

관망자료를 이용한 인공지능 기반의 누수 예측

이호현¹ · 홍성택^{1*}

Artificial Intelligence-based Leak Prediction using Pipeline Data

Hohyun Lee¹ · Sungtaek Hong^{1*}

^{1*}Lead Researcher, K-water Research Institute, K-water, Daejeon, 34045 Korea

요 약

상수도 관망은 국가 수도 시설의 주요한 구성 요소이지만 대부분이 지중에 매립되어 있어 배관의 노후화 정도 및 누수를 파악하기 어려우므로 유지관리 하기가 매우 어렵다. 본 연구에서는 관망에 설치된 다양한 센서 조합을 가정하여, 데이터 조합에 따른 관로 누수 판별 가능성을 검토하기 위하여 선형회귀분석, 뉴로퍼지 등의 인공지능 알고리즘을 통한 유량과 압력 예측을 실시하여 최적 알고리즘을 도출하였다. 공급압력 예측을 통한 누수판별의 경우 뉴로퍼지 알고리즘이 선형회귀분석에 비하여 우수하였다. 누수유량 예측에서는 뉴로퍼지를 이용한 유량예측이 우선 고려되어야 한다. 다만, 유량을 모사하기 힘든 경우에는 선형 알고리즘을 이용한 공급압력 예측이 이루어져야 할 것으로 사료된다.

ABSTRACT

Water pipeline network in local and metropolitan area is buried underground, by which it is hard to know the degree of pipe aging and leakage. In this study, assuming various sensor combinations installed in the water pipeline network, the optimal algorithm was derived by predicting the water flow rate and pressure through artificial intelligence algorithms such as linear regression and neuro fuzzy analysis to examine the possibility of detecting pipe leakage according to the data combination. In the case of leakage detection through water supply pressure prediction, Neuro fuzzy algorithm was superior to linear regression analysis. In case of leakage detection through water supply flow prediction, flow rate prediction using neuro fuzzy algorithm should be considered first. If flow meter for prediction don't exists, linear regression algorithm should be considered instead for pressure estimation.

키워드 : 누수, 상수도 관로, 압력, 유량, 인공지능

Key word : leakage, water pipeline, pressure, flow rate, artificial intelligence

Received 23 May 2022, Revised 1 June 2022, Accepted 16 June 2022

* Corresponding Author Sungtaek Hong(E-mail:sthong@kwater.or.kr, Tel:+82-42-870-7681)

Lead Researcher, K-water Research Institute, K-water, Daejeon, 34045 Korea

Open Access <http://doi.org/10.6109/jkiice.2022.26.7.963>

print ISSN: 2234-4772 online ISSN: 2288-4165

© This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서론

오늘날 세계는 지속적인 인구증가와 고도산업의 발전으로 인하여 물 수요는 늘어나고 있으나, 물 부족 현상 및 수질 악화로 인한 수원확보가 어려워지고 있다. 이런 상황에서 도시에 매설된 수도관로의 누수로 인하여 막대한 경제적 손실을 초래하고 있다. 특히 지방 도시에서는 30% 이상의 누수율로 선진국보다 높은 수준이고 UN에서 지정한 물 부족 국가이기도 하다[1-2].

국내 상수도 관망은 국가수도 시설의 주요한 구성 요소이지만 대부분이 지중에 매립되어 있어 배관의 노후화 정도를 파악하기 어려우므로 효과적으로 유지관리하기가 매우 어렵다. 표 1과 같이 2019년 우리나라에서 공급한 수돗물 총량은 6,666백만m³으로 이 가운데 유수수량은 5,683백만m³, 유수율은 85.2%으로 전년 대비 0.3% 증가하였고, 누수량은 701백만m³, 누수율은 10.5%으로 전년 대비 0.3% 감소하였다[3].

Table. 1 Current status of water supply and water flow rate and leakage rate by year

Class	2015	2016	2017	2018	2019
total water supply(106 m ³)	6,279	6,419	6,492	6,656	6,666
water flow(106 m ³)	5,293	5,446	5,529	5,652	5,683
flow rate(%)	84.3	84.8	85.2	84.9	85.2
leakage(106 m ³)	687	683	682	721	701
leak rate(%)	10.9	10.6	10.5	10.8	10.5

II. 인공지능 알고리즘

수도분야 누수에 대한 모의는 수리모형모델을 통한 가상데이터 생성 및 소형 모형 플랜트에서 생성된 자료를 통해서 랜덤포레스트, LSTM 등을 검토한 사례가 있다[4-5]. 본 논문에서는 복잡한 수도관로 네트워크에서 간헐적으로 발생하는 상태에서 정상상태를 학습하고 누수를 테스트 자료로 활용하는 경우에 대한 알고리즘 특성을 살펴보고자 하였다. 따라서 누수상황을 학습하지 않아도 판별이 가능한지를 알아보기 위하여, 선형회귀와 뉴로퍼지를 비교 분석 하였다.

