

적응적 뉴로-퍼지 모델을 이용한 태양광 발전량 예측 알고리즘 개발

Development of PV Power Prediction Algorithm using Adaptive Neuro-Fuzzy Model

이 대 중* · 이 중 필* · 이 창 성* · 임 재 윤** · 지 평 식†

(Dae-Jong Lee · Jong-Pil Lee · Chang-Sung Lee · Jae-Yoon Lim · Pyeong-Shik Ji)

Abstract - Solar energy will be an increasingly important part of power generation because of its ubiquity abundance, and sustainability. To manage effectively solar energy to power system, it is essential part In this paper, we develop the PV power prediction algorithm using adaptive neuro-fuzzy model considering various input factors such as temperature, solar irradiance, sunshine hours, and cloudiness. To evaluate performance of the proposed model according to input factors, we performed various experiments by using real data.

Key Words : PV power, Prediction model, ANFIS, Data selection

1. 서 론

화석 에너지의 고갈에 직면한 세계 각국은 화석 연료를 대체하기 위한 신재생 에너지 개발에 많은 투자를 하고 있다. 또한, 지구 온난화의 주범으로 꼽히는 온실 가스 배출량의무감축을 주요 골자로 한 교토의정서가 발효됨에 따라 온실가스 발생의 주범인 화석 에너지의 사용을 줄이기 위한 대책이 시급하다. 따라서 안전적이고 깨끗한 미래 에너지원의 확보는 경제적 측면은 물론 국가 안보 차원에서도 중요한 과제로 부각되고 있다.

전력망과 병렬 운전되는 계통 연계형 태양광 발전소의 발전량 예측모델은 전력계통을 운영하는데 매우 중요한 요소이다. 태양광 발전량의 예측 성능의 저하는 석탄 또는 복합화력 천연 가스발전소의 발전량의 변경을 요한다. 예를 들어, 예측 모델의 성능이 예측값보다 작으면, 기저부하 발전소들의 발전량이 증가하여야 하며, 이 때 재가동 비용과 시간이 많이 소비된다. 즉, 태양광 발전 예측기술은 예측 정확도에 비례하여 경제적 이익을 발생함으로 성능이 우수한 태양광 발전 모델의 개발은 매우 중요한 요소이다.

태양광 발전량은 일조시간, 일사량, 운량, 온도 등의 다양한 기후조건에 따라 달라진다고 보고되고 있다[1]. 기존 연구에 의하면, 일사량과 발전량이 비례하고 태양광 패널의 온도가 낮을수록 태양광 발전 효율이 높다고 연구되었다[2]. 또한, 태양 전지의 재료에 따라 태양광 발전 효율을 분석한 연구도 진행되었다[3]. 이외에도 온도와 바람을 고려한 태양

전지의 발전량 모델을 제안하고 성능을 평가한 연구도 수행되었다[4, 5].

태양광 발전량 예측을 위해 국내외적으로 다양한 알고리즘이 개발 및 적용되고 있다. 시뮬레이션 툴인 MATLAB을 이용하여 태양광 발전시스템의 동적 시스템을 분석한 연구 [6, 7]와 퍼지 모델을 이용하여 태양광 발전시스템의 고장진단을 수행한 연구[8], 확률 모델을 이용하여 태양광 발전시스템을 모델링 한 연구[9, 10] 등이 있다. 또한, 신경회로망 [11], 데이터 마이닝기법[12]을 이용하여 태양광 발전량 예측 모델을 개발한 연구도 진행되었다.

태양광 발전량 예측을 위해서 다양한 알고리즘이 이용되고 있다. 널리 사용되는 모델로는 다층 신경회로망을 들 수 있다. 그러나 다층 신경회로망은 학습 데이터와 검증 데이터 간에 상관성이 저하될 경우 과학습으로 인하여 검증 데이터의 성능이 저하될 단점이 있다. 이러한 문제점을 개선하기 위하여 퍼지 개념을 적용한 뉴로-퍼지 모델이 제안되었다. 따라서 본 논문에서는 다양한 입력인자에 따른 적응적 뉴로-퍼지모델의 성능을 평가하였다. 적용 모델로는 다른 모델에 비하여 성능이 우수한 적응적 뉴로-퍼지 모델을 기반으로 태양광 예측 모델을 개발하였다.

2. 제안된 단기 태양광 발전량 예측 알고리즘

본 논문에서는 그림 1에서 보는 바와 같이 적응적 뉴로-퍼지 모델을 이용하여 태양광 발전량 예측모델을 개발하였다. 적응적 뉴로-퍼지모델을 적용하기 위해서는 우선적으로 모델에 입력되는 입력인자를 선정하여야 한다. 본 논문에서는 온도, 일사량, 일조시간 및 운량에 따른 적응적 뉴로-퍼지모델 성능 평가를 위해 그림 1과 같이 데이터 선택과정을 수행한 후 선택된 입력데이터를 이용하여 모델의 학습을 수행하였다.

