

ANFIS 알고리즘을 이용한 지하수수위 예측

박귀만* · 배영철**

Groundwater Level Prediction Using ANFIS Algorithm

Gwi-Man Bak* · Young-Chul Bae**

요약

지진이 발생하기 전·후에 지하수 수위는 급격하게 변화되는 것으로 알려져 있으며 지진 예측을 위해 지하수 수위 변화를 이용한다. 본 연구는 지진을 예측에 사용하기 위해 ANFIS 알고리즘을 이용한 밀양시의 지하수수위를 예측한다. 이를 위해 본 논문에서는 경남 밀양시의 기상청의 강수량, 기온 데이터와 한국농어촌공사 농촌지하수관측망의 지하수수위 데이터가 사용되었다. 예측 측정을 위해 RMSE, MAPE 오차 계산 방법을 사용하였다. 예측 결과 수위가 자연적인 요인에 의해 주기적인 패턴은 예측이 되었으나 인위적인 요인 등 다른 변수에 의해 변동되는 지하수수위 변화값은 감지하지 못하였다. 이를 해결하기 위해서는 지하수수위를 인위적인 변수 등을 수치화하여 데이터화 하는 것과 지하수수위를 측정할 관측공의 정확한 위치에 따른 강수량과 기압 등이 필요하다.

ABSTRACT

It is well known that the ground water level changes rapidly before and after the earthquake, and the variation of ground water level prediction is used to predict the earthquake. In this paper, we predict the ground water level in Miryang City using ANFIS algorithm for earthquake prediction. For this purpose, this paper used precipitation and temperature acquired from National Weather Service and data of underground water level from Rural Groundwater Observation Network of Korea Rural Community Corporation which is installed in Miryang city, Gyeongsangnam-do. We measure the prediction accuracy using RMSE and MAPE calculation methods. As a result of the prediction, the periodic pattern was predicted by natural factors, but the change value of ground water level was changed by other variables such as artificial factors that was not detected. To solve this problem, it is necessary to digitize the ground water level by numerically quantifying artificial variables, and to measure the precipitation and pressure according to the exact location of the observation ball measuring the ground water level.

키워드

Long Term Short Term Memory, Under Ground Water Level, Root Mean Square Error, Absolute Percent Error
중기 단기 기억, 지하수 수위, 평균 제곱 오차 제곱근, 절대 백분율 오차 평균

1. 서론

최근 대규모의 자연재난들은 어느 정도 예측을 할

수 있으나 지진을 예측하는 것은 근본적으로 불가능한 일이다. 지진은 우리에게 천문학적인 피해를 줄 수 있다. 지진의 피해를 줄이기 위해서는 사전에 지진 전

*전남대학교 전기 및 반도체공학과(qkrrend@naver.com)

**교신저자 : 전남대학교 전기·전자통신·컴퓨터공학부

· 접수 일 : 2019. 10. 29

· 수정완료일 : 2019. 11. 21

· 게재확정일 : 2019. 12. 15

· Received : Oct. 29, 2019, Revised : Nov. 21, 2019, Accepted : Dec. 15, 2019

· Corresponding Author : Young-Chul Bae

Division of Electrical ·Electronic communication and Computer Eng. Chonnam National University,

Email : ycbae@chonnam.ac.kr

표 1. 지진 예측에서의 사용되는 변수
Table 1. Variables used in earthquake prediction

| Value | Summary | Data acquisition |
|--------------------------------|---|----------------------------|
| Single-layer displacement data | Estimate the magnitude of an earthquake by estimating the amount of single-layer moving displacement that can be measured by displacement | Difficult to estimate data |
| Radon radiation concentration | Earthquake prediction is possible due to the variation of radon in the atmosphere and groundwater. | Difficult to estimate data |
| <u>Groundwater level</u> | <u>Earthquake monitoring is possible by monitoring groundwater monitoring</u> | <u>Public data</u> |

조 현상을 파악하여 지진 발생 이전에 지진 경보를 발령하는 것이 최선의 방법으로 인식되고 있다. 따라서 지진 전조현상을 파악하여 지진 예측에 활용하고자 하는 노력이 진행 되고 있다.

