

태양에너지 예보기술 동향분석

전재호* · 이정태** · 김현구**** · 강용혁*** · 윤창열**** · 김창기**** · 김보영**** · 김진영**** · 박유연***** · 김태현***** · 조하나*****

*한국특허전략개발원 정부협력팀, 특허전문위원
**한국에너지기술연구원 신재생에너지자원·정책센터, 박사후연구원
***한국에너지기술연구원 신재생에너지자원·정책센터, 책임연구원
****한국에너지기술연구원 신재생에너지자원·정책센터, 선임연구원
*****한국에너지기술연구원 신재생에너지자원·정책센터, 선임기술원
*****특허법인다나, 선임변리사
*****특허법인다나, 변리사
*****특허법인다나, 대리

Trend Review of Solar Energy Forecasting Technique

Cheon Jae ho* · Lee Jung-Tae** · Kim Hyun-Goo**** · Kang Yong-Heack*** · Yun Chang-Yeol**** · Kim Chang Ki**** · Kim Bo-Young**** · Kim Jin-Young***** · Park Yu Yeon***** · Kim Tae Hyun***** · Jo Ha Na*****

*Korea Intellectual Property Strategy Agency, Government Cooperation Team, Patent Research Fellow
**New and Renewable Energy Resource & Policy Center, Korea Institute of Energy Research, Postdoctoral Researcher
***New and Renewable Energy Resource & Policy Center, Korea Institute of Energy Research, Principal Researcher
****New and Renewable Energy Resource & Policy Center, Korea Institute of Energy Research, Senior Researcher
*****New and Renewable Energy Resource & Policy Center, Korea Institute of Energy Research, Senior Engineer
*****Dana Patent Law Firm, Senior Patent Attorney
*****Dana Patent Law Firm, Patent Attorney
*****Dana Patent Law Firm, Assistant Manager



Journal of the Korean Solar Energy Society
Vol.39, No.4, pp.41-54, August 2019
<https://doi.org/10.7836/kses.2019.39.4.041>

pISSN: 1598-6411
eISSN: 2508-3562

†Corresponding author: hyungoo@kier.re.kr

Abstract

The proportion of solar photovoltaic power generation has steadily increased in the power trade market. Solar energy forecast is highly important for the stable trade of volatile solar energy in the existing power trade market, and it is necessary to identify accurately any forecast error according to the forecast lead time. This paper analyzes the latest study trend in solar energy forecast overseas and presents a consistent comparative assessment by adopting a single statistical variable (nRMSE) for forecast errors according to lead time and forecast technology.

Keywords: 태양광발전(Photovoltaic), 일사(Irradiance), 인공신경망(ANN; Artificial neural network), 발전량예보(Power forecasting), 예보시간(Forecasting horizon)

Copyright © Korean Solar Energy Society
This is an Open-Access article distributed under the terms of the Creative Commons Attribution NonCommercial License which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서론

정부의 에너지 전환 정책을 반영한 ‘재생에너지 3020 이행계획’에 따르면 2030년까지 재생에너지의 발전비중 목표를 20%로 설정하고 있어, 향후 재생에너지의 발전 비중은 가파른 상승세를 이어갈 것으로 예상된다. 하지만, 재생에너지에 의해 생산된 전력은 기존의 발전원에 비해 전력생산의 변동성이 크기 때문에 재생에너지 발전비중 확대에 따라 전력수급 과정에서 다양한 문제들이 발생할 수 있다¹⁾.

재생에너지의 변동성이 큰 이유는 태양에너지원이 자연환경에 직접적인 영향을 받기 때문이다. 화석연료를 비롯한 기존의 에너지원은 수요에 따라 전력 생산량을 조절할 수 있지만, 태양에너지는 발전량을 임의로 제어할 수 없으며, 구름, 강수, 바람 및 여러 가지 기상조건에 따라 변동한다. 따라서 변동성이 큰 태양광에너지의 공급비율이 늘어날수록 기존 전력수급 시스템(전력수급 계획, 전력거래, 계통 안정성)의 불안정성이 커질 수 있다.

재생에너지의 발전량이 일정하지 못한 특성은 기존 에너지 공급 및 거래시스템에 위해가 되는 문제이며, 이에 따른 제반 문제를 해결하기 위해 다양한 연구들이 진행되어 왔다. 에너지저장장치의 활용, 예비력시장 도입 및 인센티브제도 도입에 대한 연구들이 수행되었지만^{2,3)}, 이들 연구는 변동성의 완화방법에 가깝다. 태양광 발전량 변동과 이에 따른 전력거래 전략을 적극적으로 계획하기 위해서는 궁극적으로 태양에너지 발전량 혹은 일사량 예보의 정확도를 높이는 기술이 필요하다.

최근 시장의 요구에 따라 태양에너지 예보기술은 다양한 기법들을 통해 개발되고 있는 추세이며, 신재생에너지의 비율이 일찍이 확대된 해외에서는 이러한 기술들을 전력거래시장에 적극 활용하고 있다⁴⁾. 예보 기법들은 입력자료(지상관측, 위성, 모델)의 특성에 따라 각기 다른 시간에 대한 예보를 목표로 하게 되며, 그에 따라 예보 오차의 변동이 발생하게 된다. 태양광에너지로부터 생산된 전력이 기존의 전력거래시스템에서 원활히 거래되기 위해서는 전력거래시스템에 맞는 시간대의 예보능력을 갖추는 것이 중요하다.