2.1. 알고리즘 적용 절차

정보 기술의 발달로 인간의 데이터 수집 능력은 무한대에 가까워지고 있다. 또 수많은 데이터들을 저장하고, 필요한 데이터를 찾으려는 노력과 더불어 그들 데이터로부터 가치 있는 정보나 지식을 추출하고자 하는 욕구가 증대되고 있다.

데이터마이닝은 신경망 모형이나 의사결정 트리와 같은 특정 기법이 아니라 개념적인 정보추출의 방법론으로 일련의 과정이며, 실제 데이터마이닝이 적용되는 과정은 그림 1과 같이 6단계로 나누어 볼 수 있다.




Fig. 1 Data mining process

2.2. 다중 선형회귀 모델

선형회귀방정식은 1805년 Legendre와 1809년 Gauss에 의해 Least Square Error를 가지는 1차방정식의 해를 구하였으며, 향후 고차 다항식, 가우스 및 시그모이드 함수 등을 이용하여 해석할 수 있다.

선형 회귀는 종속 변수 y와 한 개 이상의 독립 변수 또는 설명 변수 x와의 선형 상관 관계를 모델링하는 회귀 분석 기법이다. 한 개의 설명 변수에 기반한 경우에는 단순 선형 회귀(simple linear regression), 둘 이상의 설명 변수에 기반한 경우에는 다중 선형 회귀라고 한다[6].

다중선형회귀에서 종속변수 Y를 설명하는데 k개의 독립변수인 X₁, X₂, ..., X_k를 도입할 때 다중회귀모형은 식 (1)과 같이 정의된다.

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \epsilon_i, \quad (1)$$

$$i = 1, 2, \dots, n$$

2.3. 뉴로퍼지 모델

ANFIS는 Roger Jang에 의해서 처음 제안되었으며 선형, 비선형, 시계열 데이터까지 해석할 수 있다[7-8]. 그림 2에서는 FCM(Fuzzy c-Means) 클러스터링과 TSK (Takagi-Sugeno-Kang) 형태의 ANFIS(Adaptive Neuro-Fuzzy Inference System)를 이용한 뉴로-퍼지모델을 나

타냈다. Jang에 의해 제안된 ANFIS는 규칙의 수를 최소로 하면서 복잡한 비선형 시스템의 표현에 뛰어난 능력을 보이거나 입력공간의 증가에 따른 계산량의 급증과 규칙의 수가 지수적으로 증가하는 문제점을 가지고 있다 [9-10]. 이러한 문제점을 해결하기 위해 본 연구에서는 입력공간을 기존의 그리드 분할 형태가 아닌 FCM에 의해 스캐터 분할형태로 하여 퍼지 규칙의 수를 감소하였다. 그림 2에서 알 수 있는 바와 같이 FCM 클러스터링에 의해 생성된 소속 함수는 1층에 배치되어 진다. 이렇게 함으로서 2층은 스캐터 분할에 의해 적은 규칙을 생성할 수 있어, 기존의 그리드 분할에 의한 퍼지규칙의 수가 지수적으로 증가하는 문제점을 개선하였다.

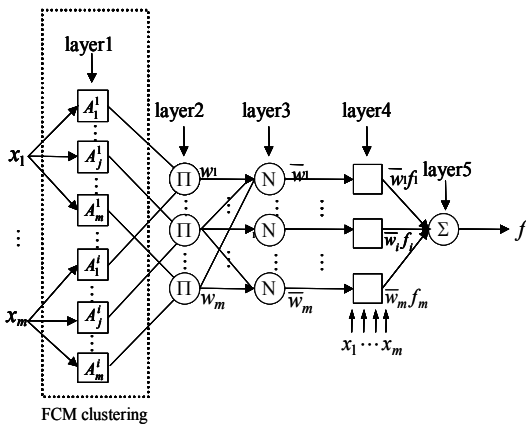


Fig. 2 Structure of ANFIS

그림 3에서 Bezdek에 의해 제안된 FCM 클러스터링 알고리즘은 목적함수를 최소화하도록 하는 반복적인 알고리즘으로서 주어진 데이터로부터 유사한 클러스터를 나누며 생성된 클러스터는 주어진 데이터의 동작을 기술하는 규칙으로서 사용된다.