표 1은 지진 예측에서 사용되는 대표적인 변수 값을 정리한다. 지진은 변위 측정이 가능한 단층 이동 변위량을 추정하여 지진 규모를 예측하는 방법[1], 라돈방사능 농도를 이용하는 방법[2], 지하수수위 변화를 이용하여 지진을 예측하는 방법[3-6]을 제시 하고 있다. 단층 이동 변위량을 추정하여 지진 규모를 예측하는 방법과 라돈방사능 농도를 이용하여 지진 규모를 예측하는 방법은 데이터를 취득함에 있어서 어려움이 있다. 하지만 지하수 수위 변화 데이터는 이전에 설치된 관측 기구에서 쉽게 데이터를 취득 할 수 있다. Robert D. Cicerone[7]은 지금까지의 연구를 통해 지하수 수위가 하강한 지진은 지진의 약 72%를 차지하고, 상승한 지진은 약 28% 정도 차지한다는 내용을 보고 하였다. 따라서 지진이 발생하기 전·후에 지하수 수위가 급격하게 변화되는 것을 알 수가 있다. 최근 다양한 종류의 머신러닝 예측의 성능비교, GRNN(GRNN; General regression neural network)을 이용한 동영상 움직임 예측 및 대역 분할 부호화에 관한 연구 등 인공지능을 이용한 다양한 예측 분야가 진행되고 있다[8-11]. 이를 이용해 본 논문은 지진을 예측하기 위해 딥러닝 알고리즘으로 지하수수위 변화를 예측한다. 이를 위해 경남 밀양시의 한국농어촌공사 농촌지하수관측망의 지하수수위 데이터와 기상청의 강수량, 기온 데이터를 이용하여 지하수수위를

Inference System) 알고리즘을 적용하여 예측하고, 시계열 그래프로 예측값과 관측값을 비교해 알고리즘을 제시한다.

II. 데이터와 알고리즘 예측 결과

2.1 데이터




그림 1. 지하수수위(a), 강수량(b), 기온(c)의 시계열 그래프

Fig. 1 Time series of precipitation(a), time series of temperature(b), time series of groundwater level(c)

그림 1은 2015년 01월부터 2017년 12월까지 경남 밀양시의 한국농어촌공사 농촌지하수 관측망의 지하수

표 2. 지하수가 영향을 받는 요인[12]
Table 2. Factors affected by groundwater[12]

| | Unconfined | Confined | Natural | Minimised | Shortlived | Diurnal | Seasonal | Longterm | Climatic influence |
|--|------------|----------|---------|-----------|------------|---------|----------|----------|--------------------|
| Ground water recharge | ○ | | ○ | | | | ○ | | ○ |
| Air entrapment | ○ | | ○ | | ○ | | | | ○ |
| Evapotranspiration and phreatophytic consumption | ○ | | ○ | | | ○ | | | ○ |
| Bank-storage effects | ○ | | ○ | | | | ○ | | ○ |
| Tidal effects | ○ | ○ | ○ | | | ○ | | | ○ |
| Atmospheric pressure effects | ○ | ○ | ○ | | | ○ | | | ○ |
| External loading of confined aquifers | | ○ | | ○ | ○ | | | | |
| Earthquakes | | ○ | ○ | | ○ | | | | |
| Groundwater pumping | ○ | ○ | | ○ | | | | ○ | |
| Deep-well injection | | ○ | | ○ | | | | ○ | |
| Artificial recharge | ○ | | | ○ | | | | ○ | |
| Agricultural activities | ○ | | | ○ | | | | ○ | ○ |
| Geotechnical drainage | ○ | | | ○ | | | | ○ | |

수위 데이터와 기상청의 강수량, 기온을 나타낸다. 표 2는 지하수 수위가 총 11가지의 영향을 받는다는 것을 나타낸다[12]. 그 중 기온과 강수량으로 groundwater recharge와 tidal effects를 대신 할 수 있다. 조력의 영향은 태양과 달의 위치에 따라 변화한다. 태양의 위치는 기온과 밀접하게 연관 되어있기 때문에 tidal effects는 기온으로 대체하였다. 본 연구는 지진을 예측하기 위한 것이므로 지진 데이터는 취득이 가능하나 변수로 사용하지 않았다. 이외 변수들은 자료화 할 수 없는 값들이거나 해당지역의 자료가 존재하지 않아 변수값으로 사용하지 않았다.




