 분석자료

3.1 예측방법

시계열 데이터를 활용한 예측에 있어서 전통적인 통계 분석 방법으로는 단일 변수 분석 모형인 ARIMA (Auto-regressive Integrated Moving Average) 모형이나, 다변량 시계열 분석 모형인 벡터 자동 회귀분석 (Vector Auto Regression, VAR) 모형이 많이 사용되고 있다.

VAR 모형은 예측할 변수의 과거 값뿐만 아니라 예측할 변수와 의존성이 있는 변수들까지 고려하여 선형 함수로 나타내는 확률적 과정이라고 할 수 있다. 모델 분석을 위해 정상성 여부와 최적 시차 결정 및 잔차항에 대한 자기상관성 확인 등이 필요하다. 독립변수가 종속변수에 미치는 영향을 확인할 수 있는 장점이 있지만, 딥러닝 모델에 비해 정확도 낮으며 단기간 예측에 비교적 적합한 특징을 가지고 있다.

최근 들어 인공지능 관련 기술의 빠른 발전과 컴퓨터 성능의 향상으로 딥러닝 기법인 순환신경망(Recurrent Neural Network, RNN), 장단기메모리(Long Short-Term Memory, LSTM), 게이트순환유닛(Gated Recurrent Unit, GRU) 등 모델들이 활발하게 활용되고 있다.

RNN(Recurrent Neural Network)은 입력과 출력을 시퀀스 단위로 처리하는 시퀀스(Sequence) 모델이다. 인공 신경망의 한 종류로, 유닛 간의 연결이 순환적 구조를 갖는 특징을 갖고 있다. RNN은 가장 기본적인 인공 신경망 시퀀스 모델이다[7].

LSTM(long short-term memory, 장단기 메모리)는 기울기 소실 문제를 해결하기 위해 고안된 딥 러닝 시스템이다. LSTM은 망각 게이트(forget gate)라 부르는 게이트를 추가적으로 가진다. LSTM은 은닉층의 메모리 셀에 입력 게이트, 망각 게이트, 출력 게이트를 추가하여 불필요한 기억을 지우고, 기억해야 할 것들을 결정한다. LSTM은 은닉 상태(hidden state)를 계산하는 방식이 전통적인 RNN보다 조금 더 복잡해졌으며, 셀 상태(cell state)라는 값이 추가되었다[8].

GRU는 LSTM에서는 출력, 입력, 삭제 게이트라는 3개의 게이트가 존재. 반면, GRU에서는 업데이트 게이트와 리셋 게이트 두 가지 게이트만 존재한다. GRU는 LSTM보다 학습 속도가 빠르다고 알려져 있으며, 여러 평가에서 GRU는 LSTM과 비슷한 성능을 보인다[9].

3.2 분석자료 및 변수선택

스마트 팜 에너지 소비량 예측을 위해 2021.12.01.~2022.02.28. 사이 분 단위 측정 데이터를 활용하였다.

수집 자료는 외부환경변수들인 일사량(Insolation)(W/m²), 외부기온(External Temperature)(°C), 외기습도(External Humidity)(%), 풍속(Wind Speed)(m/s), 풍향(Wind Direction)(°)이며 내부 환경변수들인 온도(Temperature)(°C), 습도(Humidity)(%), 차광스크린(Shading Screen)(%), 차열스크린(Heat Shielding Screen)(%), 수평 에너지스크린(Horizontal Energy Screen)(%), 수직 에너지스크린(Vertical Energy Screen)(%), 배기팬(Exhaust Fan)(on/off), 천창개폐(Skylight Opening/Closing)(%), 유동팬(Floating Fan)(on/off), 팬코일(Fan Coil)(on/off)이다. 설정온도에는 환기온도(Ventilation Temperature)(°C), 난방온도(Heating Temperature)(°C) 값을 수집하였으며, 에너지 소비량에 대한 측정변수로 온수 열 공급량(Heat Supply)(kWh)을 수집하였다.

분 단위 데이터의 과도한 변동성을 줄이고, 예측 목적에 부합하는 결과를 도출하기 위해 1시간 단위로 데이터 처리 이후, 열 공급량 에너지 소비를 측정변수로 설정하고 열 공급량에 영향을 많이 미치는 변수들을 중심으로 Fig. 1과 같이 상관성 확인을 통해 분석 변수를 선택하였다.