현재 국내의 전력거래 시장에서 신재생에너지원의 하루 전(Day-ahead) 거래를 수행하기 위해서는 40시간 이상의 중·장기 예보가 필요하며, 당일(Intra-day) 거래는 12시간 혹은 6시간 이하의 단기 예보가 요구될 것으로 추정된다(일출·몰, 거래시간, 기상모델시스템 및 예보수행 시간을 고려). 국내에서는 아직 당일 실시간 거래시장이 활성화 되어 있지 않지만 신재생에너지의 비중이 확대됨과 동시에 당일 거래시장이 활성화되고 거래 시간단위도 세분화 될 것으로 예상된다. 즉, 향후 국내의 태양광 전력거래 시장은 40시간 이하의 모든 시간에 대해 정확도 높은 예보를 필요로 할 것이며, 어떠한 예보기법들이 이러한 요구들을 충족시킬 수 있는지 검토할 필요가 있다.

본 연구에서는 국내 전력거래 환경에 적용 가능한 범위의 내에서 해외문헌들을 대상(2015년 이후)으로 최근 개발되고 있는 예보기법들을 살펴보고 예보 시간대별로 분류하여 이들의 오차를 정리하였다. 다양한 기법들의 예보오차는 normalized root mean square(nRMSE)를 기준으로 평가되었으며, 개발동향 및 예보기법들이 가진 문제점을 점검하여 국내 예보기술 개발 방향을 고찰하였다.

2. 정확도 평가방법

2.1 예보모형 분류기준

유럽 전력거래(European Power Exchange, EPEX SPOT)의 경우, 하루 전, 하루 내, 밸런싱 시장으로 구분된다. Fig. 1는 유럽내 각 국가별 하루 전 시장 및 당일시장의 거래시간 거래 단위 등을 나타낸다⁵⁾. 하루전 시장은 대부분 거래 전일 오후 12시에 마감되며, 당일 시장의 경우 독일의 경우 15분 단위, 30분 단위, 1시간 단위로 급전 1시간 전까지 갱신이 가능하다. 독일의 경우 하루 전 시장에서는 40시간 예보 정보가 필요하고 당일 시장에서는 최소 20분에서 수 시간 예보 정보가 실시간으로 요구되며, 시장의 요구에 맞춰 전력예보정보가 산출된다.

현재 국내 전력거래 시장은 하루 전 시장을 운영하고 있다. 최근 발표된 신재생에너지 거래를 위한 소규모전력중개시장 운영 규칙에 따르면(Fig. 2), 국내의 전력 중개거래는 전일 19시부터 거래다음일 5시까지 34시간 동안 시간별 발전 예측량을 전일 10시까지 제출하도록 되어있다. 즉, 제출 시각부터 43시간 후의 발전량을 예보할 수 있어야 한다. 중규모 모델자료의 시간간격과 예보기법들의 연산 시간을 감안하면 실제론 48시간 예보 시스템이 필요한 것을 알 수 있다. 따라서 본 연구는 최소 1시간과 최대 48시간 범위의 태양광 발전량 예보기술들에 대한 문헌들을 조사하였으며, 시간에 따른 예보오차를 분석하기 위해 3시간, 6시간, 24시간 예보를 구분하였다.

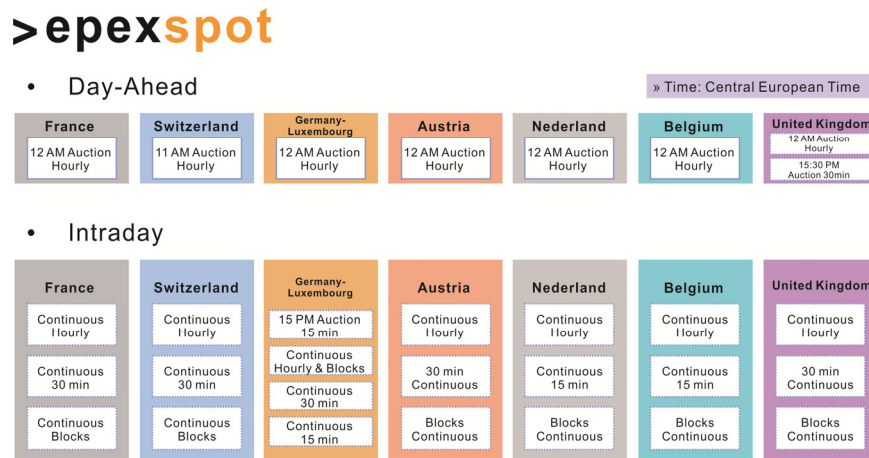


Fig. 1 Schedule of power trading by European countries

2.2 정확도 평가 방법

태양광 예보기술들의 예보성능 평가는 지상의 관측 일사량이나 발전량을 기준으로 수행한다. 예보기술의 정확도 평가를 평가하는 통계값은 문헌들마다 다양하게 나타나기 때문에 일정한 산출변수와 통계변수 없이는 정확도를 비교평가하기 어렵다. 즉, 각기 다른 예보기술의 정확도를 비교평가하기 위해서는 하나의 통계변수가 필요하며, 본 연구에서는 보편적으로 쓰이는 nRMSE를 평가의 척도로 사용하였다.

$$nRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}}{\bar{Y}_i} \quad (1)$$

일반적으로 nRMSE는 식(1)과 같이 Y_i 의 평균값(\bar{Y}_i)을 분모로 사용하지만, Y_i 의 최대와 최소의 차이값을 사용하는 경우도 빈번하며, 이 경우 nRMSE 값에 구분 표식(')을 두었다.