그림 2. ANFIS 구성도
Fig. 2 ANFIS architecture

2.2 ANFIS

ANFIS는 신경회로망과 퍼지망이 결합된 형태로서 신경회로망의 구조와 학습능력을 이용하여 제어환경으로부터 얻은 입력력 정보로부터 소속함수와 제어규칙을 제어 대상에 맞게 자동 조절하는 방식의 알고리즘이다[13]. 일반적으로 ANFIS의 구성방법은 입력 변수 공간을 규칙에 따라 반복적으로 분할하고, 분할된 공간마다 해당되는 결론부 규칙을 한 개씩 할당하여 퍼지 특성으로 표현한다. ANFIS를 기반으로 하는 분류모형은 다섯 계층(layer)의 전방향 연결 신경망 구조로 되어 있고 이는 그림 2로 나타낼 수 있다.

각 노드 i 는 사각형의 노드로 표시되며 식(1)과 같은 함수로 표현된다.

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

여기서 x, y 는 노드 i 로의 입력값이며 A_i 와 B_i 는 이 노드와 연관 되어있는 퍼지집합이다. 즉, 입력 x 와 y 가 각각 퍼지집합 A_i 와 B_i 에 소속되는 정도를 나타내는 함수는 $P_{1,i}$ 이다. 일반적으로 $\delta A_i(x)$ 와 $\delta B_i(x)$ 는 최소, 최댓값을 각각 0과 1을 갖는다. $\delta A_i(x)$ 와 $\delta B_i(x)$ 는 식(2)와 식(3)과 같은 함수로 표현한다.

$$\delta A_i(x) = e^{-((x_i - c_i)/\alpha_i)^2} \quad (2)$$

$$\delta B_{i-3}(y) = e^{-((y_i - c_i)/\alpha_i)^2} \quad (3)$$

여기서 α_i 와 c_i 는 소속함수의 모수이다.

종형 함수의 각 모수 값이 달라지면 소속함수의 shape도 달라지며 학습과정을 통해 오차를 최소화하는 방향으로 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 나타낼 수 있으며 식(4)로 표현할 수 있다.

$$P_{2,i} = w_i = \delta A_i(x) \cdot \delta B_{i-3}(y) \quad (4)$$

계층 3의 노드는 i 번째 규칙의 적합도가 전체 규칙들의 적합도 합에 대해 차지하는 비중을 표현하며 다음과 같은 값을 출력한다. 계층 3은 식(5)와 같은 함수로 표현할 수 있다.

$$P_{3,i} = \overline{w_i} = w_i / (w_1 + w_2 + \dots + w_9) \quad (5)$$

계층 4의 각 노드에서는 각 규칙 결론부의 출력함수에 표준화된 적합도를 곱하는 연산을 실행하고 식(6)과 같은 함수로 표현 된다.

$$P_{4,i} = \overline{w_i} \cdot f_i = w_i \cdot (p_i x + q_i y + r_i) \quad (6)$$

여기서 w_i 는 계층 3의 출력값이며 출력함수 p_i, q_i, r_i 는 결론부라고 부른다. 이 또한 학습과정을 통해 오차를 최소화하도록 결정한다.

계층 5은 단일노드이며 입력되는 모든 값을 합하여 출력하며 그 값은 연속형이고 식(7)과 같이 표현 된다.

$$P_{5,i} = \sum_i \overline{w_i} f_i = \sum_i w_i f_i / \sum_i w_i \quad (7)$$

2.3 예측결과

알고리즘의 훈련을 위해 데이터를 0~1 사이로 정규화를 하기 위해 식(8)을 적용하였다.

$$\text{data} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (8)$$

여기서 x 는 관측값, x_{\min} 는 관측값의 최소값, x_{\max} 는 관측값의 최대값이다.

