

관계적시점지도로 구성된 SOM을 이용한 가스배관 부식상태의 자율적 판단 방법

손충연[○], 여지혜^{*}, 고일주^{*}

[○]한국가스안전공사 가스안전연구원

^{*}숭실대학교 일반대학원 미디어과

e-mail: paperboat@kgs.or.kr, {hoya350, andy}@ssu.ac.kr

A Method For Autonomous Determination Of Corrosion State Of Gas-pipeline Using RPM-based SOM

Choongyeon Sohn[○], Jihye Yeo^{*}, Ilju Ko^{*}

[○]Institute of Gas Safety R&D, Korea Gas Safety Corporation

^{*}Dept. of Media, Soong-Sil University

● 요약 ●

시설의 안전성 평가에 대한 연구는 안전성에 영향을 주는 데이터를 정량화하여 확실적인 자동 수행하는 안전관리가 주를 이루고 있다. 이와 달리 자율수행은 수집 된 상황 정보나 상태 데이터를 이용하여 안전성을 예측하고 사고 위험성을 경보하여 사고를 예방 할 수 있다. 본 연구에서는 다양한 시설물 중에서 가스배관의 부식에 대한 판단을 위해서 신경망의 대표적 비지도학습인 자기조직화지도도를 적용한다. SOM의 적용에서는 주변효과를 보완하기 위해서 관계적관점지도로 맵을 구성한다. 학습 할 데이터는 가스배관의 방식전위이다. 배관의 부식상태를 확인하기 위하여 수집 된 데이터인 방식전위에는 부식에 대한 위험요인이 내재 되어 있다. 학습 후 새로운 데이터가 입력되면 각 상태 군집의 중심뉴런과 맵핑된 뉴런의 유사도를 측정하여 배관의 부식상태를 결정한다. 제안 된 방법으로 판단 된 결과를 기존에 사람이 판단한 결과와 비교하여 검증한다. 이를 통해 배관의 부식상태를 자율적이고 신속하게 판단하여 지능화 된 가스배관 관리로 활용한다.

키워드: 자기조직화지도(Self-Organizing Map), 관계적시점지도(Relational Perspective Map), 배관(Pipeline), 부식(Corrosion)

I. 서론

기존 대형 플랜트나 산업시설의 안전성과 상태에 대한 평가연구는 위험성에 영향을 주는 데이터를 정량화하고 수식으로 표현하여 확실적인 자동수행에 초점으로 이루어졌다. 이와 달리 시설관리를 지능화하여 자율적으로 수행하는 연구는 미흡하다. 자율수행은 수집 된 상황정보나 상태 데이터를 이용하여 시설물의 안전성을 판단하고 사고 위험을 경보하여 사고를 미연에 예방 할 수 있기에 효율적인 시설물 안전관리가 가능하게 한다[1].

본 연구에서는 다양한 시설물 중에서 가스배관의 부식상태 판단을 자율화한다. 이를 위해 신경망의 대표적 비지도학습인 자기조직화지도도를 적용한다. SOM에서 발생하는 주변효과를 보완하기위해서 관계적시점지도로 SOM을 구성하여 적용한다[2]. 학습 데이터로는 위험요인이 내재 된 가스배관의 방식전위를 사용한다. 배관의 부식상태를 판단하기 위하여 측정 된 방식전위를 학습데이터로 사용하여 관계적시점지도로 구성 된 SOM에 입력패턴으로 한다. 학습 후 새로운 데이터를 맵핑하여 각 상태 군집과의 유사도를 측정해서 배관의 부식상태를 자율적으로 판단한다. 이를 통해

기존 판단방법의 단점을 보완한 자율적인 가스배관의 부식상태 판단방법을 제시한다.

II. 가스 배관의 자율적 부식상태 판단

1. 가스 배관의 부식 판단을 위한 방식전위

대형 플랜트나 산업시설물의 이상 유무와 안전성은 측정된 데이터를 통해 시설관리자나 전문가가 육안으로 모니터링 하여 시설물의 안전성을 평가하고 관리하였다. 가스시설을 살펴보면 다양한 구성 시설물의 안전성을 사람이 평가하여 안전성 상태 평가의 일관성이 낮고 이를 토대로 시설을 관리하기에는 많은 인력과 시간과 고비용을 필요로 한다. 이를 보완하고자 위험성 기반 진단기법(Risk Based Inspection)으로 시설물 안전관리를 위해 위험성을 정량화하는 다양한 기법이 연구되고 있다[3]. 그러나 이러한 기법은 정량화에 필요한 변수가 많아 가스시설의 자율적인 안전성 평가에 의한 안전관리에 이용하기에는 어려움이 있다. 본 논문에서

는 지능 화 된 가스배관의 안전관리를 위해서 가스배관의 위험요 인 중 하나인 부식상태를 자율적으로 판단 할 수 있는 방법을 제 안한다.