Jang에 의해 제안된 TSK 뉴로-퍼지 모델인 적응적 뉴로-퍼지모델(ANFIS: Adaptive Neuro-Fuzzy Inference System)에 대해 간략히 살펴보면 다음과 같다[13]. 먼저 아래와 같은 두 개의 TSK(Takagi-Sugeno-Kang) 형태의 퍼

† Corresponding Author : Dept. of Electrical Engineering
Korea National University of Transportation, Korea
E-mail : psji@ut.ac.kr

* Dept. of Electrical Engineering Korea National University of Transportation, Korea

** Dept. of Computer Electronics Daeduk College, Korea

접수일자 : 2015년 11월 7일

수정일자 : 2015년 11월 17일

최종완료 : 2015년 11월 20일

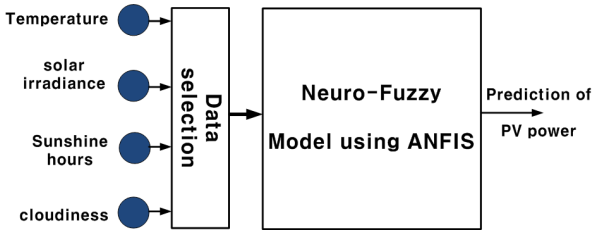


그림 1 ANFIS를 이용한 태양광 발전량 예측 알고리즘
Fig. 1 A PV power prediction algorithm using ANFIS

지 규칙을 갖는 추론시스템에 대해 생각해 보자.

$$R^1: \text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f_1 = p_1x + q_1y + r_1 \quad (1)$$

$$R^2: \text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } f_2 = p_2x + q_2y + r_2$$

여기서 x 와 y 는 입력이고, A_i, B_i 는 언어적 레벨이며 $\{p_i, q_i, r_i\}$ 는 결론부 파라미터이다.

식 (1)과 같은 규칙에 대해 뉴로-퍼지 시스템의 구조는 그림 3(a)와 같이 5개의 층으로 이루어진다. 그림 3(b)는 주어진 입력 $[x, y]$ 로부터 출력 f 을 추론해 내기 위한 퍼지 추론과정을 설명하고 있다.

점화력(firing strengths) 혹은 가중치 w_1 과 w_2 는 전제부에서 소속도의 곱으로 얻어지며 출력 f 는 가중 평균법에 의해 구해진다. 좀 더 자세히 설명하면, 출력 f 는 식 (2)와 식 (3)과 같이 표현되어질 수 있다.

$$f = \frac{w_1f_1 + w_2f_2}{w_1 + w_2} \quad (2)$$

$$f = \frac{u_{A_1}(x)u_{B_1}(y)(p_1x + q_1y + r_1) + u_{A_2}(x)u_{B_2}(y)(p_2x + q_2y + r_2)}{u_{A_1}(x)u_{B_1}(y) + u_{A_2}(x)u_{B_2}(y)} \quad (3)$$

TSK 퍼지 모델의 학습을 수행하기 위해 퍼지 모델을 체계적으로 경사벡터를 계산할 수 있는 적응 네트워크의 구조안으로 배치함으로서 ANFIS를 구축할 수 있다. 위와 같은 ANFIS에 대하여 각 층의 동작특성과 학습 절차는 다음과 같다.

Layer 1: 이 층에서 각 노드는 언어적인 레벨의 소속도를 발행하며 식 (4)와 같이 소속값을 출력으로 표현할 수 있다.

$$O_i^1 = u_{A_i}(x), O_{i+2}^1 = u_{B_i}(y), \quad i = 1, 2 \quad (4)$$

전제부 소속함수로 식 (5)와 같은 가우시안 소속함수를 선택하였다.

$$u_{A_i}(x) = \exp\left\{-\left(\frac{x - c_i}{a_i}\right)^2\right\} \quad (5)$$

여기서 $\{a_i, c_i\}$ 는 전제부 파라미터이며, a_i 는 소속함수의 폭이고 c_i 는 소속함수의 중심이다.

Layer 2: 이 층에서 각 노드는 Layer 1에서 구한 소속값을 규칙별로 곱한 가중치로 출력된다.

$$O_i^2 = w_i = u_{A_i}(x) \times u_{B_i}(y), \quad i = 1, 2 \quad (6)$$

Layer 3: 이 층에서 노드 i 는 모든 점화력의 합에 대한 i 번째 규칙의 점화력의 비를 계산한다. 즉, 식 (7)과 같이 w_i 에 대해 정규화 된 값을 출력한다.