예측 정확도를 측정하기 위해 train 90%, test 10%로 지정하여 훈련 데이터로 알고리즘을 훈련 시킨 뒤 예측을 하였다. 그림 3은 프로그램 순서도를 나타낸다. 경남 밀양시의 지하수 수위, 강수량, 기온 데이터를 얻은 뒤에 식(8)의 정규화를 이용하여 데이터를 0에서 1사이로 변환한다. 변환한 데이터를 같은 시간에 맞게 병합하고, 알고리즘 오차 측정을 위해 train, test data로 분할한다. train data를 이용하여 알고리즘을 학습하고, test data를 이용하여 알고리즘의 오차를 측정한다.

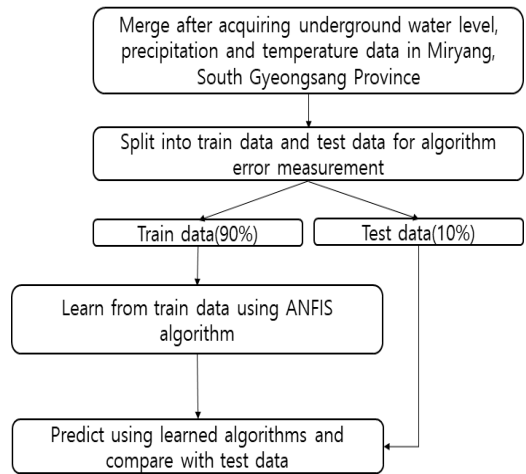


그림 3. 프로그램 순서도
Fig. 3 Program flow chart

그림 4는 ANFIS를 이용하여 train data(90%)로 시킨 뒤 훈련 시킨 알고리즘을 이용하여 예측한 예측 그래프(실선)과 관측 그래프(점선)을 나타낸다. 예측 그래프는 지하수 수위가 자연적 요인에 의해 주기적으로 변한다는 것은 감지 하였지만, 외부 요인(인위적인 요인)에 의해 변동되는 지하수수위 변화값을 감지하지 못하였다.




그림 4. 관측 그래프와 예측 그래프
(실선 : 예측 그래프, 점선 : 관측 그래프)

Fig. 4 Observation graph and prediction graph
(solid line : prediction graph, dotted line : observation graph)

그림 5은 예측 그래프만을 나타낸다.




그림 5. 예측 그래프
Fig. 5 Prediction graph

그림 6은 test data의 예측 그래프와 관측 그래프를 나타낸다.




그림 6. 예측 데이터(5%)와 test 데이터(5%)의 비교 그래프
Fig. 6 Comparison graph between prediction(5%) and test(5%) data

III. 결론

본 논문에는 모형의 정밀도와 방향성을 측정하기 위해 평균 제곱 오차 제곱근(RMSE; Root Mean Square Error)과 절대 백분율 오차 평균(MAPE; Mean Absolute Percent Error)를 이용하여 표3과 같이 얻었다. 식(9)와 식(10)은 각각 RMSE과 MAPE를 나타낸다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\alpha_i - \beta_i)^2} \quad (9)$$

$$MAPE = \frac{1}{n} \left(\sum_{i=1}^n \frac{|\alpha_i - \beta_i|}{\alpha_i} \right) \times 100 \quad (10)$$

여기서 n 은 자료의 수, α_i 는 관측 데이터, β_i 는 예측값을 의미한다.

표 3. 데이터 오차
Table 3. Measure the error of each data

| | Error |
|---------|--------|
| RMSE | 0.1381 |
| MAPE(%) | 37.86 |

RMSE 값은 약 0.14, MAPE 값은 약 38% 나왔다. 이는 지하수 수위의 예측값이 관측값에 비해 1(m) 정도 차이가 있음을 알 수 있다.

본 논문은 지하수수위 데이터를 예측하기 위해 강수량과 기온 데이터를 변수로 사용하였다. ANFIS 알고리즘을 이용하여 train, test(90, 10%)를 지정하여 학습 데이터로 학습한 뒤 test data로 RMSE과 MAPE를 이용해 정확도를 측정하였다. 예측 결과, 외부 요인(인위적인 요인)에 의해 변동되는 지하수수위 변화값을 감지하지 못하였으나 지하수 수위가 자연적 요인에 의해 주기적으로 변한다는 것은 감지 하였다. 이는 지하수수위를 인위적으로 사용한 경우를 수치화하여 정리하는 것과 지하수수위를 측정된 관측공의 정확한 위치에 따른 강수량과 기압 등이 필요하고, LSTM(LSTM; Long Short Term Memory) 역전파 알고리즘 등을 이용하여 비교하여 연구를 진행할 예정이다.

