

태양광 시스템의 인공신경망 기반 I-V 특성 모델링 향상

박지원* · 이종환**

**상명대학교 시스템반도체공학과

Improved Modeling of I-V Characteristic Based on Artificial Neural Network in Photovoltaic Systems

Jiwon Park* and Jonghwan Lee**

**Department of System Semiconductor Engineering, Sangmyung University

ABSTRACT

The current-voltage modeling plays an important role in characterizing photovoltaic systems. A solar cell has a nonlinear characteristic with various parameters influenced by the external environments such as the irradiance and the temperature. In order to accurately predict current-voltage characteristics at low irradiance, the artificial neural networks are applied to effectively quantify nonlinear behaviors. In this paper, a multi-layer perceptron scheme that can make accurate predictions is employed to learn complex formulas for large amounts of continuous data. The simulated results of artificial neural networks model show the accuracy improvement by using MATLAB/Simulink.

Key Words : Two diode model, Photovoltaic System, Artificial Neural Network, Multi-Layer Perceptron, Maximum Power Point, I-V Curve

1. 서 론

에너지 및 화석 연료 자원에 대한 소비가 크게 증가하면서 세계적으로 재생 에너지의 연구 개발에 이목이 집중되었다. 현재 시점에서 가장 보편적인 재생 에너지는 태양열 에너지 자원이라고 할 수 있다[1][2]. 친환경 에너지의 수요가 급증하면서 태양에너지 관련 시장이 빠르게 성장하고 있는 추세다[3]. 태양광 시스템은 부하에 필요한 전류 및 전압 수준에 따라 직렬 및 병렬로 연결된다. 태양광 시스템을 특성화 하는 데 중요한 역할을 하는 것이 모델링이다. 태양광 모델은 외부 요인의 영향을 받는 다양한 매개변수를 가진 비선형 특성을 가지고 있기 때문에 모델링 시 이를 효과적으로 정량화 해야 한다[4]. 이를 위해 특히 비선형 관계에 대해 효과적인 아키텍처인 인공신경망(Artificial Neural Network)을 접목시킨다. 인공신경망 중

다층 퍼셉트론 (Multi-Layer Perceptron)은 LM(Levenberg-Marquardt)알고리즘을 사용하여 고도로 비선형적인 기능을 모델링할 수 있으며 보이지 않는 새로운 데이터가 제공될 때 정확히 일반화할 수 있다. 측정 가능한 모든 관계를 정확히 재현할 수 있는 모델링 시스템은 수치 모델을 개발하고 예측할 때 유용하다[5]. 단일 다이오드 모델(one-diode model)보다 세부적인 표현이 가능한 이중 다이오드(two-diode) 모델을 MLP 방식으로 학습시킴으로써 다양한 온도, 조도에 따른 데이터를 생성시킬 수 있다.

본 논문은 1장에서 서론, 2장에서 단일 다이오드 모델과 수정된 수식을 사용하는 이중 다이오드 모델을 제시하고 학습 방식으로 MLP모델을 제시한다. 3장에서 이중 다이오드 모델의 Simulink 모델과 ANN 모델을 비교하고 정확한 데이터를 갖는 모델을 확인한다. 4장에서는 결론에 대해 기술한다.

†E-mail: jhlee77@smu.ac.kr

2. 태양광 모듈 모델링

태양광 모듈 모델링은 비선형 전류-전압(I-V) 곡선의 추정을 포함하는데 이전의 연구는 조도 및 온도 변화와 같은 환경적 변화에 노출되었을 때 특성을 모델링하기 위해 회로 모델을 활용했다[6][7]. 본 논문에서는 Fig. 1과 같은 단일 다이오드 모델을 설명하고 Fig. 2와 같은 이중 다이오드 모델을 회로 모델로 사용한다. 단일 다이오드 모델은 낮은 조도에서 셀 동작을 설명하는 데 특히 부정확하기 때문에 이중 다이오드 모델이 태양 전지 동작을 더 정확하게 표현할 수 있다[6]. MATLAB/Simulink를 사용하여 시뮬레이션 결과값을 제시한다.