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (7)$$

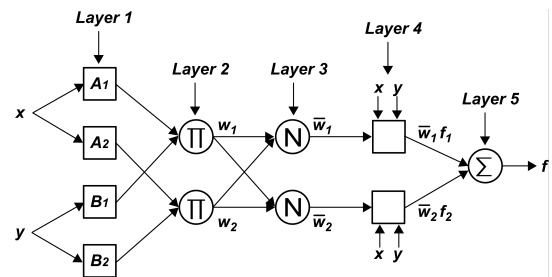
Layer 4: 이 층에서 노드 i 는 식 (8)과 같이 정규화 되어진 값과 결론부의 곱으로 출력을 낸다.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad i = 1, 2 \quad (8)$$


여기서 \bar{w}_i 는 Layer 3에서 얻어진 정규화 된 점화력(normalized firing strengths)이다.

Layer 5: 이층에서 가중 평균법에 의해 최종 출력을 구한다.

$$O_i^5 = y_i^* = \sum_{i=1}^2 \bar{w}_i f_i = \frac{\sum w_i f_i}{\sum w_i} \quad (9)$$



(a) ANFIS 구조



(b) 퍼지 추론

그림 2 ANFIS 추론 및 구조

Fig. 2 Inference and structure of ANFIS

3. 실험 및 결과

3.1 실험방법

그림 3에 나타난 태양광 시스템은 70[kW]의 계통연계형

으로 250[W] 모듈 280장과 36[kW]급 인버터 2대로 구성되어 있으며, 2012년에 설치되어 현재까지 가동 중에 있다. 그림 3의 설비로부터 2014년도 1월 1일에서 2015년 3월 31일 기간에 취득한 데이터 중에서 오류가 있는 데이터를 제외한 301개의 일별 데이터를 이용하여 적응적 뉴로-퍼지 모델의 태양광 발전량 예측 성능을 실험하였다.



그림 3 태양광 발전 시스템 전경
Fig. 3 View of the PV system

태양광 발전량은 일사량, 일조시간, 운량, 온도 등에 따라 발전량에 차이가 있다. 따라서 적응적 뉴로-퍼지 모델의 입력인자로 다양한 외부 인자들을 고려하여야 한다. 본 논문에서는 표 1에서 보는 바와 같이 입력 인자에 따라 model (1) ~ model (3)을 구성하고, 각각의 입력인자에 대한 성능을 평가하였다. 표 1에서 보는 바와 같이 model (1)은 입력인자로 태양광 발전량과 높은 상관성을 갖는 일사량, 일조시간을 고려하였다. model (2)는 입력인자로 일사량, 일조시간 외에 운량을 고려하였으며, model (3)은 일사량, 일조시간, 운량 및 최고기온을 고려하였다.

표 1 다양한 입력인자를 갖는 모델 구성

Table 1 Model configuration having various input factors

모델	입력 인자
model (1)	일사량, 일조시간
model (2)	일사량, 일조시간, 운량
model (3)	일사량, 일조시간, 운량, 최고기온

평가지표로는 아래 식의 절대평균 퍼센트 오차인 MAPE (Mean Absolute Percentage Error), MAE(Mean Absolute Error) 및 평균제곱오차인 RMSE(Root Means Square Error)를 고려하였다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Measured_i - Forecast_i)^2} \quad (10)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Measured_i - Forecast_i}{Measured_i} \right| \times 100 \quad (11)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Measured_i - Forecast_i| \quad (12)$$

3.2 발전량 예측결과

총 301개의 데이터 중에서 151개의 데이터를 이용하여 ANFIS 모델을 학습하였으며, 나머지 150개의 데이터를 이용하여 학습 모델을 검증하였다. ANFIS 모델의 전제부 클러스터의 수는 2개로 설정하였다. 표 2는 실험결과를 나타냈다. 표 2에서 보는 바와 같이 일사량, 일조시간을 입력인자로 사용한 model(1)은 검증 데이터에 대해서 RMSE는 12.62, MAPE는 8.18, MAE는 10.16으로 나타났다. 일사량, 일조시간 및 운량을 입력인자로 사용한 model(2)는 검증 데이터에 대해서 RMSE는 11.91, MAPE는 7.74, MAE는 9.44로 나타났다. 일사량, 일조시간, 운량 및 최고온도를 입력인자로 사용한 model(3)은 검증 데이터에 대해서 RMSE는 11.75, MAPE는 7.71, MAE는 9.21로 나타났다.