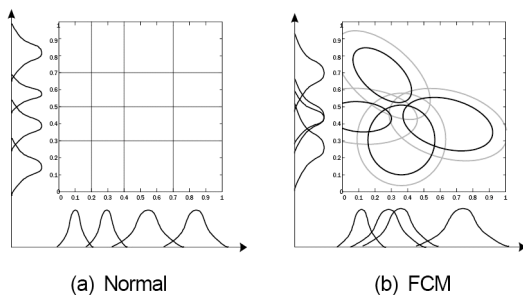


Fig. 3 Fuzzy clustering based fuzzy rule creation

뉴로퍼지 알고리즘의 추정순서는 다음과 같다.

[단계 1] 취득하고자 하는 대표점의 수 즉, 클러스터의 수 c ($2 \leq c \leq n$)를 정하고, 초기 분할행렬 $U^{(0)}$ 를 초기화한다. 분할행렬에 할당될 소속정도의 값 μ_{ik} 는 다음 식을 만족한다.

$$\mu_{ik} = \mu_{A_i}(x_k) \in [0,1] \quad (2)$$

[단계 2] 각 단계에서 데이터 x 와 초기 분할행렬값 u 를 이용하여 대표 특징의 중심 $v_i^{(r)}$ 을 계산한다.

$$v_{ij} = \frac{\sum_{k=1}^n \mu_{ik}^m \cdot x_{kj}}{\sum_{k=1}^n \mu_{ik}^m} \quad (3)$$

[단계 3] 단계 2에서 계산된 대표 특징들의 중심값과 데이터 x 와의 거리값 d 에 의하여 분할 행렬 $U^{(r)}$ 을 다음과 같이 갱신한다.

$$\mu_{ik}^{(r+1)} = \left[\sum_{j=1}^c \left(\frac{d_{ik}^{(r)}}{d_{jk}^{(r)}} \right)^{2/(m-1)} \right]^{-1} \quad (4)$$

여기서, m 은 퍼지화 정도를 나타내는 퍼지 수로써 일반적으로 2를 이용한다. 또한, d_{jk} 는 p 차원을 갖는 j 번째 데이터 x_j 와 k 번째 대표 중심값 v_k 와의 유클리디안 거리값을 의미한다.

$$d_{jk} = d(x_j, c_k) = \left[\sum_{i=1}^p (x_{ji} - v_{ki})^2 \right]^{-1} \quad (5)$$

[단계 4] 다음과 같이 목적함수를 계산한 후, 만약 $\|J(U^r, v^r) - J(U^{(r-1)}, v^{(r-1)})\| \leq \epsilon_1$ 이면 알고리즘을 종료하고 그렇지 않으면 단계 2로 가서 반복 수행한다.

$$J(U, c_1, c_2, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 \quad (6)$$

FCM에 의해 결정된 각각의 클러스터는 시스템의 특성을 기술하는 퍼지 규칙으로 되며, 식(7)과 같이 TSK 형태의 퍼지 규칙이 사용된다.

$$R^i = \text{if } t_1 \text{ is } A_1^i \text{ and } t_2 \text{ is } A_2^i \text{ and } \dots \quad (7)$$

$$t_m \text{ is } A_m^i$$

$$\text{then } f^i = a_0^i + a_1^i t_1 + \dots + a_m^i t_m$$

여기서, $a_0^i, a_1^i, \dots, a_m^i$ 는 결론부 파라미터이며 t_1, \dots, t_m 은 PCA에 의해 변환되고 0과 1사이에서 정규화된 입력이다. 퍼지 모델의 추론값 f^* 는 식(8)과 같이 가중평균법에 의해서 구해진다.

$$f^* = \frac{\sum_{i=1}^m w^i f^i}{\sum_{i=1}^m w^i} \quad (8)$$

$$w^i = \prod_{j=1}^m \mu_{A_j^i}(t_j), \mu_{A_j^i}(x_j) = \exp\left\{-\left(\frac{t_j - c_j^i}{\sigma_j^i}\right)^2\right\} \quad (9)$$

III. 관망자료를 이용한 누수분석

3.1. 실험 대상관망

관로 상에서 실제 누수를 발생시켜 해당 자료를 얻거나 과거의 누수자료를 모아 분석하기에는 데이터 수량과 누수상황에 따른 분석에 어려움이 발생한다. 따라서 유사 누수를 모의할 수 있는 관망에 대한 조사결과 K 정수장의 정·배수지를 활용하여 정수장을 모의하였다. 그림 4에서와 같이 분기_1이 물을 받지 않는 경우를 정상시로 물을 받은 경우를 누수라고 판단하여 정상시를 학습하여 누수시를 이상상태로 판단할 수 있는지를 분석하였다[11-13].