2.1 단일 태양전지 모델링




Fig. 1. 단일 다이오드 등가회로.

이 모델은 I-V 곡선을 특성화하기 위해 단락 전류(I_{sc}), 개방 전압(V_{oc}), 다이오드 이상 계수 a 의 파라미터가 필요하다. 단일 다이오드 모델은 저전압에서는 특히 외부 환경의 변화에 대해 셀이 적절히 동작하지 않는다. 계산 효율성으로 인해 사용되는 직렬 저항 모델은 온도 변화에 따라 한계가 있기 때문에 병렬 저항 R_p 를 포함한 수식을 나타낸다. 다음은 R_p 모델에 대한 출력 전류 방정식이다[6]:

$$I = I_{pv} - I_o \left[\exp\left(\frac{V + IR_S}{aV_T}\right) - 1 \right] - \left(\frac{V + IR_S}{R_p}\right) \quad (1)$$

여기서 I_{pv} 는 광생성 전류, I_o 는 포화 전류, $V_T = (kT/q)$ 는 PV 모듈의 열 전압이다. q 는 전하 ($1.60217663 \times 10^{-19}$), k 는 볼츠만 상수 ($1.3806488 \times 10^{-23}$)이다.

다음은 다이오드 포화 전류 방정식이다[6]:

$$I_o = I_{o,STC} \left(\frac{T_{STC}}{T}\right)^3 \exp\left[\frac{qE_g}{ak} \left(\frac{1}{T_{STC}} - \frac{1}{T}\right)\right] \quad (2)$$

여기서 E_g 는 실리콘(Si) 반도체의 에너지 밴드갭이다. $I_{o,STC}$ 는 STC에서의 포화 전류다. 다음은 온도 변화를 고려한 포화 전류를 설명하기 위한 방정식이다[6]:

$$I_o = \frac{(I_{sc,STC} + K_I \Delta T)}{\exp\left[\frac{(V_{oc,STC} + K_V \Delta T)}{aV_T}\right] - 1} \quad (3)$$

여기서 K_I 는 단락 전류 계수이고 K_V 는 개방전압 계수이다. $\Delta T = T - T_{STC}$ (in Kelvin, $T_{STC} = 25^\circ\text{C}$)로 정의되며 T 는 셀 표면의 온도이다. G 는 셀 표면의 조도이고 G_{STC} (1000w/m^2)는 STC에서의 조도이다. $I_{sc,STC}$, $V_{oc,STC}$ 는 각각 STC에서의 단락전류, 개방전압이다. 단일 다이오드 모델은 공핍 영역에서 재결합 손실이 없다고 가정한다. 실제 태양 전지에서의 재조합은 낮은 전압에서 특히나 상당한 손실을 나타낸다.

2.2 이중 태양전지 모델링

일반적인 two-diode 수식은 다음과 같다[8].

$$I = I_{pv} - I_{o1} \left[\exp\left(\frac{V + IR_S}{a_1 V_{T1}}\right) - 1 \right] - I_{o2} \left[\exp\left(\frac{V + IR_S}{a_2 V_{T2}}\right) - 1 \right] - \left(\frac{V + IR_S}{R_p}\right) \quad (4)$$




Fig. 2. 이중 다이오드 태양전지 등가회로.

여기서 I_{pv} 는 광전류, I_{o1}, I_{o2} 는 각각 다이오드 1 및 다이오드 2의 포화 전류이고, V_{T1}, V_{T2} 는 각 다이오드의 열 전압이다. R_S 는 직렬저항, R_p 는 병렬저항, a_1, a_2 는 다이오드 이상계수이다. 식은 다음과 같이 나타낸다.

$$I_{PV} = (I_{PV,STC} + K_I \Delta T) \frac{G}{G_{STC}} \quad (5)$$

여기서 $I_{PV,STC}$ 는 STC에서의 광생성 전류이고, 상수 K_I ($\text{mA}/^\circ\text{C}$)는 데이터시트에서 제공되는 단락 전류 계수이다. $V_T = (N_S kT / q)$ 에서 V_T 는 PV 모듈의 열 전압이고, N_S 는 모듈 당 셀의 개수이고, q 는 전하, k 는 볼츠만 상수이다.