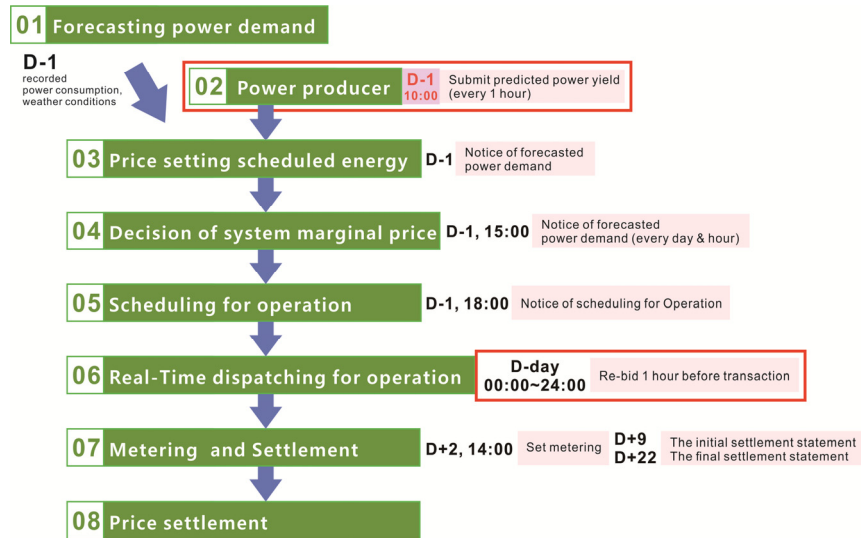


Fig. 2 Procedure of the domestic power trading

해외의 연구사례들은 수평면 전일사량 예보와 PV 발전량 예보로 나눌 수 있다. 예보된 PV 발전량은 일사량 외의 추가적인 계산과정(발전량 산정모델)을 필요로 하기 때문에 일사량 예보와 구분할 필요가 있다. 따라서 본 연구에서는 산출결과인 수평면 전일사량과 PV 발전량을 예보 시간범위별로 구별하여 비교하였다.

예보 시간범위는 크게 세 분류로 나뉘며, 각 분류의 시간영역은 1시간(intra-hour), 3-6시간(intra-day), 24-48시간 이상(Day-ahead)으로 구분된다.

3. 태양광 예보기술

3.1 태양광 예보모델 분류

(1) 시계열 통계 모델

태양광 일사량 또는 태양광 발전량을 예보하는 기법들은 크게 시계열적 통계기법, 물리적 기법, 앙상블 기법 세 가지로 분류 될 수 있다. 그 중 가장 일반적으로 사용되어지는 통계적 예보 기법은 과거 기상 변수와 일사량 간의 상관관계를 시계열적 통계 분석을 통해 재구성해 내고 미래시점의 예보된 기상 변수로 일사량을 추정하는

기법으로 아래와 같은 다양한 분석 모델이 있다⁶⁾.

인공신경망(Artificial Neural Network, ANN)은 인공지능 기술 중 하나로 동물의 신경계를 모사한 통계학적 학습 알고리즘이다. 인공신경망은 인공 뉴런(artificial neuron)들이 서로 연결되어 네트워크를 구성하고 학습을 통해 연결된 네트워크의 세기를 변화시켜 문제를 해결한다. 인공신경망의 기본 구성은 입력층, 은닉층, 출력층으로 이루어지는데 입력층의 파라미터, 은닉층의 망구조, 뉴런 간 비중을 갱신하는 학습단계에 따라 문제 해결의 정확도가 달라진다⁷⁾. 최근 발전량 예보에 가장 많이 사용되는 기법이다.

서포트 벡터 머신(support vector machine, SVM)은 패턴 인식, 자료 분류를 위한 모델이다. 서포트 벡터 머신은 고차원 영역에서 초평면(hyperplane)분리를 통해 자료를 분류하는 방법이며, 비선형 특성을 가진 자료를 분석할 수 있는 방법으로 잘 알려져 있다. 학습 데이터를 기반으로 객체를 구분할 수 있는 경계(decision boundary)를 정하고 자료간의 관계를 일반화시킬 수 있는 법칙(decision rule)을 찾는 방법이다⁸⁾.

시계열 분석에서는 시간의 변화가 분석 기준이 되는데 특정 시점의 변수는 그 이전 변수들의 영향을 받거나 이전 시점의 오차에 영향을 받는데 이를 이용한 것이 자기회귀 모델(Autoregressive model, AR)이다. 이동평균 모델(Moving average, MA)은 오차가 한정된 수에 종속되는 것을 나타낸다. AR과 MA를 합쳐 자기회귀 모델과 이동평균 모델을 적용한 것이 자기회귀 이동평균 모델(Autoregressive moving average model, ARMA)이다⁹⁾. 자기회귀 이동평균 모델 분석은 적용공분산 정상성을 만족시키는 과정을 거쳐 분석하는데 이를 자기회귀누적이동평균모델(Autoregressive integrated moving average, ARIMA)이라 한다¹⁰⁾.

(2) 물리적 모델

태양복사와 에어로졸, 구름 등과 같은 대기 성분은 지표면의 일사량에 영향을 미친다. 이러한 대기 정보 기상 관측 정보 등 실제 물리적 요소를 분석하여 일사량을 예측하는 것이 물리적 기법이다.

수치기상예측(Numerical weather prediction, NWP)은 대기 상태 및 강수를 물리적으로 모사하는 것으로 이것으로 일사량을 예측해 태양광 발전량예측에 이용한다. 수치기상예측 모델은 전역 모델(Global model)과 중간규모 모델(Mesoscale model)로 구분할 수 있는데 중간규모 모델은 제한된 지역에 대한 대기 특성을 모사하는데 비해 전역 모델은 전지구적 영역에 대해 대기 특성을 모사한다¹¹⁾. 현재 운용되는 대표적인 전역 모델로 미국해양대기청의 GFS와 유럽중장기예보센터 전구모델(ECMWF) 등이 있으며 한국 기상청에서 운용하는 전역 모델로 UM N1280L70 국지 모델로 UM 1.5 kmL70 등이 있다¹²⁾.