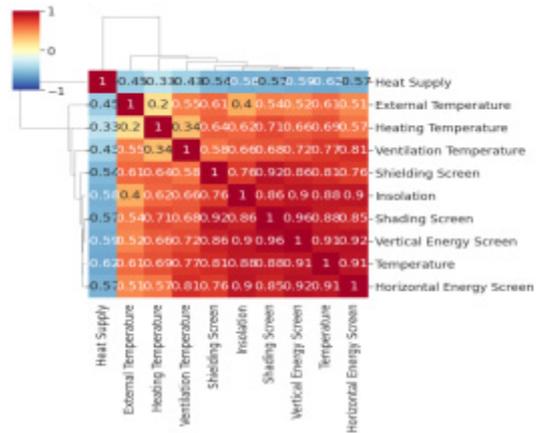


Fig. 1. Clustering Map for Energy Consumption Related Variables

이 연구에서는 서로 높은 상관관계가 보이는 외부온도(External Temperature), 외부광량(Insolation), 내부온도(Temperature), 열 공급량(Heat Supply) 변수들을 이용하여 시간대별 추이 확인하면 Fig. 2와 같이 나타낼 수 있다.

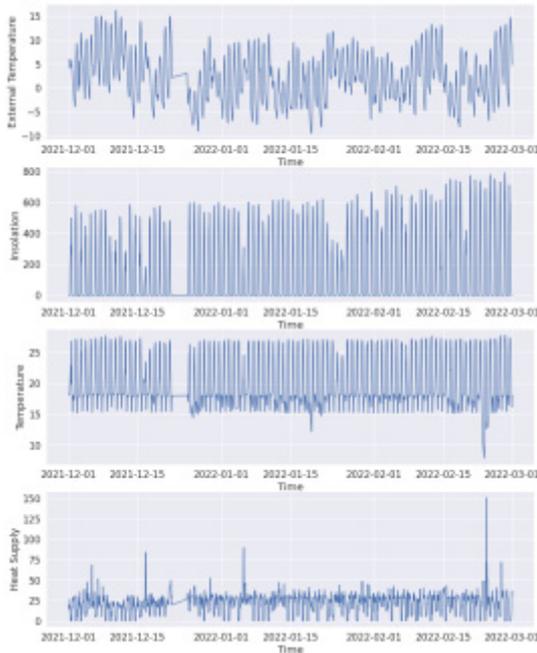


Fig. 2. Variables in Energy Prediction Model Utilization

4. 분석결과 및 예측력비교

4.1 분석결과

4.1.1 VAR모델

분석에 사용된 변수들의 정상성 관련하여 ADF 단위근 검정을 하였으며, 검정 결과 단위근이 존재하지 않았으며, 최적 시차 선정을 위해 1-9차 까지 모형 분석 이후 BIC값이 최소인 시차 4를 선택하였다.

외부온도(E.T.), 외부광량(Ins.), 내부온도(T.), 열 공급량(H.S.)에 대한 VAR(4)모형 추정 결과는 다음 표와 같이 나타나며, 잔차항에 대한 자가 상관성 확인을 위한 DW 통계량이 2.0으로 나타나 잔차항의 자기상관성이 존재하는 것을 Table 1을 통해 알 수 있다.

Table 1. VAR model estimation result

Variables	Coef.	S.E	T value	P value
const.	19.363	3.292	5.882	<0.001
L1.E.T.	-0.427	0.265	-1.612	0.107
L1.Ins.	-0.031	0.004	-7.656	<0.001
L1.T.	-1.394	0.245	-5.682	<0.001
L1.H.S.	0.645	0.023	28.115	<0.001
L2.E.T.	0.330	0.480	0.688	0.492

L2.Ins.	0.041	0.007	6.08	<0.001
L2.T.	1.090	0.368	2.964	0.003
L2.H.S.	-0.042	0.027	-1.537	0.124
L3.E.T.	0.122	0.480	0.253	0.8
L3.Ins.	0.003	0.007	0.37	0.711
L3.T.	-0.568	0.355	-1.599	0.11
L3.H.S.	0.073	0.027	2.662	0.008
L4.E.T.	0.039	0.260	0.149	0.882
L4.Ins.	-0.012	0.005	-2.597	0.009
L4.T.	0.209	0.215	0.971	0.332
L4.H.S.	0.016	0.023	0.686	0.493

D.W. : 2.0

ADF test statistic E.T.: -4.633 p-value: 0.000

ADF test statistic Ins.: -5.436, p-value: 0.000

ADF test statistic T.: -5.452, p-value: 0.000

ADF test statistic H.S.: -6.953, p-value: 0.000

4.1.2 RNN모델

RNN 모델 추정을 위해 과거 50개의 유닛을 활용하여 예측을 하며, 은닉층은 1개로 하였으며, 에폭(Epoch) 횟수는 50회, Batch size는 72개로 설정하여 총 2,801개의 파라미터를 Table 2와 같이 추정하였다.