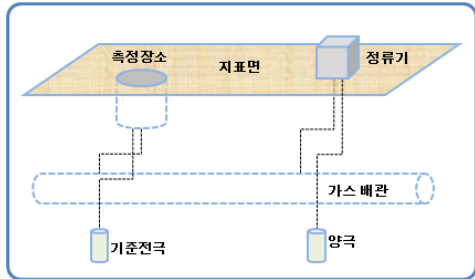


그림 1. 방식전위 측정 환경과 측정데이터
Fig. 1. Environment of Protection Potential Measurement

표 1. 방식전위 데이터
Table 1. Data of Protection Potential Measurement

측정시간	최대	최소	평균
...
18:06:24	-1554	-1372	-1455
17:06:14	-1532	-1361	-1438
16:06:04	-1278	-1046	-1157
15:06:55	-1576	-1516	-1549
14:06:45	-1134	-1041	-1079
13:06:36	-1879	-1775	-1836
...

(단위: mV)

그림 1은 가스배관의 방식전위의 측정환경이고 표 1은 측정 된 기록이다. 배관은 지하나 외부에 노출된 경우가 많아 부식 가능성 이 높다. 따라서 부식은 배관의 안전성을 위협하는 원인이다. 배관 의 부식상태 확인에는 방식전위, 분극전위, 토양비저항 등 다양한 측정 을 통해 판단된다. 일반적으로 주기적 측정이 가능한 방식전 위를 주로 이용한다[3]. 지표면 아래에 매설된 가스배관의 부식상 태를 판단하기 위해서 배관에 정류기에서 전류를 생성하면 매설배 관에서 음의 방식전류를 유입한다. 기준전극과 매설배관사이의 전 위를 측정 장소에서 수직기를 이용하여 측정한다. 위의 환경에서 측정된 데이터의 전위치는 음수로 표현되며 표 1과 같이 기록 된 다. 측정일자과 시간, 방식전위의 최대, 최소, 측정시간 동안의 최 대, 최소를 제외한 값의 평균으로 구성된다.




그림 2. 배관 관리를 위한 방식전위 기준 한계
Fig. 2. Threshold based on Protection potential for pipeline management

도시가스사에서는 배관의 안전관리를 위해서 측정 된 방식전위 를 전문가가 제시한 그림 2의 한계를 이용하여 부식상태 판단을 사람이 한다. 측정 된 방식전위에는 부식 위험성이 내재되어 구분 된 정상, 주의, 경고 상태이다. 정상 이외의 -2500 미만과 -840 초 과 범위에서는 주의 및 경고로 나뉜다. 방식전위의 상태기준 한계 를 살펴보면 내재 된 위험요인이 정상을 중심으로 순환적 형태임 을 알 수 있다. 이러한 가스 배관의 방식전위의 특성을 신경망의 관계적시점지도(Relative Perspective Map)로 구성 된 SOM으로 학습하여 사람이 판단 한 부식 판단 결과보다 일관성을 높이고 자 율적인 가스배관의 부식상태를 판단하도록 한다.

2. 관계적시점지도(Relational Perspective Map)를 적용 한 SOM(Self-Organizing Map)

가스배관의 자율적인 부식상태 판단을 위해 신경망의 대표적 비지도학습인 자기조직화지도를 적용한다. SOM은 다차원의 복잡한 입력패턴을 2차원 평면상에 맵핑할 수 있으며 실시간 학습과 연속적인 학습이 가능 한 장점이 있어 부식상태 판단에 사용한다. 배관에서 측정 한 위험성이 내재 된 방식전위를 학습데이터로 사 용하여 SOM에 학습시킨다. SOM은 입력노드로 구성 된 입력층 과 출력뉴런으로 출력층으로 되며 입력노드 i 와 출력뉴런 j 가 연 결가중치 W_{ij} 로 연결되어있다. 출력층의 각 출력뉴런은 N 차원 의 연결가중치벡터 W_j 로 연결되어 구성 된다[4].

