

전력 거래량 예측에서의 머신 러닝 성능 비교

최정곤*

Performance Comparison of Machine Learning in the Prediction for Amount of Power Market

Jeong-Gon Choi*

요약

머신 러닝은 인력을 대체함으로써 업무 효율성을 크게 높일 수 있다. 특히 4차 산업혁명 시대의 요청에 따라 인공지능을 포함한 머신 러닝의 중요성은 점점 커지고 있다. 본 논문은 MLP, RNN, LSTM, ANFIS 신경망 알고리즘을 이용하여, 월별 전력 거래량을 예측한다. 본 논문에서는 통계청에서 제공하는 월별 전력 거래량과 월별 전력 거래금액, 최종에너지 소비량, 자동차용 경유 가격에 대한 2001~2017년까지의 공공 데이터를 사용하였다. 본 논문은 제시하는 각각의 알고리즘들을 학습시키고, 알고리즘이 예측하는 시계열 그래프를 이용하여 예측 결과를 보여주며 RMSE를 이용하여 이들 중에서 가장 우수한 알고리즘을 제시한다.

ABSTRACT

Machine learning can greatly improve the efficiency of work by replacing people. In particular, the importance of machine learning is increasing according to the requests of fourth industrial revolution. This paper predicts monthly power transactions using MLP, RNN, LSTM, and ANFIS of neural network algorithms. Also, this paper used monthly electricity transactions for amount and money, final energy consumption, and diesel fuel prices for vehicle provided by the National Statistical Office, from 2001 to 2017. This paper learns each algorithm, and then shows predicted result by using time series. Moreover, this paper proposed most excellent algorithm among them by using RMSE.

키워드

Machine learning, Multi-perceptron, RNN, LSTM, ANFIS, Prediction, Power market
머신 러닝, 다중 퍼셉트론, 레귀 신경망, 중기 단기 기억, 퍼지추론 시스템 기반 적응 네트워크, 전력 거래량, 예측

1. 서론

인공지능은 인간이 수동적으로 해야 했던 일들을 최소화하거나 대체함으로써 업무 효율성을 크게 높인다. 이로 인해 상당한 노동력과 비용 절감 효과를 거둘 수 있기에 반드시 필요하다. 머신 러닝은 인력을 대체함으로써 업무 효율성을 크게 높일 수 있다. 특

히 4차 산업혁명 시대의 요청에 따라 인공지능을 포함한 머신 러닝의 중요성은 점점 커지고 있다. 인공지능을 이용하여 전력 거래량을 예측함으로써 해당 연도에 필요한 전력량을 산출할 수 있고 그에 대한 전력 발전량을 조절할 수 있기에 전력 거래량을 예측할 필요가 있다.

현재 다중 사이트를 고려한 머신 러닝 기반 태양광

*교신저자: 조선대학교 전기공학과

• 접수일 : 2019. 09. 16
• 수정완료일 : 2019. 09. 30
• 게재확정일 : 2019. 10. 15

• Received : Sep. 16, 2019, Revised : Sep. 30, 2019, Accepted : Oct. 15, 2019

• Corresponding Author : Jeong-Gon Choi
Chosun University, Electrical Engineering.
Email : chjgo@naver.com

발전량 예측 기술[1], 머신 러닝을 활용한 과학 논변 구성 요소 코딩 자동화 가능성 탐색 연구[2], 정규화 퍼지 시스템을 이용한 전력부하 예측[3], Short-term Electrical Load Forecasting Using Neuro-Fuzzy Model with Error Compensation[4], K-최근접 이웃을 이용한 모터의 고장진단[5], ANFIS 접근방식에 의한 미래 트렌드 충격 분석[6] 등 인공지능 예측 분야가 다양하게 진행되고 있다.

본 논문에서는 파이썬을 기반으로 텐서플로우를 이용하여 월별 전력 거래금액, 최종에너지 소비, 자동차용 경유 가격을 이용하여 월별 전력 거래량을 다층 퍼셉트론(: Multi Layer Perceptron, MLP), 재귀 신경망(: Recurrent Neural Network, RNN), 중기 단기 기억(: Long Short Time Memory, LSTM), 퍼지추론 시스템 기반 적응 네트워크(: Adaptive Network Based Fuzzy Inference System, ANFIS)로 예측을 수행하고 이들 기법 중 가장 우수한 기법을 판별한다.