Fig. 4 Test water distribution network

데이터 분석을 위하여 표 2와 같이 5일간 분 단위 자료 6,343개의 자료를 취득하였다. 이 중 데이터 학습을 위하여 정상 상태 1,332개의 자료와 누수 상태 5,011개의 자료를 비교 분석하였다.

Table. 2 Training and test data set

Period	Data Class	Data	Classification
'16.12.21 ~ 12.25.	Normal	1,332	TP_1 V/V Close
	Leakage	5,011	TP_1 V/V Open


3.2. 공급유량 예측

표 3에서는 공급유량 예측의 백분율 오차를 비교 분석하였다. 계측기 구성별 수주유량을 통한 공급유량을 예측한 결과, 선형알고리즘에서 0.71, 뉴로퍼지 알고리즘에서 0.66으로 낮은 오차를 나타냈다. 이외에도 압력을 통한 유량예측과 압력과 유량을 통한 공급유량 예측도 오차가 증가하긴 하지만 공급량 예측에는 지장을 초래할 정도는 아니었다. 알고리즘에 따른 유량오차는 선형회귀 분석이 뉴로퍼지보다 컸으며, 특히, 압력을 통한 유량예측 시에는 3배의 오차를 발생하였다. 이는 압력과 유량사이에 비선형 관계가 반영된 결과로 판단된다.


Table. 3 Flow estimation by sensor type and algorithm

Classification	Linear Regression	Neuro Fuzzy
TP2 Flow, TP3 Flow	0.71	0.66
TP2 Pressure, TP3 Pressure	2.81	0.94
TP2 Pressure, TP3 Flow	1.50	0.98

그림 5는 분기점 유량에 의한 공급유량 예측 결과이다. 선형회귀 분석의 결과는 0.71%, 뉴로퍼지의 알고리즘은 0.66%로 차이가 크지 않다. 이는 유량과 유량사이에 선형적인 관계가 존재하여 알고리즘에 의한 차별성이 적다는 것을 알 수 있다.





(a) Linear Regression



(b) Neuro Fuzzy
Fig. 5 Flow estimation by algorithm based on flow sensor

그림 6은 분기점 압력에 의한 공급유량 예측 결과이다. 선형회귀분석은 2.81%, 뉴로퍼지 알고리즘은 0.94%로 차이가 2.97배 발생하고 있다. 이는 유량과 압력 사이에 선형적인 관계가 존재하지 않아 알고리즘에 의한 차별성으로 판단된다. 결과적으로 비선형적인 학습이 가능한 뉴로퍼지 알고리즘이 압력에 의한 공급유량 예측 시 적합한 것으로 판단된다.





(b) Neuro Fuzzy
Fig. 7 Flow estimation by algorithm based on mixed sensor

3.3. 공급압력 예측

표 4에서는 계측기 구성 및 알고리즘별 공급압력 예측에 대한 백분율 오차를 비교 분석하여 보았다. 계측기 구성별 비교한 결과 당초 압력에 의한 예측결과가 가장 좋을 것으로 생각되었으나 예상과는 달리 유량과 압력을 혼합한 결과가 가장 양호하였다. 또한 공급유량 예측 시 백분율오차가 0.66%이었던 것에 비하여 공급압력 예측에서는 0.20으로 3.3배 개선됨을 확인 하였다. 이는 압력이 유량에 비하여 변화정도가 적어 오차가 개선된 것으로 사료된다.