Table 2. Result of RNN model fitting

Type	Output Shape	Params
Simple RNN	(None, 50)	2,750
Dense	(None, 1)	51

Total params: 2,801

에폭 회수 증가에 따라 MSE가 지속적으로 감소하지만 40회 이후에는 감소폭이 크지 않으므로 에폭 수가 적절한 것을 Fig. 3을 통해 확인할 수 있다.

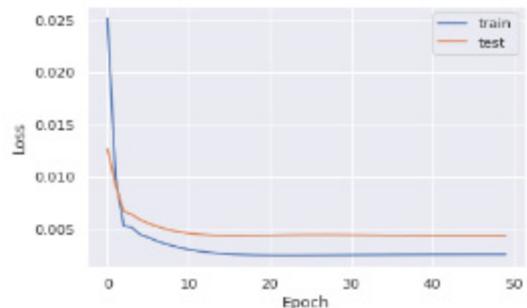


Fig. 3. RNN model improvement trend

4.1.3 LSTM모델

LSTM 모델 추정을 위해 과거 50개의 유닛을 활용하여 예측을 하며, 은닉층은 1개로 하였으며, 에폭(Epoch)

횟수는 50회, Batch size는 72개로 설정하여 총 11,000개의 파라미터를 Table 3과 같이 추정하였다.

Table 3. Result of LSTM model fitting

Type	Output Shape	Params
LSTM	(None, 50)	11,000
Dense	(None, 1)	51

Total params: 11,051

에폭 회수 증가에 따라 MSE가 지속적으로 감소하지만 40회 이후에는 감소폭이 크지 않으므로 에폭 수가 적절한 것을 Fig. 4를 통해 확인할 수 있다.

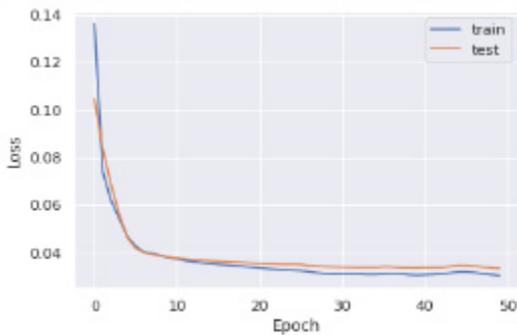


Fig. 4. LSTM model improvement trend

4.1.4 GRU모델

GRU 모델 추정을 위해 과거 50개의 유닛을 활용하여 예측을 하며, 은닉층은 1개로 하였으며, 에폭(Epoch) 횟수는 50회, Batch size는 72개로 설정하여 총 8,250개의 파라미터를 Table 4와 같이 추정하였다.

Table 4. Result of GRU model fitting

Type	Output Shape	Params
GRU	(None, 50)	8,250
Dense	(None, 1)	51

Total params: 8,301

에폭 회수 증가에 따라 MSE가 지속적으로 감소하지만 40회 이후에는 감소폭이 크지 않으므로 에폭 수가 적절한 것을 Fig. 5를 통해 확인할 수 있다.

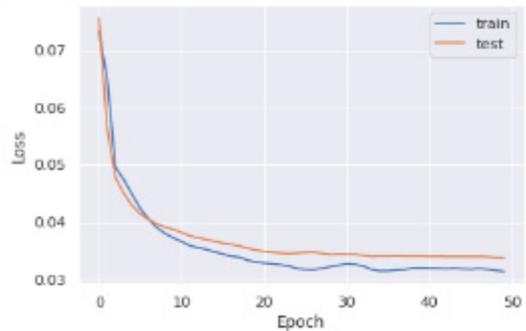


Fig. 5. GRU model improvement trend

4.2 예측모델 간 예측력비교

VAR 모델을 이용하여 미래 24시간을 예측할 경우 MSE가 201.94, RMSE가 14.2107로 나타나 단기 예측은 비교적 우수하지만 전반적인 예측력은 좋지 않은 것을 Fig. 6을 통해 확인할 수 있다.

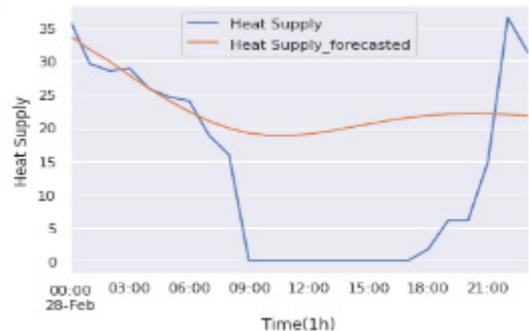


Fig. 6. Heat supply prediction result using VAR model

학습된 RNN 모델을 Test set에 적용 결과 MSE가 13.001, RMSE가 3.606로 Test set에 대한 예측력 우수한 것을 Fig. 7을 통해 확인할 수 있다.