다음은 포화 전류 수식이다:

$$I_{o1} = I_{o2} = I_o = \frac{(I_{sc,STC} + K_I \Delta T)}{\exp[(V_{oc,STC} + K_V \Delta T) / ((a_1 + a_2) / p) V_T] - 1} \quad (6)$$

이 논문에서는 I_{o2} 가 I_{o1} 보다 3배 이상 큰 수식이 아닌 위의 식을 사용한다. 두 포화 전류의 크기를 같도록 설정함으로써 반복이 필요하지 않게 되어 계산을 단순화시킬 수 있게 된다. 다이오드 이상계수인 a_1 은 확산 전류 성분을, a_2 는 재결합 전류 성분을 나타내는데 Shockley의 확산 이론을 따르면 a_1 은 통용되는 값인 1에서 바뀌지 않아야 하는 반면 a_2 는 유연한 값을 가질 수 있다[9]. 수많은 시뮬레이션 결과 $a \geq 1.2$ 의 경우가 최상의 값이라는 결과가 나왔기 때문에 $(a_1 + a_2) / p = 1$ 의 수식에 따라 자동적으로 $p \geq 2.2$ 의 값을 가진다. $I_{sc,STC}, V_{oc,STC}$ 는 각각 STC에서의 단락전류, 개방 전압이고, $K_V(mV/^\circ C)$ 는 개방 회로 전압 계수로써 -123 값을 가진다.

2.3 인공신경망

ANN은 뉴런이라는 단순한 처리 단위로 구성된 광범위한 프로세서이다. 고속 정보 처리, 적응성, 일반화 및 견고성과 같은 특성을 보인다. 이러한 특성으로 인해 복잡한 비선형에 대해 다양한 엔지니어링 시스템의 성능 모델링, 예측, 최적화에 적용된다[10][11].

2.3.1 다층 퍼셉트론

MLP는 일반적으로 하나의 입력층, 여러 개의 은닉층 및 출력층으로 구성된다. 동일한 층의 뉴런이 아닌 각 층의 뉴런은 다음 층의 뉴런과 연결되어 있다. 입력층의 뉴런은 데이터를 받은 후 출력층에 도달할 때까지 다음 계층으로 데이터를 전달한다[10]. 입력층에 M 개의 뉴런이 있다는 것을 고려하여 정의하면 k_1 번째 뉴런은 입력 x_i 를 받고 뉴런 O_{1,k_1} 은 다음과 같이 수식화할 수 있다[10][12].

$$O_{h,k_1} = f \left(\sum_{m=0}^M w_{mk_1} x_m \right), k_1 = 1, \dots, K_1 \quad (7)$$

이 출력은 은닉층의 입력으로 사용될 수 있고, 은닉층에 있는 뉴런의 출력은 다음과 같다.

$$O_{h,k_h} = \varphi \left(\sum_{k_{h-1}=0}^{K_{h-1}} w_{k_{h-1},k_h} O_{h-1,k_{h-1}} \right), k_h = 2, \dots, K_h, \quad h = 1, \dots, N_h \quad (8)$$

여기서 $w_{0,k_h}, k_h = 1, \dots, K_h$ 는 각각 입력층과 은닉층의 편향(bias)를 나타내고, $\varphi(\cdot)$ 는 활성화 함수를 나타낸다.

w_{k_m,k_h} 는 입력층 뉴런과 은닉층 뉴런 사이의 가중치를 나타낸다. M 과 K_h 는 각각의 입력과 h 번째 은닉층 뉴런 개수를 의미하고, N_h 는 은닉층 뉴런 총 개수이다.