전천영상(Sky imagery)을 이용하는 방법은 하늘과 수평면까지 촬영가능한 고해상도 카메라를 이용해 촬영한 전천 영상에서 구름 영역을 식별하고 구름의 높이, 이동 방향 등을 측정해 일사량 등 예측하는 기법이다. 전천영상 기반의 태양광발전 예보는 다음과 같이 네 개의 단계로 이루어지는데, (1) 전천영상기를 이용해 예보지점의 전천영상의 획득하는 단계, (2) 획득한 전천 영상에서 영상분석을 통해 구름을 식별하는 단계, (3) 시간적으로 연속된 영상을 이용해 구름 이동 벡터를 산출하는 단계 및 (4) 구름의 위치와 이동 벡터를 이용해 단기간의

구름 영향, 일사량, 발전량 등을 예측하는 단계로 구성된다. 전천영상을 이용한 예보는 해상도가 높은 예보가 가능하지만 시간적으로는 1시간 미만의 초단기 예보가 가능하다⁶⁾.

위성영상을 이용한 예보는 전천영상 기법과 유사하지만, 위성에 장착된 센서로부터 획득된 가시광 이미지와 적외선 이미지를 이용하여 구름패턴을 인식할 수 있다. 일반적으로 정지위성의 데이터를 이용하기 때문에 전천영상 보다 훨씬 넓은 영역을 관측할 수 있으나 공간해상도는 전천영상보다 낮다. 위성영상을 이용한 일사량 예보는 수증기량, 에어로졸 등 입력 값으로 예보 대상 지역에 청천 일사량을 예측하는 단계, 예측된 일사량을 위성영상과 조합하여 일사량을 예측하는 단계, 연속적인 위성이미지를 이용해 구름 이동 벡터를 산출하여 미래의 구름 위치를 예측하는 단계로 이루어진다. 이러한 일사량 예보는 1분 내지 5시간 앞의 예보에 효과적이다.

(3) 혼합 모델

혼합모델은 각 예보 기법의 단점을 보완하고 예측 정확도를 높이기 위해 다수의 예보 기법들을 조합하여 결과를 도출한다. 하이브리드(Hybrid) 기법으로 칭해지기도 한다. 혼합모델은 경쟁적(Competitive) 및 협력적(Cooperative) 예보로 구분할 수 있다¹³⁾.

경쟁적 예보 기법은 다수의 예측기에 서로 다른 파라미터 또는 입력 데이터를 적용하여 개별적으로 해결한다. 예보 결과는 각 예측기의 예보 결과를 평균하여 얻어진다. 경쟁적 예보기법은 데이터 다양성, 파라미터 다양성, 커널 다양성으로 나뉜다. 협력적 앙상블 기법은 예보 작업을 다수의 하위 작업으로 나누고 각 하위 작업은 개별적으로 해결한다. 전체적인 예보 결과는 모든 예측기의 예보 값을 종합하여 얻어진다.

3.2 예보모형 및시간별 정확도

문헌들을 예보기간에 따라 분류한 결과는 Table 1에 나타내었다. 2015년 이후에 발간된 최근 연구들을 대상으로 사용된 기법들과 입력자료를 정리하였으며, nRMSE 값을 기준으로 정확도를 비교할 수 있도록 하였다. 하루 내 예보는 1시간, 3시간, 6시간으로 구별하였으며, 1시간 예보는 하루 내 예보와 별도로 구분한다. 24시간과 48시간 예보는 전일 예보로 구분하였다.

(1) 하루 내 일사량 예보(Intra-hour and Intra-day)

Azimi et al.¹⁴⁾은 지상에서 측정된 10년간의 일사량 자료를 기반으로 시간당 일사량의 오차를 최대 72시간까지 평가하였다. TB K-mean clustering과 3개의 은닉층으로 이루어진 ANN 모형의 예보 일사량은 1시간 예보 범위에서 평균적으로 7.2%의 nRMSE 수치를 기록하였다. 24시간 예보는 28.9%, 48시간 예보는 32.2%로 증가하였다.

Table 1 Summary of the studies for solar irradiance forecasting

	Time horizon	Author	Method	Input data	nRMSE		
Intra-hour	1 h	Azimi et al., 2016	TB K-mean cluster + ANN (3 hidden layers)	MEAS: Irradiance (sfc)	7.2		
	1 h	Sharma et al., 2016	Wavelet neural network	MEAS: Irradiance (sfc)	18.1		
	1 h	Alonso-Montesinos et al., 2015	Cross-correlation method	MEAS: Irradiance (sfc; sky camera)	19.4		
	1 h	Aguiar et al., 2015	Bayesian ANN (multilayer)	MEAS: Irradiance (sfc, satellite)	19.8		
	1 h	Notton et al., 2019	ANN (4 hidden layers)	MEAS: Irradiance, weather variables (sfc)	22.5		
	1 h	Gutierrez-Corea et al., 2016	ANN (2 hidden layers)	MEAS: Irradiance, weather variables (sfc)	22.6		
	1 h	Dong et al., 2015	Combine SOM+SVR+PSO	MEAS: Irradiance weather variables (sfc)	23.0		
	1 h	de Paiva et al., 2018	Multigene genetic programming	MEAS: Irradiance, weather variables (sfc)	34		
AVERAGE					20.8		
Solar irradiance forecasting	Intra-day	3 h	Aguiar et al., 2015	Bayesian ANN (multilayer)	MEAS: Irradiance (sfc, satellite)	28.5	
		3 h	Montesinos et al., 2015	Cross-correlation method	MEAS: Irradiance (sfc; sky camera)	27.6	
		3 h	Notton et al., 2019	ANN (4 hidden layers)	MEAS: Irradiance, weather variables (sfc)	31.4	
		3 h	Gutierrez-Corea et al., 2016	ANN (2 hidden layers)	MEAS: Irradiance, weather variables (sfc)	28.1	
		AVERAGE					28.9
		6 h	Aguiar et al., 2015	Bayesian ANN (multilayer)	MEAS: Irradiance (sfc, satellite)	29.4	
		6 h	Gutierrez-Corea et al., 2016	ANN (2 hidden layers)	MEAS: Irradiance, weather variables (sfc)	34.5	
		6 h	Notton et al., 2019	ANN (4 hidden layers)	MEAS: Irradiance, weather variables (sfc)	34.8	
AVERAGE					32.9		
Day-ahead	24 h	Azimi et al., 2016	TB K-mean cluster + ANN (3 hidden layers)	MEAS: Irradiance (sfc)	28.9		
	24 h	Trapero et al., 2015	Dynamic Harmonic Regression	MEAS: Irradiance (sfc)	29.6		
	24 h	Piazza et al., 2016	NARX neural network	MEAS: Irradiance (sfc)	31.8		
	24 h	Lima et al., 2016	NWP + ANN (post processing; hidden layers 8-22)	NWP: forecasted variables MEAS: Clear sky model (sfc)	35.8		
	AVERAGE					31.5	
	48 h	Piazza et al., 2016	NARX neural network	MEAS: Irradiance, weather variables (sfc)	28.8(*)		
	48 h	Azimi et al., 2016	TB K-mean cluster + ANN (3 hidden layers)	NWP: Irradiance	32.2		
	48 h	Lorenz et al., 2009	ECMWF-OL		44.0		
AVERAGE					35.0		