Fig. 7. Heat supply prediction result using RNN model

학습된 LSTM 모델을 Test set에 적용결과 MSE가 5.913, RMSE가 2.432로 Test set에 대한 예측력이 RNN 모델보다 우수한 것을 Fig. 8을 통해 확인할 수 있다.

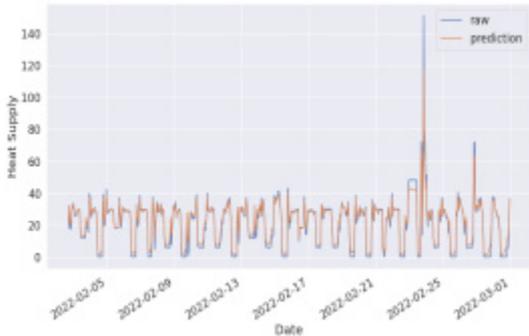


Fig. 8. Heat supply prediction result using LSTM model

학습된 GRU 모델을 Test set에 적용결과 MSE가 5.659, RMSE가 2.379로 Test set에 대한 예측력 LSTM보다 우수한 것을 Fig. 9를 통해 확인할 수 있다.

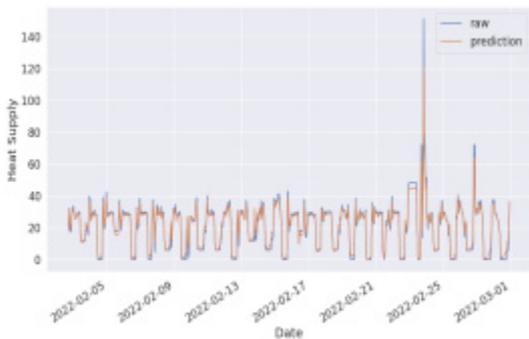


Fig. 9. Heat supply prediction result using GRU model

sklearn의 RandomizedSearchCV 활용하여 배치 사이즈를 24, 48, 72 등 세 가지 수준으로 설정하고, 에폭을 50회와 100회 및 뉴런 수를 10, 30, 50으로 구분하여 GRU 모델 하이퍼 파라미터 튜닝하였으며, 분석 결과 최적 조합이 배치 사이즈 24, 에폭 50회, 뉴런 수 30으로 나타났으며, 예측력에 있어서는 MSE가 4.362, RMSE가 2.089로 나타나 Test set에 대한 예측력이 기존 GRU 모델 보다 많이 개선된 것을 Fig. 10을 통해 확인할 수 있다.



Fig. 10. GRU model hyperparameter tuning result

4가지 모델 예측력에 대한 비교결과 RMSE 통계량을 활용한 경우와 실측값과 예측값 평균 차이를 비교한 예측력 전반에 있어서 모두 GRU 모델이 가장 우수한 것으로 나타났으며, 다음으로 LSTM, RNN, VAR 순으로 나타났다. GRU 모델일 경우, Test set에 대한 예측결과 실제 데이터 평균에 98.9% 정도로 전반적인 예측이 Table 5와 같이 높게 나타났다.

Table 5. Deep Learning Model Prediction Accuracy Level

Type	Mean	RMSE	Accuracy (1- A-B)	
Raw(A)	20.961	-	1	
Predicted(B)	RNN	20.302	3.606	0.968
	LSTM	21.792	2.432	0.962
	GRU	21.186	2.089	0.989

5. 결론 및 시사점

이 연구에서는 스마트 팜 경영비용 중 많은 부분을 차지하는 에너지 소비량에 대한 예측 모델을 구축하였으며, 분석 결과를 다음과 같이 요약할 수 있다.

첫째, 예측력에 우수한 모델 구축을 위해 전통적인 시계열분석 모형인 VAR 모델과, 딥러닝 모델인 RNN, LSTM, GRU 모델을 추정하였다.

둘째, 4가지 모델 예측력에 대한 비교결과 RMSE 통계량을 활용한 경우와 실측값과 예측값 평균 차이를 비교한 예측력 전반에 있어서 모두 GRU모델이 가장 우수한 것으로 나타났으며, 다음으로 LSTM, RNN, VAR 순으로 나타났다.

이러한 분석 결과로부터 다음과 같은 시사점을 도출할 수 있다.