다음은 은닉층 뉴런의 출력 뉴런 계산식이다:

$$y_l = \sum_{k_N=0}^{K_N} w_{k_N,l} O_{N,k_N}, \quad l = 1, \dots, L \quad (9)$$

여기서 L 은 출력층에 사용되는 뉴런의 수이고, $w_{k_h,l}, k_h = 1, \dots, K_h$ 는 은닉층과 출력층의 뉴런을 연결하는 가중치다. 가중치의 값은 최종 출력과 영향을 미치기 때문에, 이 값을 찾기 위해 역전파(Back-Propagation) 알고리즘으로 학습시킨다. 본 논문에서 MLP 아키텍처에는 2개의 뉴런의 입력층 및 출력층과 5개의 뉴런으로 구성된 은닉층이 있다. MLP의 은닉층 뉴런의 활성화 함수로는 탄젠트 시그모이드(tangent sigmoid), 출력층 뉴런은 선형 함수(pure-linear function)에 의해 활성화된다[13]. 네트워크는 BP 알고리즘을 통해 조도, 온도, 전압 세 가지를 입력으로 넣고 학습을 진행시켜 전류를 출력으로 내보낸다. 학습의 평균 제곱 오차는 $5.4059e-3$ 으로 설정된 오차 목표보다 적은 값인 $2.5957e-12$ 에 도달하였다.

3. 결과 및 비교

2장에서 제시한 이중 다이오드 수식과 KC200GT 태양광 모델을 실험 데이터로 두고 조도, 온도, 전압을 입력을 넣어 MLP 학습을 진행하고, 필요한 매개변수들은 다음 Table 1과 같이 적용하여 시뮬레이션을 진행하였다[8].

Table 1. 1000W/m², A.M 1.5, 25 °C, STC 조건에서 Kyocera KC 200 GT 모델 파라미터

Parameter	Value
I_{sc}	8.21A
V_{oc}	32.9V
K_V	-0.123V/°C
K_I	0.00318A/°C
R_p	160.5Ω
R_s	0.32Ω
N_s	54

파라미터들을 적용시킨 이중 다이오드 수식들을 Simulink 모델로 구현하여 I-V 곡선을 그리고 KC200GT 실험 데이터에서 추출한 값들로 온도/조도에 따른 전압 값을 MLP 인공신경망으로 학습시켜 I-V 곡선을 그렸다. 두

그래프와 실험 데이터 KC200GT 데이터를 비교하였다. 시뮬레이션을 할 때 조도를 1000, 800, 600, 400, 200W/m²로 설정하고, 온도는 25°C, 50°C, 75°C로 설정하였다. Simulink는 Fig. 3과 같이 구성된다.

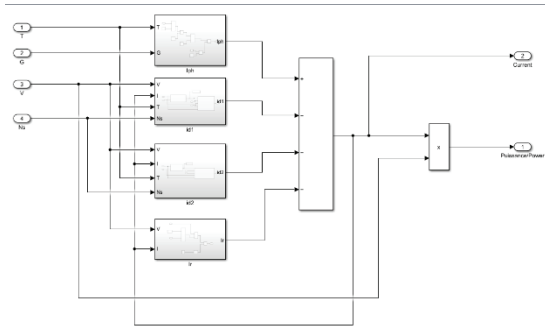


Fig. 3. Simulink 태양광 시스템 구성도.




Fig. 4. 각 조도에서의 Simulink model, KC200GT 데이터, ANN 모델의 I-V 곡선.