Table. 4 Pressure estimation by sensor type and algorithm

Classification	Linear Regression	Neuro Fuzzy
TP2 Flow, TP3 Flow	0.82	0.57
TP2 Pressure, TP3 Pressure	0.66	0.28
TP2 Pressure, TP3 Flow	0.49	0.20



(b) Neuro Fuzzy
Fig. 6 Flow estimation by algorithm based on pressure sensor

그림 7은 분기점 유량과 압력 혼합 센서에 의한 공급유량 예측 결과이다. 선형회귀분석 결과는 1.50%, 뉴로퍼지 알고리즘은 0.98%로 1.53배의 차이가 발생하였다. 이는 공급유량 예측 시 압력센서를 한 개 이상 포함할 시 선형알고리즘으로는 학습이 나빠질 수 있음을 나타낸다. 압력센서를 이용한 학습 시 반드시 비선형 알고리즘을 사용하는 학습효과를 높일 수 있다.

그림 8은 분기점 유량에 의한 공급압력 예측 결과이다. 선형회귀분석 결과는 0.82%, 뉴로퍼지 알고리즘은 0.57%로 차이가 1.42배 발생하고 있다. 유량에 의한 압력 예측 알고리즘에 의한 차이가 크지 않음을 나타내고 있다.

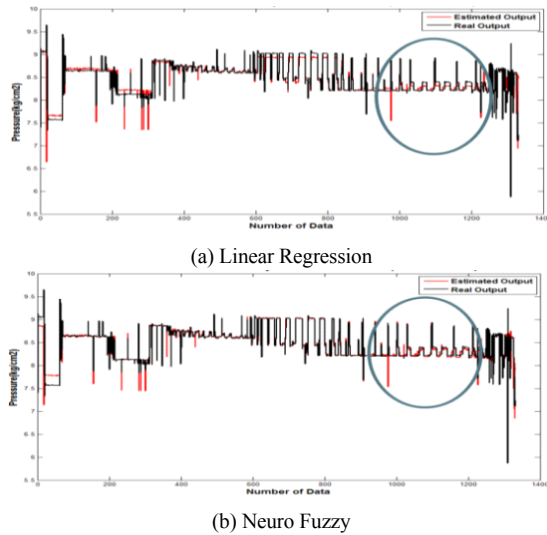


Fig. 8 Pressure estimation by algorithm based on flow sensor

그림 9는 분기점 압력에 의한 공급압력 예측 결과이다. 선형회귀분석 결과는 0.66%, 뉴로퍼지 알고리즘은 0.28%로 차이가 2.35배 발생하고 있다. 분기 압력을 통한 압력 예측은 분기유량을 통한 유량예측과는 달리 선형적인 관계가 성립하지 않는 것으로 사료된다. 따라서 동일 압력을 예측하는 경우에도 뉴로퍼지 알고리즘을 통한 예측이 적합하다고 사료된다.

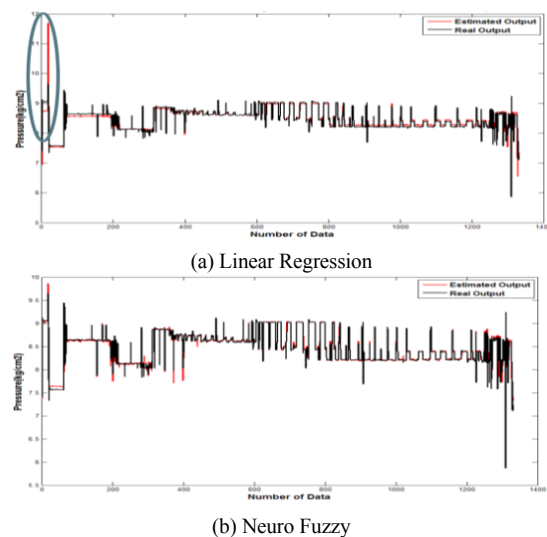


Fig. 9 Pressure estimation by algorithm based on pressure sensor

그림 10은 분기점 유량과 압력 혼합센서에 의한 공급 압력 예측 결과이다. 선형회귀 알고리즘은 0.49%, 뉴로 퍼지 알고리즘은 0.20%로 2.4배 차이가 발생하였다. 여기에서는 혼합센서를 이용하는 것이 가장 좋은 결과를 얻었으며, 이는 상관관계가 높은 센서를 사용하였기 때문이다. 따라서, 센서 선정 시 알고리즘의 상관관계를 우선 검토해 보는 것이 필요하다.