Sharma et al.¹⁵⁾은 WNN(Wavelet Neural Network)를 사용하여 15분 및 1시간 예보범위에 대한 초단기 예보를 수행하였다. 15분 월평균 예보오차는 11.3%이며, 1시간 예보오차는 상대적으로 높은 18.1%이다. 사용된 WNN기법은 다른 통계적 기법들(Persistence, ETS, ARIMA, ANN, WNN)과 비교되었으며, 모든 경우에 대해 1-2% 가량 낮은 값을 보였다.

Alonso-Montesinos et al.¹⁶⁾은 스카이 카메라를 이용하여 최대 3시간 까지 일사량 예보를 수행하고 예보의 오차를 나타내었다. 이 방법은 연속된 3장의 스카이 이미지에 대해 Maximum Cross-Correlation 기법을 사용하여 구름이동벡터를 산정하며, 이미지 픽셀의 밝기와 일사량간의 관계식을 통해 일사량을 산정하는 과정을 가진다. 시간 안 예보의 오차는 19.4%로 나타나며, 3시간 예보는 27.6%이다.

Aguilar et al.¹⁷⁾은 위성자료로 산출된 지상일사량 자료와 지상의 관측일사량 자료를 사용하여 6시간 예보를 수행하였다. 다중레이어를 사용하는 Bayesian ANN 기법을 사용하였으며, 예보오차는 예보시간 1, 3, 6 h에 대해 19.8, 28.5, 29.4%(평균치)가 나타났다. 구름이 자주 위치하는 지역은 위성 일사량과 예보 오차가 높은 것으로 분석되며, 위성자료의 사용유무에 따른 예보 정확도를 판단 할 수 있는 연구결과이다. 결과에 따르면 위성 산출 일사량을 사용한 결과가 지상의 청천일 모델(Clear sky model)을 통한 일사량과 기후자료보다 nRMSE가 낮은 것을 알 수 있다(Table 2).

Table 2 Input-specific average nRMSE (Mazorra et al.)

Model	nRMSE (%)
CLI	26.7
ANN	21.9
ANN+Satellite	20.2

Notton et al.¹⁸⁾은 지상의 관측일사량과 기상변수를 입력자료로 사용하여 ANN 기반 6시간 일사량 예측 연구를 수행하였다. 4개의 은닉층으로 ANN을 구성하였으며 1시간, 3시간, 6시간에 대해 22.5, 31.4, 34.8%의 오차가 나타났다. 이 연구는 GHI와 DNI를 구분하여 예보를 수행하였으며, GHI의 nRMSE가 DNI 보다 약 2배 낮게 나타났다. DNI의 오차가 더 큰 이유는 구름에 민감한 DNI의 특성 때문인 것으로 분석되었다. 6시간 예보는 1시간 간격으로 수행되었으며, 시간별 예보오차는 Table 3에 제시되었다. 1시간과 2시간 예보에서 오차의 증가가 가장 크게 나타난다.

Gutierrez-Corea et al.¹⁹⁾은 정해진 반경 내의 지점에서 관측된 과거 일사량과 기상변수를 ANN의 입력자료로 사용하는 연구를 수행하였으며, 2개의 은닉층을 사용하였다. 예보오차는 1시간, 3시간, 6시간에 대해 22.6, 28.1, 34.5%로 나타났다.

Dong et al.²⁰⁾은 지상에서 관측된 일사량과 기상변수를 입력자료로 사용하였으며, 통계모델을 결합하여 1시간 일사량 예보를 수행하였다. 이 연구의 통계모델 결합은 SOM(Self-Organizing Map), SVR(Support Vector

Regression), PSO(Particle Swarm Optimization) 기법들을 역할에 따라 구분하여 사용함을 의미한다. 1시간 예보오차는 23%로 나타났다.

de Paiva et al.²¹⁾은 MGGP(Multigene genetic programming) 기법을 1시간 일사량 예보에 적용한 연구로서 관측된 지상일사량과 기상변수를 입력자료로 사용한다. 예보오차 평가는 흐린 날과 비온 날을 모두 포함하기 때문에 검토된 논문 중 가장 높은 nRMSE(34%)가 나타난다.

Table 3 Time-specific nRMSE for indra-day forecasting (Notton et al.)