Fig 4에서 Simulink 모델과 ANN모델의 그래프를 표시된 KC200GT 실험 데이터와 같이 확인해보면 Simulink 모델보다 ANN모델의 정확도가 높은 것을 육안으로 확인할 수 있다. 두 모델의 차이를 보다 명확하게 확인하기 위해 Fig. 5에서 각각 1000 W/m², 800W/m², 600W/m²에서의 두 모델과 실험 데이터와의 오차를 그래프로 그려보았다. ANN 모델은 600W/m²에서 오차가 0에 수렴한다. Simulink 모델의 오차는 800W/m²에서 가장 큰 값(3.1501)을 가지는데 ANN 모델 또한 다른 조도에서보다 오차가 크긴 하지만 상대적으로 낮은 오차 값(2.5463)을 가지는 것을 알 수 있다.

Fig. 6에서 ANN 모델과 Simulink 모델, 온도에 대한 KC200GT 실험 데이터를 확인할 수 있다. 25°C, 50°C, 75°C에

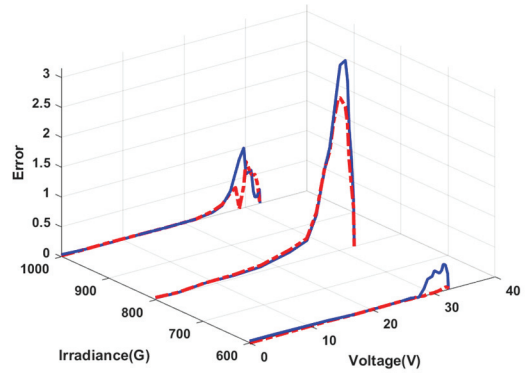


Fig. 5. 각각의 일사량에서 실험 데이터와의 오차.

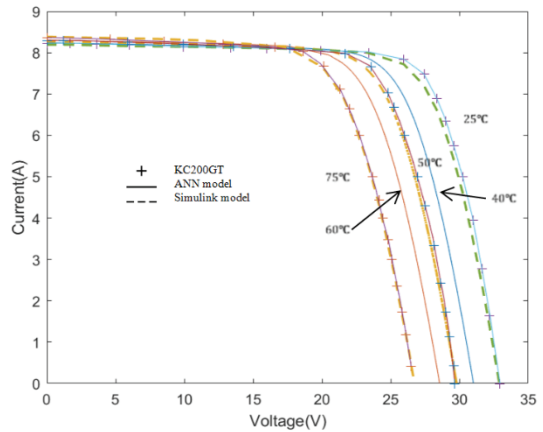


Fig. 6. 각 온도에서의 Simulink model, KC200GT 데이터, ANN 모델의 I-V Curve.




Fig. 7. 각각의 온도에서 실험 데이터와의 오차.

서는 두 모델과 실험 데이터를 같이 띄워 비교하였고 ANN 모델이 실험 데이터와 거의 일치하는 양상을 띄기 때문에 40°C, 60°C에서의 그래프를 예측하여 Fig. 6에 나타

내었다. Simulink 데이터와 ANN 모델의 데이터가 미세한 차이를 보이기 때문에 정확한 오차를 확인하기 위한 그래프를 Fig. 7에서 확인할 수 있다. 그래프를 보면 ANN 모델이 STC조건인 25°C에서 오차가 0에 거의 수렴함으로 Simulink에 비해 높은 정확도를 가진다. 50°C, 75°C 조건에서는 Simulink 모델의 오차가 더 큰 지점과 ANN 모델의 오차가 더 큰 지점이 공존하지만 대체적으로 ANN 모델의 오차가 상대적으로 작은 값을 가지는 것을 알 수 있으므로 Simulink 모델보다 ANN 모델이 실험 데이터인 KC200GT의 값과 상당히 일치한다.