$$w_{ij}^{(k+1)} = \begin{cases} w_{ij}^{(k)} + \alpha^{(k)} [x_i^{(k)} - w_{ij}^{(k)}] & \text{for } i \in N_j^* \\ w_{ij}^{(k)} & \text{otherwise} \end{cases} \quad (1)$$

SOM에 입력패턴이 입력되면 초기 가중치벡터와 입력패턴의 벡터와의 거리를 계산하여 가장 가까운 거리의 연결가중치 벡터를 갖는 뉴런을 승자(Winner)로 선택한다. 선택된 승자 뉴런과 이웃 반경에 포함되는 이웃(Neighbor) 뉴런을 중심으로 식 (1)과 같이 연결가중치를 변경하며 경쟁학습 한다. 학습이 진행되면서 이웃반 경은 승자뉴런을 중심으로 수렴하게 된다. 학습과정에서 출력층 위상에 큰 변화가 없게 되면 학습을 종료한다.




그림 3. SOM의 승자뉴런과 이웃뉴런
Fig. 3. Winner and Neighbor Neurons of General SOM Algorithm

그림 3의 (a)는 SOM의 학습과정에서 출력층의 중심에 승자가 선택되고 승자를 중심으로 설정된 이웃반경에 의해 선택된 이웃뉴런이다. 출력층을 2차원 평면으로 구성하고 반복적으로 경쟁학습하게 되는 기존의 SOM은 연결가중치를 변경할 뉴런이 그림 3의 (b)처럼 출력층의 가장자리에서 선택되면 이웃뉴런이 일부 누락되어 학습되고 결과적으로 결과에 영향을 준다. 이러한 현상을 일컬어 주변효과(Border Effect)라 한다[n].




그림 4. 관계적시점지도로 구성된 SOM의 학습반경
Fig. 4. Learning Boundary of SOM based on Relative Perspective Map

그림 4는 기존 SOM의 출력층 가장자리를 각각 대칭되는 가장자리를 연결하여 관계적시점지도로 구성된 SOM이다. 그림 4의 (a)는 관계적시점지도로 구성된 SOM의 출력층의 우측 상단 가장자리에서 승자뉴런이 선택되고 이웃반경에 의해 선택된 이웃뉴런이다. 그림 4의 (b), (c), (d)는 기존 SOM의 주변효과를 보완하고자 출력층의 가장자리에서 승자를 중심으로 선택되지 못한 이웃뉴런들이 가장자리에서 보존되어 선택된 뉴런이다. 관계적시점지도로 구성된 SOM은 입체형의 맵을 전개도로 펼쳐서 시각화한다. 따라서 출력층의 가장자리는 2차원상의 맞은편의 가장자리와 연결되어 순환성이 존재한다[6]. 순환성이 있는 입체형의 맵을 구성한 후 학습하면 출력층의 가장자리에서 승자가 선택되어 기존 SOM에서 발생하는 주변효과를 보완하여 학습하게 된다.

III. 실험

가로 24, 세로 24의 크기의 관계적시점지도로 구성된 SOM에 학습할 데이터는 실제 도시가스사에서 측정 기록한 2007년 6월부터 10월까지 약 4개월 동안의 위험요인이 내재된 6161개의 방식전위를 사용한다. 데이터의 최대, 최소, 평균을 학습데이터의 특징패턴으로 하여 사용한다. 표 2는 학습할 데이터의 개수와 구성이다.

표 2. 학습 데이터 구성
Table 2. Learning Data Composition

상태	데이터 수
정상	3804
주의	511
경고	1846
합계	6161




그림 5. 기존 SOM과 관계적시점지도로 구성된 SOM 위상
Fig. 5. Learning Results of General SOM and SOM based on Relative Perspective Map

그림 5의 (a)는 기존 SOM의 학습결과이고 (b)는 (a)과 동일한 데이터를 사용하여 관계적시점지도로 구성된 SOM에 학습한 결과이다. 그림 5의 (b)는 (a)과 달리 맵 위에 시점이 존재하고 입체적인 형상을 하고 있으나 전개도로 펼쳐놓은 형태이다. 따라서 가장자리에서 발생하는 주변효과를 보완할 수 있으며 기존 SOM의 학습결과보다 맵의 위상이 순환적으로 시각화된다. 위험요인이 잠재적으로 내재된 가스배관의 방식전위를 관계적시점지도로 구성된 SOM에 부식상태를 학습하여 자율적으로 부식상태를 결정하면 기존 사람이 수행했던 판단보다 일관성을 높일 수 있다. 이는 잠재적으로 내재되어 있는 위험요인을 누락하지 않고 학습을 수행하기에 부식상태 판단의 신뢰성을 높일 수도 있다. 더불어 사람이 부식상태를 판단하기 위한 기준인 배관의 방식전위의 한계의 특성에도 부합되어 SOM의 학습결과인 맵의 위상에 순환적으로 표현된다.