II. 머신러닝 이론

2.1 MLP(Multi Layer Perceptron)

다층 퍼셉트론(MLP)은 그림1과 같이 구성된다.




그림 1. MLP 구성도
Fig. 1 MLP architecture

입력이 주어진 층을 입력층(input layer)이라 하는데, 주어진 입력을 다음 층으로 전달하는 역할을 한다. 여기에서 입력값들을 식(1)로 나타낸다.[7]

$$x = (x_1, x_2, \dots, x_d) \quad (1)$$

입력층의 노드는 첨자로 i 를 사용한다. 입력층에서 다음 층으로 연결되는 선의 가중치는 u_{ji} 로 나타낸다. 최종 출력을 계산하는 마지막 층을 출력층(output layer)이라 하는데, 여기에서는 출력값들을 식(2)로 나타낸다.

$$o = (o_1, o_2, \dots, o_m) \quad (2)$$

입력층과 출력층 사이에 있는 층은 은닉층(hidden layer)이라고 한다. 다층 퍼셉트론은 여러 개의 은닉층을 가질 수 있다. 본 논문에서는 편의상 은닉층이 두 개인 것을 대상으로 설명한다. 층간 가중치는 v_{kj} 로 나타낸다. 전형적인 다층 퍼셉트론에서는 인접한 층 사이에서만 연결선이 만들어진다. 다층 퍼셉트론은 (입력, 출력) 쌍의 학습 데이터를 사용하여 학습한다. 입력이 주어질 때 어떤 값이 출력되어야 하는지에 대한 정보를 사용하여 연결선의 가중치와 편차항을 결정한다. 출력층에는 입력에 대해 기대하는 출력값에 대한 정보가 있는 반면에, 은닉층에 대해서는 어떤 값이 나와야 하는지에 대한 정보가 없다. 중간에 있는 층에는 어떤 값이 나와야 하는지에 대한 정보가 없기 때문에 은닉층이라고 부른다.

2.2 RNN(Recurrent Neural Network)

RNN은 그림 2와 같이 구성된다.[8]




그림 2. RNN 구성도
Fig. 2 RNN architecture

RNN은 Neural Networks의 구조 중 하나로, 특히 앞뒤 순서가 존재하는 시계열 데이터에 대해 강력한 성능을 보여준다. RNN은 Neural Network 구조에 이전 시간 $(t-1)$ 의 은닉층의 출력(output)을 다음 시간 (t) 에 은닉층으로 다시 집어넣는 경로가 추가된 형태이다. 이 구조는 현재 시간 (t) 의 결과가 다음 시간 $(t+1)$ 에 영향을 미치고, 이는 다시 다음 시간 $(t+2)$ 에 영향을 미치는 과정이 끊임 없이 반복되는 형태이다.

x_i^t 는 시간 t 일 때 출력 i , a_j^t 와 b_j^t 는 각각 시간 t 일 때, unit j 에 대한 network input, activation(활성값)을 나타낸다고 가정하면, 히든 유닛에서 출력되는

활성값 b_i^t 은 식(3)과 같이 계산된다.

$$a_h^t = \sum_{i=1}^I w_{ih}x_i^t + \sum_{h'=1}^H w_{h'h}b_{h'}^{t-1} \quad (3)$$

2.3 LSTM(Long Short Time Memory)

LSTM은 그림 3과 같이 구성된다.[9]




그림 3. LSTM 구성도
Fig. 3 LSTM architecture

LSTM은 RNN에서 파생된 알고리즘으로 전체적인 그림은 RNN 알고리즘과 같다. 또한 RNN의 은닉층을 Input Gate, Output Gate, Forget Gate라는 세 가지 게이트로 구성된 Memory Block으로 대체한 구조이다.




그림 4. 게이트로 구성된 LSTM
Fig. 4 Gate configured LSTM

그림 4에서 $\sigma_1, \sigma_2, \sigma_3$ 은 각각 Forget Gate, Input Gate, Output Gate 이며 Input Gate에서 일어나는 연산은 식(4), 식(5)과 같다. (f, g, h 는 활성화 함수이다.)

$$a_I^t = \sum_{i=1}^I w_{iI}x_i^t + \sum_{h=1}^H w_{hI}b_h^{t-1} + \sum_{c=1}^C w_{cI}s_c^{t-1} \quad (4)$$

$$b_F^t = f(a_I^t) \quad (5)$$

Forget Gate에서 일어나는 연산은 식(5)과 같다.