References

- [1] Y. Kim and K. Jin, "Estimated earthquake magnitudes based on fault displacement data of quaternary faults in SE Korea," *J. of the Geology of Korea*, vol. 3, 2007, pp. 57-78.
- [2] Y. Kim, C. Lee, and S. Lee, "A study of the prediction of earthquake occurrence by detecting radon radioactivity," *J. of the Environmental Sciences*, vol. 12, no. 6, 2013, pp. 677-688.
- [3] G. D. L. Touche, "Earthquakes and Groundwater and Surface Water Management at Mines Sites," In *Proc. IMWA 2016*, Freiberg, Germany, 2016, pp. 102-017.
- [4] H. Lee, M. Kim, and T. Woo, "Earthquake Observation through Groundwater Monitoring: A case of M4.9 Odaesan Earthquake," *J. of soil and groundwater environment*, vol. 16, no. 3, 2011, pp. 38-47.
- [5] F. L. Huang, M. Ma, Y. Tian, L. Yan, W. Li, and W. X., "Studies on earthquake precursors in China: A review for recent 50 years," *J. of the Geodesy and geodynamics*, vol. 8, no. 1, 2017, pp. 1-12.
- [6] 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 the Engineering geology*, vol. 23, no. 2, 2013, pp. 137-147.
- [7] R. D. Cicerone, J. E. Ebel, and J. Britton, "A systematic compilation of earthquake precursors," *Tectonophysics*, vol. 476, no. 3-4, 2009, pp. 371-396.
- [8] G. Bak and Y. Bae, "Performance comparison of machine learning in the various kind of prediction," *J. of the Korea institute of electronic communication science*, vol. 14, no. 1, 2019, pp. 169-178.
- [9] Y. Han, "A study on motion prediction and subband coding of moving pictures using GRNN," *J. of the Korea institute of electronic communication science*, vol. 5, no. 3, 2010, pp. 256-261.
- [10] S. Bang, "Implementation of Image based Fire Detection System Using Convolution Neural Network," *J. of the Korea institute of electronic communication science*, vol. 12, no. 2, 2017, pp. 331-336.
- [11] J. Jang, Y. Lee, K. Lee, M. Kim, S. Oh, and S. Park, "The Improvement of predictability for very short range precipitation by blending of VDAPS and MAPLE using micro-genetic algorithm," *J. of the Korea institute of intelligent systems*, vol. 29, no. 4, 2019, pp. 258-267.
- [12] R. Allan Freeze and John A. Cherrey, *Groundwater*. Vancouver, Canada: Prentice-Hall, 1979.
- [13] J. R. Jang, "ANFIS: Adaptive-Network-Based Fuzzy Inference System," *IEEE Transactions on systems, man, and cybernetics*, vol. 23, no. 3, 1993, pp. 665-685.

저자 소개



박귀만(Gwi-Man Bak)

2019년 : 전남대학교 전기 및 반도체공학과 졸업(공학사)
 2019년~현재 : 전남대학교대학원 전기 및 반도체 공학과 석사과정
 ※ 관심분야 : Artificial intelligence, Soft Computing



배영철(Young-Chul Bae)

1984년 광운대학교 전기공학과 졸업 (공학사)
 1986년 광운대학교대학원 전기공학과 졸업 (공학석사)
 1997년 광운대학교대학원 전기공학과(공학박사)
 1986년~1991년 한국전력공사
 1991년~1997년 산업기술정보원 책임연구원
 1997년~현재 전남대학교 전기·전자통신·컴퓨터공학부 교수
 2002년~2002년 Brigham Young University 방문교수
 2011년~2011년 University of Utah 방문교수
 ※ 관심분야 : Chaos Control and Chaos Robot, Robot control etc.