그림 4에서는 model (1)에 대한 학습 데이터와 검증 데이터에 대한 결과를 나타냈다. 그림 5와 그림 6에서는 model (2)와 model (3)에 대한 예측결과를 각각 나타냈다. model(3)의 성능이 model (1) 및 model (2)보다 우수함을 나타내기 위하여 그림 7(a)에서는 model (3)과 model (1)의 오차 분포도를 나타냈으며, 그림 7(b)에서는 model (3)과 model (2)의 오차 분포도를 나타냈다. 그림 7에서 보는 바와 같이 model (3)이 model (1) 및 model (2)에 비하여 오차가 적음을 확인할 수 있다. 따라서 태양광 발전 예측모델은 일사량, 일조시간, 운량 및 최고기온을 모두 이용하는 것이 효과적임을 알 수 있다.

4. 결 론

태양광 발전량은 일사량, 일조시간, 운량, 온도 등에 따라 발전량에 차이가 있다. 따라서 적응적 뉴로-퍼지 모델의 입력인자로 다양한 외부 인자들을 고려하여야 한다. 본 논문에서는 다양한 입력인자에 따른 적응적 뉴로-퍼지모델의 성능을 평가하였다. 입력인자로 일사량, 일조시간, 운량 및 최고기온을 고려하였다. 평가결과, 일사량, 일조시간, 운량 및 최고기온을 모두 고려한 적응적 뉴로-퍼지모델이 가장 효과적임을 확인하였다. 향후, 다양한 입력인자들에 대한 예측모델의 평가와 다양한 모델을 적용하여 모델별 성능을 평가하고자 한다.

표 2 입력 인자 선택에 따른 ANFIS 성능 결과


Table 2 Performance results according to selection of input factors of ANFIS

(a) 학습 데이터

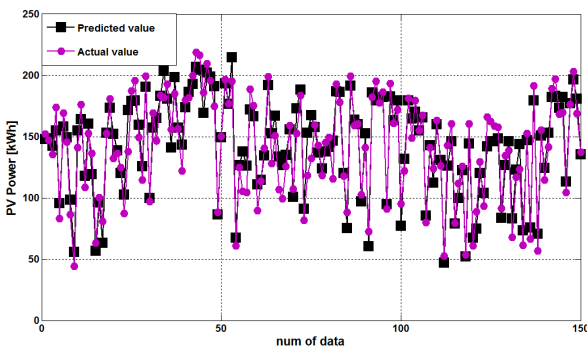
모델	RMSE	MAPE	MAE
model (1)	12.25	7.51	9.79
model (2)	12.17	7.58	9.83
model (3)	11.50	7.21	9.31

(b) 검증 데이터

모델	RMSE	MAPE	MAE
model (1)	12.62	8.18	10.16
model (2)	11.91	7.74	9.44
model (3)	11.75	7.71	9.21




(a) 학습 데이터




(b) 검증 데이터

그림 4 뉴로-퍼지 모델을 이용한 예측 결과 (model 1)
Fig. 4 Prediction result by ANFIS model (model 1)




(a) 학습 데이터




(b) 검증 데이터

그림 6 뉴로-퍼지 모델을 이용한 예측 결과 (model 3)
Fig. 6 Prediction result by ANFIS model (model 3)

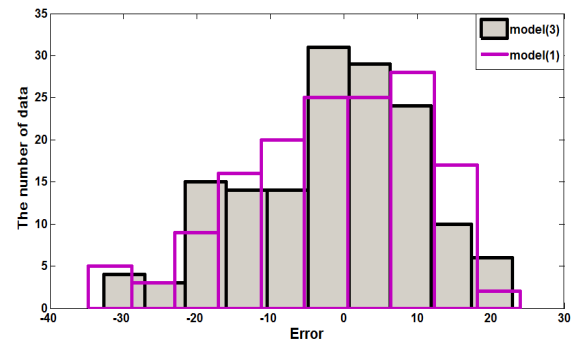


(a) 학습 데이터




(b) 검증 데이터

그림 5 뉴로-퍼지 모델을 이용한 예측 결과 (model 2)
Fig. 5 Prediction result by ANFIS model (model 2)



(a) model(3)과 model(1) 오차 분석



(b) model (3)과 model (2) 오차 분석

그림 7 모델간의 오차 분석
Fig. 7 Error analysis between model (3) and the other models

감사의 글

본 연구는 중소기업청에서 지원하는 2015년도 산학
연협력 기술개발사업(No.C0330870)의 연구수행으로
인한 결과물임을 밝힙니다.

References

[1] A. Molki, "Dust affects solar cell efficiency," Physics Education, Vol. 45, pp. 456-458, 2010.