$$a_F^t = \sum_{i=1}^I w_{iF}x_i^t + \sum_{h=1}^H w_{hF}b_h^{t-1} + \sum_{c=1}^C w_{cF}s_c^{t-1} \quad (6)$$

$$b_F^t = f(a_F^t) \quad (7)$$

그다음에, Input Gate와 Memory Block의 입구의 Output을 곱한 값에 Forget Gate의 Output과 $(t-1)$ 시간의 셀의 출력을 곱한 값을 더해서 t 시간의 셀의 출력 s_c^t 를 식(9)과 같이 표현한다.

$$a_c^t = \sum_{i=1}^I w_{ic}x_i^t + \sum_{h=1}^H w_{hc}b_h^{t-1} \quad (8)$$

$$s_c^t = b_F^t s_c^{t-1} + b_I^t g(a_c^t) \quad (9)$$

Output Gate에서 일어나는 연산은 식(10), 식(11)과 같다.

$$a_O^t = \sum_{i=1}^I w_{iO}x_i^t + \sum_{h=1}^H w_{hO}b_h^{t-1} + \sum_{c=1}^C w_{cO}s_c^t \quad (10)$$

$$b_O^t = f(a_O^t) \quad (11)$$

마지막으로, Memory Block의 셀의 출력인 Cell Output는 셀의 출력과 Output Gate의 출력을 곱해서 얻어진다.(이 값이 Memory Block(Hidden Layer h 의 Output이다.)

$$b_c^t = b_O^t h(s_c^t) \quad (12)$$

2.4 ANFIS(Adaptive Network Based Fuzzy Inference System)

ANFIS는 신경회로망과 퍼지이론이 결합된 형태로서 신경회로망의 구조와 학습능력을 이용하여 제어환경으로부터 얻은 입출력 정보로부터 소속함수와 제어 규칙을 제어 대상에 맞게 자동 조절하는 방식의 모형이다. 일반적으로 ANFIS의 퍼지 제어기 구성방법은 입력 변수 공간을 격자 형태로 분할하고, 분할된 공간마다 해당되는 결론부 규칙을 한 개씩 할당하여 퍼지 특성으로 표현한다. ANFIS를 기반으로 하는 분류 모형은 다섯 계층의 전방향 연결 신경망 구조로 되어 있고 이는 그림 5로 나타낼 수 있다.[10-12]




그림 5. ANFIS 구성도
Fig. 5 ANFIS architecture

각 노드 i 는 사각형의 노드로 표시되며 식 (13)과 같은 함수로 표현된다.

$$P_{1,i} = \rho A_i(x) \quad , \quad P_{1,i} = \rho B_{i-3}(y) \quad (13)$$

여기서 x 와 y 는 노드 i 로의 입력값이며 A_i 와 B_i 는 이 노드함수와 연관된 퍼지집합이다. 즉, $P_{1,i}$ 는 입력 x 와 y 가 각각 퍼지집합 A_i 와 B_i 에 소속되는 정도를 나타내는 함수이다. 일반적으로 $\rho A_i(x)$ 와 $\rho B_i(x)$ 는 최댓값과 최솟값을 각각 1과 0을 갖고 식 (14), 식 (15)와 같은 식으로 표현된다.

$$\rho A_i(x) = e^{-((x_i - c_i)/a_i)^2} \quad (14)$$

$$\rho B_{i-3}(y) = e^{-((y_i - c_i)/a_i)^2} \quad (15)$$

여기서 a_i 와 c_i 는 소속함수의 모수이다. 종형 함수의 각 모수 값이 달라지면 소속함수의 모양도 달라지며 학습과정을 통해 오차를 최소화하는 방향으로 모수 값을 조정하게 된다. 소속 함수의 모수는 퍼지규칙의 조건부에 나타나기 때문에 조건부 모수로 부른다.