첫째, 에너지 소비에 영향을 미치는 요인이 아니 예측 정확도를 목적으로 할 경우 딥러닝 모델 활용이 적합하다.

둘째, 딥러닝 모델별 예측력에도 차이 있으므로, 다양한 모델 적합 이후 최적 모델 선택하는 것이 효과적인을 알 수 있다.

보다 우수한 딥러닝 모델 구축을 위해서는 적절한 하이퍼 파라미터에 대한 설정이 필요하다.

References

- [1] J. B. Goo, H. J. Shin, Y. H. Kwak, J. H. Huh, "Development of Smart Greenhouse Energy Analysis Model and Analysis of Cooling Packages Performance", *Journal of the Korean Solar Energy Society*, Vol. 41, No. 6, pp.1-18, 2021.
DOI: <https://doi.org/10.7836/kses.2021.41.6.001>
- [2] M. S. Choi, "Smart Farm Control System for Improving Energy Efficiency", *Journal of Digital Convergence*, Vol. 19, No. 12, pp. 331-337, 2021.
DOI: <https://doi.org/10.14400/JDC.2021.19.12.331>
- [3] S. H. Park, H. R. Han, H. K. Hong, J. K. Min, "A Study on Energy Performance Evaluation of Combined Heat Source Heat Pump System Consisting of Ground and Water Sources in Smart Farm", *Korean Journal of Air-Conditioning and Refrigeration Engineering*, Vol. 33, No. 11, pp. 608-618, 2021.
DOI: <https://doi.org/10.6110/KJACR.2021.33.11.608>
- [4] B. S. Seo, S. Y. Shim, "Forecasting the Demand for Local District-Heating System", *Korean Energy Economic Review*, Vol. 11, No 2, pp. 27-55, 2012.
- [5] J. W. Kim, Y. H. Kwak, J. H. Huh, "Development of Energy Prediction Model for Residential Buildings through Statistical Analysis", *Journal of the Korean Solar Energy Society*, Vol.40, No.6, pp.51-60, 2020.
DOI: <https://doi.org/10.7836/kses.2020.40.6.051>
- [6] D. H. Shin, C. B. Kim, "A Study on Deep Learning Input Pattern for Summer Power Demand Prediction", *Journal of KIIT*, Vol. 14, No. 11, pp. 127-134, 2016.
DOI: <http://dx.doi.org/10.14801/jkiit.2016.14.11.127>
- [7] A. Tealab, "Time series forecasting using artificial neural networks methodologies: A systematic review", *Future Computing and Informatics Journal*, Vol 3, pp. 334-340, 2018.
DOI: <https://doi.org/10.1016/i.fcij.2018.10.003>
- [8] F. A. Gers, N. N. Schraudolph, J. Schmidhuber, "Learning Precise Timing with LSTM Recurrent Networks", *Journal of Machine Learning Research*, Vol 3, pp. 115-143, 2002.
DOI: <https://doi.org/10.1162/153244303768966139>
- [9] J. Heck, F. M. Salem, "Simplified Minimal Gated Unit Variations for Recurrent Neural Networks", *2017 IEEE*

60th International Midwest Symposium on Circuits and Systems, 2017.

DOI: <https://10.1109/MWSCAS.2017.8053242>

임 청 룡(Cheong-Ryong Lim)

[정회원]



- 2008년 2월 : 경북대학교 대학원 농업경제학과 (경제학석사)
- 2012년 2월 : 경북대학교 대학원 농업경제학과 (경제학박사)
- 2014년 9월 : 연변대학교 농림경제학과 전임강사
- 2017년 1월 ~ 현재 : 한국농어촌공사 농어촌연구원 주임연구원

<관심분야>

농업경영, 환경경제, 농산물마케팅, 빅데이터

박 영 준(Young-Jun Park)

[정회원]



- 2008년 3월 : 신수대학교 대학원 농업연구 (농학석사)
- 2011년 3월 : 경북대학교 대학원 농업연구 (농학박사)
- 2011년 4월 : JSPS 외국인특별연구원
- 2013년 4월 : 신수대학교 연구원
- 2017년 1월 ~ 현재 : 한국농어촌공사 농어촌연구원 주임연구원

<관심분야>

간척지개발, 노지스마트농업, 농업연구

이 철 성(Chul-Sung Lee)

[정회원]



- 2008년 2월 : 한밭대학교 대학원 건축공학과 (공학석사)
- 2017년 2월 : Department of Built Environment, University of Eindhoven (공학박사)
- 2018년 1월 ~ 현재 : 한국농어촌공사 농어촌연구원 주임연구원

<관심분야>

스마트농업, 스마트제어, 신재생에너지, 온실에너지