Lead time	nRMSE (%)
1 h	21.6
2 h	28.0
3 h	31.4
4 h	33.3
5 h	34.3
6 h	34.8

(2) 전일 일사량 예보(Intra-day)

Trapero et al.²²⁾은 DHR(Dynamic Harmonic Regression) 기법을 사용하여 24시간 일사량 예보를 수행하였다. 관측된 지상일사량 자료를 입력자료로 사용하며, Notton et al.과 마찬가지로 DNI 보다 GHI의 예보정확도가 높게 나타난다(Table 4). GHI 24시간 예보의 nRMSE는 29.6%이며, DNI는 46.7%로 나타나며, 다른 통계 모형들에 비해 낮은 오차를 기록하였다.

Table 4 Method-specific nRMSE of GHI and DNI for day-ahead forecasting (Trapero et al.)

Model	nRMSE (%)	
	GHI	DNI
Persistence model	94.5	83.6
Seasonal persistence model	32.4	50.8
Exponential smooting	34.1	49.0
ARIMA	37.4	112.6
Dynamic harmonic regression	29.6	46.7

Piazza et al.²³⁾이 제안한 다층 퍼셉트론(Multilayer perceptron)기반 NARX(Nonlinear Autoregressive Network with Exogenous Input) 기법은 지상관측자료를 사용하였으며, 24시간은 31.8%, 48시간은 28%의 예보오차를 기록하였다.

Lima et al.²⁴⁾은 Numerical Weather Prediction(NWP)의 복사모수화 오차를 줄이기 위해 ANN에 기반한 후처리 과정을 제안하였다. ANN모형에 사용된 자료는 브라질 110지점의 지상관측자료(일사량, 기상변수)이며,

NWP 예보 일사량은 ANN을 통해 재생산되었다. ANN 후처리 모형을 사용한 결과의 예보오차가 NWP의 자료만 사용한 결과보다 낮았으며, 우기(rainy season)와 건기(dry season)로 나누어 평가된 24시간 예보오차의 평균은 각각 35.6, 29.5%로 건기의 예보오차가 낮았다(Table 5).

Table 5 nRMSE of rainy and dry season for day-ahead forecasting (Lima et al.)

Model	Rainy season (nRMSE)		Dry season (nRMSE)	
	NWP	NWP+ANN	NWP	NWP+ANN
Region 1	44.8	34.3	41.6	31.8
Region 2	45.1	34.3	35.4	24.5
Region 3	50.8	38.1	49.5	37.1
Region 4	48.8	35.6	40.1	24.5
Average	47.4	35.6	41.7	29.5

(3) PV 발전량 예보

일사량 예보와 구분된 아래의 연구들은 최종적으로 PV 발전량을 예보하며, 최종산출물이 다르기 때문에 따로 구별되었다(Table 6).

Table 6 Summary of the studies for PV power forecasting

	Time horizon	Author	Method	Input data	nRMSE	
PV power forecasting	Intra-hour	1 h	Agoua et al., 2017	Satio-Temporal model	MEAS: PV power	8.0
		1 h	Bouzerdoum et al., 2013	SARIMA-SVM	CLIM: GHI, T / MEAS: PV power	9.4
		1 h	Degiorgi et al., 2014	ANN (1 hidden layers)	MEAS: GHI, T, PV power	12.0
					AVERAGE	9.8
	Intra-day	3 h	Agoua et al., 2017	Satio-Temporal model	MEAS: PV power	14.0
		3 h	Degiorgi et al., 2014	ANN (1 hidden layers)	MEAS: GHI, T, PV power	17.2
					AVERAGE	15.6
		6 h	Agoua et al., 2017	Satio-Temporal model	PV power	20.0
		6 h	Degiorgi et al., 2014	ANN (1 hidden layers)	MEAS: GHI, T, PV power	20.9
				AVERAGE	20.4	
	Day-ahead	24 h	Gandelli et al., 2014	Physical Hybrid ANN (2 hidden layers)	NWP: forecasted variables MEAS: PV power	20.4
		24 h	Antonanzas et al., 2017	Combined (SVR+DNN+XGB+RF)	NWP: GHI, T, RH, WS, etc MEAS: PV power	22.2
24 h		Degiorgi et al., 2014	ANN (1 hidden layers)	MEAS: GHI, T, PV power	24.4	
			AVERAGE	22.3		

Agoua et al.²⁵⁾은 지리적으로 분산된 프랑스 PV 플랜트의 공간 및 시간 상관으로 특정 플랜트 발전량을 예보하는 시공간(spatio-temporal)모형을 사용하였다. 185 개의 PV 플랜트 발전량이 입력자료로 사용되었으며, 9 개의 특정 지점들에 대해 예보정확도 평가가 수행되었다. 1, 3, 6시간에 대한 예보오차는 8.0, 14.0, 20.0%(9개 지점 평균)로 나타났다.

De Giorgi et al.²⁶⁾은 ANN을 사용하여 이태리 PV 플랜트(960 kW)의 발전량을 예보한다. 지상에서 1년 동안 관측된 PV 발전량과 기상자료가 ANN의 입력자료로 사용되며, 입력자료의 구성을 다르게 설정하여 시간별 예보성능을 평가하였다. 1, 3, 6, 24시간 예보오차는 12.0, 17.2, 20.9, 24.4%로 나타나며, PV 발전량이 단일로 사용된 경우보다 일사량과 모듈온도가 함께 입력된 결과의 오차가 더 낮은 결과를 보였다.

Bouzerdoum et al.²⁷⁾은 Seasonal Auto-Regression Integrated Moving Average(SARIMA)와 Support Vector Machine(SVM)기법을 사용하여 이태리 PV 플랜트(20 kW)의 발전량을 예보하였다. 측정된 PV 발전량 및 기후자료(일사량, 모듈온도, 환경온도)가 입력자료로 사용되었고 1시간 예보오차는 9.4%이다.