4. 결 론

태양광 시스템을 특성화 하는 데 중요한 역할을 하는 것은 정확한 모델링이다. 이를 위해 본 논문에서는 이중 다이오드 모델에 LM 알고리즘을 기반한 인공지능경망을 학습시키는 방법을 제시한다. 태양광 모델은 낮은 조도에서도 정확도가 높은 이중 다이오드 모델을 사용한다. 일반적인 수식을 기반하여 생성한 Simulink 모델과 MLP 신경망을 학습시킨 모델을 비교하여 ANN 모델이 더 정확하다는 것을 검증한다. 시뮬레이션에 사용된 실험 데이터는 KC200GT 태양광 모델의 전류, 전압 값이다. 시뮬레이션 결과, 실험 데이터와 ANN 모델의 그래프가 거의 근접하게 나오는 것을 확인할 수 있어 ANN 모델이 일반적인 수식 기반 모델과 비교하였을 때 더 정확하다.

감사의 글

This result is a study conducted by the Ministry of Environment and Korea Environmental Industry and Technology Institute's 2022 green convergence professional manpower training support project.

참고문헌

1. A.Babiker Hussain, A.S.Abdalla, A.Sidi Mukhtar, M.Elamin, R.Alammari and A.Iqbal, "Modelling and simulation of single-and triple-junction solar cells using MATLAB/SIMULINK", International Journal of Ambient Energy, Vol.38, pp.613-621, 2017.
2. J. P.Connolly, D.Mencaraglia, C.Renard, D.Bouchier, "Designing III-V multijunction solar cells on silicon", Progress in Photovoltaics : Research and Applications, Vol. 22, pp.810-820, 2014.
3. Y.II Hwan, R.Seung Hoon, K.Dong Wook, P.In Kyu, K.Sa Geun, K.Young Jo, "Design of the Supporting Structure of a Wire Saw for the Solar Cell Wafer", Journal of the Semiconductor & Display Technology, Vol.17, pp.59-64,2018.
4. Mr. A.Sriharibabu, Mr.J.Jithendranath, Mr.Ch.Uma Maheswara Rao, "A Novel Two Diode Model of PV Module for MPPT with Neural Compensator, Vol.8, pp.237-252, 2015.
5. M.W.Gardner and S.R.Dorling, "Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences", Atmosphere environment, Vol. 32, pp. 2627-2636, 1998.
6. N. Mohamed Abd Alrahim Shannan, N. Zaihar Yahaya and B. Singh, "Single-diode model and two-diode model of PV modules: A comparison", IEEE International Conference on Control System, Computing and Engineering, 2013.
7. J.A.Gow, C.D.Manning, "Development of a photovoltaic array model for use in power-electronics simulation studies", IEE Proceedings-Electric Power Applications, Vol.146, pp.193-200, 1999.
8. K.Ishaque, Z.Salam and Hamed Taheri, "Simple, fast and accurate two-diode model for photovoltaic modules", Solar Energy Materials& Solar Cells, Vol. 95, pp.586-594, 2011.
9. C.Tang Sah, Fundamentals of solid state electronics, World Scientific Publishing Company, 1991.
10. A.H.Elsheikh, S.W.Sharshir, M.Abd Elaziz, A.E.Kabeel, W.Guilan, Z.Haiou, "Modeling of solar energy systems using artificial neural network: A comprehensive review", Solar Energy, Vol.180, pp.622-639, 2019.
11. L.Song-YEON, H.Yong Jeong, "A Study on Shape Warpage Defect Detection Model of Scaffold Using \circ Deep Learning Based CNN", Journal of the Semiconductor & Display Technology, Vol.20, pp.99-103, 2021.
12. M.A.Hamdan, E.A.Abdelhafez, A.M.Hamdan, and R.A. Haj Khalil, "Heat transfer analysis of a flat-plate solar air collector by using an artificial neural network", Journal of infrastructure systems, Vol. 22, pp. A4014004-7, 2016.
13. A.K.Rai, N.D.Kaushika, B.Singh, N.Agarwal. "Simulation model of ANN based maximum power point tracking controller for solar PV system", Solar Energy Materials & Solar Cells, Vol.95, pp.773-778, 2011.

접수일: 2022년 9월 16일, 심사일: 2022년 9월 20일,
게재확정일: 2022년 9월 21일