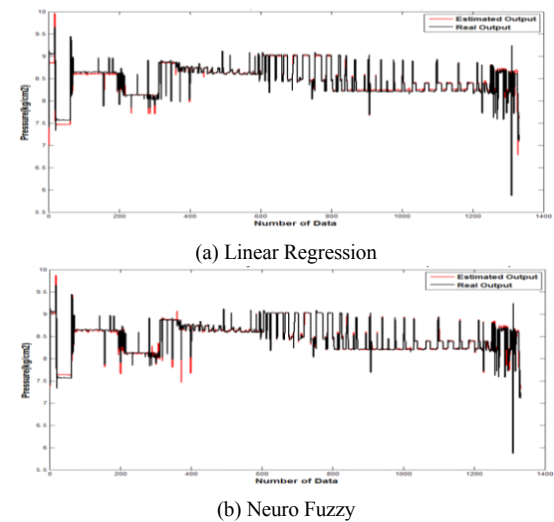


Fig. 10 Pressure estimation by algorithm based on mixed sensor

3.4. 공급유량 기반 누수시험 분석

표 5에서는 누수 발생 시 센서 타입 및 알고리즘별 예측 공급유량과 실제 공급유량의 백분율 오차를 비교 분석하여 보았다. 분석결과 센서조합에 상관없이 백분율 오차가 2% 미만 발생하였다.

Table. 5 Leakage test by sensor type and algorithm(flow)

Classification	Linear Regression	Neuro Fuzzy
TP2 Flow, TP3 Flow	0.64	0.72
TP2 Pressure, TP3 Pressure	2.02	1.91
TP2 Pressure, TP3 Flow	1.02	1.34

그림 11은 누수 발생 시 분기점 유량을 통한 예측 공급유량과 실제 공급유량과의 백분율 오차를 비교 분석하였다. 선형회귀분석 결과는 0.64%, 뉴로퍼지 알고리즘은 0.72%로 1.14배의 차이로 선형회귀분석이 다소 적은 오차를 보였다. 선형회귀분석과 뉴로퍼지 알고리즘 모두 누수량이 증가할수록 오차가 커져 쉽게 이상을 감

지할 수 있었다.




Fig. 11 Leakage test by algorithm based on flow sensor(flow)

그림 12는 누수 발생 시 분기점 압력을 통한 예측 공급 유량과 실제 공급유량과의 백분율 오차를 비교 분석하여 보았다. 선형회귀분석 결과는 2.02%, 뉴로퍼지 알고리즘은 1.91%로 1.05배 차이로 뉴로퍼지 알고리즘이 좋은 결과를 나타냈다. 다만, 뉴로퍼지 알고리즘의 경우 누수량이 620m³/h 가량 발생할 시 이상치가 1회 발생하였다. 이는 과적합(Over-Fitting)에 따른 오차로 판단된다.

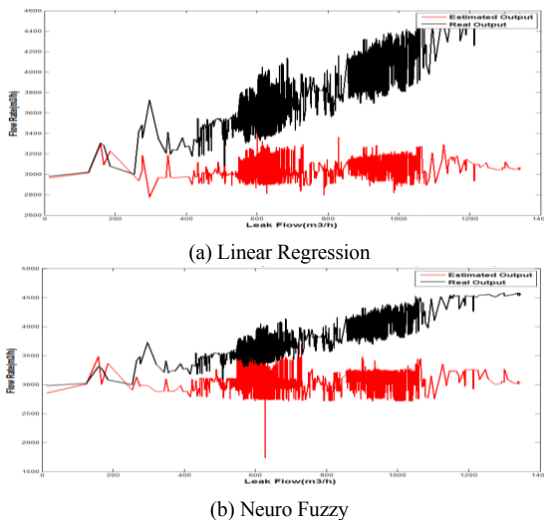


Fig. 12 Leakage test by algorithm based on pressure sensor(flow)

그림 13은 누수 발생 시 분기점 유량·압력을 통한 예측 공급유량과 실제 누수유량과의 백분율 오차를 비교 분석하여 보았다. 선형회귀분석 결과는 1.02%, 뉴로퍼지 알고리즘은 1.34%로 1.31배 차이로 선형회귀분석이 우수하였다. 선형회귀분석과 뉴로퍼지 알고리즘 모두 과적합 문제가 없이 안정적으로 누수를 판별할 수 있었다.




Fig. 13 Leakage test by algorithm based on mixed sensor(flow)

3.5. 공급압력 기반 누수시험 분석

표 6에서는 누수 발생 시 센서 타입 및 알고리즘별 예측 공급압력과 실제 공급압력의 백분율 오차를 비교 분석하여 보았다. 분석결과 유량을 통한 압력예측에서는 신경망이 가장 우수하였고, 압력을 통한 예측과 혼합센서에 의한 예측에서는 선형회귀분석이 우수하였다. 따라서 공급압력예측은 선형회귀분석으로 구성하여도 될 것이다.