Gandelli et al.²⁸⁾의 hybrid 모형은 NWP의 예보결과인 운량(Cloud cover) 및 예보변수(온도, 풍속 등)를 ANN과 Clear sky 모델의 입력자료로 사용하며, 24시간 예보오차는 20.4%로 나타났다.

Antonanzas et al.²⁹⁾는 스페인 PV 플랜트(1,800 kW)에 대해 다양한 통계모형을 통한 예보를 수행하였다. NWP의 예보변수(일사량, 온도, 풍속 등)들과 PV 발전량이 입력자료로 사용되었고, 여러 모형들 중 SVR 모형의 24시간 예보오차가 22.4%로 가장 낮게 나타났다(Table 7). 통계모형들의 오차정보를 최소화한 통합모형(Blended model)을 제시하였으며, 예보오차는 22.2%를 기록하였다.

Table 7 Method-specific nRMSE (Antonanzas et al.)

Model	nRMSE (%)
Deep neural networks	23.5
Support vector machines	22.4
Random forests	22.7
Extreme gradient boosting	23.0
Blended model	22.2

4. 결론

국내의 재생에너지 발전비중이 증가함에 따라 발생할 수 있는 발전량의 변동성 문제는 전력거래 시장에서 중요한 화두이다. 이에 대한 선제적 대응 방안으로 정확도 높은 발전량 예보기술 개발이 요구된다. 해외에서는 일찍이 재생에너지의 전력거래를 수행해왔고 예보기술에 대한 연구들이 활발히 진행되었기에 본 연구에서는 해외의 문헌들을 조사하여 현재의 예보기술 수준을 파악하고자 하였으며, 시간에 따른 예보오차를 파악하여 전력거래시장에 반영할 수 있는 정보를 제시하고자 하였다. 조사결과는 아래와 같이 요약할 수 있다.

- (1) 최근의 많은 연구들은 통계적 기법으로 일사량이나 PV 발전량 예보연구를 수행하고 있으며, ANN기법이 모든 시간영역대에서 가장 많이 사용되는 기법으로 조사되었다. ANN의 결과는 은닉층의 개수와 구성에 따라 변화가 발생하지만 대부분 2-4개의 은닉층으로 구성하여 예보를 수행하였다.
- (2) 예보시간이 길어지면 예보오차는 증가하였다. 시간 내 예보와 하루 내 예보의 경계지(1-3 시간)에서 예보오차는 가장 크게 증가하였고, 그 이후로는 예보오차의 증가폭이 줄어들었다. 일사량의 24시간과 48시간 예보는 각각 평균 31.5%와 35%의 예보오차를 보였으며, 평균을 기준으로 예보자료의 신뢰도 평가가 가능할 것으로 사료된다.
- (3) DNI 예보는 구름에 민감한 영향을 받기 때문에 GHI 예보보다 큰 오차를 가지는 것으로 조사되었다. 우기의 예보오차가 건기보다 큰 이유도 구름이나 강수 시 지면의 일사량예보에 어려움이 있기 때문인 것으로 사료된다.
- (4) 조사된 문헌들에 따르면 발전량 예보는 일사량 예보보다 평균적으로 낮은 오차를 보인다. 일사량 예보의 경우 PV 플랜트의 발전량을 산정하기 위해선 추가적인 전기모델 연산이 필요하며, 그에 따른 오차발생을 고려한다면, PV 발전량 예보가 전력거래시장에 더 유용한 방안이 될 수 있을 것으로 사료된다.
- (5) 하이브리드예보는 대부분 NWP 예보와 통계기법을 혼합하거나 각기 다른 통계기법들을 혼합하는 방법들이 제안되었으며, NWP와 통계기법의 혼합은 NWP 예보오차를 뚜렷이 줄일 수 있는 방안으로 사료된다.

후기

본 연구는 한국에너지기술연구원 주요사업(B9-2414)과 한국특허전략개발원 정부 R&D 특허전략 지원사업(중대형 R&D 전략지원)의 지원으로 수행되었습니다.

REFERENCES

1. Kim, S. J., Kim, S. W., and Yoon, Y. T., Master Optimization Process Based on Neural Net Works Ensemble for 24-h Solar Irradiance Forecast, Conference of Information and Control Systems, pp. 209-211, 2017.
2. Kim, M. J., Lee, D. K., and Kim, G. S., Analysis to reduce PV Generation Output Variation using Energy Storage System, Power Electronics Conference, pp. 113-114, 2013.
3. Moon, S. I., Economic Assessment of Grid-Connected Energy Storage System, Journal of Electrical World Monthly Magazine, pp. 44-48, 2013.
4. Park, C. K. and Kim, Y. S., Feasibility Study of P2P Power Trading in Korea, Korea Energy Economics Institute, Research Report 15-10, pp. 1-85, 2016
5. Spot, E. P. E. X., EPEX Spot. EPEX Spot, Paris, France, accessed Dec, 18, 2017.
6. Cornaro, C., Pierro, M., and Bucci, F., Master Optimization Process Based on Neural Net Works Ensemble for 24-h Solar Irradiance Forecast, Solar Energy, Vol. 111, pp. 297-312, 2015.