그림 6. 새로운 데이터 입력 및 안전성 평가
Fig. 6. New Data Classification and Safety Estimation

그림 6은 가스배관의 자율적인 부식상태 판단과정이다. 학습이 완료된 관계적시점지도로 구성된 SOM에 분류된 학습데이터를 입력하여 다수결의 원리에 따라 선택된 횡수가 가장 많은 뉴런을 군집의 중심뉴런으로 사용한다. 출력된 뉴런의 위상과 각 군집의 중심점의 유클리디안 거리(Euclidean Distance)로 유사도를 측정한다. 측정된 유사도가 가장 높은 해당 군집의 부식상태 상태를 입력된 데이터의 부식상태로 자율적으로 결정한다. 예를 들어 그림 6의 (a)는 정상, (b)은 주의, (c)는 경고의 각 상태 군집의 중심점이다. 군집의 중심점들과 정상으로 분류된 데이터 -1544, -1372, -1445의 방식전위를 맵핑한 뉴런은 그림 6의 (i)이다. 각 중심뉴런과 맵핑된 뉴런과의 각 유사도의 총합을 100으로 환산하면 정상과의 유사도 50.1, 주의와의 유사도 30.9, 경고의 유사도 19.0으로 측정된다. 측정된 유사도 중 가장 높은 상태인 정상을 입력된 방식전위 데이터의 부식상태로 결정한다. 이는 기존에 사람이 수행하던 판단 결과와 동일한 결과를 얻을 수 있다.

IV. 결론 및 향후연구

효율적이고 자율적인 가스배관의 부식상태 판단을 위해서 관계적시점지도로 구성된 SOM을 사용하였다. 배관의 위험요인이 잠재적으로 내재되어 있는 방식전위로 가스배관의 부식상태를 학습

하였다. 관계적시점지도로 구성되어 학습된 SOM에 배관을 관리하고자 마련하였던 관리기준에 의해서 부식상태가 이미 분류된 데이터를 맵핑하여 안전성 상태를 자율적 평가하고 비교하여 제안한 판단방법을 검증하였다.

향후 연구로 관계적시점지도로 구성된 SOM을 이용한 가스배관의 부식상태 판단 방법의 신뢰성에 대한 연구를 위해 더 많은 실제 방식전위 데이터를 확보 실험하고 검증해야 한다.

참고문헌

- [1] Jeong-Seok Oh, Seung-Kyu Kang, Kyung-Suhk. Choi, "Autonomous Context-Aware Analysis Method for Ubiquitous Environments", Korea Society for Energy Engineering Conference, pp. 257~262, Nov. 2007.
- [2] James XinZhi Li, "Visualization of high-dimensional data with relational perspective map", Palgrave-Journals of Information Visualization, Vol. 3, pp. 49~59, 2004. www.palgrave-journals.com/ivs
- [3] Young-do Cho, "Quantitative risk assessment technology pipeline", News & Information Korea Center for Chemical Engineering Research, Vol.28, No.3, 336~339, 2010
- [4] Jeong-Seok Oh, Kyung-Suhk. Choi, Jeong-Rock Kwon, Ki-Bong Yoon, "A Study on Autonomic Analysis for Servicing Intelligent Gas Safety Management Based on RFID/USN", Journal of Korean Society of Safety, Vol.23, No.6, pp 63~68, 2008
- [5] X. Zhang and Y. Li, "Self-Organizing Map As a New Method for Clustering and Data Analysis.", Proceedings of International Joint conference on Neural Network, pp.2448~2451, 1993
- [6] Yingxin Wu, and Masahiro Takasuka, "Spherical self-organizing map using efficient indexed geodesic data structure", Journal Neural Networks, Vol.19, Issue.6, pp.900~910, 2006.