Table. 6 Leakage test by sensor type and algorithm (pressure)

Classification	Linear Regression	Neuro Fuzzy
TP2 Flow, TP3 Flow	2.92	3.30
TP2 Pressure, TP3 Pressure	2.61	2.72
TP2 Pressure, TP3 Flow	2.63	2.90

그림 14는 누수 발생 시 분기점 유량을 통한 예측 공급압력과 실제 공급압력의 백분율 오차를 비교 분석하여 보았다. 선형회귀분석의 경우 누수유량이 증가할수록 예측압력도 증가하였지만, 뉴로퍼지 알고리즘의 경우에는 과적합이 발생하여 압력이 급감하는 이례불가

한 상태가 예측 되었다. 따라서 비선형 알고리즘을 이용한 누수감지는 적합하지 않다.




Fig. 14 Leakage test by algorithm based on flow sensor (pressure)

그림 15는 누수 발생 시 분기점 압력을 통한 예측 공급압력과 실제 공급압력의 백분율 오차를 비교 분석하여 보았다. 선형회귀분석의 경우 누수유량이 증가할수록 압력오차도 증가하였지만, 뉴로퍼지 알고리즘의 경우에는 과적합이 발생하였으며, 이전과는 달리 600m³/h 구간에서 과대 예측하는 경우가 발생하여 누수분석 알고리즘으로 합리적이지 않다고 판단된다.




Fig. 15 Leakage test by algorithm based on pressure sensor (pressure)

그림 16은 누수 발생 시 분기점 유량·압력을 통한 예측 공급압력과 실제 공급압력의 백분율 오차를 비교 분석하여 보았다. 선형회귀분석의 경우 이전과 같이 누수 유량이 증가할수록 압력오차도 증가하였고, 뉴로퍼지 알고리즘의 경우에도 이전과는 달리 과적합이 발생하지 않았다.

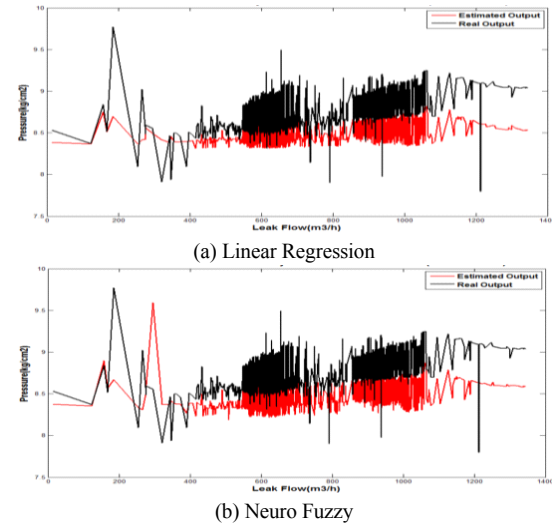


Fig. 16 Leakage test by algorithm based on mixed sensor (pressure)

IV. 결론

상수관망 관로누수를 실시간 판별하기 위해서는 공급유량과 수수유량 관계로 해석하는 예측 알고리즘이 필요하다. 본 연구에서는 관망에 설치된 다양한 센서 조합을 가정하여, 데이터 조합에 따른 관로누수 판별 가능성을 검토하기 위하여 선형회귀분석, 뉴로퍼지 등의 인공지능 알고리즘을 통한 유량과 압력 예측을 실시하여 최적 알고리즘을 도출하였다.

예측 알고리즘에 의한 공급유량 학습에서는 센서조합에 따라 선형회귀분석과 뉴로퍼지 알고리즘 간에 약간의 정확성의 차이는 있으나 누수판별에 있어 충분히 가능하리라 판단된다. 하지만 공급압력 학습의 경우 뉴로퍼지 알고리즘이 선형회귀분석에 비하여 월등히 우수하였다. 누수시험 분석 측면에서는 뉴로퍼지 알고리즘이 과적합 문제가 발생하여 이를 활용하기에는 한계가 있었으나 선형회귀분석으로 일관성 있는 압력 예측

이 가능하였다. 누수감지 능력 측면에서 비교한다면 누수량에 따른 유량은 큰 범위로 변화하나 압력은 적게 변화하여 감지 능력이 저하된다.