7. Amrouche, B. and Le Pivert, X., Artificial Neural Network Based Daily Local Forecasting for Global Solar Radiation, *Applied Energy*, Vol. 130, pp. 333-341, 2014.
8. Olatomiwa, L., Mekhilef, S., Shamshirband, S., Mohammadi, K., Petković, D., and Sudheer, C., A Support Vector Machine-firefly Algorithm-based Model for Global Solar Radiation Prediction, *Solar Energy*, Vol. 115, pp. 632-644, 2015.
9. Box, G. E., Jenkins, G. M., Reinsel, G. C., and Ljung, G. M., *Time Series Analysis: Forecasting and Control*, John Wiley & Sons, 2015.
10. Diagne, M., David, M., Lauret, P., Boland, J., and Schmutz, N., Review of Solar Irradiance Forecasting Methods and A Proposition for Small-scale Insular Grids, *Renewable and Sustainable Energy Reviews*, Vol. 27, pp. 65-76, 2013.
11. Monteiro, C., Santos, T., Fernandez-Jimenez, L. A., Ramirez-Rosado, I. J., and Terreros-Olarte, M. S., Short-term Power Forecasting Model for Photovoltaic Plants Based on Historical Similarity, *Energies*, Vol. 6, pp. 2624-2643, 2013.
12. Tuohy, A., Zack, J., Haupt, S. E., Sharp, J., Ahlstrom, M., Dise, S., Gritmit, E., Mohrlen, M., Lange, M., Casado, M. G., Black, J., Marquis, M., and Collier, C., Solar Forecasting: Methods, Challenges, and Performance, *IEEE Power and Energy Magazine*, Vol. 13, pp. 50-59, 2015.
13. Ren, Y., Suganthan, P., and Srikanth, N., Ensemble Methods for Wind and Solar Power Forecasting—a State-of-the-art Review, *Renewable and Sustainable Energy Reviews*, Vol. 50, pp. 82-91, 2015.
14. Azimi, R., Ghayekhloo, M., and Ghofrani, M., A Hybrid Method Based on A New Clustering Technique and Multilayer Perceptron Neural Networks for Hourly Solar Radiation Forecasting, *Energy Conversion and Management*, Vol. 118, pp. 331-344, 2016.
15. Sharma, V., Yang, D., Walsh, W., and Reindl, T., Short Term Solar Irradiance Forecasting Using a Mixed Wavelet Neural Network, *Renewable Energy*, Vol. 90, pp. 481-492, 2016.
16. Alonso-Montesinos, J., Batlles, F. J., and Portillo, C., Solar Irradiance Forecasting at One-minute Intervals for Different sky Conditions Using sky Camera Images, *Energy Conversion and Management*, Vol. 105, pp. 1166-1177, 2015.
17. Aguiar, L. M., Pereira, B., David, M., Díaz, F., and Lauret, P. Use of Satellite Data to Improve Solar Radiation Forecasting with Bayesian Artificial Neural Networks, *Solar Energy*, Vol. 122, pp. 1309-1324, 2015.
18. Notton, G., Voyant, C., Fouilloy, A., Duchaud, J. L., and Nivet, M. L. Some Applications of ANN to Solar Radiation Estimation and Forecasting for Energy Applications, *Applied Sciences*, Vol. 9, No. 1, p. 209, 2019.
19. Gutierrez-Corea, F. V., Manso-Callejo, M. A., Moreno-Regidor, M. P., and Manrique-Sancho, M. T. Forecasting Short-term Solar Irradiance Based on Artificial Neural Networks and Data From Neighboring Meteorological Stations, *Solar Energy*, Vol. 134, pp. 119-131, 2016.
20. Dong, Z., Yang, D., Reindl, T., and Walsh, W. M. A Novel Hybrid Approach Based on Self-organizing Maps, Support Vector Regression and Particle Swarm Optimization to Forecast Solar Irradiance, *Energy*, Vol. 82, pp. 570-577, 2015.
21. de Paiva, G. M., Pimentel, S. P., Leva, S., and Mussetta, M. Intelligent Approach to Improve Genetic Programming Based Intra-Day Solar Forecasting Models, In *2018 IEEE Congress on Evolutionary Computation (CEC)*, pp. 1-8. IEEE, 2018.
22. Trapero, J. R., Kourentzes, N., and Martin, A. Short-term Solar Irradiation Forecasting Based on Dynamic Harmonic Regression, *Energy*, Vol. 84, 289-295, 2015.
23. Di Piazza, A., Di Piazza, M. C., and Vitale, G. Solar and Wind Forecasting by NARX Neural Networks, *Renewable Energy and Environmental Sustainability*, Vol. 1, p. 39, 2016.

24. Lima, F. J., Martins, F. R., Pereira, E. B., Lorenz, E., and Heinemann, D. Forecast for Surface Solar Irradiance at the Brazilian Northeastern Region Using NWP Model and Artificial Neural Networks, *Renewable Energy*, Vol. 87, pp. 807-818, 2016.
25. Agoua, X. G., Girard, R., and Kariniotakis, G. Short-term Spatio-temporal Forecasting of Photovoltaic Power Production, *IEEE Transactions on Sustainable Energy*, Vol. 9, No. 2, pp. 538-546, 2017.
26. De Giorgi, M. G., Congedo, P. M., and Malvoni, M. Photovoltaic Power Forecasting Using Statistical Methods: Impact of Weather Data, *IET Science, Measurement & Technology*, Vol. 8, No. 3, pp. 90-97, 2014.
27. Bouzerdoun, M., Mellit, A., and Pavan, A. M. A Hybrid Model (SARIMA – SVM) for Short-term Power Forecasting of a Small-scale Grid-connected Photovoltaic Plant, *Solar Energy*, Vol. 98, pp. 226-235, 2013.
28. Gandelli, A., Grimaccia, F., Leva, S., Mussetta, M., and Ogliari, E. Hybrid Model Analysis and Validation for PV Energy Production Forecasting, In 2014 International Joint Conference on Neural Networks (IJCNN), pp. 1957-1962. IEEE, July, 2014.
29. Antonanzas, J., Urraca, R., Aldama, A., Fernández-Jiménez, L. A., and Martínez-de-Pisón, F. J., Single and Blended Models for Day-Ahead Photovoltaic Power Forecasting, In International Conference on Hybrid Artificial Intelligence Systems, pp. 427-434, Springer, Cham., June, 2017.