원형으로 표시되는 2 계층의 노드들은 이전 계층에서 산출된 소속도를 입력받고 각 소속도를 곱하여 출력한다. 출력값은 퍼지 규칙의 적합도를 나타내며 식 (16)으로 표현된다.

$$P_{2,i} = w_i = \rho A_i(x) \cdot \rho B_{i-3}(y) \quad (16)$$

계층 3의 노드 i 는 i 번째 규칙의 적합도가 전체 규칙들의 적합도 합에 대해 차지하는 비중을 표현하게 되며 식 (17)과 같은 값을 출력한다.

$$P_{3,i} = \overline{w}_i = w_i / (w_1 + w_2 + \dots + w_9) \quad (17)$$

계층 4의 각 노드에서는 각 규칙 결론부의 출력함수에 표준화된 적합도를 곱하는 연산을 수행한다. 여기서 w_i 는 계층 3의 출력값이며 출력함수 모수인 p_i ,

q_i, r_i 는 결론부 모수라고 부른다. 이 모수 또한 학습 과정을 통해 오차를 최소화하도록 결정된다.

$$P_{4,i} = \overline{w}_i \cdot f_i = w_i \cdot (p_i x + q_i y + r_i) \quad (18)$$

계층 5은 단일노드이며 입력되는 모든 값을 합하여 출력하며 그 값은 연속형으로 표현된다.

$$P_{5,i} = \sum_i \overline{w}_i f_i = \sum_i w_i f_i / \sum_i w_i \quad (19)$$

III. 예측 및 성능 비교

3.1 적용 데이터

머신 러닝에 사용할 데이터는 통계청을 참고하였다. 2001~2017년까지 월별로 전력 거래량(GWh), 전력 거래금액(억 원), 생산확산지수(광공업), 최종에너지 소비량(1000TOE), 자동차용 경유 가격(원/L)을 사용하여 대략 1,000개의 데이터를 사용하였다.

그림 6, 그림 7, 그림 8, 그림 9은 월별 전력 거래량(GWh), 전력 거래금액(억 원), 최종에너지 소비량(1000TOE), 자동차용 경유 가격(원/L)를 나타낸다.




그림 6. 전력거래량의 시계열 그래프
Fig. 6 Time series of Amount of Power




그림 7. 전력 거래금액의 시계열 그래프
Fig. 7 Time series of power transaction amount




그림 8. 최종에너지 소비량의 시계열 그래프
Fig. 8 Time series of final energy consumption




그림 9. 자동차용 경유 가격의 시계열 그래프
Fig. 9 Time series of car diesel prices

3.2 적용 알고리즘

데이터는 각각 0-1 사이로 정규화를 시켰다. 적용 알고리즘은 훈련 데이터(Train data), 시험 데이터(Test data) 각각 70%, 30%로 각각 지정하여 예측을 하였다. 그래프에서 파랑색 그래프가 관측 데이터이고, 주황색 그래프가 알고리즘이 예측한 값이다.

MLP 알고리즘을 적용하여 그림 10으로 예측값과 관측 데이터를 비교하여 나타내었다.




그림 10. MLP 알고리즘을 적용한 예측 그래프와 전력 거래량 그래프(실선: 관측 데이터, 점선: 예측값)
Fig. 10 Power trade volume graph and prediction graph after applying MLP algorithm(solid line: Predicted value, dash line: observation value)

RNN 알고리즘을 적용하여 그림 11로 예측값과 관측 데이터를 비교하여 나타내었다.




그림 11. RNN 알고리즘을 적용한 예측 그래프와 전력 거래량 그래프(실선: 관측 데이터, 점선: 예측값)
Fig. 11 Power trade volume graph and prediction graph after applying RNN algorithm(solid line: Predicted value, dash line: observation value)

LSTM 알고리즘을 적용하여 그림 12로 예측값과 관측 데이터를 비교하여 나타내었다.




그림 12. LSTM 알고리즘을 적용한 예측 그래프와, 전력 거래량 그래프(실선: 관측 데이터, 점선: 예측값)
Fig. 12 Power trade volume graph and prediction graph after applying LSTM algorithm(solid line: Predicted value, dash line: observation value)

ANFIS 알고리즘을 적용하여 그림 13으로 예측값과 관측 데이터를 비교하여 나타내었다.




그림 13. ANFIS 알고리즘을 적용한 예측 그래프와, 전력 거래량 그래프(실선: 관측 데이터, 점선: 예측값)

Fig. 13 Power trade volume graph and prediction graph after applying ANFIS algorithm(solid line: Predicted value, dash line: observation value)

3.2 성능 비교

본 논문에서는 각 알고리즘에 대한 적합성 및 예측 정확도 비교 평가를 위해 평균 제곱 오차 제곱근 (: Root Mean Square Error, RMSE)을 이용하였다.[13] RMSE는 각 오차를 제곱값을 이용함으로써 큰 오차에 대한 가중치를 주어 모형의 정밀도를 측정하는 지표이며 식(20)과 같다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - o_i)^2} \quad (20)$$

여기서 n 은 자료의 수 t 는 관측 데이터, o 는 예측값이다.