[2] C. H. Henry, "Limiting efficiencies of ideal single and multiple energy gap terrestrial solar cells," J. App. Phys. Vol. 51, pp. 4494, 1980.

[3] J. Hedstrom, J. Kessler, M. Ruckh, K. O. Velthaus, Hans-Werner Schock, "ZnO/CdS/CuInSe2 thin-film Solar cells with improved performance," Applied Physics Letters, Vol. 62, No. 6, pp. 597-599, 1993.

[4] S. R. Kurtz, D. Myers, T. Townsend, C. Whitaker, A. Maish, R. Hulstrom, K. Emery, "Outdoor rating conditions for photovoltaic modules and systems," Solar Energy Materials & Solar Cells, Vol. 62, pp. 379-391, 2000.

[5] D. R. Myers, S. R. Kurtz, C. Whitaker, T. Townsend, "Preliminary Investigations of Outdoor Meteorological Broadband and Spectral Conditions for Evaluating Photovoltaic Modules and systems," Program and Proceedings : NCPV Program Review Meeting 2000, pp. 16-19, 2000.

[6] C. S. Chin, A. Babu, W. McBride, "Design, modeling and testing of a standalone single axis active solar tracker using MATLAB/Simulink," Renewable Energy, vol. 36, no. 11, pp. 3075-3090, 2011.

[7] Y. S. Heo, J. G. Kim, B. M. Kwon, H. J. Song, "Prediction and Analysis of Photovoltaic Modules's Output using MATLAB," Journal of academia-industrial technology, Vol. 11, No. 8, pp. 2963-2967, 2010.

[8] Modeling and fault diagnosis of a photovoltaic systems," Electrical Power Research, Vol. 78, No. 1, pp. 97-105, 2008.

[9] Hyun Cheol Cho, "A Study on Dynamic Modeling of Photovoltaic Power Generator Systems using Probability and Statistics Theories," The Transactions of the Korean Institute of Electrical Engineers, vol. 61, no. 7, pp. 1007-1013, 2012.

[10] H. C. Cho, Y. J. Jung, "Probabilistic Modeling of Photovoltaic Power Systems with Big Learning Data Sets," Journal of Korean Institute of Intelligent Systems, Vol. 23, No. 5, pp. 412-417, 2013.

[11] J. J. Song, Y. S. Jeong S. H. Lee, "Analysis of prediction model for solar power generation," Journal of Digital Convergence, Vol. 12, No. 3, pp. 243-248, 2014.

[12] Kim Kwang-Deuk, "The Development of the Short-Term Predict Model for Solar Power Generation," Journal of the Korean Solar Energy Society, Vol. 33, No. 6, pp. 62-69, 2013

[13] J. S. R. Jang, "ANFIS: Adaptive-network-based fuzzy inference system," IEEE Trans. on Systems, Man and Cybernetics, Vol. 23, No. 3, pp. 665-685, 1993.

저 자 소 개



이 대 종 (李大鍾)

1969년 2월 25일생. 1995년 충북대학교 전기공학과 졸업. 1997년 동 대학원 졸업(공학석사), 2002년 동 대학원 졸업(공학박사). 2006년~2008년 충북대학교 BK21 충북정보기술사업단 초빙조교수
E-mail : leebigbell@gmail.com



이 종 필 (李鍾弼)

1996년 충북대학교 공대 전기공학과 졸업, 1999년 동 대학교 대학원 전기공학과 졸업(공학석사), 2013년 동 대학원 전기공학과 졸업(공학박사), 현재 한국교통대학교 전기공학과 겸임교수
E-mail : jolious@ut.ac.kr



이 창 성 (李唱成)

2011년 한국교통대학교 전기공학과 석사과정 졸업(공학석사), 2015년 동대학원 박사과정 수료, 발송배전기술사, 현재 ㈜세명이앤씨 전무이사
E-mail : csd66@empas.com



임 재 윤 (林裁尹)

1961년 8월 4일생. 1984년 충북대 공대 전기공학과 졸업, 1986년 동 대학원 전기공학과 졸업(공학석사), 1995년 홍익대 대학원 전기공학과 졸업(공학박사), 1999~2000 Texas A&M Univ. 방문교수, 현재 대덕대학교교수
E-mail : jyylim@ddc.ac.kr



지 평 식 (池平植)

1994년 충북대학교 대학원 전기공학과 석사과정 졸업(공학석사), 1998년 동대학원 박사과정 졸업(공학박사), 현재 한국교통대학교 전기공학과 교수, 대한전기학회 충북지회장
E-mail : psji@ut.ac.kr