매우 이례적으로 발생하는 누수를 판단하는 곳에는 유량계 센서를 많이 설치하고, 압력대신 공급유량을 예측하여야 하며, 과적합이 덜한 선형 알고리즘을 이용하는 것이 일관성 있는 예측을 한다고 사료된다.

ACKNOWLEDGEMENT

This work was supported by Korea Institute of Energy Technology Evaluation and Planning(KETEP) grant funded by the Korea government(MOTIE) (No. 2020200000010.)

REFERENCES

[1] D. H. Nam, D. H. Kim, H. I. Lim, S. M. Jin, K. H. Gi, and K. I. Nho, *Understanding Flow Management*, 1th ed. Daejeon, Korea, Kwater, 2016.

[2] J. Y. Gu, "Leakage prevention and reduction technology in water supply network," *Magazine of Korea Water Resources Association*, vol. 41, no. 6, pp. 10-17, 2008.

[3] Ministry of Environment, "Summary," in *2019 Statistics of Waterworks*, 1th ed. Sejong, Korea, ch. 1, pp. 21, 2020.

[4] C. W. Lee and D. G. Yoo, "Development of leakage detection model in water distribution networks applying LSTM-based deep learning algorithm," *Journal of Korea Water Resources Association*, vol. 54, no. 8, pp. 599-606, Aug. 2021.

[5] I. Lučin, B. Lučin, Z. Čarija, and A. Sikirica, "Data-Driven Leak Localization in Urban Water Distribution Networks Using Big Data for Random Forest Classifier," *Mathematics*, vol. 9, no. 6, p. 672, Mar. 2021.

[6] D. A. Freedman, *Statistical Models: Theory and Practice*, Cambridge University Press, New York: NY, USA, pp. 26, 2009.

[7] J. -S. R. Jang, "ANFIS: Adaptiv-Network-Based Fuzzy Inference System," *IEEE Transactions on System, Man and Cybernetic*, vol. 23, no. 3, pp. 665-685. May-Jun. 1993.

[8] W. Sun, S. Shao, and R. Yan, "Induction Motor Fault Diagnosis Based on Deep Neural Network of Sparse Auto-encoder," *Journal of Mechanical Engineering*, vol. 52,

no. 9, pp. 65-71, May. 2016.

[9] R. Liu, G. Meng, B. Yang, C. Sun, and X. Chen, "Dislocated Time Series Convolutional Neural Architecture: An Intelligent Fault Diagnosis Approach for Electric Machine," *IEEE Transactions on Industrial Informatics*, vol. 13, no. 3, pp. 1310-1320, Jun. 2017.

[10] O. Janssens, V. Slavkovikj, B. Vervisch, K. Stockman, M. Loccufier, S. Verstockt, R. V. Walle, and S. V. Hoecke, "Convolutional Neural Network Based Fault Detection for Rotating Machinery," *Journal of Sound and Vibration*, vol. 377, pp. 331-345, Sep. 2016.

[11] Y. J. Heo, H. H. Lee, and S. T. Hong, "Calibration System and Data Analysis for improving the Reliability of Pressure Sensor," in *Proceeding of Symposium of the Korean Institute of communications and Information Sciences*, Jeju, Korea, pp. 806-807, 2017.

[12] K. M. Choi, H. H. Lee, G. W. Shin, and S. T. Hong, "Analysis of Elastic Wave Based Leakage Detection Technology Using Accel," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 24, no. 9, pp. 1121-1130, Sep. 2020.

[13] H. H. Lee and S. T. Hong, "Data-based Analysis for Pressure Gauge Optimal Positioning in Water Supply Pipeline," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 25, no. 6, pp. 834-840, Jun. 2021.



이호현(Hohyun Lee)

1998년 ~ 현재 한국수자원공사
 1998년 원광대학교 전자공학 학사
 2010년 KAIST 로봇학제 석사
 2017년 충북대학교 제어로봇공학 박사
 ※관심분야: AI, 퍼지, 머신러닝, 최적화



홍성택(Sungtaek Hong)

1996년 ~ 현재 한국수자원공사
 1993년 한밭대학교 전자공학과 학사
 1995년 한밭대학교 전자공학과 석사
 2020년 배재대학교 컴퓨터공학과 박사
 ※관심분야: 컴퓨터공학, 위성통신, 계측제어, USN, IoT, 원격감시제어 및 센서응용 기술