파이썬에 기반한 텐서플로우를 이용하여 MLP, RNN, LSTM, ANFIS 알고리즘을 이용한 결과 예측 정확도를 표 1과 같이 얻었다.

표 1. 예측 결과
Table 1. Result of prediction

Algorithm	RMSE
MLP	7.39×10^{-2}
RNN	10.81×10^{-2}
LSTM	6.48×10^{-2}
ANFIS	8.08×10^{-2}

IV. 결론


본 논문에서는 여러 지도 학습 중에 MLP, RNN, LSTM, ANFIS 알고리즘을 이용하여 월별 전력 거래량을 예측한다. 이를 위해 통계청에 나와 있는 월별 전력 거래량과 월별 전력 거래금액, 월별 최종에너지 소비량, 월별 자동차용 경유 가격을 변수로 사용했다. 각 알고리즘의 정확도 비교 평가를 위해 평균 제곱 오차 제곱근(RMSE)를 사용했다. 비교 결과 LSTM 알고리즘이 정확도가 가장 높게 추정되었음을 확인할 수 있었다. 이는 데이터가 LSTM에 최적화되어 있기 때문이다.

References

- [1] C. Jung, R. Jang, D. Nyang, and K. Lee, "A Study of User Behavior Recognition-Based PIN Entry Using Machine Learning Technique," *Korea Information Processing Society review, computer and communication systems*, vol. 7, no. 2, 2018, pp. 127-136.
- [2] G. Lee, H. Ha, H. Hong, and H. Kim, "Exploratory Research on Automating the Analysis of Scientific Argumentation Using Machine Learning," *J. of the Korean Association for Science Education*, vol. 38, no. 2, 2018, pp. 219-234.
- [3] Y. Bang, C. Lee, and H. Park, "Electricity Load Forecasting by using a Normalized Fuzzy System," *J. of Fuzzy Logic and Intelligent Systems*, vol. 28, no. 1, Feb. 2018, pp. 57-64.
- [4] B. Wang, "Short-term Electrical Load Forecasting Using Neuro-Fuzzy Model with Error Compensation," *J. of Fuzzy Logic and Intelligent Systems*, vol. 9, no. 4, Dec. 2009, pp. 327-332.
- [5] Y. Bae and N. Kim, "Classification of Motor status using K-nearest neighbors," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 13, no. 6, Dec. 2018, pp. 1249-1256.
- [6] Y. Kim, G. Mun, and S. Choi, "Future Trend Impact Analysis Based on Adaptive Neuro-Fuzzy Inference System," *J. of The Korea*

- Institute of Electronic Communication Sciences*, vol. 10, no. 4, Apr. 2015, pp. 499-506.
- [7] H. Yoon, Y. Kim, K. Ha, and G. Kim "Application of groundwater-level prediction models using data-based learning algorithms to National Groundwater Monitoring Network data," *J. of Engineering Geology*, vol. 23, no. 2, June 2013, pp. 137-147.
- [8] A. Graves, *Supervised Sequence Labelling with Recurrent Neural Networks*. Heidelberg New York: Springer, 2012.
- [9] S. Kim, *Coding Chef's 3 Minute Deep Learning, Keras flavor*. seoul Korea: HanbitMedia, 2018.
- [10] J. R. Jang, "ANFIS: Adaptive-Neural-Network-Based-Fuzzy Inference System," *IEEE Transactions on systems, man, and cybernetics*, vol. 23, 1993, pp. 665-685.
- [11] J. Yi and C. Choi, "Flood Forecasting and Warning Using Neuro-Fuzzy Inference Technique," *J. of Korea Water Resources Association*, vol. 41, no. 3, 2008, pp.341-351.
- [12] K. Lee, H. Lee, and K. Oh, "Using fuzzy-neural network to predict hedge fund survival," *J. of the Korean Data & Information Science Society*, vol. 26, no. 6, 2015, pp. 1189-1198.
- [13] G. Lee, *Artificial Intelligence : from Turing test to Deep Learning*. seoul Korea: saengneung, 2018.

저자 소개



최정곤(Jeong-Gon Choi)

1996년 한양대학교 전기공학과
(공학사)

2013년 한양대학교대학원 전기공
학과 (공학석사)

1995년~2001년 한국전력공사

2001년~현재 한국전력거래소 정보기술처

※ 관심분야 : AI and Machine Learning, Policy
etc.

